



escola
britânica de
artes criativas
& tecnologia

Profissão: Cientista de Dados


Probabilidade

Introdução:



Variáveis Aleatórias e

Amostragem

Probabilidade





Probabilidade





Amostragem tipo
cross section

Probabilidade



Probabilidade



Amostragem de Processo Estocástico



Modelos discretos

Modelos discretos - Bernoulli



$$X = \begin{cases} 1 & \text{se o resultado do ensaio é "sucesso"} \\ 0 & \text{se o resultado do ensaio é "fracasso"} \end{cases}$$

Definimos: "cara" = "sucesso", "coroa" = "fracasso"


$$P(X = 1) = 0,5$$

$$P(X = 1) = p$$


$$P(X = 0) = 0,5$$

$$P(X = 0) = 1 - p$$

Modelos discretos - Bernoulli




Modelos discretos - Binomial



Se retirarmos N bolas, com reposição, qual a probabilidade de retirarmos x bolas brancas?

Modelos discretos - Binomial




Qual a probabilidade de retirarmos 1 bola branca?



$$p * (1 - p) * (1 - p)$$

$$= p(1 - p)^2$$

Modelos discretos - Binomial



Qual a probabilidade de retirarmos 1 bola branca?

OBS: Considerando a ordem, podemos fazer isso de 3 formas diferentes:

Forma 1:


Forma 2:

Forma 3:

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

Distribuição condicional e independência

Conjunta




$$X_1: \text{Resultado do dado 1} \\ X_2: \text{Resultado do dado 2} \\ Y: \text{Soma}$$
$$1 + 1 = 2$$

Conjunta

1	+	1	=	2
1	+	2	=	3
1	+	3	=	4
1	+	4	=	5
1	+	5	=	6
1	+	6	=	7

2	+	1	=	3
2	+	2	=	4
2	+	3	=	5
2	+	4	=	6
2	+	5	=	7
2	+	6	=	8

3	+	1	=	4
3	+	2	=	5
3	+	3	=	6
3	+	4	=	7
3	+	5	=	8
3	+	6	=	9



4	+	1	=	5
4	+	2	=	6
4	+	3	=	7
4	+	4	=	8
4	+	5	=	9
4	+	6	=	10

$$\begin{array}{r} 5 \\ + \\ 1 \\ \hline \end{array} = 6$$
$$\begin{array}{r} 5 \\ + \\ 2 \\ \hline \end{array} = 7$$
$$\begin{array}{r} 5 \\ + \\ 3 \\ \hline \end{array} = 8$$
$$\begin{array}{r} 5 \\ + \\ 4 \\ \hline \end{array} = 9$$
$$\begin{array}{r} 5 \\ + \\ 5 \\ \hline \end{array} = 10$$
$$\begin{array}{r} 5 \\ + \\ 6 \\ \hline \end{array} = 11$$


6	+	1	=	7
6	+	2	=	8
6	+	3	=	9
6	+	4	=	10
6	+	5	=	11
6	+	6	=	12

$$P(X_1 = i, X_2 = j)$$

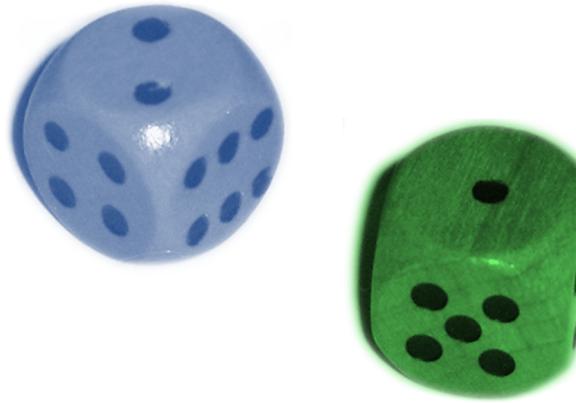

$$= P(X_1 = i) \cdot P(X_2 = j)$$

$$= \frac{1}{6} \cdot \frac{1}{6} = \frac{1}{36}$$

Conjunta




Independência



$$P(X_1 = i, |X_2 = j) = P(X_1 = i)$$


Condisional



$$P(Y = i | X_1 = 6) = \begin{cases} \frac{1}{6} \text{ se } i = 7 \\ \frac{1}{6} \text{ se } i = 8 \\ \frac{1}{6} \text{ se } i = 9 \\ \frac{1}{6} \text{ se } i = 10 \\ \frac{1}{6} \text{ se } i = 11 \\ \frac{1}{6} \text{ se } i = 12 \\ 0 \text{ caso contrário} \end{cases}$$


Função Densidade de Probabilidade

Função Densidade de Probabilidade




$$P(a \leq X \leq b) = \int_a^b f(x)dx$$

Função Densidade de Probabilidade



$$P(-\infty \leq X \leq +\infty) = \int_{-\infty}^{+\infty} f(x)dx = 1$$

Função Densidade de Probabilidade




$$P(0 \leq X \leq +\infty) = \int_0^{+\infty} f(x)dx = 50\%$$

Quando a função é simétrica, a probabilidade para valores maiores que média é de 50%

Função Distribuição Acumulada de Probabilidade


Distribuição acumulada



$$F(x) = P(X < x)$$

$$F(+\infty) = 1$$


Distribuição acumulada




$$F(x) = \int_{-\infty}^x f(x)dx = P(X < x)$$

$$F(+\infty) = 1$$


Função Densidade de Probabilidade



$$F(1)$$




$$F(0)$$



$$P(0 < X < 1) = F(1) - F(0)$$


Distribuição Normal

Distribuição normal




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

Distribuição normal




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



$$x^* = \frac{x - \mu}{\sigma}$$


$$f(x^*) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(x^*)^2}$$

Por que a Normal é tão importante?




Galton Board ou Tabuleiro de Galton:

Por que a Normal é tão importante?




Galton Board ou Tabuleiro de Galton:

Por que a Normal é tão importante?




Galton Board ou Tabuleiro de Galton:

Por que a Normal é tão importante?




Galton Board ou Tabuleiro de Galton:

Por que a Normal é tão importante?




Galton Board ou Tabuleiro de Galton:

Por que a Normal é tão importante?



Galton Board ou Tabuleiro de Galton:

Por que a Normal é tão importante?



Vários caminhos levam ao meio


Galton Board ou Tabuleiro de Galton:

Por que a Normal é tão importante?



Galton Board ou Tabuleiro de Galton:

Conjunta, condicional e independência



Combinação linear

- Se $X_1 \sim N(\mu, \sigma^2)$
- $X_1^* = a + bX_1 \sim N(a + \mu, b^2\sigma^2)$ com a e b constantes.
- Ou seja:
 - A média de X_1^* é $a + \mu$
 - A variância de X_1^* é $b^2 \cdot \sigma^2$
 - O que significa que o desvio padrão de X_1^* é $b \cdot \sigma$ (que é $\sqrt{b^2\sigma^2}$)
- POR ISSO QUE SE $X_1 \sim N(\mu, \sigma^2)$:
 - $X_1^* = \frac{X_1 - \mu}{\sigma} \Rightarrow X_1^* \sim N(0,1)$

Combinação linear

- Se $X_1 \sim N(\mu, \sigma^2)$ e $X_2 \sim N(\mu, \sigma^2)$
- E se X_1 e X_2 são independentes,

$$X_1 + X_2 \sim N(2\mu, 2\sigma^2)$$

Distribuição da média

- Dos dois resultados anteriores, temos a distribuição da média:

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \sim N\left(\mu, \frac{\sigma^2}{n}\right)$$

Ou seja:

$$\text{Desvio Padrão}(\bar{X}) = \frac{\sigma}{\sqrt{n}}$$

Ou ainda:

$$\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1)$$

Distribuição da média

Teorema Central do Limite

Se temos uma amostra X_1, X_2, \dots, X_n iid (independentes, identicamente distribuídas), então:

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \sim N\left(\mu, \frac{\sigma^2}{n}\right)$$

Ou ainda:

$$\frac{\bar{X} - \mu}{\sigma / \sqrt{n}} \sim N(0, 1)$$

Teorema do Limite Central


Mas se o parâmetro de variância σ^2 não é conhecido, nos resta substituí-lo pela sua estimativa S^2 .

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \sim N\left(\mu, \frac{S^2}{n}\right)$$

Ou ainda:

$$\frac{\bar{X} - \mu}{S/\sqrt{n-1}} \sim t(n-1)$$


Média com Variância não conhecida



A distribuição t-student possui 'caudas mais pesadas'.

Isso significa que, com mesma média e desvio padrão, valores mais distantes da média são mais frequentes (têm maior probabilidade)

Média com Variância não conhecida



Um fato interessante da distribuição t-student é que ela se aproxima da distribuição normal conforme o número de graus de liberdade aumenta. Na prática, a partir de 20 a aproximação pela normal já é bem razoável.