

# VARIÁVEIS ALEATÓRIAS CONTÍNUAS

Vanderlei da Costa Bueno

Instituto de Matemática e Estatística

Universidade de São Paulo, SP. Brasil

Abril de 2020

Introduzimos definição da variável aleatória contínua com argumentos semelhantes àqueles da definição das variáveis aleatórias discretas. Contudo, se o espaço amostral  $\Omega$  é o resultado de um experimento quantitativo contínuo, a imagem de  $\Omega$  através de uma função real  $X$  não é, certamente, enumerável.

**Definição** Seja  $(\Omega, \mathfrak{S}, P)$  um espaço de probabilidade e  $X$  uma aplicação de  $\Omega$  nos reais ( $\mathfrak{R}$ ).  $X$  é uma variável aleatória contínua se assume valores em um intervalo de números reais.

A variável aleatória contínua  $X$  é completamente caracterizada por sua função de distribuição (acumulada)

$$F_X(t) = P(X \leq t), \forall t \in \mathfrak{R}$$

que, neste caso, é uma função contínua.

Se a função de distribuição de  $X$  é diferenciável com

$\frac{dF_X(t)}{dt} = f_X(t)$ , definimos

## Definição

Se  $X$  é uma variável aleatória contínua com função de distribuição

$$F_X(t) = \int_{-\infty}^t f_X(y) dy,$$

dizemos que  $f_X(t)$  é a função densidade de probabilidade de  $X$  e que é (absolutamente) contínua.

É evidente que a função densidade de probabilidade é positiva, isto é,  $f_X(t) \geq 0, \forall t$ , que

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

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

e pode-se provar que

$$\lim_{t \downarrow -\infty} f_X(t) = \lim_{t \uparrow \infty} f_X(t) = 0.$$

## Exemplo

O custo mensal dos sinistros de uma Uma Cia. de Seguros é modelado por uma variável aleatória  $X$  com função densidade de probabilidade

$$f(x) = \begin{cases} 0 & x < 0 \\ k \cdot (1+x)^{-4} & 0 < x < \infty \end{cases},$$

onde  $k$  é uma constante.

Como devemos ter  $\int_{-\infty}^{\infty} f(x)dx = 1$  e

$$1 = k \int_0^{\infty} (1+x)^{-4} dx = -\frac{k}{3}(1+x)^{-3} \Big|_0^{\infty} = \frac{k}{3},$$

temos  $k = 3$ .

A função de distribuição de  $X$  é

$$F(x) = \begin{cases} 0 & x < 0 \\ \int_0^x 3(1+y)^{-4} dy = 1 - (1+x)^{-3} & x \geq 0 \end{cases} .$$

A probabilidade condicional de que o custo mensal ultrapasse 40 conhecendo-se que é maior do que 10 é

$$P(X > 40 | X > 10) = \frac{P(X > 40, X > 10)}{P(X > 10)} = \frac{P(X > 40)}{P(X > 10)} =$$
$$\frac{3 \int_{40}^{\infty} (1+y)^{-4} dy}{3 \int_{10}^{\infty} 3(1+y)^{-4} dy} = \left(\frac{11}{41}\right)^3 = 0,02.$$

Lembrando que as integrais de Riemann são limites de somas infinitesimais é natural que os parâmetros de uma variável aleatória contínua sejam definidos de maneira semelhante aos da variável aleatória discreta:

**Definição** Se  $X$  é uma variável aleatória contínua com função densidade de probabilidade  $f(x)$ , definimos a média de  $X$ , que denotamos por  $E[X]$  ou  $\mu$ , à "soma"

$$\mu = \int_{-\infty}^{\infty} xf(x)dx,$$

onde a integral deve ser absolutamente convergente, caso contrário dizemos que a média não existe.

Por vezes estamos interessados em variáveis aleatórias que resultam da transformação de outra variável. Por exemplo, seja  $X$  uma variável aleatória,  $Y = g(X)$ , onde  $g$  é uma função real, também é uma variável aleatória.

A medida  $P(Y \leq y)$  é caracterizada por

$$P(g(X) \leq y) = \int_{\{x:g(x) \leq y\}} f_X(x) dx.$$

Pode-se provar que

$$E[g(X)] = E[Y] = \int_{-\infty}^{\infty} y f_Y(y) dy = \int_{-\infty}^{\infty} g(x) f_X(x) dx.$$



No exemplo anterior, em que

$$f(x) = \begin{cases} 0 & x < 0 \\ 3.(1+x)^{-4} & 0 < x < \infty \end{cases},$$

$$\mu = E[X] = 3 \int_0^{\infty} x(1+x)^{-4} dx = 3 \int_1^{\infty} (y-1)y^{-4} dy = 3.\left(\frac{1}{2} - \frac{1}{3}\right) = \frac{1}{2}.$$

$$E[X^2] = 3 \int_0^{\infty} x^2(1+x)^{-4} dx = 2 \int_0^{\infty} x(1+x)^{-3} dx = \frac{1}{3} \int_0^{\infty} (1+x)^{-2} dx = 1.$$

# Esperança e Variância de $X$

Em particular a esperança da  $n$ -ésima potência de variável aleatória, se existir, é denominada momento.

**Definição** Seja  $X$  uma variável aleatória contínua. O  $n$ -ésimo momento de  $X$ , denotado por  $\mu_n$  é definida como:

$$\mu_n = E[X^n] = \int_{-\infty}^{\infty} x^n f(x) dx, \text{ se existir.}$$

Observe que  $\mu_1 = \mu = E[X]$ . A esperança de potências da forma  $E[(X - \mu)^n]$  são denominadas momentos centrais. **Definição** Seja  $X$  uma variável aleatória contínua com média  $\mu$ . O  $n$ -ésimo momento central de  $X$ , denotado por  $\sigma_n$  é definido como:

$$\sigma_n = E[(X - \mu)^n] = \int_{-\infty}^{\infty} (x - \mu)^n f(x) dx,$$

se existir.

Em particular o segundo momento central em torno da média é a variância, interpretada como uma dispersão em torno da média.

**Definição** Se  $X$  é uma variável aleatória contínua com média  $\mu$  e função de densidade de probabilidade  $f(x)$ , definimos a variância de  $X$ , que denotamos por  $E[(X - \mu)^2] = \sigma^2$ , à integral

$$\sigma_2 = \sigma^2 = \int_{-\infty}^{\infty} (x - \mu)^2 f(x) dx.$$

relembrando que a integral deve ser absolutamente convergente, caso contrário dizemos que a variância não existe. Como no caso

discreto, é fácil provar que  $\sigma^2 = \text{Var}(X) = E[X^2] - \mu^2$ . O desvio padrão de  $X$  é definido pela raiz quadrada de  $\sigma^2$ . No exemplo anterior temos que  $\text{Var}(X) = 1 - \frac{1}{4} = \frac{3}{4}$  e  $dP(X) = \frac{\sqrt{3}}{2}$ .

**Definição** Se  $X$  é uma variável aleatória contínua . A função geradora de momentos de  $X$ ,  $M_X(t)$ , é o valor esperado  $E[\exp[tX]]$ , se existir, em um intervalo simétrico,  $(-s, s)$ , de números reais.

$$M_X(t) = E[\exp[tX]] = \int_{-\infty}^{\infty} \exp[tx]f(x)dx.$$

**Exemplo** Em uma Cia. de manufaturas, as perdas por danos à propriedade segue uma distribuição contínua com função densidade de probabilidade  $f(y) = 0,02 \exp[-0,02y]$ ,  $y > 0$ .

# Função Geradora de Momentos

A função geradora de momentos de  $Y$  é

$$M_Y(t) = E[\exp[tY]] = \int_0^{\infty} \exp[ty] 0,02 \exp[-0,02y] dy =$$
$$\int_0^{\infty} 0,02 \exp[(t - 0,02)y] dy = \frac{0,02}{0,02 - t}$$

, se  $t < 0,02$ .

A primeira derivada de  $M_Y(t)$  é  $M_Y^{(1)}(t) = \frac{0,02}{(0,02-t)^2}$  e

$$E[Y] = M_Y^{(1)}(0) = \frac{1}{0,02}.$$

A segunda derivada de  $M_Y(t)$  é  $M_Y^{(2)}(t) = \frac{2 \cdot (0,02)}{(0,02-t)^3}$  que no número 0 vale

$$E[Y^2] = M_Y^{(2)}(0) = \frac{2}{(0,02)^2}.$$

Portanto a variância de  $Y$  é  $\sigma^2 = E[Y^2] - E[Y]^2 = \frac{1}{(0,02)^2}$ .

## Distribuição uniforme.

Em um espaço amostral discreto e finito, a distribuição uniforme associa a cada elemento amostral a mesma probabilidade. Em um modelo contínuo cada ponto tem probabilidade igual a zero e a distribuição uniforme se caracteriza associando a cada intervalo de mesmo comprimento a mesma probabilidade. A variável aleatória  $X$  tem distribuição uniforme em um intervalo finito,  $(a, b]$ , de números reais se sua função densidade de probabilidade é :

$$f(x) = \begin{cases} \frac{1}{b-a} & a < x \leq b \\ 0 & \text{c.c.} \end{cases} .$$

A esperança de  $X$  é

$$\mu = E[X] = \int_a^b \frac{x}{b-a} dx = \frac{1}{b-a} \frac{x^2}{2} \Big|_a^b = \frac{(b-a).(b+a)}{2(b-a)} = \frac{a+b}{2} .$$

## Distribuição uniforme.

Também temos

$$E[X^2] = \int_a^b \frac{x^2}{b-a} dx = \frac{1}{b-a} \frac{x^3}{3} \Big|_a^b = \frac{(b-a) \cdot (b^2 + ab + a^2)}{3(b-a)} = \frac{b^2 + ab + a^2}{3}$$

e portanto

$$\text{Var}(X) = \sigma^2 = E[X^2] - \mu^2 = \frac{b^2 + ab + a^2}{3} - \left(\frac{a+b}{2}\right)^2 = \frac{(b-a)^2}{12}.$$

A função de distribuição de  $X$  é

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

e a função geradora de momentos

$$M_X(t) = E[\exp[tX]] = \int_a^b \frac{\exp[tX]}{b-a} dx = \frac{\exp[tb] - \exp[ta]}{t(b-a)}.$$

**Distribuição uniforme. Exemplo** Uma seguradora de automóveis cobra R\$250,00 pela franquia de determinada apólice e paga o máximo de R\$1.500,00 por uma perda total. Se o custo dos sinistros, em relação à apólice, é modelado por uma distribuição uniforme no intervalo  $(0, 2.000]$ , qual a probabilidade de um pagamento de perda total? Qual a probabilidade do segurado não usar a apólice?



## Distribuição uniforme.

Se  $X$  é a variável custo, tem distribuição uniforme no intervalo  $(0, 2000]$ , com função densidade de probabilidade

$$f(x) = \begin{cases} \frac{1}{2.000} & 0 < x \leq 2.000 \\ 0 & \text{c.c.} \end{cases} .$$

A probabilidade de um pagamento de perda total é

$$P(X > 1.500) = \int_{1.500}^{2000} \frac{1}{2.000} dx = 0,25.$$

Entendemos que o segurado não usa a apólice quando a franquia é maior do que o custo do conserto e portanto, com probabilidade

$$P(X \leq 250) = \int_0^{250} \frac{1}{2.000} dx = 0,125.$$

**Distribuição exponencial. Definição** Uma variável aleatória  $T$  tem função de distribuição exponencial se, e somente se,

$$F_T(t) = \begin{cases} 0 & t < 0 \\ 1 - \exp[-\lambda t] & t \geq 0 \end{cases} .$$

$$F_T(t) = 1 - \exp[-\lambda \cdot t].$$

$F_T(t)$  é diferenciável e tem função densidade de probabilidade

$$f(t) = \begin{cases} 0 & t < 0 \\ \lambda \exp[-\lambda t] & t \geq 0 \end{cases} .$$

## Distribuição exponencial.

A função geradora de momentos de  $T$  é dada por

$$M_T(t) = E[\exp[t \cdot T]] = \int_0^{\infty} \exp[tx] \lambda \exp[-\lambda \cdot x] dx =$$
$$\int_0^{\infty} \lambda \exp[-x \cdot (\lambda - t)] dx = \frac{\lambda}{\lambda - t}, t < \lambda.$$

com primeira e segunda derivadas iguais a  $M_T^{(1)}(t) = \frac{\lambda}{(\lambda - t)^2}$  e  $M_T^{(2)}(t) = \frac{2 \cdot \lambda \cdot (\lambda - t)}{(\lambda - t)^4}$ , respectivamente. No ponto zero temos

$$\mu = E[T] = M_T^{(1)}(0) = \frac{1}{\lambda}$$

e  $E[T^2] = M_T^{(2)}(0) = \frac{2}{\lambda^2}$  de forma que

$$\sigma^2 = \text{Var}(T) = \frac{2}{\lambda^2} - \frac{1}{\lambda^2} = \frac{1}{\lambda^2}.$$

Observe que a média de  $T$  é o inverso de seu parâmetro.

## Distribuição exponencial.

**Exemplo** Uma Cia. de Seguros tem observado que o custo dos sinistros de aeronaves de porte médio é modelado por uma variável aleatória com função de distribuição

$$F(t) = \begin{cases} 0 & t < 0 \\ 1 - \exp[-0,001t] & t \geq 0 \end{cases} \quad ''$$

isto é,  $X$  tem distribuição exponencial. A probabilidade de um sinistro com custo maior do que 4.000 é

$$P(X > 4.000) = 0,001 \int_{4.000}^{\infty} \exp[-0,001x] dx = \exp[-4] = 0,018.$$

## Distribuição exponencial.

**Teorema**  $T$  é uma variável aleatória contínua com a propriedade de falta de memória se, e somente se,  $T$  tem distribuição exponencial.

### Prova

A condição suficiente vale, isto é, se  $T$  tem distribuição exponencial, temos

$$P(T > t+s) = \exp[-\lambda(t+s)] = \exp[-\lambda t] \cdot \exp[-\lambda s] = P(T > t) \cdot P(T > s)$$

e  $T$  tem falta de memória .

A condição necessária está demonstrada nas notas do professor.

## Distribuição exponencial.

### Exemplo

Uma industria fabrica lâmpadas especiais que ficam continuamente em operação. Caso a lâmpada dure menos do que 50 horas oferece a seus clientes a garantia de reposição. O tempo de vida útil dessas lâmpadas é modelado através da distribuição exponencial com parâmetro  $\frac{1}{8.000}$ . Portanto, a proporção de lâmpadas trocadas por garantia é

$$P(T \leq 50) = \int_0^{\infty} \frac{1}{8.000} \exp\left[-\frac{t}{8.000}\right] dt =$$
$$1 - \frac{1}{8.000} \exp\left[-\frac{50}{8.000}\right] = 0,006.$$

**Distribuição exponencial.** Você acha razoável substituir uma lâmpada que já durou 5.000 horas? Como a distribuição exponencial tem a propriedade da falta de memória, a resposta é não pois uma lâmpada usada é tão boa quanto uma nova. Analiticamente podemos escrever

$$P(T > t + 5.000 | T > 5.000) = \frac{P(T > t + 5.000, T > 5.000)}{P(T > 5.000)} =$$
$$\frac{\exp\left[-\frac{1}{8.000}(t + 5.000)\right]}{\exp\left[-\frac{1}{8.000}5.000\right]} = \exp\left[-\frac{1}{8.000}t\right] = P(T > t).$$

## Distribuição normal.


**Definição** Dizemos que uma variável aleatória  $X$  tem distribuição normal com parâmetros  $\mu$  e  $\sigma^2$ , e denotamos  $X \sim N(\mu, \sigma^2)$ , se  $X$  tem função densidade de probabilidade

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left[-\frac{(x - \mu)^2}{2\sigma^2}\right], \quad -\infty < x < \infty, \quad \sigma > 0, \quad -\infty < \mu < \infty.$$



**Distribuição normal.** A expressão de  $f(x)$  parece complexa mas tem um gráfico suave em forma de um sino.


Figura 7.1 - Gráfico da curva normal



## Distribuição normal.

O parâmetro  $\mu$  é de escala e o gráfico de normais com mesmo  $\sigma$  e diferentes  $\mu$  são como segue:


Figura 7.2 - Gráficos de curvas normais



## Distribuição normal.

O parâmetro  $\sigma^2$  é o da forma da densidade e quanto maior o  $\sigma$  a densidade é mais dispersa em torno de  $\mu$  e existe chances maiores de encontrar valores, da variável, distantes de  $\mu$ . Se  $\sigma$  é pequeno, a densidade tem forma mais concentrada em torno de  $\mu$  e a chance de observarmos valores próximos de  $\mu$  aumenta.

Figura 7.3 - Gráficos de curvas normais (variando  $\sigma$ )



**Distribuição normal.** O parâmetro  $\sigma^2$  é o da forma da densidade e quanto maior o  $\sigma$  a densidade é mais dispersa em torno de  $\mu$  e existe chances maiores de encontrar valores , da variável, distantes de  $\mu$ . Se  $\sigma$  é pequeno, a densidade tem forma mais concentrada em torno de  $\mu$  e a chance de observarmos valores próximos de  $\mu$  aumenta.

Na realidade estamos definindo uma classe de distribuições normais pois a cada número real  $\mu$  e número real positivo  $\sigma$ , temos uma distribuição normal.

Em particular a distribuição normal com  $\mu = 0$  e  $\sigma^2 = 1$ , denominada de distribuição normal padrão e denotada por  $Z \sim N(0, 1)$  tem função densidade de probabilidade

$$f(x) = \frac{1}{\sqrt{2\pi}} \exp\left[-\frac{x^2}{2}\right], \quad -\infty < x < \infty.$$

**Distribuição normal.** A função de distribuição dessa variável,  $Z \sim N(0, 1)$ , é dada por


$$F(z) = \int_{-\infty}^z \frac{1}{\sqrt{2\pi}} \exp\left[-\frac{x^2}{2}\right] dx$$

mas o cálculo analítico para tal expressão é complexo e devemos utilizar técnicas numéricas. Na prática, simplificamos com o uso das tabelas estatísticas, apresentadas no final das notas.

**Distribuição normal.** A tabela fornece a área sob a função densidade de probabilidade entre o valor zero (0) e um valor real  $z$  à sua direita. O valor  $z$ , até sua primeira casa decimal é encontrado na primeira coluna e sua segunda casa decimal na primeira linha da tabela. O cruzamento dessa linha e coluna, no interior da tabela, nos dá a probabilidade  $P(0 < Z \leq z)$ . Procedendo dessa maneira verificamos, por exemplo:

## Distribuição normal.

Figura 7.4- Cálculo de probabilidades com a distribuição normal



$$P(0 \leq Z \leq 1,64) = 0,45;$$

$$P(0 \leq Z \leq 1,96) = 0,475;$$



## Distribuição normal.

Desde que a função densidade de probabilidade da distribuição normal padrão é perfeitamente simétrica em relação a zero, concluímos que;

$$P(Z \leq -1,64) = P(Z \geq 1,64) = 0,5 - P(0 < Z \leq 1,64) = 0,05;$$

$$P(-1,96 \leq Z \leq 1,96) = 2.P(0 < Z \leq 1,96) = 0,95;$$

$$\begin{aligned} P(-1,64 \leq Z \leq 1,96) &= P(-1,64 \leq Z \leq 0) + P(0 < Z \leq 1,96) = \\ &P(0 < Z \leq 1,64) + P(0 < Z \leq 1,96) = 0,975. \end{aligned}$$

**Distribuição normal.** Reversamente, podemos encontrar o valor de  $z$ , tal que a área (probabilidade) à sua esquerda, ou direita seja fixada. Consideremos encontrar  $z$ , tal que  $P(Z \leq z) = 0,8$ .

Observe que este valor de  $z$  deve ser positivo, caso contrário, a área à sua esquerda seria menor ou igual a 0,5. Como  $z$  é positivo podemos escrever

$$P(Z \leq z) = P(Z \leq 0) + P(0 < Z \leq z) = 0,5 + P(0 < Z \leq z) = 0,8,$$

que implica  $P(0 < Z \leq z) = 0,3$ . Observando o valor mais próximo de 0,3 no corpo da tabela, percorremos sua linha e sua coluna, no sentido contrário do que vínhamos fazendo.

## **Distribuição normal.**

No caso obtemos  $z = 0,85$ .

Para encontrar o valor de  $z$  com  $P(Z \leq z) < 0,5$  podemos proceder com os mesmos argumentos, por exemplo:

Se  $P(Z \leq z) = 0,05$ , temos que  $z$  é negativo e que  $P(Z \geq -z) = 0,05$ . Portanto  $P(0 < Z \leq -z) = 0,45$  e concluímos que  $-z = 1,64$  e  $z = -1,64$ .

## Distribuição normal.

Conhecemos que a distribuição de uma variável aleatória é completamente determinada pela sua função geradora de momentos,  $M_Z(t) = E[\exp[tZ]]$ , quando esta função existir. A função geradora de momentos de  $Z$  é

$$M_Z(t) = \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} \exp[tz] \exp\left[-\frac{z^2}{2}\right] dz =$$
$$\exp\left[\frac{t^2}{2}\right] \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} \exp\left[-\frac{(z-t)^2}{2}\right] dz = \exp\left[\frac{t^2}{2}\right].$$

## Distribuição normal.

Podemos calcular a média e a variância de  $Z$  através da sua função geradora de momentos. A primeira derivada de  $M_Z(t)$  é igual a

$$M_Z^{(1)}(t) = t \cdot \exp\left[\frac{t^2}{2}\right] \text{ com } \mu = E[Z] = M_Z^{(1)}(0) = 0.$$

A segunda derivada de  $M_Z(t)$  é  $M_Z^{(2)}(t) = \exp\left[\frac{t^2}{2}\right] + t \cdot \exp\left[\frac{t^2}{2}\right]$  que

no ponto zero vale  $E[Z^2] = M_Z^{(2)}(0) = 1$ . Portanto

$$\sigma^2 = \text{var}(Z) = E[Z^2] - \mu^2 = 1.$$

## Distribuição normal.

Se consideramos a transformação linear da variável aleatória  $Z$ ,  $X = \sigma.Z + \mu$  onde  $\mu$  é um número real e  $\sigma$ , um número real positivo, temos que a função geradora de momentos de  $X$  é

$$M_X(t) = E[\exp[tX]] = E[\exp[t.(\sigma.Z + \mu)]] = E[\exp[t.\sigma.Z] \exp[t.\mu]] = \exp[t.\mu] M_Z(t.\sigma) = \exp\left[t.\mu + \frac{t^2\sigma^2}{2}\right].$$

Acontece que tal função geradora de momentos caracteriza completamente a distribuição normal com média  $\mu$  e variância  $\sigma^2$ .

## Distribuição normal.

Calculando as derivadas da função geradora de momentos no ponto zero, obtemos  $E[X] = M_X^{(1)}(0) = \mu$  e  $E[X^2] = M_X^{(2)}(0) = \sigma^2 + \mu^2$  e concluímos que os parâmetros da distribuição Normal, denotada por  $X \sim N(\mu, \sigma^2)$  são sua média e variância.

Inversamente, podemos considerar a transformação reversa,

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

$$M_Z(t) = E[\exp[t.Z]] = E[\exp[t.(\frac{X}{\sigma} - \frac{\mu}{\sigma})]] = \exp[-t.\frac{\mu}{\sigma}].M_X(\frac{t}{\sigma}) = \exp[\frac{t^2}{2}].$$

## Distribuição normal.

Concluimos que existe uma equivalência entre a normal de média  $\mu$  e variância  $\sigma^2$ ,  $N(\mu, \sigma^2)$ , e a normal padrão,  $N(0, 1)$ , através das citadas transformações e utilizaremos este resultado para cálculos envolvendo a função de distribuição de  $X \sim N(\mu, \sigma^2)$  através da função de distribuição da normal padrão  $Z \sim N(0, 1)$ .

Assim, se  $X \sim N(\mu, \sigma^2)$ , a sua função de distribuição pode ser calculada como

$$F_X(x) = P(X \leq x) = P\left(\frac{X - \mu}{\sigma} \leq \frac{x - \mu}{\sigma}\right) = P\left(Z \leq \frac{x - \mu}{\sigma}\right) = F_Z\left(\frac{x - \mu}{\sigma}\right).$$



## Distribuição normal.

**Exemplo** O custo dos sinistros de certo tipo de apólice tem distribuição normal com média de R\$1.800,00 e desvio padrão R\$400,00. A probabilidade de que um sinistro escolhido aleatoriamente custe mais do que R\$1.500,00 é

$$P(X > 1500) = P\left(\frac{X - \mu}{\sigma} > \frac{1500 - 1800}{400}\right) = P(Z > -0,75) =$$

$$P(Z \leq 0,75) = 0,5 + P(0 < Z \leq 0,75) = 0,5 + 0,27337 = 0,77.$$

## Distribuição normal.

A probabilidade de que o custo esteja entre R\$1.500,00 e R\$2.000,00 é

$$P(1500 < X \leq 2000) = P\left(\frac{1500 - 1800}{400} < \frac{X - \mu}{\sigma} \leq \frac{2000 - 1800}{400}\right) =$$

$$P(-0,75 < Z \leq 0,5) = P(-0,75 < Z \leq 0) + P(0 < Z \leq 0,5) = \\ P(0 < Z \leq 0,75) + 0,19146 = 0,27337 + 0,19146 = 0,46.$$

A probabilidade de que o custo esteja a 1,96 desvio padrão de sua média é

$$P(|X - 1800| \leq 1,96 \cdot 400) = P(-1,96 \cdot 400 \leq X - 1800 \leq 1,96 \cdot 400) =$$

$$P(-1,96 \leq \frac{X - 1800}{400} \leq 1,96) = P(-1,96 \leq Z \leq 1,96) = 0,95.$$

## Distribuição normal.

Caso a Cia de Seguros deseje estabelecer uma franquia de forma que 10% das ocorrências não utilizem o seguro, devemos procurar o custo  $x$  tal que  $P(X \leq x) = 0,1$ . Padronizando  $X$ , a equação é equivalente a

$$P\left(\frac{X - \mu}{\sigma} \leq \frac{x - 1800}{400}\right) = 0,1 \Leftrightarrow P\left(Z \leq \frac{x - 1800}{400}\right) = 0,1 \Leftrightarrow$$

$$P\left(Z \geq \frac{x - 1800}{400}\right) = 0,1 \Leftrightarrow P\left(0 < Z \leq \frac{1800 - x}{400}\right) =$$

$$0,4 \Leftrightarrow \frac{1800 - x}{400} = 1,64 \Leftrightarrow x = 1.144,$$

isto é, a franquia deve ser de R\$1.144,00.

## Aproximação da binomial pela normal.

Consideremos o cálculo da probabilidade de que entre 10.000 segurados, 15 solicitem benefícios devido à ocorrências de sinistros. A probabilidade da ocorrência de tais sinistros foi estipulada como  $p = 0,001$ . Se  $Y$  é a variável aleatória definida pelo número de segurados que reclamam os benefícios, temos que  $Y$  tem distribuição binomial de parâmetros 10.000 e 0,001, ( $Y \sim B(10.000, 0,001)$ ). A probabilidade do evento  $\{Y = 15\}$  é

$$P(Y = 15) = \binom{10.000}{15} 0,001^{15} 0,999^{9985},$$

de cálculo complicado. Para calcular tal quantidade, consideramos a aproximação da distribuição binomial pela distribuição normal com mesma média e variância da binomial.

## Aproximação da binomial pela normal.


Para um melhor entendimento consideremos a distribuição binomial de parâmetros  $n = 10$  e  $p = 0,5$ . A função de probabilidade da variável aleatória  $Y \sim B(10; 0,5)$  é

$y$	0	1	2	3	4	5
$P(Y = y)$	0,001	0,01	0,044	0,117	0,205	0,246

$y$	6	7	8	9	10
$P(Y = y)$	0,205	0,117	0,044	0,01	0,001

**Aproximação da binomial pela normal.** com representação gráfica:

Figura 7.5- Aproximação da binomial pela normal



## **Aproximação da binomial pela normal.**

Uma primeira aproximação gráfica de uma variável discreta por uma variável contínua é através do histograma, o gráfico de retângulos contíguos cujas áreas somam 1. Se para cada valor da variável discreta construirmos um retângulo de base 1 e altura igual à sua probabilidade teremos a soma dessas áreas igual a 1. A base do retângulo correspondente ao valor  $x_i$ , da variável, é definida por  $x_i - 0,5$  e  $x_i + 0,5$ , como na figura acima.

Seja  $X$  a variável aleatória que corresponde ao histograma. No caso em que  $n$  é grande a variável  $X$  converge para uma variável normal com média  $\mu = np$  e  $\sigma^2 = n.p.(1 - p)$ , a média e variância da distribuição  $B(n, p)$ .

## Aproximação da binomial pela normal.

No exemplo em que  $n = 10$  e  $p = 0,5$  temos  $P(Y = 5) = 0,246$ ,  
 $P(Y \leq 3) = 0,172$  e  $P(2 \leq Y < 6) = 0,612$ .

Se  $X \sim N(5; 2,5)$ ,

$$P(4,5 \leq X \leq 5,5) = P\left(\frac{4,5 - 5}{1,58} \leq \frac{X - 5}{1,58} \leq \frac{5,5 - 5}{1,58}\right) =$$

$$P(-0,32 \leq Z \leq 0,32) = 2.P(0 \leq Z \leq 0,32) = 2.0,12552 = 0,251,$$

uma aproximação por menos de 5 milésimos.



## Aproximação da binomial pela normal.

$$P(X \leq 3,5) = P\left(\frac{X - 5}{1,58} \leq \frac{3,5 - 5}{1,58}\right) = P(Z \leq -0,95) =$$

$$P(Z > 0,95) = 0,5 - P(0 \leq Z \leq 0,95) = 0,5 - 0,32894 = 0,171.$$

$$P(1,5 \leq X \leq 5,5) = P\left(\frac{1,5 - 5}{1,58} \leq \frac{X - 5}{1,58} \leq \frac{5,5 - 5}{1,58}\right) =$$

$$P(-2,21 \leq Z \leq 0,32) = P(0 \leq Z \leq 2,21) +$$

$$P(0 \leq Z \leq 0,32) = 0,48645 + 0,12552 = 0,61.$$

**Aproximação da binomial pela normal.** OBS :A aproximação colocada tem justificativa rigorosa quando demonstramos o Teorema do Limite Central que aproxima soma de variáveis aleatórias independentes e identicamente distribuídas por uma distribuição normal. Observe que uma variável binomial pode ser interpretada como soma de Bernoulli que são independentes e identicamente distribuídas.

Portanto, considerando o exemplo 8 do Capítulo anterior, poderíamos aproximar  $Y \sim B(10.000; 0,001)$  pela distribuição normal  $X \sim N(10; 9,99)$  e

$$P(Y = 15) \approx P(14,5 \leq X \leq 15,5) = P\left(\frac{14,5 - 10}{3,16} \leq \frac{X - 10}{3,16} \leq \frac{15,5 - 10}{3,16}\right) =$$
$$P(1,4 \leq Z \leq 1,74) = P(Z \leq 1,74) - P(Z \leq 1,4) = 0,45907 - 0,41924 = 0,0398.$$

O resultado da aproximação pela distribuição de Poisson foi 0,0347.

## **Transformação de variáveis aleatórias.**

**Teorema** Se  $Z$  é uma variável aleatória contínua com distribuição normal com média  $\mu = 0$  e variância  $\sigma^2 = 1$ , a variável aleatória  $Y$ , resultado da transformação  $Y = Z^2$ , tem função densidade de probabilidade

$$f(y) = \frac{1}{\sqrt{\pi}} \frac{1}{\sqrt{y}} \exp\left[-\frac{y}{2}\right], \quad y > 0,$$

denominada de distribuição qui-quadrado com um grau de liberdade.

## Transformação de variáveis aleatórias.

**Prova** Evidentemente, os valores de  $Y$  são positivos e a função de distribuição de  $Y$  é dada por

$$P(Y \leq y) = P(Z^2 \leq y) = P(-\sqrt{y} \leq Z \leq \sqrt{y}) = \\ \int_{-\sqrt{y}}^{\sqrt{y}} \frac{1}{\sqrt{2\pi}} \exp\left[-\frac{x^2}{2}\right] dx = 2 \cdot \int_0^{\sqrt{y}} \frac{1}{\sqrt{2\pi}} \exp\left[-\frac{x^2}{2}\right] dx.$$

Portanto a função densidade de probabilidade de  $Y$ ,  $f(y) = \frac{dF(y)}{dy}$  é

$$f(y) = \frac{1}{\sqrt{\pi}} \frac{1}{\sqrt{y}} \exp\left[-\frac{y}{2}\right], \quad y > 0,$$

**Transformação de variáveis aleatórias. Teorema** Suponha que  $X$  é uma variável aleatória do tipo contínuo com função de densidade de probabilidade  $f_X(x)$ , com domínio

$\mathfrak{R}_X = \{x : f_X(x) > 0\}$ . Assuma que:

(a)  $y = g(x)$  define uma transformação um a um e sobrejetora de  $\mathfrak{R}_X$  em  $\mathfrak{R}_Y = \{y : g(y) > 0\}$ .

(b) A derivada de  $x = g^{-1}(y)$ , com respeito a  $y$  é contínua em  $\mathfrak{R}_Y$ .

Então  $Y = g(X)$  é uma variável aleatória do tipo contínuo com função de densidade de probabilidade

$$f_Y(y) = \left| \frac{dg^{-1}(y)}{dy} \right| \cdot f_X(g^{-1}(y)), \quad y \in \mathfrak{R}_Y.$$

## Transformação de variáveis aleatórias.

Prova

A prova é fácil e está nas notas do professor.

A restrição de que  $y = g(x)$  seja bijetiva no domínio  $\mathfrak{R}_X$  é restritiva. Se podemos particionar  $\mathfrak{R}_X$  em  $\mathfrak{R}_X^1, \mathfrak{R}_X^2, \dots, \mathfrak{R}_X^m$  de maneira que em cada  $\mathfrak{R}_X^i$ ,  $g(x)$  é bijetora, podemos aplicar o Teorema em cada  $\mathfrak{R}_X^i$  e concluir que

$$f_Y(y) = \sum_{i=1}^m \left| \frac{dg^{i-1}(y)}{dy} \right| \cdot f_X(g^{i-1}(y)), \quad y \in \mathfrak{R}_Y.$$

## Distribuição log-normal

**Teorema** Se  $X$  é uma variável aleatória contínua com distribuição normal com média  $\mu$  e variância  $\sigma^2$ , a variável aleatória  $Y$ , resultado da transformação  $Y = \exp[X]$ , tem função densidade de probabilidade

$$f(y) = \frac{1}{y \cdot \sigma \cdot \sqrt{2\pi}} \exp\left[-\frac{(\ln y - \mu)^2}{2\sigma^2}\right], \quad y > 0.$$

denominada de distribuição log-normal.

## Distribuição log-normal

**Prova** É evidente que os valores  $y$  que  $Y$  assume são positivos. A função de distribuição de  $Y$  é

$$F(y) = P(Y \leq y) = P(\exp[X] \leq y) = P(X \leq \ln y) =$$

$$\int_{-\infty}^{\ln y} \frac{1}{\sigma\sqrt{2\pi}} \exp\left[-\frac{(x - \mu)^2}{2\sigma^2}\right] dx.$$

Portanto, a função densidade de probabilidade de  $Y$  é

$$f(y) = \frac{dF(y)}{dy} = \frac{1}{y \cdot \sigma \cdot \sqrt{2\pi}} \exp\left[-\frac{(\ln y - \mu)^2}{2\sigma^2}\right].$$



## Distribuição log-normal

Recordemos que a função geradora de momentos da variável aleatória  $X \sim N(\mu, \sigma^2)$  é

$$M_X(t) = E[\exp[t.X]] = \exp\left[t.\mu + \frac{\sigma^2 t^2}{2}\right].$$

Portanto

$$E[Y] = E[\exp[X]] = M_X(1) = \exp\left[\mu + \frac{\sigma^2}{2}\right],$$

$$E[Y^2] = E[\exp[2.X]] = \exp[2.\mu + 2.\sigma^2]$$

e

$$\sigma_Y^2 = \exp[2.\mu + 2.\sigma^2] - \exp[2.\mu + \sigma^2].$$

## Distribuição log-normal

**Exemplo** A taxa de crescimento de uma população é uma variável aleatória  $Y$  com distribuição normal com média 0,03 e variância 0,0001. O crescimento da população, com tamanho inicial de 100.000 indivíduos no período de um ano é modelado por  $Y = 100.000 \exp[X]$ . Reconhecemos que a variável  $\frac{Y}{100.000}$  tem distribuição lognormal com os mesmos parâmetros de  $X$  e portanto, no período de um ano esperamos uma população de

$$E[Y] = 100.000 \cdot E[\exp[X]] = 100.000 \exp\left[0,03 + \frac{0,0001}{2}\right] = 103.051.$$