

# فصل ۶: توزیع‌های شرطی

Chapter 6

۱.  $pmf$ ،  $CDF$  و  $pdf$  شرطی

۶. امید ریاضی شرطی

۲. قضیه احتمال کل و قضیه بیز

۷. امید ریاضی شرطی تابعی از دو متغیر تصادفی

۳. شرط واقع‌های در ارتباط با همان متغیر تصادفی ۸. تخمین  $I_S$

۴. قابلیت اعتماد ۹. تخمین  $II_S$

۵. شرط واقع‌های در ارتباط با متغیر تصادفی دیگر

می‌دانیم که با فرض  $P(M) \neq 0$ ، داریم:

$$P(A | M) = \frac{P(A \cap M)}{P(M)}$$

### تابع احتمال شرطی (pmf شرطی):

اگر  $\mathbf{x}$  یک متغیر تصادفی گسسته باشد که مقادیر  $x_i$  ( $i = 0, 1, 2, \dots$ ) را اختیار می‌کند، تابع احتمال شرطی  $\mathbf{x}$  به شرط واقعه  $M$ ، طبق تعریف برابر است با:

$$P_x(x_i | M) = P\{\mathbf{x} = x_i | M\} = \frac{P\{\mathbf{x} = x_i, M\}}{P(M)} = \frac{P\{\omega : \mathbf{x}(\omega) = x_i, \omega \in M\}}{P(M)}$$

ثابت کرده بودیم که احتمال شرطی تمام خواص احتمال را دارد. لذا  $P_x(x | M)$  نیز تمام خواص تابع احتمال غیرشرطی را دارد، از جمله اینکه داریم:

$$1) \sum_i P_x(x_i | M) = 1$$

$$2) \forall D \subset \mathbb{R} : P\{\mathbf{x} \in D | M\} = \sum_{x_i \in D} P_x(x_i | M)$$

## تابع توزیع انباشته شرطی (CDF شرطی):

طبق تعریف، تابع توزیع انباشته شرطی  $\mathbf{x}$  به شرط واقعه  $M$  برابر است با:

$$F_{\mathbf{x}}(\mathbf{x} | M) = P\{\mathbf{x} \leq \mathbf{x} | M\}$$

این تابع نیز تمام خواص CDF غیرشرطی را دارد، از جمله داریم:

1)  $F(-\infty | M) = 0$

2)  $F(+\infty | M) = 1$

3)  $P(x_1 \leq \mathbf{x} \leq x_2 | M) = F(x_2 | M) - F(x_1 | M)$

## تابع چگالی شرطی (pdf شرطی):

طبق تعریف، تابع چگالی شرطی  $x$  به شرط واقعه  $M$  برابر است با:

$$f_x(x|M) = \frac{dF_x(x|M)}{dx}$$

این تابع نیز تمام خواص pdf غیرشرطی را دارد، از جمله داریم:

$$1) \int_x^{x+dx} f_x(x|M)dx = P\{x \leq \mathbf{x} \leq x + dx | M\}$$

$$2) \int_{-\infty}^{+\infty} f_x(x|M)dx = F(+\infty | M) - F(-\infty | M) = 1$$

یادآوری: اگر  $A_i$  ها ( $i = 0, 1, 2, \dots, m$ ) افرازی از  $\Omega$  باشند، قضایای زیر را داشتیم:

۱. قضیه احتمال کل:

$$P(B) = \sum_{i=1}^m P(B | A_i)P(A_i)$$

۲. قضیه بیز:

$$P(A_k | B) = \frac{P(B | A_k)P(A_k)}{P(B)} = \frac{P(B | A_k)P(A_k)}{\sum_{i=1}^m P(B | A_i)P(A_i)}$$

حال اگر  $\mathbf{x}$  یک متغیر تصادفی گسسته باشد، در رابطه با pmf شرطی آن داریم:

$$P\{\mathbf{x} = \mathbf{x}\} = \sum_{i=1}^m P\{\mathbf{x} = \mathbf{x} | A_i\}P(A_i)$$

یعنی:

۱. قضیه احتمال کل:

$$P_{\mathbf{x}}(\mathbf{x}) = \sum_{i=1}^m P_{\mathbf{x}}(\mathbf{x} | A_i)P(A_i)$$

همچنین داریم:

$$P\{A | \mathbf{x} = \mathbf{x}_k\} = \frac{P\{\mathbf{x} = \mathbf{x}_k | A\}P(A)}{P\{\mathbf{x} = \mathbf{x}_k\}}$$

یعنی:

۲. قضیه بیز:

$$P(A | \mathbf{x}_k) = \frac{P_{\mathbf{x}}(\mathbf{x}_k | A)P(A)}{P_{\mathbf{x}}(\mathbf{x}_k)}$$

و نیز اگر  $\{\mathbf{x} = \mathbf{x}_i\}$  ها را به عنوان وقایع افرازکننده در نظر بگیریم، خواهیم داشت:

۱. قضیه احتمال کل:

$$P(A) = \sum_i P(A | \mathbf{x} = \mathbf{x}_i) P\{\mathbf{x} = \mathbf{x}_i\} = \sum_i P(A | \mathbf{x}_i) P_{\mathbf{x}}(\mathbf{x}_i)$$

همچنین داریم:

$$P\{\mathbf{x} = \mathbf{x}_k | A\} = \frac{P(A | \mathbf{x} = \mathbf{x}_k) P\{\mathbf{x} = \mathbf{x}_k\}}{P(A)}$$

پس:

۲. قضیه بیز:

$$P_{\mathbf{x}}(\mathbf{x}_k | A) = \frac{P(A | \mathbf{x}_k) P_{\mathbf{x}}(\mathbf{x}_k)}{P(A)} = \frac{P(A | \mathbf{x}_k) P_{\mathbf{x}}(\mathbf{x}_k)}{\sum_i P(A | \mathbf{x}_i) P_{\mathbf{x}}(\mathbf{x}_i)}$$

در رابطه با CDF شرطی نیز داریم:

۱. قضیه احتمال کل:

$$F_x(x) = \sum_{i=1}^m F_x(x | A_i) P(A_i)$$

۲. قضیه بیز:

$$P(A | \mathbf{x} \leq x) = \frac{F_x(x | A) P(A)}{F_x(x)}$$

در نهایت، در رابطه با pdf شرطی خواهیم داشت:

۱. قضیه احتمال کل:

$$f_x(x) = \sum_{i=1}^m f_x(x | A_i) P(A_i)$$

۲. قضیه بیز:

$$P(A | \underbrace{\mathbf{x} = x}_{\Delta x \rightarrow 0}) = \lim_{\Delta x \rightarrow 0} P(A | x \leq \mathbf{x} \leq x + \Delta x) = \frac{f_x(x | A) P(A) \Delta x}{f_x(x) \Delta x} = \frac{f_x(x | A) P(A)}{f_x(x)}$$

احتمالش صفر است



و اگر  $\{x = x\}$  ها را وقایع افرازکننده در نظر بگیریم، داریم:

۱. قضیه احتمال کل:

$$P(A) = \int_{-\infty}^{+\infty} P(A | x) f_x(x) dx$$

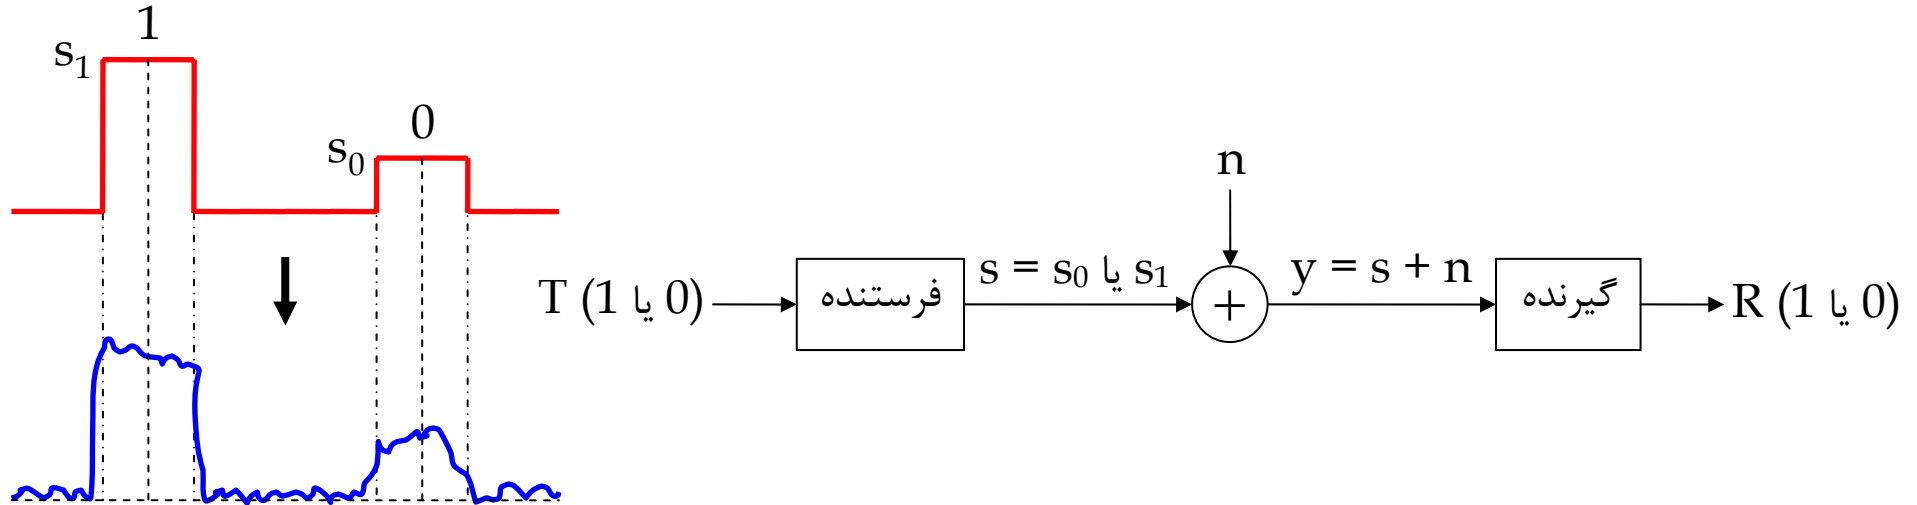
۲. قضیه بیز:

$$f_x(x | A) = \frac{P(A | x) f_x(x)}{P(A)} = \frac{P(A | x) f_x(x)}{\int_{-\infty}^{+\infty} P(A | x) f_x(x) dx}$$

(برای اثبات رابطه بالایی می توان از رابطه پایینی (بیز) استفاده کرد و از طرفین، از  $-\infty$  تا  $+\infty$  انتگرال گرفت.)

## مثالی از مخابرات دیجیتال:

برای ارسال 0 و 1، ولتاژهای  $s_0$  و  $s_1$  را به کار می‌بریم، ولی به دلیل وجود نویز در کانال، گیرنده خود  $s_0$  و  $s_1$  را دریافت نمی‌کند.




فرض کنید نویز دارای توزیع گوسی  $N(0, \sigma)$  است. می‌توان نشان داد برای اینکه گیرنده از روی این داده‌های نویزی بتواند به طور بهینه (کمترین احتمال خطا) تصمیم بگیرد که 0 یا 1 ارسال شده بوده، باید ولتاژ دریافتی را با سطح آستانه‌ای مقایسه کند. اگر از این سطح آستانه بزرگتر بود، 1 و اگر کوچکتر بود، 0 فرض می‌شود. مقدار سطح آستانه در صورتی که  $P(T_0) = P(T_1) = \frac{1}{2}$  باشد، برابر

$$\gamma = \frac{s_0 + s_1}{2} \text{ است (در حالت کلی داریم: } \gamma = \frac{s_0 + s_1}{2} + \frac{\sigma^2}{s_0 - s_1} \ln \frac{P(T_1)}{P(T_0)}).$$

در هر بیت، احتمال خطا، یعنی  $P_{\text{error}}$ ، چقدر است؟

$$\begin{aligned}
P_{\text{error}} &= P(E | T_1)P(T_1) + P(E | T_0)P(T_0) \\
&= P(R_0 | T_1)P(T_1) + P(R_1 | T_0)P(T_0) \\
&= P\{\mathbf{y} < \gamma | T_1\}P(T_1) + P\{\mathbf{y} > \gamma | T_0\}P(T_0) \\
&= F_{\mathbf{y}}(\gamma | T_1)P(T_1) + (1 - F_{\mathbf{y}}(\gamma | T_0))P(T_0) \\
&= P(T_1) \int_{-\infty}^{\gamma} f_{\mathbf{y}}(y | T_1) dy + P(T_0) \int_{\gamma}^{+\infty} f_{\mathbf{y}}(y | T_0) dy
\end{aligned}$$



در واقع، به شرط  $T_1$  یعنی:  $\mathbf{y} = \mathbf{s}_1 + \mathbf{n}$  (مثل  $\mathbf{y} = \mathbf{x} + 2$ )، پس:

$$f_{\mathbf{y}}(\mathbf{y} | T_1) = f_{\mathbf{n}}(\mathbf{y} - \mathbf{s}_1)$$

و به همین ترتیب خواهیم داشت:

$$f_{\mathbf{y}}(\mathbf{y} | T_0) = f_{\mathbf{n}}(\mathbf{y} - \mathbf{s}_0)$$

در نتیجه:

$$\begin{aligned} P_{\text{error}} &= \frac{1}{2} \int_{-\infty}^{\gamma} \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(y-s_1)^2}{2\sigma^2}} dy + \frac{1}{2} \int_{\gamma}^{+\infty} \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(y-s_0)^2}{2\sigma^2}} dy \\ &= \frac{1}{2} G\left(\frac{\gamma-s_1}{\sigma}\right) + \frac{1}{2} \left[ 1 - G\left(\frac{\gamma-s_0}{\sigma}\right) \right] \end{aligned}$$

ولی  $\gamma = \frac{s_0 + s_1}{2}$ ، پس:

$$\begin{aligned} P_{\text{error}} &= \frac{1}{2} G\left(\frac{s_0-s_1}{2\sigma}\right) + \frac{1}{2} \left[ 1 - G\left(\frac{s_1-s_0}{2\sigma}\right) \right] = \frac{1}{2} \left[ 1 - G\left(\frac{s_1-s_0}{2\sigma}\right) \right] + \frac{1}{2} \left[ 1 - G\left(\frac{s_1-s_0}{2\sigma}\right) \right] \\ &= 1 - G\left(\frac{s_1-s_0}{2\sigma}\right) = Q\left(\frac{s_1-s_0}{2\sigma}\right) \end{aligned}$$

هر چه  $\frac{s_1 - s_0}{\sigma}$  بزرگتر باشد (یعنی نسبت سیگنال به نویز بیشتر باشد)، خطا کوچکتر خواهد بود. مثلاً اگر  $s_1 = 2V$  و  $s_0 = -2V$  و  $\sigma = 1V$  باشد، داریم:

$$P_{\text{error}} = Q(2) = 0.0227$$

یعنی ۲٪ احتمال خطا وجود دارد.

## شرط واقعهای در ارتباط با همان متغیر تصادفی:

ممکن است واقعه مشروط کننده، واقعهای در ارتباط با همان متغیر تصادفی باشد. مثلاً اگر:


$$M = \{b < \mathbf{x} \leq a\}$$

آنگاه داریم:

$$F_x(x | b < \mathbf{x} \leq a) = \frac{P\{\mathbf{x} \leq x | b < \mathbf{x} \leq a\}}{P\{b < \mathbf{x} \leq a\}} = \begin{cases} 1 & x \geq a \\ 0 & x < b \\ \frac{P\{b < \mathbf{x} \leq x\}}{P\{b < \mathbf{x} \leq a\}} = \frac{F_x(x) - F_x(b)}{F_x(a) - F_x(b)} & b \leq x < a \end{cases}$$

با مشتق گیری خواهیم داشت:

$$f_x(x | b < x \leq a) = \begin{cases} 0 & x \geq a \\ 0 & x < b \\ \frac{f_x(x)}{F_x(a) - F_x(b)} = \frac{f_x(x)}{\int_b^a f_x(x) dx} & b \leq x < a \end{cases}$$




## مثالی از کاربرد توزیع مشروط: قابلیت اعتماد

فرض کنید متغیر تصادفی  $x$  زمان خراب شدن سیستمی باشد که از  $t = 0$  شروع به کار کرده است (متغیر تصادفی  $x$  را عمر سیستم (Time to Failure) می‌گویند). اصطلاحاً  $1 - F(x)$  را قابلیت اعتماد سیستم می‌گویند:

$$R(x) = 1 - F(x) = P\{x > x\}$$

یعنی احتمال اینکه سیستم لااقل تا زمان  $x$  کار کند.

پس:  $R(0) = 1$ ،  $R(+\infty) = 0$  و  $R(x)$  همواره نزولی است.



امید ریاضی  $x$  را Mean Time to Failure (MTTF) می‌گویند (عمر متوسط سیستم):

$$E(x) = \int_0^{+\infty} xf(x)dx = \int_0^{+\infty} R(x)dx$$

$$\left( \int_{-\infty}^{+\infty} xf(x)dx = \int_{-\infty}^0 F(x)dx + \int_0^{+\infty} (1 - F(x))dx \right) \text{ چون:}$$



حال می‌خواهیم  $F(x | x \geq t)$  و  $f(x | x \geq t)$  را حساب کنیم.

$F(x | x \geq t)$  یعنی احتمال اینکه سیستمی که تا لحظه  $t$  کار می‌کرده است قبل از لحظه  $x$  خراب شود:

$$F(x | x \geq t) = \frac{P\{x \leq x, x \geq t\}}{P\{x \geq t\}} = \begin{cases} 0 & x < t \\ \frac{F(x) - F(t)}{1 - F(t)} & x \geq t \end{cases}$$

با مشتق‌گیری،  $f(x | x \geq t)$  به دست می‌آید. تابع فوق در  $x = t$  پیوسته است، پس  $f$  شامل  $\delta$  نخواهد شد:


$$f(x | x \geq t) = \begin{cases} 0 & x < t \\ \frac{f(x)}{1 - F(t)} & x \geq t \end{cases}$$

$f(x | x \geq t)dx$  یعنی احتمال اینکه سیستمی که تا لحظه  $t$  کار می‌کرده است بین لحظات  $x$  و  $x + dx$  خراب شود.

مثال: اگر  $f(x) = \lambda e^{-\lambda x} u(x)$  باشد، داریم:

$$F(x) = (1 - e^{-\lambda x})u(x) \Rightarrow R(x) = e^{-\lambda x} : x \geq 0$$

$$E(x) = \frac{1}{\lambda}$$



$$f(x | x \geq t) = \frac{f(x)}{1 - F(t)} = \frac{\lambda e^{-\lambda x}}{e^{-\lambda t}} = \lambda e^{-\lambda(x-t)} = f(x-t) : x \geq t$$

که همان خاصیت بی حافظه بودن توزیع نمایی را نشان می دهد.

در واقع وقتی  $f(x)$  نمایی باشد، نرخ خرابی شرطی ثابت است.

## نرخ خرابی شرطی:

طبق تعریف، نرخ خرابی شرطی متغیر تصادفی  $X$  برابر است با:

$$\beta(t) \triangleq f(t | X \geq t)$$

$\beta(t)dt$  بیانگر احتمال این است که سیستمی که تا لحظه  $t$  سالم بوده، در لحظه  $t$  (یعنی بین  $t$  و  $t + dt$ ) خراب شود.

$$\beta(t) = \frac{f(t)}{1 - F(t)} = \frac{F'(t)}{1 - F(t)} = \frac{-R'(t)}{R(t)}$$

اگر از طرفین انتگرال بگیریم و با توجه به اینکه:  $R(0) = 1$ ، داریم:

$$-\int_0^x \beta(t)dt = \ln R(x)$$

$$\Rightarrow R(x) = e^{-\int_0^x \beta(t)dt} : x \geq 0$$

$$\Rightarrow F(x) = 1 - e^{-\int_0^x \beta(t)dt} : x \geq 0$$

$$\Rightarrow f(x) = \beta(x)e^{-\int_0^x \beta(t)dt} : x \geq 0$$

## خواص $\beta(t)$ :

$$1) \beta(t) = \frac{f(t)}{1-F(t)} \Rightarrow \beta(t) \geq 0$$

$$2) F(+\infty) = 1 \Rightarrow \int_0^{+\infty} \beta(t) dt \rightarrow +\infty$$

مثلاً اگر  $\beta(t) = \lambda$ ، یعنی مقدار ثابت باشد، داریم:



$$f(x) = \lambda e^{-\lambda x} u(x)$$

اگر  $\beta(t) = \lambda t^{r-1}$  باشد، در بسیاری موارد تابع مناسبی است و داریم:

$$f(x) = \lambda x^{r-1} e^{-\lambda \frac{x^r}{r}} u(x)$$


این توزیع را توزیع ویبول (Weibull) می‌گویند که برای  $r = 1$  همان توزیع نمایی و برای  $r = 2$  همان توزیع رایلی می‌شود.

برای  $r = 1$ ،  $\beta(t)$  ثابت است و برای  $r$ های بزرگتر، فرسودگی را مدل می‌کند:



$$MTTF = E(x) = \left(\frac{r}{\lambda}\right)^{\frac{1}{r}} \Gamma\left(\frac{r+1}{r}\right)$$

ولی خیلی اوقات  $\beta(t)$  به این شکل است:



## شرط واقعهای در ارتباط با متغیر تصادفی دیگر:

گاهی واقعه مشروط کننده، واقعهای در ارتباط با یک متغیر تصادفی دیگر است.

اگر  $\mathbf{x}$  و  $\mathbf{y}$  گسسته باشند، تابع احتمال  $\mathbf{y}$  به شرط  $x_1 < \mathbf{x} \leq x_2$  برابر است با:

$$P_{\mathbf{y}}(y_j | x_1 < \mathbf{x} \leq x_2) = \frac{P\{\mathbf{y} = y_j, x_1 < \mathbf{x} \leq x_2\}}{P\{x_1 < \mathbf{x} \leq x_2\}} = \frac{\sum_{x_1 < x_i \leq x_2} P_{\mathbf{xy}}(x_i, y_j)}{\sum_{x_1 < x_i \leq x_2} P_{\mathbf{x}}(x_i)}$$

و تابع احتمال  $\mathbf{y}$  به شرط  $\mathbf{x} = x_i$  نیز برابر است با:

$$P_{\mathbf{y}}(y_j | \mathbf{x} = x_i) = P_{\mathbf{y}}(y_j | x_i) = \frac{P\{\mathbf{y} = y_j, \mathbf{x} = x_i\}}{P\{\mathbf{x} = x_i\}} = \frac{P_{\mathbf{xy}}(x_i, y_j)}{P_{\mathbf{x}}(x_i)}$$

در مورد pdf نیز داریم:

$$f_y(y | x_1 < \mathbf{x} \leq x_2) = \frac{\int_{x_1}^{x_2} f_{xy}(x, y) dx}{\int_{x_1}^{x_2} f_x(x) dx}$$

و همچنین:

$$f_y(y | \mathbf{x}) = \frac{f_{xy}(x, y)}{f_x(x)}$$

در حالت خاص اگر  $\mathbf{x}$  و  $\mathbf{y}$  مستقل باشند، آنگاه برای هر  $\mathbf{x}$  و  $\mathbf{y}$  داریم:  $f_{xy}(x, y) = f_x(x) f_y(y)$ ، لذا:

$$f_y(y | \mathbf{x}) = f_y(y)$$

و نیز:

$$f_x(x | \mathbf{y}) = f_x(x)$$

می دانیم که:

$$f_y(y) = \int_{-\infty}^{+\infty} f_{xy}(x, y) dx$$

ولی داریم:

$$f_{xy}(x, y) = f_y(y | x) f_x(x)$$

پس:

$$f_y(y) = \int_{-\infty}^{+\infty} f_y(y | x) f_x(x) dx$$

که همان قضیهٔ احتمال کل است.

حال با تعویض نقش  $x$  و  $y$  داریم:

$$f_x(x | y) = \frac{f_{xy}(x, y)}{f_y(y)}$$

$$\Rightarrow f_x(x | y) = \frac{f_y(y | x) f_x(x)}{f_y(y)} = \frac{f_y(y | x) f_x(x)}{\int_{-\infty}^{+\infty} f_y(y | x) f_x(x) dx}$$

که همان قضیهٔ بیز است.



مثال ۱:  $\mathbf{x} \sim \text{Binomial}(n, \mathbf{p})$ ، ولی احتمال موفقیت را نمی‌دانیم و  $\mathbf{p}$  خود یک متغیر تصادفی است:  $\mathbf{p} \sim u(0,1)$ ؛ مثلاً سکه‌ای که احتمال شیر آمدنش را نمی‌دانیم.

$$P_{\mathbf{x}}(k | \mathbf{p} = p) = P\{\mathbf{x} = k | \mathbf{p} = p\} = \binom{n}{k} p^k (1-p)^{n-k} : k = 0, 1, \dots, n$$

$$f_{\mathbf{p}}(p) = \begin{cases} 1 & 0 \leq p < 1 \\ 0 & \text{otherwise} \end{cases}$$

توابع  $P_{\mathbf{x}}(k) = P\{\mathbf{x} = k\}$  و  $f_{\mathbf{p}}(p | \mathbf{x} = k)$  را بیابید.






$$P_{\mathbf{x}}(k) = \int_{-\infty}^{+\infty} P_{\mathbf{x}}(k | \mathbf{p} = p) f_{\mathbf{p}}(p) dp : k = 0, 1, \dots, n$$

$$= \int_0^1 \binom{n}{k} p^k (1-p)^{n-k} dp$$


$$\rightarrow \beta(a, b) = \int_0^1 x^{a-1} (1-x)^{b-1} dx = \frac{\Gamma(a)\Gamma(b)}{\Gamma(a+b)}$$

$$= \binom{n}{k} \beta(k+1, n-k+1) = \frac{n!}{k!(n-k)!} \cdot \frac{k!(n-k)!}{(n+1)!}$$

$$= \frac{1}{n+1} : k = 0, 1, \dots, n$$



$P_x(k):$



$$f_p(p | \mathbf{x} = k) = \frac{P\{\mathbf{x} = k | \mathbf{p} = p\}f_p(p)}{P\{\mathbf{x} = k\}} = \frac{P_x(k | p)f_p(p)}{P_x(k)} = \frac{\binom{n}{k} p^k (1-p)^{n-k}}{\frac{1}{n+1}} : 0 \leq p < 1$$

$$= \frac{(n+1)!}{k!(n-k)!} p^k (1-p)^{n-k} : 0 \leq p < 1$$


$$\Rightarrow (\mathbf{p} | \mathbf{x} = k) \sim \text{Beta}(k+1, n-k+1)$$

یادآوری: توزیع بتا:



$$f(x) = \frac{\Gamma(a+b)}{\Gamma(a)\Gamma(b)} x^{a-1} (1-x)^{b-1} : 0 < x < 1$$

یعنی  $\mathbf{p}$  که توزیع یکنواخت داشت، با مشاهده مقدار  $\mathbf{x}$  (مثلاً تعداد شیرهای آمده در  $n$  بار پرتاب سکه) توزیع بتا پیدا می‌کند.

ماکزیمم توزیع بتا در  $\frac{a-1}{a+b-2}$  یعنی  $\frac{k}{n}$  اتفاق می‌افتد. هر چه  $n$  بزرگتر باشد، نمودار تیزتر می‌شود.



کتاب در فصل ۶ (Section 6.1) در مورد تخمین بیس نیز بحث کرده است که ما بعداً مفصل درباره آن صحبت خواهیم کرد.



مثال ۲: مقادیر  $P\{\mathbf{x} > 1 | \mathbf{y} = y\}$ ،  $E(\mathbf{x} | \mathbf{y} = y)$  و  $\text{var}(\mathbf{x} | \mathbf{y} = y)$  را برای توزیع زیر پیدا کنید:

$$f_{\mathbf{xy}}(x, y) = \begin{cases} \frac{e^{-\frac{x}{y}} e^{-y}}{y} & x > 0, y > 0 \\ 0 & \text{otherwise} \end{cases}$$

حل: ابتدا باید  $f_{\mathbf{x}}(x | y)$  را به دست آوریم:

$$f_{\mathbf{x}}(x | y) = \frac{f_{\mathbf{xy}}(x, y)}{f_{\mathbf{y}}(y)} = \frac{f_{\mathbf{xy}}(x, y)}{\int_0^{+\infty} f_{\mathbf{xy}}(x, y) dx} = \frac{\frac{e^{-\frac{x}{y}} e^{-y}}{y}}{e^{-y} \int_0^{+\infty} \frac{e^{-\frac{x}{y}}}{y} dx} = \frac{e^{-\frac{x}{y}}}{y} : x > 0, y > 0$$

$$\Rightarrow (\mathbf{x} | \mathbf{y}) \sim \exp\left(\frac{1}{y}\right)$$

$$P\{\mathbf{x} > 1 | \mathbf{y}\} = \int_1^{+\infty} f_{\mathbf{x}}(x | y) dx = \int_1^{+\infty} \frac{1}{y} e^{-\frac{x}{y}} dx = -e^{-\frac{x}{y}} \Big|_1^{+\infty} = e^{-\frac{1}{y}} : \text{بیشتر برای } y \text{ بزرگتر}$$

$$E(\mathbf{x} | \mathbf{y}) = y$$

$$\text{var}(\mathbf{x} | \mathbf{y}) = y^2$$

مثال ۳:  $\mathbf{x}$  و  $\mathbf{y}$  متغیرهای تصادفی مشترکاً نرمال هستند.  $f_{y|x}$  را بیابید.

$$f_y(y|x) = \frac{f_{xy}(x,y)}{f_x(x)} = \frac{\frac{1}{2\pi\sigma_x\sigma_y\sqrt{1-r^2}} \exp\left\{-\frac{1}{2(1-r^2)} \left[ \frac{(x-\eta_x)^2}{\sigma_x^2} - 2r \frac{(x-\eta_x)(y-\eta_y)}{\sigma_x\sigma_y} + \frac{(y-\eta_y)^2}{\sigma_y^2} \right]\right\}}{\frac{1}{\sqrt{2\pi}\sigma_x} \exp\left\{-\frac{(x-\eta_x)^2}{2\sigma_x^2}\right\}}$$

$$= \frac{1}{\sqrt{2\pi}\sigma_y\sqrt{1-r^2}} \exp\left\{-\frac{\left[y-\eta_y - r \frac{\sigma_y}{\sigma_x}(x-\eta_x)\right]^2}{2\sigma_y^2(1-r^2)}\right\}$$

یعنی  $(y|x) \sim N\left(\eta_y + r \frac{\sigma_y}{\sigma_x}(x-\eta_x), \sigma_y \sqrt{1-r^2}\right)$  و داریم:

$$\eta_{y|x} = \eta_y + r \frac{\sigma_y}{\sigma_x}(x-\eta_x) = \eta_y + \frac{\mu_{xy}}{\sigma_x^2}(x-\eta_x)$$

$$\sigma_{y|x}^2 = \sigma_y^2(1-r^2) = \sigma_y^2 - \frac{\mu_{xy}^2}{\sigma_x^2}$$

(اهمیت زیادی در بحث تخمین دارد)

## مثال دیگری از کاربرد توزیع شرطی:

روش دیگری برای تعیین توزیع  $z = g(x, y)$  با استفاده از چگالی شرطی به صورت زیر است:

$$f_z(z) = \int_{-\infty}^{+\infty} f_z(z | x) f_x(x) dx$$

برای  $x = x$  داده شده،  $z = g(x, y)$  تابعی از  $y$  است و لذا به راحتی، اگر ریشه  $z = g(x, y)$  نقطه  $y_0$  باشد، داریم:

$$f_z(z | x) = \frac{f_y(y_0 | x)}{\left| \frac{\partial g(x, y_0)}{\partial y} \right|}$$

(یا می توان  $y = y$  را مشروط گرفت.)



مثال: اگر  $z = xy$  باشد، برای  $x = X$  داده شده،  $Z$  ضریبی از  $Y$  است و داریم:

$$f_z(z|x) = \frac{1}{|x|} f_y\left(\frac{z}{x} | x\right)$$

$$f_z(z) = \int_{-\infty}^{+\infty} \frac{1}{|x|} f_y\left(\frac{z}{x} | x\right) f_x(x) dx = \int_{-\infty}^{+\infty} \frac{1}{|x|} f_{xy}\left(x, \frac{z}{x}\right) dx$$

که قبلاً هم این را به دست آورده بودیم.

مثلاً اگر  $X$  و  $Y$  مشترکاً نرمال با متوسطهای صفر و واریانسهای یک و ضریب همبستگی  $r$  باشند، داریم:

$$f_{xy}(x, y) = \frac{1}{2\pi\sqrt{1-r^2}} \exp\left[-\frac{1}{2(1-r^2)}(x^2 - 2rxy + y^2)\right]$$

$$\begin{aligned} f_z(z) &= \frac{1}{2\pi\sqrt{1-r^2}} \int_{-\infty}^{+\infty} \frac{1}{|x|} e^{\left[-\frac{1}{2(1-r^2)}\left(x^2 - 2rx\left(\frac{z}{x}\right) + \left(\frac{z}{x}\right)^2\right)\right]} dx = \frac{e^{\frac{rz}{1-r^2}}}{\pi\sqrt{1-r^2}} \int_0^{+\infty} \frac{1}{x} e^{-\frac{x^2 + \frac{z^2}{x^2}}{2(1-r^2)}} dx \\ &= \frac{e^{\frac{rz}{1-r^2}}}{\pi\sqrt{1-r^2}} \int_0^{+\infty} \frac{1}{2u} e^{-\frac{u + \frac{z^2}{u}}{2(1-r^2)}} du = \frac{e^{\frac{rz}{1-r^2}}}{\pi\sqrt{1-r^2}} K_0\left(\frac{|z|}{1-r^2}\right) \end{aligned}$$

(تابع بسل اصلاح شده نوع دوم مرتبه صفر)

## امید ریاضی شرطی:

ابتدا یک متغیر تصادفی را در نظر می‌گیریم.

می‌دانیم که:

$$E(\mathbf{x}) = \int_{-\infty}^{+\infty} \mathbf{x} f_{\mathbf{x}}(\mathbf{x}) d\mathbf{x}$$

$$E(g(\mathbf{x})) = \int_{-\infty}^{+\infty} g(\mathbf{x}) f_{\mathbf{x}}(\mathbf{x}) d\mathbf{x}$$

در حالت شرطی، تابع چگالی شرطی جایگزین می‌شود، یعنی:

$$E(\mathbf{x} | M) = \int_{-\infty}^{+\infty} \mathbf{x} f_{\mathbf{x}}(\mathbf{x} | M) d\mathbf{x}$$

$$E(g(\mathbf{x}) | M) = \int_{-\infty}^{+\infty} g(\mathbf{x}) f_{\mathbf{x}}(\mathbf{x} | M) d\mathbf{x}$$

از قضیهٔ احتمال کل می‌دانیم که اگر  $A_i$  ها ( $i = 1, 2, \dots, m$ ) افرازی از  $\Omega$  باشند، داریم:

$$f_{\mathbf{x}}(\mathbf{x}) = \sum_{i=1}^m f_{\mathbf{x}}(\mathbf{x} | A_i) P(A_i)$$

لذا خواهیم داشت:

$$E(\mathbf{x}) = \sum_{i=1}^m E(\mathbf{x} | A_i) P(A_i)$$

ممکن است واقعه  $M$ ، خود، واقعه‌ای در ارتباط با متغیر تصادفی  $\mathbf{x}$  باشد.

مثال: اگر  $\mathbf{x} \sim N(0, \sigma)$  باشد، مقدار  $\text{var}(\mathbf{x} | \mathbf{x} > 0)$  را حساب کنید.

$$f_{\mathbf{x}}(\mathbf{x}) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{\mathbf{x}^2}{2\sigma^2}}$$

$$f_{\mathbf{x}}(\mathbf{x} | \mathbf{x} > 0) = \begin{cases} \frac{f_{\mathbf{x}}(\mathbf{x})}{1 - F(0)} = 2f_{\mathbf{x}}(\mathbf{x}) & \mathbf{x} > 0 \\ 0 & \mathbf{x} < 0 \end{cases}$$

$$E(\mathbf{x} | \mathbf{x} > 0) = \int_{-\infty}^{+\infty} \mathbf{x} f_{\mathbf{x}}(\mathbf{x} | \mathbf{x} > 0) d\mathbf{x} = \int_0^{+\infty} \frac{2\mathbf{x}}{\sqrt{2\pi}\sigma} e^{-\frac{\mathbf{x}^2}{2\sigma^2}} d\mathbf{x} = \sqrt{\frac{2}{\pi}}\sigma$$

$$E(\mathbf{x}^2 | \mathbf{x} > 0) = \int_0^{+\infty} \frac{2\mathbf{x}^2}{\sqrt{2\pi}\sigma} e^{-\frac{\mathbf{x}^2}{2\sigma^2}} d\mathbf{x} = \sigma^2$$

$$\text{var}(\mathbf{x} | \mathbf{x} > 0) = \sigma^2 \left(1 - \frac{2}{\pi}\right)$$

(مانند مسألهٔ یکسوساز تمام موج در تمرین سری چهارم)

ممکن است واقعه مشروط کننده در ارتباط با متغیر تصادفی دیگر باشد. می دانیم که:

$$E(\mathbf{y} | M) = \int_{-\infty}^{+\infty} y f_y(y | M) dy$$

اگر  $M = \{\mathbf{x} = x\}$  باشد،  $f_y(y | \mathbf{x} = x)$  را باید در انتگرال فوق قرار دهیم:

$$E(\mathbf{y} | \mathbf{x} = x) = E(\mathbf{y} | x) = \int_{-\infty}^{+\infty} y f_y(y | x) dy : \text{(که فقط تابع } x \text{ است)}$$

به همین ترتیب خواهیم داشت:

$$E(g(\mathbf{y}) | x) = \int_{-\infty}^{+\infty} g(y) f_y(y | x) dy : \text{(که فقط تابع } x \text{ است)}$$

در مثالی که داشتیم،  $E(\mathbf{y} | \mathbf{x})$  و  $E\left(\left[\mathbf{y}^2 - E(\mathbf{y} | \mathbf{x})\right] | \mathbf{x}\right)$  را دیدیم. در آن مثال تابعی خطی از  $\mathbf{x}$  بود:

$$\eta_{\mathbf{y}|\mathbf{x}} = \eta_{\mathbf{y}} + r \frac{\sigma_{\mathbf{y}}}{\sigma_{\mathbf{x}}} (\mathbf{x} - \eta_{\mathbf{x}}) = \eta_{\mathbf{y}} + \frac{\mu_{\mathbf{xy}}}{\sigma_{\mathbf{x}}^2} (\mathbf{x} - \eta_{\mathbf{x}})$$

$$\sigma_{\mathbf{y}|\mathbf{x}}^2 = \sigma_{\mathbf{y}}^2 (1 - r^2) = \sigma_{\mathbf{y}}^2 - \frac{\mu_{\mathbf{xy}}^2}{\sigma_{\mathbf{x}}^2}$$

$E(\mathbf{y})$  یک عدد است. به همین ترتیب  $E(\mathbf{y} | \mathbf{x} = \mathbf{x})$  دیگر یک متغیر تصادفی نیست، بلکه برای هر  $\mathbf{x}$  یک عدد است. یعنی تابعی از  $\mathbf{x}$  است:

$$\Phi(\mathbf{x}) = E(\mathbf{y} | \mathbf{x})$$

حال می‌توانیم  $\Phi(\mathbf{x})$  را در نظر بگیریم که خود یک متغیر تصادفی است:

$$\Phi(\mathbf{x}) = E(\mathbf{y} | \mathbf{x})$$

خواص متوسط مشروط یک متغیر تصادفی (به شرط متغیر تصادفی دیگر):

(۱)

$$E(E(\mathbf{y} | \mathbf{x})) = E(\mathbf{y})$$

اثبات:

$$\begin{aligned} E(\underbrace{E(\mathbf{y} | \mathbf{x})}_{\Phi(\mathbf{x})}) &= \int_{-\infty}^{+\infty} \underbrace{E(\mathbf{y} | \mathbf{x})}_{\Phi(\mathbf{x})} f_{\mathbf{x}}(\mathbf{x}) d\mathbf{x} = \int_{-\infty}^{+\infty} \left( \int_{-\infty}^{+\infty} y f_{\mathbf{y}}(y | \mathbf{x}) dy \right) f_{\mathbf{x}}(\mathbf{x}) d\mathbf{x} \\ &= \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} y f_{\mathbf{xy}}(\mathbf{x}, y) d\mathbf{x} dy = E(\mathbf{y}) \end{aligned}$$

(۲) اگر  $\mathbf{x}$  و  $\mathbf{y}$  مستقل باشند، آنگاه:  $E(\mathbf{y} | \mathbf{x}) = E(\mathbf{y})$ .

اثبات: اگر  $\mathbf{x}$  و  $\mathbf{y}$  مستقل باشند، آنگاه داریم:

$$\begin{aligned} \forall \mathbf{x} : E(\mathbf{y} | \mathbf{x}) &= \int_{-\infty}^{+\infty} y f_{\mathbf{y}}(y | \mathbf{x}) dy = \int_{-\infty}^{+\infty} y f_{\mathbf{y}}(y) dy = \eta_{\mathbf{y}} \\ \Rightarrow \forall \mathbf{x} : \Phi(\mathbf{x}) &= c \Rightarrow \Phi(\mathbf{x}) = c \\ \Rightarrow E(\mathbf{y} | \mathbf{x}) &= \eta_{\mathbf{y}} \end{aligned}$$

مثال ۱: در مثال ۲، صفحه ۲۹ دیدیم که:

$$E(\mathbf{x} | \mathbf{y}) = \mathbf{y}$$

پس:

$$E(\mathbf{x} | \mathbf{y}) = \mathbf{y}$$

$$\Rightarrow E[E(\mathbf{x} | \mathbf{y})] = E(\mathbf{y})$$

مثال ۲: در مثال ۳، صفحه ۳۰ دیدیم که:

$$E(\mathbf{y} | \mathbf{x}) = \eta_{\mathbf{y}} + r \frac{\sigma_{\mathbf{y}}}{\sigma_{\mathbf{x}}} (\mathbf{x} - \eta_{\mathbf{x}})$$

پس:

$$E(\mathbf{y} | \mathbf{x}) = \eta_{\mathbf{y}} + r \frac{\sigma_{\mathbf{y}}}{\sigma_{\mathbf{x}}} (\mathbf{x} - \eta_{\mathbf{x}})$$

$$\Rightarrow E[E(\mathbf{y} | \mathbf{x})] = \eta_{\mathbf{y}}$$

در همین مثال اگر  $r = 0$  باشد (یعنی  $\mathbf{x}$  و  $\mathbf{y}$  مستقل باشند)، خواهیم داشت:

$$\forall \mathbf{x} : E(\mathbf{y} | \mathbf{x}) = \eta_{\mathbf{y}}$$



**مثال ۳:** آزمایشهای ساده و مستقل برنولی با احتمال موفقیت  $p$  به طور متوالی انجام می‌شوند. اگر  $\mathbf{N}$  تعداد شکستها تا حصول اولین موفقیت باشد،  $E(\mathbf{N})$  و  $\text{var}(\mathbf{N})$  را پیدا کنید.

حل: فرض کنید:

$$\mathbf{z} = \begin{cases} 1 & \text{اگر آزمایش اول موفق باشد} \\ 0 & \text{اگر آزمایش اول موفق نباشد} \end{cases}$$

$$E(\mathbf{N}) = E[E(\mathbf{N} | \mathbf{z})]$$

$$E(\mathbf{N} | \mathbf{z} = 1) = 0$$

$$E(\mathbf{N} | \mathbf{z} = 0) = E(1 + \mathbf{N})$$

$$E(\mathbf{N}) = E(\mathbf{N} | \mathbf{z} = 1)P(\mathbf{z} = 1) + E(\mathbf{N} | \mathbf{z} = 0)P(\mathbf{z} = 0) = 0 + qE(1 + \mathbf{N})$$

$$\Rightarrow E(\mathbf{N}) = q + qE(\mathbf{N}) \Rightarrow E(\mathbf{N}) = \frac{q}{p}$$

همچنین:

$$E(\mathbf{N}^2) = E[E(\mathbf{N}^2 | \mathbf{z})]$$

$$E(\mathbf{N}^2 | \mathbf{z} = 1) = 0$$

$$E(\mathbf{N}^2 | \mathbf{z} = 0) = E[(1 + \mathbf{N})^2]$$

$$E(\mathbf{N}^2) = E(\mathbf{N}^2 | \mathbf{z} = 1)P(\mathbf{z} = 1) + E(\mathbf{N}^2 | \mathbf{z} = 0)P(\mathbf{z} = 0) = 0 + qE[(1 + \mathbf{N})^2]$$

$$\Rightarrow E(\mathbf{N}^2) = \frac{pq + 2q^2}{p^2}$$

$$\Rightarrow \text{var}(\mathbf{N}) = E(\mathbf{N}^2) - (E(\mathbf{N}))^2 = \frac{q}{p^2}$$

(در توزیع دو جمله‌ای منفی داشتیم:  $E(\mathbf{x}) = \frac{rq}{p}$  و  $\text{var}(\mathbf{x}) = \frac{rq}{p^2}$ )

## امید ریاضی مشروط تابعی از دو متغیر تصادفی:

$$E(g(\mathbf{x}, \mathbf{y}) | M) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} g(\mathbf{x}, \mathbf{y}) f_{\mathbf{xy}}(\mathbf{x}, \mathbf{y} | M) dx dy$$

از جمله می توان واقعه  $M = \{\mathbf{x} = x\}$  را در نظر گرفت.

بنا به تعریف  $E(g(\mathbf{y}) | x)$

ویژگی ۱:

$$E(g(\mathbf{x}, \mathbf{y}) | \mathbf{x} = x) = E(g(\mathbf{x}, \mathbf{y}) | \mathbf{x} = x) \stackrel{\uparrow}{=} \int_{-\infty}^{+\infty} g(\mathbf{x}, \mathbf{y}) f_{\mathbf{y}}(\mathbf{y} | \mathbf{x} = x) dy$$

واضح است (اثبات در کتاب فرآیند Papoulis، فصل ۲، صفحه ۸۰).

حالت خاص:

$$g(\mathbf{x}, \mathbf{y}) = g_1(\mathbf{x})g_2(\mathbf{y})$$

در این حالت داریم:

$$E(g_1(\mathbf{x})g_2(\mathbf{y}) | \mathbf{x} = x) = E(g_1(\mathbf{x})g_2(\mathbf{y}) | \mathbf{x} = x) = g_1(x)E(g_2(\mathbf{y}) | \mathbf{x} = x)$$

چون تساوی فوق برای هر  $x$  برقرار است، پس:

$$E(g_1(\mathbf{x})g_2(\mathbf{y}) | \mathbf{x}) = g_1(\mathbf{x})E(g_2(\mathbf{y}) | \mathbf{x})$$

## ویژگی ۲:

$$E[E(g(\mathbf{x}, \mathbf{y}) | \mathbf{x})] = E(g(\mathbf{x}, \mathbf{y}))$$

اثبات: چون  $E(g(\mathbf{x}, \mathbf{y}) | \mathbf{x} = x)$  تابعی از  $x$  است، اگر آن را  $\theta(x)$  بنامیم، متغیر تصادفی  $\theta(\mathbf{x})$  قابل تعریف است.

$$E\left[\underbrace{E(g(\mathbf{x}, \mathbf{y}) | \mathbf{x})}_{\theta(\mathbf{x})}\right] = \int_{-\infty}^{+\infty} \underbrace{E(g(\mathbf{x}, \mathbf{y}) | \mathbf{x} = x)}_{\theta(x)} f_x(x) dx$$

حال بنا بر ویژگی ۱ خواهیم داشت:

$$\begin{aligned} E[E(g(\mathbf{x}, \mathbf{y}) | \mathbf{x})] &= \int_{-\infty}^{+\infty} \left( \int_{-\infty}^{+\infty} g(\mathbf{x}, \mathbf{y}) f_y(\mathbf{y} | \mathbf{x}) d\mathbf{y} \right) f_x(\mathbf{x}) d\mathbf{x} \\ &= \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} g(\mathbf{x}, \mathbf{y}) f_{xy}(\mathbf{x}, \mathbf{y}) d\mathbf{x} d\mathbf{y} = E(g(\mathbf{x}, \mathbf{y})) \end{aligned}$$

حالت خاص:

$$g(\mathbf{x}, \mathbf{y}) = g_1(\mathbf{x})g_2(\mathbf{y})$$

بنا بر حالت خاص در ویژگی ۱

در این حالت داریم:

$$E(g_1(\mathbf{x})g_2(\mathbf{y})) = E[E(g_1(\mathbf{x})g_2(\mathbf{y}) | \mathbf{x})] \stackrel{\uparrow}{=} E[g_1(\mathbf{x})E(g_2(\mathbf{y}) | \mathbf{x})]$$

## مثالی از کاربرد متوسط مشروط: تخمین یک متغیر تصادفی:

### بدون مشاهده:

متغیر تصادفی  $y$  را در نظر بگیرید. اگر بخواهیم  $y$  را با عددی پیش‌بینی کنیم (تخمین بزنیم)، داریم:

$$\hat{y} = c$$

و خطای تخمین برابر خواهد بود با:

$$y - \hat{y} = y - c$$

می‌خواهیم به نحوی خطا می‌نیمم شود. مثلاً یک معیار برای این منظور، معیار  $mae$  (Mean Absolute Error) است:

$$mae = E(|y - c|)$$

می‌توان نشان داد برای اینکه  $mae$  می‌نیمم شود، باید داشته باشیم:

$$c = \text{median}(y)$$

معیار متداول تر، معیار mse (Mean Square Error) است:

$$\text{mse} = E[(\mathbf{y} - c)^2]$$

حال باید  $c$  را آنچنان بیابیم که mse می‌نیمم شود. در یکی از مسائل نشان دادید که:

$$E[(\mathbf{y} - c)^2] = (\eta_y - c)^2 + \sigma_y^2$$

پس mse وقتی می‌نیمم می‌شود که:

$$c = \eta_y$$

تخمینی را که mse را می‌نیمم می‌کند، تخمین ls (Least Square) یا LMS (Least Mean Square) می‌نامند. در اینجا دیدیم که تخمین حداقل مربعات  $\mathbf{y}$  (بدون هیچ مشاهده)، همان میانگین آن است:

$$\hat{\mathbf{y}}_{ls} = \eta_y \text{ (بدون مشاهده)}$$

در این صورت حداقل خطای تخمین mmse (Minimum Mean Square Error) برابر خواهد بود با:

$$\text{mmse} = \sigma_y^2 \text{ (بدون مشاهده)}$$

## با مشاهده:

حال می‌خواهیم بر مبنای اطلاعاتمان از مقدار متغیر تصادفی دیگری مثل  $\mathbf{x}$ ،  $\mathbf{y}$  را تخمین بزنیم (با توجه به اینکه  $\mathbf{x}$  و  $\mathbf{y}$  به نحوی ارتباط دارند و مستقل نباشند).

مثلاً مقدار  $\mathbf{x} = \mathbf{x}$  رؤیت شده و می‌خواهیم به وسیله تابع  $\Phi(\mathbf{x})$  مقدار متغیر تصادفی  $\mathbf{y}$  را تخمین بزنیم (به طوری که  $\text{mse}$  می‌نیمم شود):

$$\hat{\mathbf{y}}_{1s} = \Phi(\mathbf{x}) : \text{منحنی رگرسیون}$$

$$\hat{\mathbf{y}}_{1s} = \Phi(\mathbf{x})$$

خطای تخمین برابر است با:  $\mathbf{y} - \hat{\mathbf{y}}$ ؛

برای به دست آوردن  $\hat{\mathbf{y}}_{1s}$ ، باید تابع  $\Phi$  را چنان تعیین کنیم که:

$$\text{mse} = E[(\mathbf{y} - \hat{\mathbf{y}})^2]$$

می‌نیمم شود، یعنی:

$$\text{minimize mse} \leftrightarrow \hat{\mathbf{y}} = \hat{\mathbf{y}}_{1s}$$

قضیه:

$$\hat{y}_{ls} = E(\mathbf{y} | \mathbf{x})$$

اثبات:

$$\begin{aligned} \text{mse} &= E[(\mathbf{y} - \hat{\mathbf{y}})^2] = E[(\mathbf{y} - \Phi(\mathbf{x}))^2] = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} (y - \hat{y})^2 f_{\mathbf{xy}}(\mathbf{x}, y) dx dy \\ &= E[E((\mathbf{y} - \hat{\mathbf{y}})^2 | \mathbf{x})] = \int_{-\infty}^{+\infty} f_{\mathbf{x}}(\mathbf{x}) \left( \int_{-\infty}^{+\infty} (y - \hat{y})^2 f_{\mathbf{y}}(y | \mathbf{x}) dy \right) dx \end{aligned}$$

برای اینکه mse می‌نیمم شود، عبارت داخل انتگرال را برای هر  $\mathbf{x}$  می‌نیمم می‌کنیم:

$$A = \int_{-\infty}^{+\infty} (y - \hat{y})^2 f_{\mathbf{y}}(y | \mathbf{x}) dy = \int_{-\infty}^{+\infty} (y - \Phi(\mathbf{x}))^2 f_{\mathbf{y}}(y | \mathbf{x}) dy = E(\mathbf{y}^2 | \mathbf{x}) - 2\hat{y}E(\mathbf{y} | \mathbf{x}) + \hat{y}^2$$

$$\frac{\partial A}{\partial \hat{y}} = 0 \Rightarrow \hat{y}_{ls} = E(\mathbf{y} | \mathbf{x}) : \forall \mathbf{x}$$

پس:

$$\hat{y}_{ls} = E(\mathbf{y} | \mathbf{x})$$



## اصل تعامد:

خطا در تخمین LS بر هر تابعی از داده عمود است، یعنی:

$$E[(\mathbf{y} - \hat{\mathbf{y}}_{ls})\mathbf{g}(\mathbf{x})] = E[(\mathbf{y} - E(\mathbf{y} | \mathbf{x}))\mathbf{g}(\mathbf{x})] = 0$$

این قضیه استفاده زیادی دارد.

اثبات: طبق حالت خاص در ویژگی دوم امید مشروط تابعی از دو متغیر تصادفی داریم:

$$E(\mathbf{g}(\mathbf{x})\mathbf{h}(\mathbf{y})) = E[\mathbf{g}(\mathbf{x})E(\mathbf{h}(\mathbf{y}) | \mathbf{x})]$$

به ازای  $\mathbf{h}(\mathbf{y}) = \mathbf{y}$  داریم:

$$E(\mathbf{y}\mathbf{g}(\mathbf{x})) = E[\mathbf{g}(\mathbf{x})E(\mathbf{y} | \mathbf{x})] \Rightarrow E[\mathbf{g}(\mathbf{x})(\mathbf{y} - E(\mathbf{y} | \mathbf{x}))] = 0$$

**تعریف:** تخمین را بدون بایاس (Unbiased) (نااریب) گویند، هرگاه:

$$E(\hat{\mathbf{y}}) = E(\mathbf{y})$$

یعنی  $E(\text{error})$  صفر باشد.

قضیه: تخمین ls نااریب است.

زیرا:

$$E(\hat{\mathbf{y}}_{ls}) = E[E(\mathbf{y} | \mathbf{x})] = E(\mathbf{y})$$

قضیه: مقدار حداقل mse که به وسیله تخمین ls حاصل می شود، عبارت است از:

$$\text{mmse} = E(\mathbf{y}^2) - E(\mathbf{y} \hat{\mathbf{y}}_{ls}) = E(\mathbf{y}^2) - E(\hat{\mathbf{y}}_{ls}^2) = \sigma_{\mathbf{y}}^2 - \sigma_{\hat{\mathbf{y}}_{ls}}^2$$

اثبات:

$$\text{mmse} = E[(\mathbf{y} - \hat{\mathbf{y}}_{ls})^2] = E[(\mathbf{y} - \hat{\mathbf{y}}_{ls})\mathbf{y}] - E[(\mathbf{y} - \hat{\mathbf{y}}_{ls})\hat{\mathbf{y}}_{ls}]$$

ولی بنا بر اصل تعامد داریم:

$$E[(\mathbf{y} - \hat{\mathbf{y}}_{ls})\hat{\mathbf{y}}_{ls}] = 0$$

$$\Rightarrow \text{mmse} = E(\mathbf{y}^2 - \mathbf{y} \hat{\mathbf{y}}_{ls}) = E(\mathbf{y}^2) - E(\mathbf{y} \hat{\mathbf{y}}_{ls})$$

ولی با توجه به اصل تعامد  $E(\mathbf{y} \hat{\mathbf{y}}_{ls}) = E(\hat{\mathbf{y}}_{ls}^2)$ ، پس:

$$\text{mmse} = E(\mathbf{y}^2) - E(\hat{\mathbf{y}}_{ls}^2)$$

می دانیم که:  $E(\mathbf{y}) = E(\hat{\mathbf{y}}_{ls})$ ، پس:

$$\text{mmse} = E(\mathbf{y}^2) - E(\hat{\mathbf{y}}_{ls}^2) - (E(\mathbf{y}))^2 + (E(\hat{\mathbf{y}}_{ls}))^2 = \sigma_{\mathbf{y}}^2 - \sigma_{\hat{\mathbf{y}}_{ls}}^2$$

نتیجه ۱: mmse نسبت به حالتی که بدون مشاهده  $\mathbf{x}$ ،  $\mathbf{y}$  را تخمین زده بودیم، کمتر شده است:

$$\sigma_{\mathbf{y}}^2 - \sigma_{\hat{\mathbf{y}}_{ls}}^2 < \sigma_{\mathbf{y}}^2$$

نتیجه ۲ (قضیه رانو-بَلکول):  $\sigma_{\hat{\mathbf{y}}_{ls}}^2 \leq \sigma_{\mathbf{y}}^2$ ، زیرا  $\text{mmse} \geq 0$ .

مثال: اگر  $\mathbf{x}$  و  $\mathbf{y}$  مشترکاً گوسی باشند، تخمین بهینه  $\mathbf{y}$  بر اساس مشاهده  $\mathbf{x}$  عبارت است از:

$$\hat{\mathbf{y}}_{ls} = E(\mathbf{y} | \mathbf{x}) = \eta_{\mathbf{y}} + \mathbf{r} \frac{\sigma_{\mathbf{y}}}{\sigma_{\mathbf{x}}} (\mathbf{x} - \eta_{\mathbf{x}}) = \eta_{\mathbf{y}} + \frac{\mu_{\mathbf{xy}}}{\sigma_{\mathbf{x}}^2} (\mathbf{x} - \eta_{\mathbf{x}})$$

مشاهده می‌شود که در اینجا تابع تخمین خطی است. ولی در حالت کلی تابع  $\Phi(\mathbf{x}) = E(\mathbf{y} | \mathbf{x})$  تابعی خطی نیست و ممکن است تابع پیچیده‌ای باشد (اگر  $\mathbf{x}$  و  $\mathbf{y}$  مشترکاً نرمال باشند،  $E(\mathbf{y} | \mathbf{x})$  خطی است، ولی عکس این مطلب صحیح نیست. مثال در کتاب فرآیند Papoulis، فصل ۷، صفحه ۱۹).


## تخمین خطی حداقل مربعات (lls):

اگر الزام داریم که تابع تخمین  $\Phi(x)$  خطی باشد، یعنی:  $\Phi(x) = a + bx$  (رگرسیون خطی)، آنگاه باید  $a$  و  $b$  را چنان تعیین کنیم که  $mse$  می‌نیمم شود (بهترین تابع خطی را می‌یابیم، طبیعتاً ممکن است تابعی غیر خطی وجود داشته باشد که  $mse$  را کمتر از این کند. تابع  $E(y|x)$  کمترین  $mse$  را در میان تمام توابع می‌داد). پس داریم:

$$mse = E\left[(y - (a + bx))^2\right] = E(y^2) + a^2 + b^2 E(x^2) - 2aE(y) - 2bE(xy) + 2abE(x)$$

$$\left. \begin{aligned} \frac{\partial mse}{\partial a} = 0 &\Rightarrow 2a - 2E(y) + 2bE(x) = 0 \\ \frac{\partial mse}{\partial b} = 0 &\Rightarrow 2bE(x^2) - 2E(xy) + 2aE(x) = 0 \end{aligned} \right\} \Rightarrow \begin{cases} a = \eta_y + r \frac{\sigma_y}{\sigma_x} \eta_x \\ b = r \frac{\sigma_y}{\sigma_x} \end{cases}$$

$$\Rightarrow \hat{y}_{lls} = \eta_y + r \frac{\sigma_y}{\sigma_x} (x - \eta_x)$$



یعنی خطی که از نقطه  $(\eta_x, \eta_y)$  می‌گذرد و شیب آن  $r \frac{\sigma_y}{\sigma_x}$  است.

این همان چیزی است که برای تخمین ls (بدون الزام به خطی بودن) در مورد فرآیند نرمال یافتیم. یعنی اگر فرآیند نرمال باشد ( $\mathbf{y}$  و  $\mathbf{x}$  مشترکاً نرمال باشند)، تخمین lls بهینه است (همان تخمین ls است).

قضیه: در تخمین lls خطا بر داده عمود است، یعنی:

$$E[(\mathbf{y} - \hat{\mathbf{y}}_{lls})\mathbf{x}] = 0$$

اثبات:

$$\begin{aligned} E(\hat{\mathbf{y}}_{lls}\mathbf{x}) &= E\left[\eta_y\mathbf{x} + r\frac{\sigma_y}{\sigma_x}(\mathbf{x} - \eta_x)\mathbf{x}\right] = \eta_y\eta_x + r\frac{\sigma_y}{\sigma_x}\underbrace{(E(\mathbf{x}^2) - \eta_x^2)}_{\sigma_x^2} = \sigma_x^2\eta_y\eta_x + r\underbrace{\sigma_x\sigma_y}_{\mu_{xy}} \\ &= \eta_y\eta_x + E(\mathbf{xy}) - E(\mathbf{x})E(\mathbf{y}) = E(\mathbf{xy}) \\ \Rightarrow E[(\mathbf{y} - \hat{\mathbf{y}}_{lls})\mathbf{x}] &= 0 \end{aligned}$$

توجه کنید که در تخمین ls خطا بر هر تابعی از داده‌ها عمود بود، ولی در اینجا فقط بر خود  $\mathbf{x}$  عمود است.

قضیه: تخمین lls ناریب است.

زیرا:

$$E(\hat{y}_{lls}) = \eta_y + r \frac{\sigma_y}{\sigma_x} E(\mathbf{x} - \eta_x) = E(\mathbf{y})$$

قضیه: در تخمین lls داریم:

$$mse = \sigma_y^2(1 - r^2)$$

اثبات:

$$\begin{aligned} E[(\mathbf{y} - \hat{y}_{lls})^2] &= E\left[\left(\mathbf{y} - \eta_y - r \frac{\sigma_y}{\sigma_x}(\mathbf{x} - \eta_x)\right)^2\right] \\ &= E[(\mathbf{y} - \eta_y)^2] + r^2 \frac{\sigma_y^2}{\sigma_x^2} E[(\mathbf{x} - \eta_x)^2] - 2r \frac{\sigma_y}{\sigma_x} E[(\mathbf{x} - \eta_x)(\mathbf{y} - \eta_y)] \\ &= \sigma_y^2 + r^2 \sigma_y^2 - 2r \frac{\sigma_y}{\sigma_x} \cdot r \sigma_x \sigma_y = \sigma_y^2 - r^2 \sigma_y^2 = \sigma_y^2(1 - r^2) \end{aligned}$$

(در اینجا هم ملاحظه می‌کنید که mse نسبت به خطای تخمین بدون مشاهده ( $\sigma_y^2$ ) کمتر است.)