

Fórmulas Estatística I

- Média amostral: $\bar{X} = \frac{\sum_{i=1}^n X_i}{n}$
- Variância amostral: $\hat{\sigma}^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n}$ ou $S^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n-1}$
- Coeficiente de variação: $CV = (S/\bar{X}).100\%$
- Probabilidade Condicional: $P(A | B) = \frac{P(A \cap B)}{P(B)}$
- Esperança: $\mu = E(X) = \sum_{x:f(x)>0} xf(x)$ ou $\int_{-\infty}^{\infty} xf(x)dx$
- Variância: $\sigma^2 = Var(X) = E[(X - \mu)^2] = E(X^2) - \mu^2$
- Propriedade da esperança: $E[g(X)] = \sum_{x:f(x)>0} g(x)f(x)$ ou $\int_{-\infty}^{\infty} g(x)f(x)dx$
- Distribuição Binomial: $X \sim Bin(n, p)$
 $f(x) = \binom{n}{x} p^x (1-p)^{n-x}$, $x = 0, 1, 2, \dots, n$
 $E(X) = np$ e $Var(X) = np(1-p)$
- Distribuição Hipergeométrica: $X \sim Hiper(N, n, k)$
 $f(x) = \frac{\binom{k}{x} \binom{N-k}{n-x}}{\binom{N}{n}}$, $max\{0, n - (N - k)\} \leq x \leq min\{n, k\}$
 $E(X) = \frac{nk}{N}$ e $Var(X) = \frac{N-n}{N-1} \cdot n \cdot \frac{k}{N} \left(1 - \frac{k}{N}\right)$
- Distribuição Binomial Negativa: $X \sim BN(k, p)$
 $f(x) = \binom{x-1}{k-1} p^k q^{x-k}$, $x = k, k+1, k+2, \dots$
 $E(X) = \frac{k}{p}$ e $Var(X) = \frac{k(1-p)}{p^2}$
- Distribuição Geométrica: $X \sim Geom(p)$
 $f(x) = pq^{x-1}$, $x = 1, 2, 3, \dots$
 $E(X) = \frac{1}{p}$ e $Var(X) = \frac{1-p}{p^2}$
- Distribuição de Poisson: $X \sim Poisson(\lambda)$
 $f(x) = \frac{\exp^{-\lambda} (\lambda)^x}{x!}$, $x = 0, 1, 2, \dots$
 $E(X) = \lambda$ e $Var(X) = \lambda$
- Distribuição Uniforme contínua: $X \sim Uniforme(A, B)$
 $f(x) = \frac{1}{B-A}$, $A \leq x \leq B$
 $E(X) = \frac{A+B}{2}$ e $Var(X) = \frac{(B-A)^2}{12}$

- Distribuição Exponencial: $X \sim Exp(\lambda)$

$$f(x) = \lambda \exp^{-\lambda x}, \quad x > 0$$

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

- Distribuição Normal: $X \sim N(\mu, \sigma^2)$

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp^{-\frac{(x-\mu)^2}{2\sigma^2}}, \quad -\infty \leq x \leq \infty$$

$$E(X) = \mu \text{ e } Var(X) = \sigma^2$$

- Transformação da Normal para a Normal Reduzida:

$$Z = \frac{X-\mu}{\sigma}$$

- Teorema Central do Limite: Sejam X_1, \dots, X_n v.a. independentes e identicamente distribuídas, com $E(X_i) = \mu$ e $Var(X_i) = \sigma^2 < \infty$, para $i = 1, \dots, n$, então, quando $n \rightarrow \infty$:
 $\bar{X} \approx N(\mu, \frac{\sigma^2}{n})$, ou seja: $\frac{\bar{X}-\mu}{\sigma/\sqrt{n}} \approx N(0, 1)$

Casos particulares e observações:

- se $X_i \sim Bernoulli(p)$, para $i = 1, \dots, n$: $\hat{p} \approx N(p, \frac{p(1-p)}{n})$
- se $Y \sim Binomial(n, p)$: $Y \approx N(np, np(1-p))$: aproximação da Binomial pela Normal
- se σ desconhecido, pode-se usar adicionalmente o Teorema de Slutsky e: $\frac{\bar{X}-\mu}{S/\sqrt{n}} \approx N(0, 1)$
- Sejam X_1, \dots, X_n v.a. independentes e identicamente distribuídas, com $X_i \sim N(0, 1)$, para $i = 1, \dots, n$, então: $\frac{\bar{X}-\mu}{S/\sqrt{n}} \sim t - Student(n-1)$
- Função de verossimilhança: $L(\theta) = f(x_1, x_2, \dots, x_n/\theta) = \prod_{i=1}^n f(x_i)$, sendo a última igualdade decorrente da suposição de independência de X_1, \dots, X_n
- $\hat{\theta}$ é estimador não viciado de θ se: $E(\hat{\theta}) = \theta$, para todo valor de θ .
- $\hat{\theta}$ é estimador consistente de θ se: $\lim_{n \rightarrow \infty} E(\hat{\theta}) = \theta$ e $\lim_{n \rightarrow \infty} V(\hat{\theta}) = 0$