

RESUMO para a P2 de PROBABILIDADE - 2015
Por Arthur Sales. R\$ 7,20

± - Média e Variância - Variáveis aleatórias discretas

1) Para variáveis aleatórias discretas, definiu-se a média ou valor esperado como:

MÉDIA
$$\mu = E(x) = \sum_j x_j \cdot p(x_j)$$

O que nada mais é do que uma média dos valores assumidos por x , ponderados por sua probabilidade de ocorrência.

Por exemplo:

| | | | |
|--------|-----|-----|-----|
| x | 2 | 5 | 10 |
| $P(x)$ | 0,2 | 0,4 | 0,4 |

$$E(x) = 2 \cdot 0,2 + 5 \cdot 0,4 + 10 \cdot 0,4$$
$$E(x) = 6,4$$

2) Média de uma função: se quisermos determinar o valor esperado não de x , mas de uma função de x $h(x)$, podemos fazer:

VALOR ESPERADO DE UMA FUNÇÃO
$$E(h(x)) = \sum_j h(x_j) \cdot p(x_j)$$

Por exemplo, se quiséssemos calcular a média de $h(x) = x^2 + 1$ no exercício anterior teríamos

| | | | |
|--------|-----|-----|-----|
| x | 2 | 5 | 10 |
| $h(x)$ | 5 | 26 | 101 |
| $p(x)$ | 0,2 | 0,4 | 0,4 |

$$E(h(x)) = \sum h(x) \cdot p(x)$$

$$E(h(x)) = 5 \cdot 0,2 + 26 \cdot 0,4 + 101 \cdot 0,4$$

$$E(h(x)) = 51,8$$

3) Propriedade da média: Se X é uma v.a. discreta

e a e b são números reais:

$$E(ax + b) = a \cdot E(x) + b$$

4) Variância: Se X é uma v.a. discreta com função de probabilidade $p(x)$, a variância de X é dada por:

$$\text{VARIÂNCIA} \quad \boxed{\text{Var}(X) = E((X - \mu)^2)} = \sum (x_j - \mu)^2 \cdot p(x_j)$$

Ou seja, é a média da distância ao quadrado dos valores que X assume até a sua média.

Podemos interpretar isso como o quão "espalhados" estão os valores de X : se $\text{var}(X)$ é pequena, os valores se concentram perto da média; se é grande, eles estão bem espalhados distantes da média.

Uma outra forma de representar a variância é da forma σ^2 , em que σ é o desvio padrão de X

DESVIO PADRÃO $\boxed{\sigma = \sqrt{\text{var}(X)}}$

Uma forma muito útil de calcular a variância é usar:

$$\boxed{\text{var}(X) = E(X^2) - [E(X)]^2}$$

5) Propriedade da variância:

$$\boxed{\text{var}(aX+b) = a^2 \cdot \text{var}(X)}$$

6) Variância de uma função: se quisermos calcular a variância de uma função $h(X)$ fazemos

$$\boxed{\text{var}(h(X)) = \sum_j [h(x_j) - E(h(X))]^2 \cdot p(x_j)}$$

7) Propriedade para v.a. independentes: Se X_1, X_2, \dots, X_m são variáveis aleatórias independentes, das quais conhecemos média ($E(X_j) = \mu_j$) e variância ($\text{var}(X_j) = \sigma_j^2$) com $a_1, \dots, a_m \in \mathbb{R}$:

i) $E(\sum a_j X_j) = \sum a_j E(X_j)$

ii) $\text{var}(\sum a_j X_j) = \sum a_j^2 \text{var}(X_j)$

(3)

II - Média e Variância - variáveis aleatórias contínuas

Se X for uma variável aleatória contínua e se $f(x)$ for sua função densidade de probabilidade, podemos calcular:

1) Média: a média (ou esperança, ou valor esperado) de X é dado por:

$$\text{MÉDIA} \quad \left| \mu = E(X) = \int_{-\infty}^{\infty} x \cdot f(x) \cdot dx \right|$$

2) Valor esperado de uma função: de forma similar ao que ocorre com as v.a. discretas, temos:

$$\text{VALOR ESPERADO DE UMA FUNÇÃO} \quad \left| E(h(x)) = \int_{-\infty}^{\infty} h(x) \cdot f(x) \cdot dx \right|$$

3) Variância: a variância de X é dada por:

$$\left| \sigma^2 = \text{Var}(X) = E((X-\mu)^2) = \int_{-\infty}^{\infty} (x-\mu)^2 \cdot f(x) \cdot dx \right|$$

Novamente, podemos calcular:

$$\text{Var}(X) = E(X^2) - [E(X)]^2$$

4) Propriedades:

Valim as mesmas propriedades que vimos para v.a. discretas:

i) $E(ax + b) = aE(x) + b$

ii) $\text{Var}(ax + b) = a^2 \text{Var}(x)$

Além disso, vale a propriedade do item 7, a respeito de variáveis aleatórias independentes.

III - Distribuição de Probabilidade Discretas

Existem algumas distribuições de probabilidade $(p(x))$ que aparecem com frequência em problemas reais.

Por isso, elas recebem nomes bonitos e se tornam mircudoras de um estudo mais detalhado. Vejamos algumas delas:

1) Distribuição de Bernoulli: ocorre quando uma v.a. X assume apenas valores 1 ou 0, com probabilidade p e $(1-p)$, respectivamente. Termos:

$$\begin{array}{l} p(x) \quad \left\{ \begin{array}{l} p(0) = 1-p \\ p(1) = p \end{array} \right. \\ \\ E(X) = p \\ \text{var}(X) = p(1-p) \end{array}$$

2) Distribuição Binomial: suponha que façamos n ensaios de Bernoulli, um que cada ensaio é independente e com mesma probabilidade de sucesso p .

Se X é o número de sucessos nos n ensaios digamos que X tem distribuição binomial e:

$$X = B(n; p)$$

↑ ensaios ↙ probabilidade sucesso

Esse tipo de distribuição é muito comum. Por exemplo se estou analisando 100 bandejas do bardeco e queremos descobrir quantas não têm resquícios do alimento anterior, estou fazendo um experimento binomial, em que um sucesso é pegar uma bandjeia sem resquícios.

Alguns valores importantes:

$$P(X=k) = \binom{n}{k} p^k (1-p)^{n-k}$$

$$E(X) = np$$

$$\text{Var}(X) = np(1-p)$$

Uma propriedade importante se relaciona com o resultado da soma de binomiais:

Se $X_1 = B(n_1, p)$, $X_2 = B(n_2, p), \dots$

$$X_m = B(n_m, p)$$

Com X_1, X_2, \dots, X_n variáveis independentes:

$$\sum_{i=1}^m X_i = B\left(\sum_{i=1}^m n_i, p\right)$$

3) Distribuição de Poisson :

Dada uma taxa de ocorrência de um fenômeno (λ), X é o número de ocorrências do fenômeno em um dado intervalo.

Por exemplo, se na média encontramos 2 pedaços de alface por bandeja no bardeco, um experimento de Poisson pode ser ver quantos pedaços de alface há em uma certa bandeja.

* Diferença da Binomial : o exemplo anterior ilustra a diferença entre Poisson e Binomial. A binomial vê sucessos (tem ou não tem alface); já a Poisson se relaciona a contagem de ocorrências por evento (não se tem, mas quanto tem).

Se X tem distribuição de Poisson com taxa λ ($X = \text{Poisson}(\lambda)$), temos que :

$$P(X = k) = \frac{e^{-\lambda} \lambda^k}{k!}$$
$$E(X) = \lambda$$
$$\text{Var}(X) = \lambda$$

Além disso, se tomarmos $X_1 = \text{Poisson}(\lambda_1), \dots, X_m = \text{Poisson}(\lambda_m)$ independentes, a soma delas também será Poisson e :

$$\sum_{i=1}^m X_i = \text{Poisson}\left(\sum_{i=1}^m \lambda_i\right)$$

IV - Distribuição de Probabilidade Contínuas


Vejam algumas distribuições de probabilidade muito comuns para v.a. contínuas.

1) Distribuição Uniforme

Seja X tal que sua distribuição de probabilidade

Seja:

$$F(x) = \begin{cases} \frac{1}{b-a}, & x \in [a, b] \\ 0, & \text{caso contrário} \end{cases}$$



Pode-se provar que:

$$E(X) = \frac{a+b}{2}$$


$$\text{Var}(X) = \frac{(b-a)^2}{12}$$

$$F(x) = \begin{cases} 0, & x < a \\ \frac{x-a}{b-a}, & a \leq x \leq b \\ 1, & x > b \end{cases}$$

2) Distribuição Exponencial

Dizemos que uma v.a. contínua tem distribuição exponencial com parâmetro λ se sua função densidade de probabilidade for da forma:

$$f(x) = \begin{cases} \lambda e^{-\lambda x} & , x \geq 0 \\ 0 & , \text{caso contrário} \end{cases}$$



Pode-se provar que:

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

$$\text{Var}(X) = \frac{1}{\lambda^2}$$

$$F(x) = \begin{cases} 1 - e^{-\lambda x} & , x \geq 0 \\ 0 & , \text{caso contrário} \end{cases}$$

3) Distribuição Normal

Dizemos que uma v.a. contínua tem distribuição normal com parâmetros μ (média) e σ (desvio padrão) se sua f.d.p. é dada por:

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}, \quad x \in \mathbb{R}$$

Nesse caso, representamos:

$$X = N(\mu; \sigma^2)$$

Tenha calma, não temos que usar essa fórmula, pois temos tabelados os valores para a normal padrão ($N(0,1)$) e a partir deles podemos achar outros como veremos mais adiante.

Temos em tabelas os valores de $P(0 \leq x \leq a)$ para a normal padrão $N(0,1)$. Para outros valores dos parâmetros fazemos:

$$P(a \leq x \leq b) = P\left(\frac{a-\mu}{\sigma} \leq \frac{x-\mu}{\sigma} \leq \frac{b-\mu}{\sigma}\right)$$

Em que $\frac{x-\mu}{\sigma} = Z$ segue a normal padrão.

* Soma de normais: Se X_1, \dots, X_n são v.a. independentes com distribuição normal: $X_i = N(\mu_i, \sigma_i^2)$ temos que $\sum_{i=1}^n a_i X_i$ tem distribuição normal com parâmetros

$$\mu = \sum_{i=1}^n a_i \mu_i$$

$$\sigma^2 = \sum_{i=1}^n a_i^2 \sigma_i^2$$

V - Teorema Central do Limite

Por muitos motivos, na estatística gosta-se de trabalhar com distribuições normais. Felizmente, a normal é mais comum do que se imagina. Um exemplo em que a normal aparece para facilitar nossas vidas é dado pelo Teorema Central do Limite (TCL).

Segundo o TCL, se X_1, X_2, \dots, X_n são variáveis aleatórias independentes com média μ e variância σ^2 , a média de X_i tenderá a uma distribuição normal na forma,

$$\bar{X} = \frac{X_1 + X_2 + \dots + X_n}{n} \xrightarrow{\text{tende a}} N\left(\mu; \frac{\sigma^2}{n}\right)$$

Aproximação da Binomial por Normal

Se X_1, X_2, \dots, X_n forem resultados de experimentos de Bernoulli com probabilidade de sucesso p , já vimos que a soma dos X_i terá uma distribuição binomial com média np e variância $np(1-p)$.

Se aplicarmos o TCL, sabemos que:

$$\frac{X_1 + X_2 + \dots + X_n}{n} \text{ tende à normal } N\left(\mu, \frac{\sigma^2}{n}\right)$$

Logo para a soma (resultado da binomial):

$$X_1 + X_2 + \dots + X_n \text{ tende à normal } N(n\mu; n\sigma^2)$$

Como para cada X_i de Bernoulli $\mu = p$ e $\sigma^2 = p(1-p)$, segue que a binomial se aproxima da normal $N(np; np(1-p))$.

* Quando usar: o TCL diz que a variável X binomial tende a uma distribuição normal. Quando, porém, podemos tratar de fato X como uma normal?

Quando n for suficientemente grande. Não há um valor exato para dizer se n é grande ou pequeno, mas algumas regrinhas podem ser usadas

i) $np > 10$ e $np(1-p) > 10$; 00

ii) $n > 30$

* Por que o TCL é legal? imagine que X é um experimento binomial com 100 repetições ($n = 100$) e que queremos calcular a probabilidade de X ser menor do que 50

Ou seja: $P(X < 50) = F(50)$

Se não usássemos o TCL, deveríamos somar $P(X_j)$ para X_j entre 0 e 49. Não parece divertido, não é mesmo. Por outro lado, se sei que X pode ser aproximada por uma normal, bastará consultar a tabela da acumulada.

VI - Distribuição de Probabilidade Conjunta

Até agora estudamos distribuição de probabilidade com uma única variável aleatória. Entretanto, muitas vezes o fenômeno que queremos estudar depende de um número maior de variáveis aleatórias.

Neste tópico vamos estudar as variáveis aleatórias bidimensionais, que dependem de duas variáveis aleatórias (X e Y , digamos)

1) Distribuição Conjunta (Caso DISCRETO)

Para variáveis aleatórias, vimos que a função densidade de probabilidade $p(x)$ nos fornece a probabilidade da variável X assumir cada valor no domínio.

Para o caso de duas variáveis aleatórias discretas, a função de probabilidade conjunta $p(x, y)$ é definida como a probabilidade de:

$$| p(x, y) = P(X = x \text{ e } Y = y) |$$

Analogamente ao que vimos com uma v.a., a soma de todas as probabilidades deve ser 1:

$$\sum_{x_i, y_j} P(X = x_i, Y = y_j) = 1$$

2) Distribuições Marginais (caso DISCRETO)

Apesar da distribuição depender de X e Y , muitas vezes vamos querer a probabilidade de X assumir certo valor, independentemente do valor de Y , e vice-versa.

Para isso, podemos usar as funções massa de probabilidade marginais de X e Y , representadas por $p_X(x)$ e $p_Y(y)$ e calculadas como:

$$\left[\begin{array}{l} p_X(x) = \sum_y p(x,y) \\ p_Y(y) = \sum_x p(x,y) \end{array} \right]$$

3) Independência:

Dizemos que duas variáveis aleatórias X e Y são independentes se:

$$\left[p(x,y) = p_X(x) * p_Y(y) \right]$$

Exemplo: Fonte: DEVORE

Considere a seguinte função massa de probabilidade conjunta de X e Y

| $X \backslash Y$ | 0 | 1 | 2 |
|------------------|------|------|------|
| 0 | 0,10 | 0,04 | 0,02 |
| 1 | 0,08 | 0,20 | 0,06 |
| 2 | 0,06 | 0,14 | 0,30 |

a) Qual x $P(X=1 \text{ e } Y=1)$

b) Calcule $P(X \leq 1 \text{ e } Y \leq 1)$

c) Calcule a fmp marginal de X e de Y

d) Calcule $P(X \leq 1)$

e) X e Y são variáveis independentes?

Solução

a) Da tabela : $p(1,1) = P(X=1 \text{ e } Y=1) = 0,2$

b) $P(X \leq 1 \text{ e } Y \leq 1) = p(0,0) + p(0,1) + p(1,0) + p(1,1)$

$P(X \leq 1 \text{ e } Y \leq 1) = 0,1 + 0,04 + 0,08 + 0,2$

$P(X \leq 1 \text{ e } Y \leq 1) = 0,42$

c) Para calcular a marginal, basicamente fixamos o valor de uma variável e somamos as probabilidades para todos os valores da outra.

Na tabela, fazemos isso somando linhas ou colunas:

| X \ Y | 0 | 1 | 2 | $P_X(x)$ |
|----------|------|------|------|----------|
| 0 | 0,10 | 0,04 | 0,02 | 0,16 |
| 1 | 0,08 | 0,20 | 0,06 | 0,34 |
| 2 | 0,06 | 0,14 | 0,30 | 0,5 |
| $P_Y(y)$ | 0,24 | 0,38 | 0,38 | |

← $P_X(0)$, ou seja, $x=0$ e y qualquer

↑ $P_Y(1)$, ou seja, $Y=1$ e X qualquer

d) $P(X \leq 1) = P(X=0) + P(X=1) = P_X(0) + P_X(1) = 0,5$


e) Não, note por exemplo que $p(0,0) \neq P_X(0) * P_Y(0)$
 $0,1 \neq 0,16 * 0,24$

Agora vamos estudar o caso de variáveis aleatórias bidimensionais contínuas

4) Distribuição Conjunta (caso CONTÍNUO)

Se X e Y são v.a. contínuas, $f(x,y)$ é a função de densidade de probabilidade conjunta. Para qualquer conjunto A de valores de (x,y) temos que:


$$P[(X,Y) \in A] = \iint_A f(x,y) dx dy$$



No caso especial de A ser um retângulo com $a \leq x \leq b$ e $c \leq y \leq d$, temos:

$$P[(X,Y) \in A] = \int_a^b \int_c^d f(x,y) dy dx$$

Em que A é o retângulo:



Propriedades

i) $f(x,y) \geq 0 \quad \forall x,y \in \mathbb{R}$

ii) $\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x,y) dx dy = 1$

5) Distribuição Marginal (caso CONTÍNUO)

Para X e Y variáveis contínuas, as funções densidade de probabilidade marginais são dadas por:

$$f_x(x) = \int_{-\infty}^{\infty} f(x,y) dy \qquad f_y(y) = \int_{-\infty}^{\infty} f(x,y) dx$$

↑
fixo x e integro
(como) em y

↑
fixo y e integro
em x

Exemplo (Fonte: DEVORE)

Considere a seguinte distribuição de probabilidade:

$$f(x,y) = \begin{cases} K(x^2 + y^2), & 20 \leq x \leq 30, 20 \leq y \leq 30 \\ 0, & \text{caso contrário} \end{cases}$$

- Qual o valor de K ?
- Calcule $P(X \leq 26 \text{ e } Y \leq 26)$
- Calcule $P(|X - Y| \leq 2)$
- Determine $F_x(x)$ e $F_y(y)$
- X e Y são independentes?

a) Aplicamos que:

$$\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) dx dy = 1$$

$$\int_{20}^{30} \int_{20}^{30} K(x^2 + y^2) dx dy = 1$$

$$\int_{20}^{30} K \left(\frac{x^3}{3} + xy^2 \right) \Big|_{20}^{30} dy = 1$$

$$\int_{20}^{30} K \left(\frac{19000}{3} + 10y^2 \right) dy = 1$$

$$K \left(\frac{19000}{3} y + \frac{10}{3} y^3 \right) \Big|_{20}^{30} = 1$$

$$K \left(\frac{190000}{3} + \frac{190000}{3} \right) = 1$$

$$\boxed{K = \frac{3}{380000}}$$

$$b) P(X \leq 26 \text{ e } Y \leq 26) = \int_{-\infty}^{26} \int_{-\infty}^{26} f(x, y) dx dy$$

$$P(X \leq 26 \text{ e } Y \leq 26) = \int_0^{26} \int_0^{26} \frac{3}{380000} (x^2 + y^2) dx dy$$

(...)

$$P(X \leq 26 \text{ e } Y \leq 26) = \frac{189}{625} = 0,3024$$

c)

avermos calcular a probabilidade de:

$$|X - Y| \leq 2$$

$$-2 \leq X - Y \leq 2$$

$$-2 + Y \leq X \leq 2 + Y$$

ou seja:

$$P(|X - Y| \leq 2) = \int_{20}^{30} \int_{y-2}^{y+2} K(x^2 + y^2) dx dy$$

$$P(|X - Y| \leq 2) = \int_{20}^{30} K \left(\frac{x^3}{3} + xy^2 \right) \Big|_{y-2}^{y+2} dy$$

$$P(|X - Y| \leq 2) = K \int_{20}^{30} \left(\frac{(y+2)^3}{3} + (y^3 + 2y^2) - \frac{(y-2)^3}{3} - (y^3 - 2y^2) \right) dy$$

$$P(|X - Y| \leq 2) = 0,3593$$

$$d) e) f_x(x) = \int_{-\infty}^{\infty} f(x, y) dy = \int_{20}^{30} K(x^2 + y^2) dy = K \left(x^2 y + \frac{y^3}{3} \right) \Big|_{20}^{30}$$

$$f_x(x) = K \left(30x^2 + \frac{30^3}{3} - 20x^2 - \frac{20^3}{3} \right)$$

$$f_x(x) = 10Kx^2 + 0,05$$

Analogamente:

$$f_y(y) = 10Ky^2 + 0,05$$

$$f_x(x) \cdot f_y(y) = (10Kx^2 + 0,05) \cdot (10Ky^2 + 0,05)$$

$$f_x(x) \cdot f_y(y) = 100Kx^2y^2 + 0,5Kx^2 + 0,5Ky^2 + 0,0025$$

Claramente $f_x(x) \cdot f_y(y) \neq f(x, y)$
Logo X e Y não são independentes