

## Momentos: Esperança e Variância.

### Introdução

Em uma relação determinística pode-se ter a seguinte relação:

$$by + ax = 0$$

Assim,  $m = -\frac{b}{a}$ , é a declividade e  $a$  e  $b$  são parâmetros. Sabendo os valores dos parâmetros pode-se plotar a relação entre  $x$  e  $y$

Da mesma forma que nos modelos determinísticos, nos modelos não determinísticos os parâmetros são empregados para caracterizar a distribuição de probabilidade. A cada distribuição podemos associar certos parâmetros, gerando informações valiosas sobre a distribuição.

Esses parâmetros terão a princípio dois nomes: Esperança e Variância, que são o primeiro e segundo momento de uma distribuição. O primeiro fornece uma medida de posição e o segundo uma medida de variabilidade.

#### **EXEMPLO:**

Suponha que  $f(x) = ke^{-kx}$ ,  $x \geq 0$  é a função densidade de probabilidade de uma variável aleatória e  $k$  o parâmetro dessa distribuição. Verificando se é uma função densidade de probabilidade:

$$\int_0^{\infty} ke^{-kx} = k \int_0^{\infty} e^{-kx} = k \left[ \frac{e^{-kx}}{-k} \right]_0^{\infty} = e^{-kx} \Big|_0^{\infty}$$

$$= e^{-k\infty} + e^{-k0} = 0 + 1 = 1 \text{ Para todo } k > 0$$

**Nota**

$$\int e^{ax} dx = \frac{e^{ax}}{a}$$

Essa é a distribuição exponencial, útil para representar a duração de vida  $x$

**EXEMPLO:**

Suponha uma linha de montagem onde  $x$  é o número de peças até que a primeira seja defeituosa. Assim, os valores possíveis de  $x$ :  $1, 2, 3, \dots, n, \dots$ . Sendo  $x = k$  e  $p$  a probabilidade de peça defeituosa a distribuição de probabilidade será:

$$P(x = k) = p (1 - p)^{k-1} \text{ para } k = 1, 2, \dots$$

Para ser uma distribuição de probabilidade

$$\sum_{k=1}^{\infty} p(1 - p)^{k-1} = p[1 + (1 - p) + (1 - p)^2 + \dots]$$

$$= p \frac{1}{1 - (1 - p)} = 1 \text{ se } 0 < p < 1$$

Se especificarmos a variável aleatória e a sua distribuição de probabilidade, existirá alguma maneira de caracterizar essa distribuição em termos de alguns parâmetros numéricos?

## Esperança ou Valor esperado

### Caso Discreto

#### Definição:

Seja  $x$  uma variável aleatória discreta, com valores possíveis  $x_1, x_2, \dots, x_n, \dots$ . Seja  $p(x_i) = P(X = x_i)$ ,  $i = 1, 2, \dots, n$  então o valor esperado de  $x$ , denotado por  $E(X)$  será

$$E(x) = \sum_{i=1}^{\infty} x_i p(x_i)$$

Se a série convergir absolutamente:

$$\sum_{i=1}^{\infty} (x_i) p(x_i) < \infty$$

A Esperança pode ser compreendida intuitivamente como a “*média ponderada*” dos possíveis valores de  $x$ . Caso os valores de  $x$  sejam igualmente prováveis, tem-se a “*média aritmética*”

$$E(X) = \frac{1}{n} \sum_{i=1}^n x_i$$

Apesar da semelhança entre média ponderada e  $E(X)$ , existe uma diferença fundamental entre elas:

- $E(X)$  é um parâmetro de uma distribuição de probabilidade teórica, ou seja, é um valor teórico
- $\bar{x}$  é a média ponderada, o resultado de uma combinação de um conjunto numérico – valor empírico

Se o experimento for realizado  $n$  vezes, originando os valores  $x_1, x_2, \dots, x_n$  (são as  $n$  medições repetidas das características numéricas de  $x$ )

- $\bar{x}$  é a média ponderada e está próxima de  $E(X)$  em certo sentido se  $n$  for suficientemente grande.
- Da mesma forma a  $f_A$  frequência relativa estão próximas de  $p_A$  probabilidade

### **Caso contínuo**

Definição:

Seja  $x$  uma variável aleatória contínua com função densidade de probabilidade  $f(x)$ , assim o valor esperado ou  $E(X)$  será:

$$E(X) = \int_{-\infty}^{\infty} xf(x)dx$$

$E(X)$  existirá somente se:

$$E(X) = \int_{-\infty}^{\infty} |x| f(x)dx \text{ for finita}$$

$E(X)$  é o que se chama de primeiro momento de uma distribuição de probabilidade e fornece uma medida de posicionamento da distribuição podendo também ser representada o “centro de gravidade” da distribuição de probabilidade.

**EXEMPLO:**

$$f(x) \begin{cases} = \frac{1}{(1500)^2}x & 0 \leq x \leq 1500 \\ = \frac{-1}{(1500)^2}(x - 3000) & 1500 \leq x \leq 3000 \\ = 0 & \text{caso contrário} \end{cases}$$

$$E(X) = \int_{-\infty}^{\infty} xf(x)dx$$

$$= \left[ \int_0^{1500} \frac{1}{(1500)^2} x^2 dx + \int_{1500}^{3000} -\frac{1}{(1500)^2} (x^2 - 3000x) dx \right]$$

$$= \left[ \frac{1}{(1500)^2} \frac{x^3}{3} \Big|_0^{1500} \right] + \left[ -\frac{1}{(1500)^2} \frac{x^3}{3} \Big|_{1500}^{3000} \right] + \left[ -\frac{1}{(1500)^2} 3000 \frac{x^2}{2} \Big|_{1500}^{3000} \right]$$

= ...

= ...

= ...

= 1500

## Valor Esperado de uma Função de uma Variável Aleatória

Seja  $X$  uma variável aleatória e  $Y$  uma transformação dessa variável. Assim,  $Y = H(X)$  é uma função de  $X$  e  $Y$  é uma variável aleatória. Suponha que o interesse está em calcular  $E(Y)$ . Existem duas maneiras:

### **a) Utilizando a distribuição de probabilidade de $Y$**

Definição:

Seja  $X$  uma variável aleatória e  $Y = H(X)$

(a) Se  $Y$  for discreta:

$$E(Y) = \sum_i^{\infty} y_i q(y_i)$$

(b) Se  $Y$  for contínua

$$E(Y) = \int_{-\infty}^{\infty} y g(y) dy$$

Assim, para obter  $E(Y)$  é preciso obter a distribuição de probabilidade  $Y$ . Encontrar essa distribuição nem sempre é uma tarefa fácil

### **b) Utilizando a distribuição de probabilidade de $X$**

Podemos obter  $E(Y)$  apenas conhecendo a distribuição de probabilidade de  $X$ .

Teorema:

Seja  $X$  uma variável aleatória e  $Y = H(X)$

(a) Se  $X$  for discreta:

$$E(Y) = E[H(X)] = \sum_{j=1}^{\infty} H(x_j)p(x_j)$$

(b) Se  $X$  for contínua:

$$E(Y) = E[H(X)] = \int_{-\infty}^{\infty} H(x)f(x)dx$$

Demonstração:

$\sum_{j=1}^{\infty} H(x_j)p(x_j) = \sum_{j=1}^{\infty} [\sum_i H(x_i)p(x_i)]$  Onde a soma interior é tomada para todos os  $i$  os quais  $H(x_i) = y_j$  com  $y_j$  fixo. Assim  $H(x_i)$  é constante na soma interior. Portanto:

$$\sum_{j=1}^{\infty} H(x_j)p(x_j) = \sum_{j=1}^{\infty} y_j \sum_i p(x_i)$$


No entanto:

$$\sum_i p(x_i) = \sum_i p(x|H(x_i) = y_j) = q(y_j)$$

Assim:

$$\sum_{j=1}^{\infty} H(x_j)p(x_j) = \sum_{j=1}^{\infty} y_j q(y_j)$$

Visualizando:



No esquema anterior pode-se calcular a  $E(Y)$  de duas maneiras distintas conforme apresentado. A primeira é utilizando a distribuição de  $Y$ .

$$E(Y) = \sum_i^{\infty} y_i q(y_i) = 1 \cdot \frac{1}{2} + 2 \cdot \frac{1}{2} = 1,5$$

A segunda é utilizando a distribuição de  $X$ , assim:

$$E(Y) = \sum_{j=1}^{\infty} H(x_j) p(x_j) = \sum_{j=1}^{\infty} \left[ \sum_i H(x_i) p(x_i) \right] = H(1)p(1) + H(2)p(2) + H(3)p(3) + H(4)p(4)$$

$$E(Y) = \sum_{j=1}^2 H(x_j) p(x_j) = \sum_{j=1}^2 \left[ \sum_i H(x_i) p(x_i) \right] = 1 \cdot \frac{1}{4} + 1 \cdot \frac{1}{4} + 2 \cdot \frac{1}{4} + 2 \cdot \frac{1}{4} = 1,5$$

Ambos geram o mesmo resultado. No entanto nem sempre é uma tarefa fácil encontrar a distribuição de  $Y$ ! Vejamos mais um exemplo de como encontrar a  $E(Y)$

**EXEMPLO:**

$x$  uma va com f.d.p.

$$f(x) = \begin{cases} \frac{e^x}{2} & \text{se } x \leq 0 \\ \frac{e^{-x}}{2} & \text{se } x > 0 \end{cases}$$

Pois queremos o modulo. Como nesse intervalo  $x$  é negativo, utilizamos  $-x$

$$E y = |x|$$

$$\int_{-\infty}^{\infty} |x| f(x) dx = \frac{1}{2} \left[ \int_{-\infty}^0 \overbrace{(-x)} e^x dx + \int_0^{\infty} x e^{-x} dx \right] = 1$$

F.d.p. de  $y$

$$G(y) = p(Y \geq y) = p[|x| \leq y] = [-y \leq x \leq y] = 2p[0 \leq x < y]$$

Simétrico em relação a zero

$$G(y) = 2 \int_0^y f(x) dx = 2 \int_0^y \frac{e^{-x}}{2} = -e^{-x} + 1 \text{ para } y \geq 0$$

$$g(y) = G'(y) = e^{-y} \text{ para } y \geq 0$$

$$E(y) = \int_0^{\infty} yg(y)dy = \int_0^{\infty} ye^{-y}dy =$$

$$= \left[ \frac{e^{-y}}{-1} (y + 1) \right]_0^{\infty} = [-e^{-y}y - e^{-y}]_0^{\infty} = [0 - 0 - (0 - 1)] = 1$$

**Nota**

$$\int xe^{ax}dx = \frac{e^{ax}}{a} \left( x - \frac{1}{a} \right)$$

### Valor Esperado de Variáveis Aleatórias Bidimensionais

#### Definição:

Seja  $(X, Y)$  uma variável aleatória bidimensional e  $Z = H(X, Y)$  então  $Z$  será uma variável aleatória unidimensional e  $E(Z)$  será:

- (a) Se  $Z$  for discreta

$$E(Z) = \sum_i^{\infty} z_i p(z_i)$$

- (b) Se  $z$  for contínua

$$E(Z) = \int_{-\infty}^{\infty} zf(z)dz$$

#### Teorema:

Seja  $(X, Y)$  uma variável aleatória bidimensional e  $Z = H(X, Y)$  então  $Z$  será uma variável aleatória unidimensional e  $E(Z)$  será:

- (a) Se  $(X, Y)$  for discreta:

$$E(Z) = \sum_j^{\infty} \sum_i^{\infty} H(x_i, y_j) p(x_i, y_j)$$



(b) Se  $(X, Y)$  for contínua:

$$E(Z) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} H(x, y) f(x, y) dx dy$$

Um caso especial é quando  $Z = (X, Y)$ . Assim, tem-se:

(a) Se  $(X, Y)$  for discreta:

$$E(X, Y) = \sum_j \sum_i x_i \cdot y_j p(x_i, y_j)$$

(b) Se  $(X, Y)$  for contínua:

$$E(X, Y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x \cdot y f(x, y) dx dy$$

### Propriedades do Valor Esperado

Propriedade (1):

Se  $X = c$ , sendo  $c$  uma constante, então:

$$E(X) = c$$

Demonstração:

$$E(X) = \int_{-\infty}^{\infty} x f(x) dx = \int_{-\infty}^{\infty} c f(x) dx = c \int_{-\infty}^{\infty} f(x) dx = c$$

Observe que  $R_X$  é constituído de um único valor sendo a  $P[X_{(s)} = c] = 1$ . Esse tipo de variável aleatória é chamada de degenerada

Propriedade (2):

Seja  $c$  uma constante e  $X$  uma variável aleatória, então:

$$E(cX) = cE(X)$$

Demonstração:

$$E(cX) = \int_{-\infty}^{\infty} cxf(x)dx = c \int_{-\infty}^{\infty} xf(x)dx = cE(X)$$

Propriedade (3):

Seja  $(X, Y)$  uma variável aleatória bidimensional e  $Z = H_1(X, Y)$  e  $W = H_2(X, Y)$ , então:

$$E(Z + W) = E(Z) + E(W)$$

Demonstração:

$$\begin{aligned} E(Z + W) &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} [H_1(x, y) + H_2(x, y)]f(x, y)dxdy \\ &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} H_1(x, y)f(x, y)dxdy + \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} H_2(x, y)f(x, y)dxdy = E(Z) + E(W) \end{aligned}$$

Propriedade (4):

Seja  $X$  e  $Y$  duas variáveis aleatórias quaisquer

$$E(X + Y) = E(X) + E(Y)$$

Demonstração:

Decorre da propriedade 3, onde  $X = H_1(\cdot)$  e  $Y = H_2(\cdot)$ .

**Observações:**

Note que

$Y = aX + b \rightarrow E(Y) = aE(x) + b$  , pois a esperança é um operador linear

Mas

$E(x^2) \neq (E(x))^2$ ;  $E(\ln x) \neq \ln E(x)$ ;  $E\left(\frac{1}{x}\right) \neq \frac{1}{E(x)}$  , pois são operações não lineares

Propriedade (5):

Para  $n$  variáveis aleatórias  $X_1, \dots, X_n$ , tem-se:

$$E(X_1 + \dots + X_n) = E(X_1) + \dots + E(X_n)$$

Demonstração:

Decorre da Propriedade 4.

Propriedade (6):

Se  $(X, Y)$  for uma variável aleatória bidimensional, sendo  $X$  e  $Y$  independentes, então:

$$E(X, Y) = E(X)E(Y)$$

Demonstração:

$$E(X, Y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} xyf(x, y) dx dy = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} xyg(x)h(y) dx dy$$

$$E(X, Y) = \int_{-\infty}^{\infty} xg(x) dx \int_{-\infty}^{\infty} yh(y) dy = E(X)E(Y)$$

Observe a diferença em relação a propriedade 4, a qual não requer independência