

تقریباً سری ۱۴ ام :

$$y = \eta_x H(\omega) = \dots$$

(۹) (۱) ~~۱~~

$$S_{yy} = S_{xx} \cdot |H(\omega)|^2 = r \frac{r}{\left(\frac{r}{\alpha}\right)^2 + \omega^2} \times \left(\frac{\omega}{r} + \frac{1}{r} (e^{-j\omega} + e^{j\omega})\right)$$

$$= \frac{\frac{\omega}{r}}{\left(\frac{r}{\alpha}\right)^2 + \omega^2} + \frac{r}{\left(\frac{r}{\alpha}\right)^2 + \omega^2} (e^{-j\omega} + e^{j\omega})$$

$$\rightarrow R_{yy} = \mathcal{F}^{-1}\left(\frac{\frac{\omega}{r}}{\left(\frac{r}{\alpha}\right)^2 + \omega^2}\right) + \mathcal{F}^{-1}\left(\frac{r}{\left(\frac{r}{\alpha}\right)^2 + \omega^2}\right)(t-r) + \mathcal{F}^{-1}\left(\frac{r}{\left(\frac{r}{\alpha}\right)^2 + \omega^2}\right)(t+r)$$

$$= \frac{\omega}{r} e^{-\frac{|\pi|}{\alpha}} + e^{-\frac{|\pi-r|}{r}} + e^{-\frac{|\pi+r|}{r}}$$

با سیستم LTI خطی است. در نتیجه به زمان گوسی را به یک زمان گوسی تبدیل می کند.

$$a) K_1 + K_2 = \phi_1^T(x) \phi_1(y) + \phi_r^T(x) \phi_r(y) \quad (۲)$$

$$\phi' = \begin{bmatrix} \phi_1 \\ \phi_r \end{bmatrix} \rightarrow \phi'^T(x) \phi'(y) = \phi_1^T(x) \phi_1(y) + \phi_r^T(x) \phi_r(y) = K_1 + K_2$$

$$b) K_1 K_2 = (\phi_1^T(x) \phi_1(y)) (\phi_r^T(x) \phi_r(y)) \\ = \left(\sum \phi_1^{(i)}(x) \phi_1^{(i)}(y)\right) \left(\sum \phi_r^{(j)}(x) \phi_r^{(j)}(y)\right)$$

$$= \sum_{i,j} \phi_i^{(i)}(x) \phi_i^{(i)}(y) \phi_r^{(j)}(x) \phi_r^{(j)}(y)$$

$$= \sum_{i,j} (\phi_i^{(i)}(x) \phi_r^{(j)}(x)) (\phi_i^{(i)}(y) \phi_r^{(j)}(y))$$

$$\rightarrow \phi'(x) \otimes = \left[ \phi_i^{(i)} \times \phi_r^{(j)} \right]_{i,j} \quad \uparrow$$

(c)

$$e^{K_1} = \sum_{n=0}^{\infty} \frac{K_1^n}{n!} e$$

$$\sum_{n=0}^{\infty} \frac{K_1^n}{n!} \leftarrow \text{جزئی } K_1^n \leftarrow \text{جزئی } K_1 \quad (b)$$

$$\begin{aligned} \text{cov}(N(t), N(t+T)) &= \text{cov}(N(t), (N(t) + N(t, t+T))) \\ &= \text{cov}(N(t), N(t)) \\ &\quad + \underbrace{\text{cov}(N(t), N(t, t+T))}_{\text{صفر}} \\ &= \text{var}(N(t)) = \lambda t \end{aligned}$$

جزء جزیرا مع auto-covariance  $t_2$  اور  $t_1$

$$\begin{aligned} P(N(t_1) = k, N(t_2) = j) &= P(N(t_1) = k, N(t_2, t_2) = j - k) \\ &= P(N(t_1) = k) P(N(t_2, t_2) = j - k) = e^{-\lambda t_1} \frac{(\lambda t_1)^k}{k!} \cdot e^{-\lambda(t_2 - t_1)} \frac{(\lambda(t_2 - t_1))^{j-k}}{(j-k)!} \end{aligned}$$

$$= \frac{e^{-\lambda t} \lambda^j t^k (t-t_1)^{j-k}}{k! (j-k)!}$$

$j \geq k, \text{ o.w. } 0$

(c)

$$P(t_0 = a_0, \dots, t_n = a_n) = \frac{e^{-\lambda t_n} \lambda^{a_n} t_0^{a_0} (t_1 - t_0)^{a_1 - a_0} \dots (t_n - t_{n-1})^{a_n - a_{n-1}}}{(a_0)! (a_1 - a_0)! \dots (a_n - a_{n-1})!}$$

$$f(a_0, a_1, \dots, a_{n-1}, a + kn)$$

(d)  $= n^{a_n} = n^{kn}$

$$= \frac{e^{-\lambda(a+kn)} \lambda^{a+kn} \cdot t_0^{a_0} \dots t_{n-1}^{a_{n-1}}}{(a+kn)! (a_1 - a_0)! \dots (a_n - a_{n-1})!}$$

$$= \frac{e^{-\lambda(a+kn)} \lambda^{a+kn} \cdot t_0^{a_0} \dots t_{n-1}^{a_{n-1}}}{(a+kn)! (a_1 - a_0)! \dots (a_n - a_{n-1})!}$$

$$r_i = a_i - a_{i-1} \quad (a_0 = a)$$

$\frac{r_i}{(r_1 + \dots + r_n)}$

$$\rightarrow f(a_1, \dots, a + kn) = e^{-\lambda(a+kn)} \lambda^{a+kn} \cdot \frac{1}{r_1! \dots r_n!} = \frac{e^{-\lambda \sum r_i} \lambda^{\sum r_i}}{(\sum r_i)!} \binom{\sum r_i}{r_1, \dots, r_n}$$

$$= \frac{e^{-\lambda kn} \lambda^{kn}}{(kn)!} \binom{kn}{r_1, \dots, r_n} \quad \text{s.t. } r_1 + \dots + r_n = kn$$


$$\rightarrow \sum_{i=1}^n r_i = kn \quad r_i = n$$

که این هم به ازای

$$\rightarrow a_i^* = a + in$$

(e)

$$P(N(\epsilon) < \mu, N(a) - N(\mu) > \mu) = P(N(\epsilon) = 0, N(\mu, a) \geq \epsilon)$$



$$+ P(N(\epsilon) = 1, N(\mu, a) \geq \epsilon) + P(N(\epsilon) = 2, N(\mu, a) \geq \epsilon)$$



$$= P(N(\epsilon) = 0) \times P(N(\epsilon, \omega) \geq \epsilon) + P(N(\nu) = 0) P(N(\nu, \epsilon) = 1) \\ \times P(N(\epsilon, \omega) \geq \nu) \\ + P(N(\nu) = 1) P(N(\nu, \epsilon) = 0) \\ \times P(N(\epsilon, \omega) \geq \epsilon)$$

$$+ P(N(\nu) = 0) P(N(\nu, \epsilon) = \nu) P(N(\epsilon, \omega) \geq \nu) \\ + P(N(\nu) = 1) P(N(\nu, \epsilon) = 1) P(N(\epsilon, \omega) \geq \nu) \\ + P(N(\nu) = \nu) P(N(\nu, \epsilon) = 0) P(N(\epsilon, \omega) \geq \epsilon)$$

a)  $\text{cov}(X_t, X_s) = ?$  -E

$$\text{var}(X_t + X_s) = \text{var}(X_t) + \text{var}(X_s) + 2\text{cov}(X_t, X_s)$$

$$X_t + X_s \sim N(0, \sqrt{t-s})$$

$$\Rightarrow X_t \sim N(0, 0) \rightarrow X_t \approx \frac{1}{\sqrt{t}} \delta(0)$$

$$\rightarrow \sqrt{t-s} = 0 + 0 + 2\text{cov}(X_t, X_s) \rightarrow \text{cov}(X_t, X_s) = \frac{1}{2} \sqrt{t-s}$$

b) یک توزیع گاوسی است یا ماتریس کوواریانس

$$\sum_{ij} \sigma_{ij} = \frac{1}{2} \sqrt{|t_j - t_i|}$$

$$\mu = 0 \quad \text{دیاگنالی}$$

$t \neq s$ :

$$\text{var}(X_t - X_s) = \text{var}(X_t) + \text{var}(X_s) - 2\text{cov}(X_t, X_s) \quad (c)$$

$$= 0 + 0 - 2 \times \frac{1}{\sqrt{t-s}} \sqrt{t-s} = -\sqrt{t-s} < 0 \quad t \neq s$$

که این نشان می‌دهد که  $\text{var}$  همیشه مثبت یا صفر است و هرگز منفی نیست.  
چنین فرآیندی وجود ندارد.

(a) (5)


~~⊗~~ ~~⊗~~  $T_i \rightarrow$  maintenanc times

$$P(T_i > h) = e^{-\mu h}$$

break down  $x$  (اولین) (b)

$$\begin{aligned} E[X] &= E[X | T_i > h] P(T_i > h) \\ &\quad + E[X | T_i \leq h] P(T_i \leq h) \\ &= h e^{-\lambda h} \\ &\quad + (E[T_i | T_i \leq h] + E[X]) (1 - e^{-\mu h}) \end{aligned}$$

$$\begin{aligned} \rightarrow E[X] &= h + (e^{\mu h} - 1) \underbrace{E[T_i | T_i \leq h]}_{\frac{h}{\mu}} \\ &= h + \frac{h}{\mu} (e^{\mu h} - 1) \end{aligned}$$



(5)  
20

(c)

→ break proportion

$$= \frac{\lambda}{\lambda + E[X]}$$

که  $E[X]$  دو سمت قبلی می باشد.

۶- به طور میانگین  $\frac{1}{\lambda_1}$  طول می کشد تا ما شین اولی از

ایستگاه اول خارج شود. پس به اندازه  $\max(\exp(\lambda_1), \exp(\lambda_2))$

طول می کشد. پس از آن که به ایستگاه دوم رسیدیم به اندازه  $\frac{1}{\lambda_2}$

طول می کشد تا از دومی هم خارج شویم.

$$\rightarrow \frac{1}{\lambda_1} + \frac{1}{\lambda_1} + \frac{1}{\lambda_2} - \frac{1}{\lambda_1 + \lambda_2} + \frac{1}{\lambda_2}$$

$$= 2\left(\frac{1}{\lambda_1} + \frac{1}{\lambda_2}\right) - \frac{1}{\lambda_1 + \lambda_2}$$

$$G_t < \alpha, D_t < \beta$$

تا  $\alpha$  تا قبلی و همچنین تا  $\beta$  تا بعدی  
 event رخ داده باشد،  
 تعداد event در لحظه  $t$   
 $t-x$  است و در لحظه  $t$   
 از  $t-y$  تا  $t$  می باشد

$$G_t - V$$

$G_t$ : فاصله تا نزدیک ترین  
 event قبلی  
 $D_t$ : فاصله تا نزدیک ترین  
 event بعدی



$$= P(N_{t-x} < N_t < N_{t+y}) =$$

$$\begin{aligned} \rightarrow P(G_t < x, D_t \leq y) &= P(N(t-x, t) \geq 1) \\ &\quad \times P(N(t, t+y) \geq 1) \\ &= (1 - e^{-\lambda x})(1 - e^{-\lambda y}) \end{aligned}$$

في  $t$  event  $G_t = t$  ~~في  $t$  event~~ (b)

في  $t$  event  $(0, t)$  ~~في  $t$  event~~ في  $t$  event

$$\begin{aligned} \rightarrow P(G_t = t, D_t \leq y) &= (N_t = 0, N_{t+y} > 0) \\ &= (N(t) = 0, N(t, t+y) \geq 1) \end{aligned}$$

$$\begin{aligned} \rightarrow P(G_t = t, D_t \leq y) &= P(N(t) = 0) P(N(t, t+y) \geq 1) \\ &= e^{-\lambda t} (1 - e^{-\lambda y}) \end{aligned}$$

~~$P(D_t \leq y) = P(G_t \leq t, D_t \leq y)$~~

~~$P(G_t < x) = (1 - e^{-\lambda x})(1 - e^{-\lambda y})$~~

~~exponential~~

$$\begin{aligned} \rightarrow P(D_t \leq y) &= P(G_t = t, D_t \leq y) + P(G_t < t, D_t \leq y) \\ &= e^{-\lambda t} (1 - e^{-\lambda y}) + (1 - e^{-\lambda t}) (1 - e^{-\lambda y}) \\ &= 1 - e^{-\lambda y} \\ \rightarrow D_t &\sim \text{Exponential}(\lambda) \end{aligned} \quad (e)$$

$$P(G_t < x, D_t \leq y) = (1 - e^{-\lambda x}) (1 - e^{-\lambda y}) \quad (d)$$

$$\rightarrow P(G_t < x) = \lim_{y \rightarrow \infty} P(G_t < x, D_t \leq y) = 1 - e^{-\lambda x} \quad \leftarrow \boxed{n \leq t}$$

$$\lim_{y \rightarrow \infty} P(G_t < x, D_t \leq y) = (1 - e^{-\lambda x})$$

$$\rightarrow P(G_t = x) = \begin{cases} \lambda e^{-\lambda x} & x \leq t \\ e^{-\lambda t} & x = t \\ 0 & x > t \end{cases}$$

$$x > t, P(G_t < x) = 1$$

$$\begin{aligned} P(\min(T_1, t) > x) & \quad (e) \\ P(\min(T_1, t) > x) &= 0 \quad \min(T_1, t) \leq x \Rightarrow x > t \text{ (impossible)} \\ P(\min(T_1, t) > x) &= P(T_1 > x) = e^{-\lambda x} \quad = x < t \text{ (possible)} \end{aligned}$$



$$\Rightarrow P(\min(T_i, t) < x) = \begin{cases} 1 - e^{-\lambda x} & x < t \\ 1 & x \geq t \end{cases}$$

که همان رابطه ای است که برای  $G_t$  داریم

$$f) P(G_t < x, D_t \leq y) = \underbrace{(1 - e^{-\lambda y})}_{f(y)} \left( \underbrace{1[x \leq t]}_{f(x)} (1 - e^{-\lambda x}) + \underbrace{1[x > t]}_{f(x)} \right)$$

$$= f(y) \times f(x)$$

به صورت ضرب دو تابع که یکی فقط به  $x$  و یکی فقط به  $y$  بستگی دارد. توضیح این است که مستقل هستند.

$$g) E[G_t] = \int_0^{+\infty} P(G_t \geq x) dx = \int_0^t (1 - (1 - e^{-\lambda x})) dx + \int_t^{+\infty} (1 - 1) dx$$

$$= \int_0^t e^{-\lambda x} dx = \frac{1}{\lambda} (1 - e^{-\lambda t})$$

$$E[G_t + D_t] = \frac{1}{\lambda} (1 - e^{-\lambda t}) + \frac{1}{\lambda} = \frac{1}{\lambda} (1 + 1 - e^{-\lambda t})$$

↳ Exponential

$D_t$  یک فضای ~~مختصا~~ محاسبه‌ای را پوشش می‌دهد اما فضای  
 محدود  $[0, t]$  را. هر چه قدر  $t$  از  $0$  بزرگ‌تر کنیم  $e^{-\lambda t}$  از  $0$  بزرگ‌تر شده  
 و  $E[G_t + D_t]$  و  $E[G_t]$  بزرگ‌تر می‌شوند.

$$\Rightarrow \frac{E[G_t]}{E[G_t + D_t]} = \frac{\frac{1}{\lambda}(1 - e^{-\lambda t})}{\frac{1}{\lambda} + \frac{1}{\lambda}(1 - e^{-\lambda t})}$$

در واقع  $G_t$  همان نیمی محدود شده‌ی  $D_t$  به زمان  $t$   
 است.  $t \rightarrow \infty$ ،  $G_t$  همان  $D_t$  می‌شود و تفاوت آن  
 در اسید ریاضی با یک فرمول نیازی مشخص می‌شود.