

1. Vetores Aleatórios

Seja $(\Omega, \mathfrak{S}, P)$ um espaço de probabilidades. Nosso objetivo é definir uma função $\mathbf{X} = (X_1, X_2, \dots, X_n)$ do espaço amostral Ω no conjunto dos números reais \mathfrak{R}^n , de dimensão n . Na realidade construímos um outro espaço de probabilidades $(\mathfrak{R}^n, \mathfrak{S}_{\mathbf{X}}, P_{\mathbf{X}})$, onde $\mathfrak{S}_{\mathbf{X}}$ é a σ -álgebra de Borel, β^n , em \mathfrak{R}^n (no caso discreto, β^n poderia ser substituída pelo conjunto das partes da imagem da aplicação $\mathbf{X}, \mathbf{X}(\Omega)$).

Se assumimos que a imagem inversa de qualquer conjunto A em $\mathfrak{S}_{\mathbf{X}}$ pertence a \mathfrak{S} , isto é, $\mathbf{X}^{-1}(A) \in \mathfrak{S}, \forall A \in \mathfrak{S}_{\mathbf{X}}$, podemos definir

$$P_{\mathbf{X}}(A) = P(\mathbf{X}^{-1}(A)), \quad \forall A \in \mathfrak{S}_{\mathbf{X}}.$$

Observe que:

$P_{\mathbf{X}}(\mathfrak{R}^n) = P(\mathbf{X}^{-1}(\mathfrak{R}^n)) = P(\Omega) = 1$, e que se $(A_k)_{k \geq 1}$ é uma seqüência de eventos em $\mathfrak{S}_{\mathbf{X}}$, dois a dois disjuntos

$$\begin{aligned} P_{\mathbf{X}}(\cup_{k=1}^{\infty} A_k) &= P(\mathbf{X}^{-1}(\cup_{k=1}^{\infty} A_k)) = P(\cup_{k=1}^{\infty} \mathbf{X}^{-1}(A_k)) = \\ &= \sum_{k=1}^{\infty} P(\mathbf{X}^{-1}(A_k)) = \sum_{k=1}^{\infty} P_{\mathbf{X}}(A_k). \end{aligned}$$

Portanto os axiomas de Kolmogorov estão satisfeitos e o espaço de probabilidades $(\mathfrak{R}^n, \mathfrak{S}_{\mathbf{X}}, P_{\mathbf{X}})$ esta bem definido e procedemos na formalização do conceito:

Definição 1.1. Seja $(\Omega, \mathfrak{S}, P)$ um espaço de probabilidade e \mathbf{X} uma aplicação de Ω em \mathfrak{R}^k . \mathbf{X} é uma variável aleatória se $\mathbf{X}^{-1}(A) \in \mathfrak{S}, \forall A \in \mathfrak{S}_{\mathbf{X}}$.

Denominamos $(\mathfrak{R}^k, \mathfrak{S}_{\mathbf{X}}, P_{\mathbf{X}})$ como o espaço de probabilidade induzido por \mathbf{X} .

Observação 1.2. Observe que um conjunto básico de β^n é um retângulo da forma $A = A_1 \times A_2 \times \dots \times A_n$, onde $A_j \subseteq \beta$ e que se $w \in \Omega$

$$\mathbf{X}(w) = (X_1(w), X_2(w), \dots, X_n(w)) \in A \Leftrightarrow$$

$$X_1(w) \in A_1, X_2(w) \in A_2, \dots, X_n(w) \in A_n \Leftrightarrow$$

$$w \in X_1^{-1}(A_1), w \in X_2^{-1}(A_2), \dots, w \in X_n^{-1}(A_n) \Leftrightarrow w \in \cap_{j=1}^n X_j^{-1}(A_j).$$

Portanto se $X_j, 1 \leq j \leq n$ são variáveis aleatórias unidimensionais, $X_j^{-1}(A_j) \in \mathfrak{S}$ e \mathbf{X} é um vetor aleatório.

Vetores aleatórios discretos

No caso discreto, a configuração de um conjunto A de $\mathfrak{S}_{\mathbf{X}}$ é $A = \{\mathbf{x}_{i_1}, \dots, \mathbf{x}_{i_n}\}$, onde $\mathbf{x}_{i_j} = \mathbf{X}(w_{i_j})$ para algum $w_{i_j} \in \Omega$. Portanto A

pode ser escrito como a união disjunta dos conjuntos unitários $\{\mathbf{x}_{i_j}\}$, $A = \cup_{j=1}^n \{\mathbf{x}_{i_j}\}$ e

$$\mathbf{X}^{-1}(A) = \mathbf{X}^{-1}(\cup_{j=1}^n \{\mathbf{x}_{i_j}\}) = \cup_{j=1}^n \mathbf{X}^{-1}(\{\mathbf{x}_{i_j}\})$$

com

$$\begin{aligned} P_{\mathbf{X}}(A) &= P(\mathbf{X} \in A) = P(\mathbf{X}^{-1}(A)) = P(\cup_{j=1}^k \mathbf{X}^{-1}(\{\mathbf{x}_{i_j}\})) = \\ &= \sum_{j=1}^k P(\mathbf{X}^{-1}(\{\mathbf{x}_{i_j}\})) = \sum_{j=1}^k P_X(\{\mathbf{x}_{i_j}\}). \end{aligned}$$

Consequentemente o espaço de probabilidade induzido por \mathbf{X} fica completamente caracterizado pelos valores \mathbf{x}_i que \mathbf{X} assume e suas probabilidades $P(\mathbf{X} = \mathbf{x}_i) = P(X_1 = x_{i_1}, X_2 = x_{i_2}, \dots, X_n = x_{i_n})$ com $0 \leq P(\mathbf{X} = \mathbf{x}_i) \leq 1$ e $\sum P(\mathbf{X} = \mathbf{x}_i) = 1$.

Definição 1.3. A função que associa o valor da vetor aleatório à sua probabilidade é denominada função de probabilidade conjunta (distribuição de probabilidade conjunta).

x	\mathbf{x}_1	\mathbf{x}_2	...	\mathbf{x}_n
$P(\mathbf{X} = \mathbf{x})$	$P(\mathbf{X} = \mathbf{x}_1)$	$P(\mathbf{X} = \mathbf{x}_2)$...	$P(\mathbf{X} = \mathbf{x}_n)$

Observação 1.4. Em resumo, se X é uma variável aleatória assumindo valores x_1, x_2, \dots com probabilidades

$$P_X(\{x_k\}) = P(X = x_k) = P(\omega \in \Omega : X(\omega) = x_k)$$

e Y é uma variável aleatória assumindo valores y_1, y_2, \dots com probabilidades

$$P_Y(\{y_k\}) = P(Y = y_k) = P(\omega \in \Omega : Y(\omega) = y_k),$$

então (X, Y) é um vetor aleatório assumindo valores (x_j, y_k) com probabilidades conjunta

$$P_{(X,Y)}((x_j, y_k)) = P((X, Y) = (x_j, y_k)) = P(\omega \in \Omega : X(\omega) = x_j, Y(\omega) = y_k).$$

As distribuições marginais de X e de Y são obtidas fixando o valor de interesse da variável e somando sobre os valores da outra variável:

$$P(X = x_j) = \sum_{y_k} P((X, Y) = (x_j, y_k));$$

$$P(Y = y_k) = \sum_{x_j} P((X, Y) = (x_j, y_k)).$$

Exemplo 1.5. A alocação de 2 bolas em 3 urnas resulta na seguinte configuração

$$\begin{array}{ccc} \{ab| \mid \} & \{a|b| \} & \{b|a| \} \\ \{ \mid ab \} & \{a| \mid b\} & \{b| \mid a\} \\ \{ \mid \mid ab \} & \{ \mid a|b \} & \{ \mid b|a \} \end{array}$$

Sejam as variáveis aleatórias definidas por :

N : O número de urnas ocupadas;

X_i : O número de bolas no i -ésimo compartimento, $1 \leq i \leq 3$.

As distribuições conjuntas de (N, X_1) e de (X_1, X_2) bem como suas marginais estão nas tabelas

Tabela 1- Distribuição conjunta de (N, X_1)

N, X_1	0	1	2	total
1	0,22	0	0,12	0,34
2	0,22	0,44	0	0,66
total	0,44	0,44	0,12	1

A distribuição conjunta de (N, X) está no corpo da tabela e as distribuições marginais estão nas marginais.

Portanto, $E[N] = 1.0,34 + 2.0,66 = 1,66$, $E[N^2] = 1.0,34 + 4.0,66 = 2,98$ e $Var(N) = 2,98 - (1,66)^2 = 0,23$.

(X_1, X_2) tem distribuição de probabilidade conjunta

Tabela 2- Distribuição conjunta de (X_1, X_2)

X_2, X_1	0	1	2	total
0	0,11	0,22	0,11	0,44
1	0,22	0,22	0	0,44
2	0,11	0	0	0,12
total	0,44	0,44	0,12	1

Observe que as distribuições marginais de X_1 e X_2 são iguais e dizemos que X_1 e X_2 são identicamente distribuídas.

Exemplo 1.6. Suponha que uma amostra de tamanho n , com reposição, seja retirada de uma população com várias subpopulações. Seja X_j o número de elementos da amostra que pertence à j -ésima subpopulação. Então (X_1, X_2, X_3) tem distribuição multinomial caracterizada completamente pela distribuição de probabilidade conjunta $P(X_1 = x_1, X_2 = x_2, X_3 = x_3) =$

$$\frac{n!}{x_1!x_2!x_3!(n-x_1-x_2-x_3)!} p_1^{x_1} p_2^{x_2} p_3^{x_3} (1-p_1-p_2-p_3)^{(n-x_1-x_2-x_3)},$$

onde x_1, x_2, x_3 são inteiros não negativos tais que $x_1 + x_2 + x_3 \leq n$, $0 < p_i < 1$, $i = 1, 2, 3$ e p_i é a probabilidade de que um elemento pertence à i -ésima subpopulação.

A distribuição de probabilidade marginal de (X_1, X_2) é

$$\begin{aligned} P(X_1 = x_1, X_2 = x_2) &= \sum_{x_3=0}^{n-x_1-x_2} P(X_1 = x_1, X_2 = x_2, X_3 = x_3) = \\ &= \sum_{x_3=0}^{n-x_1-x_2} \frac{n!}{x_1!x_2!x_3!(n-x_1-x_2-x_3)!} p_1^{x_1} p_2^{x_2} p_3^{x_3} (1-p_1-p_2-p_3)^{(n-x_1-x_2-x_3)} = \\ &= \frac{n! p_1^{x_1} p_2^{x_2}}{x_1! x_2! (n-x_1-x_2)!} \sum_{x_3=0}^{(n-x_1-x_2)} \frac{(n-x_1-x_2)!}{x_3! (n-x_1-x_2-x_3)!} p_3^{x_3} (1-p_1-p_2-p_3)^{(n-x_1-x_2-x_3)} = \\ &= \frac{n!}{x_1! x_2! (n-x_1-x_2)!} p_1^{x_1} p_2^{x_2} (1-p_1-p_2)^{n-x_1-x_2}. \end{aligned}$$

A distribuição de probabilidade marginal de X_1 é a distribuição binomial.

$$P(X_1 = x_1) = \binom{n}{x_1} p_1^{x_1} (1-p_1)^{n-x_1}.$$

Variáveis aleatórias discretas condicionais

No Capítulo 1 definimos o espaço de probabilidade condicional $(\Omega_B, \mathfrak{S}_B, P(\cdot|B))$ onde

$$\forall A \in \mathfrak{S}_B, P(A|B) = \frac{P(A \cap B)}{P(B)}, \quad P(B) > 0$$

satisfazendo o teorema de Kolmogorov.

No momento utilizamos tal definição para estudarmos as distribuições de probabilidades das variáveis aleatórias condicionais. Se (X, Y) é um vetor aleatório que assume valores (x_j, y_k) com probabilidade conjunta

$$P_{(X,Y)}((x_j, y_k)) = P((X, Y) = (x_j, y_k)) = P(w \in \Omega : X(w) = x_j, Y(w) = y_k),$$

definimos, para cada valor y_k fixado com $P(Y = y_k) > 0$, da variável aleatória Y , a variável aleatória condicional $(X|Y = y_k)$ que assume os valores de X com probabilidades

$$P_{\{Y=y_k\}}(X = x_j) = P(X = x_j|Y = y_k) = \frac{P(X = x_j, Y = y_k)}{P(Y = y_k)}$$

obtida considerando os eventos $A = \{X = x_j\}$ e $B = \{Y = y_k\}$, no espaço de probabilidade condicional (se $P(Y = y_k) = 0$, definimos $P_{\{Y=y_k\}}(X = x_j) = 0$.)

A variável aleatória condicional $(X|Y = y_k)$ fica completamente caracterizada pelos valores x_i que assume e suas probabilidades $P(X =$

$x_j|Y = y_k)$ com $0 \leq P(X = x_j|Y = y_k) \leq 1$ e $\sum P(X = x_j|Y = y_k) = 1$. Sua função de probabilidade é

$(X Y = y_k)$	x_1	...	x_n
$P(X = x Y = y_k)$	$P(X = x_1 Y = y_k)$...	$P(X = x_n Y = y_k)$

Exemplo 1.7. Recordando o exemplo 1.4, observamos que a variável aleatória condicional $(N|X_1 = 0)$ assume os valores 1 e 2 com probabilidades:

$$P(N = 1|X_1 = 0) = \frac{P(N = 1, X_1 = 0)}{P(X_1 = 0)} = \frac{0,22}{0,44} = 0,5$$

$$P(N = 2|X_1 = 0) = \frac{P(N = 2, X_1 = 0)}{P(X_1 = 0)} = \frac{0,22}{0,44} = 0,5.$$

Portanto $E[N|X_1 = 0] = 1,0,5 + 2,0,5 = 1,5$,

$$E[N^2|X_1 = 0] = 1,0,5 + 4,0,5 = 2,5 \text{ e}$$

$Var((N|X_1 = 0)) = 2,5 - (1,5)^2 = 0,25$. Por outro lado, a variável

aleatória condicional $(N|X_1 = 1)$ assume os valores 1 e 2 com probabilidades:

$$P(N = 1|X_1 = 1) = \frac{P(N = 1, X_1 = 1)}{P(X_1 = 1)} = \frac{0}{0,44} = 0$$

$$P(N = 2|X_1 = 1) = \frac{P(N = 2, X_1 = 1)}{P(X_1 = 1)} = \frac{0,44}{0,44} = 1.$$

Portanto $(N|X_1 = 1)$ tem distribuição degenerada no valor 2 e $E[N|X_1 = 1] = 2$ e $Var((N|X_1 = 1)) = 0$.

A variável aleatória condicional $(N|X_1 = 2)$ tem distribuição degenerada no valor 1 e $E[N|X_1 = 2] = 1$, com $Var((N|X_1 = 2)) = 0$.

Observamos, pelo exemplo anterior, que as distribuições das variáveis aleatórias condicionais $(X|Y = y_k)$ depende do valor fixado y_k da variável aleatória Y e que $E(X|Y = y)$ é uma função $\varphi(Y)$ de Y ($E(X|Y = y) = \varphi(y)$). Como a função de uma variável aleatória é uma variável aleatória, podemos calcular sua esperança e variância.

Teorema 1.8. *Se (X, Y) é uma variável aleatória bidimensional, então*

$$E\{E[(X|Y)]\} = E[X];$$

$$Var(X) = E\{Var((X|Y))\} + Var(E[(X|Y)]).$$

Prova

Como $E(X|Y) = \varphi(Y)$ é uma função de Y , $\varphi(y_k) = E(X|Y = y_k) = \sum_{x_j} x_j P(X = x_j | Y = y_k)$. A esperança de $\varphi(Y)$ é

$$E[\varphi(Y) = \sum_{y_k} \varphi(y_k) P(Y = y_k) = \sum_{y_k} \sum_{x_j} x_j P(X = x_j | Y = y_k) P(Y = y_k) = \sum_{y_k} \sum_{x_j} P(X = x_j, Y = y_k) = \sum_{x_j} x_j P(X = x_j) = E[X].$$

$$\begin{aligned} E\{Var((X|Y))\} &= E\{E[(X^2|Y)]\} - E\{E[(X|Y)]^2\} = \\ &= E[X^2] - E[X^2] - E\{E[(X|Y)]^2\} + E[X]^2 = \\ Var(X) - E\{E[(X|Y)]^2\} + \{E[E(X|Y)]\}^2 &= Var(X) - Var(E(X|Y)). \end{aligned}$$

Exemplo 1.9. Continuando o exemplo 1.6, $E\{E[(N|X_1)]\} =$

$$\begin{aligned} &E[(N|X_1 = 0)]P(X_1 = 0) + E[(N|X_1 = 1)]P(X_1 = 1) + \\ &E[(N|X_1 = 2)]P(X_1 = 2) = 1, 5 \cdot 0, 44 + 2 \cdot 0, 44 + 1 \cdot 0, 12 = 1, 66 = EN. \end{aligned}$$

Com respeito à variância, $Var(N) = E\{Var((N|X_1))\} + Var(E[(N|X_1)])$. Contudo

$$\begin{aligned} Var(E[(N|X_1)]) &= E\{E[(N|X_1)]^2\} - E\{E[(N|X_1)]\}^2 = \\ &= E\{E[(N|X_1)]^2\} - (1, 66)^2 = E\{E[(N|X_1)]^2\} - 2, 75 \\ e E\{E[(N|X_1)]^2\} &= \end{aligned}$$

$$\begin{aligned} &E[(N|X_1 = 0)]^2 P(X_1 = 0) + E[(N|X_1 = 1)]^2 P(X_1 = 1) + \\ &E[(N|X_1 = 2)]^2 P(X_1 = 2) = (1, 5)^2 \cdot 0, 44 + 2^2 \cdot 0, 44 + 1^2 \cdot 0, 12 = 2, 87. \end{aligned}$$

Portanto $Var(E[(N|X_1)]) = 2, 87 - 2, 75 = 0, 12$.

Por outro lado $E\{Var((N|X_1))\} =$

$$\begin{aligned} &Var((N|X_1 = 0))P(X_1 = 0) + Var((N|X_1 = 1))P(X_1 = 1) + \\ &Var((N|X_1 = 2))P(X_1 = 2) = 0, 25 \cdot 0, 44 + 0 \cdot 0, 44 + 0 \cdot 0, 12 = 0, 11. \end{aligned}$$

Concluimos que $E\{Var((N|X_1))\} + Var(E[(N|X_1)]) = 0, 11 + 0, 12 = 0, 23 = Var(N)$.

Exemplo 1.10. Suponha que uma amostra de tamanho 2, seja retirada de uma urna com 3 bolas pretas, 4 bola brancas e 2 bolas vermelhas, com reposição. Seja X_j a cor da bola retirada no j -ésimo ensaio, assumindo valores 1, 2 e 3 correspondentes à bola retirada ser preta, branca ou vermelha, respectivamente.. Então os (X_j) são identicamente distribuídos desde que a urna é reconstituída com a reposição da bola retirada.

(X_1, X_2) tem distribuição de probabilidade conjunta

X_2, X_1	1	2	3	total
1	$\frac{9}{81}$	$\frac{12}{81}$	$\frac{6}{81}$	$\frac{27}{81}$
2	$\frac{12}{81}$	$\frac{16}{81}$	$\frac{8}{81}$	$\frac{36}{81}$
3	$\frac{6}{81}$	$\frac{8}{81}$	$\frac{4}{81}$	$\frac{18}{81}$
total	$\frac{27}{81}$	$\frac{36}{81}$	$\frac{18}{81}$	1

Observe que

$$P(X_1 = 1, X_2 = 1) = \frac{9}{81} = \frac{27}{81} \cdot \frac{27}{81} = P(X_1 = 1) \cdot P(X_2 = 1),$$

$$P(X_1 = 1, X_2 = 3) = \frac{6}{81} = \frac{27}{81} \cdot \frac{36}{81} = P(X_1 = 1) \cdot P(X_2 = 2),$$

e

$$P(X_1 = x_1, X_2 = x_2) = P(X_1 = x_1) \cdot P(X_2 = x_2), \quad \forall x_1, x_2 \in \{1, 2, 3\}.$$

Concluimos que

$$P(X_1 = x_1 | X_2 = x_2) = \frac{P(X_1 = x_1, X_2 = x_2)}{P(X_2 = x_2)} = \frac{P(X_1 = x_1)P(X_2 = x_2)}{P(X_2 = x_2)} = P(X_1 = x_1)$$

e que, equivalentemente,

$$P(X_1 = x_1, X_2 = x_2) = P(X_1 = x_1) \cdot P(X_2 = x_2), \quad \forall x_1, x_2 \in \{1, 2, 3\}.$$

Definição 1.11. As variáveis aleatórias X_1, X_2, \dots, X_n , definidas em $(\Omega, \mathfrak{F}, P)$ so estocásticamente independentes se, e somente a distribuição conjunta de qualquer subconjunto $\{X_{i_1}, \dots, X_{i_k}\}$ de $\{X_1, X_2, \dots, X_n\}$ é o produto de suas marginais, isto é

$$P(\mathbf{X} = \mathbf{x}_i) = P(X_{i_1} = x_{i_1}, X_{i_2} = x_{i_2}, \dots, X_{i_k} = x_{i_k}) = P(X_{i_1} = x_{i_1}) \cdot P(X_{i_2} = x_{i_2}) \dots P(X_{i_k} = x_{i_k}), \quad k = 2, 3, \dots, n.$$

Um conjunto básico de \mathfrak{R}^n é um retângulo da forma $A = A_1 \times A_2 \times \dots \times A_n$, onde $A_j \subseteq \beta$. Então pode-se provar que as variáveis aleatórias X_1, X_2, \dots, X_n são estocásticamente independentes se, e somente se,

$$P(X_1 \in A_1, X_2 \in A_2, \dots, X_n \in A_n) = P(X_1 \in A_1)P(X_2 \in A_2) \dots P(X_n \in A_n),$$

para quaisquer $A = A_1 \times A_2 \times \dots \times A_n$ em β^n . No caso particular, discreto, em que $n = 2$, temos

$$\begin{aligned} P(X_1 \in A_1, X_2 \in A_2) &= \sum_{x_1 \in A_1} \sum_{x_2 \in A_2} P(X_1 = x_1, X_2 = x_2) = \\ &= \sum_{x_1 \in A_1} \sum_{x_2 \in A_2} P(X_1 = x_1)P(X_2 = x_2) = \\ &= \sum_{x_1 \in A_1} P(X_1 = x_1) \sum_{x_2 \in A_2} P(X_2 = x_2) = P(X_1 \in A_1)P(X_2 \in A_2). \end{aligned}$$

Operações com variáveis aleatórias

Operações com variáveis aleatórias resultam em variáveis aleatórias. Portanto, se X e Y são variáveis aleatórias, as operações \sqrt{X} , $\ln Y$, $X + Y$, $X \cdot Y$ são variáveis aleatórias e como tais, cada uma tem sua função de distribuição, sua média, sua variância e outras medidas.

A função de probabilidade induzida pela variável aleatória $g(X, Y)$ é caracterizada por:

$$P_{g(X,Y)}(k) = P(g(X, Y) = k) = \sum_{\{(x_i, y_j): g(x_i, y_j) = k\}} P(X = x_i, Y = y_j).$$

Exemplo 1.12. Sejam X e Y variáveis aleatórias independentes com distribuições geométricas de parâmetros p_1 e p_2 respectivamente. Então $P(X = x) = p_1(1 - p_1)^{x-1}$, $x = 1, 2, \dots$ e $P(Y = y) = p_2(1 - p_2)^{y-1}$, $y = 1, 2, \dots$ e

A) a distribuição de $Z = \max\{X, Y\}$ é:

$$\begin{aligned} P(Z \leq z) &= P(\max\{X, Y\} \leq z) = P(X \leq z, Y \leq z) = \\ &= P(X \leq z)P(Y \leq z) = [1 - (1 - p_1)^z][1 - (1 - p_2)^z]; \end{aligned}$$

B) a probabilidade $P(\max\{X, Y\} = X)$ é

$$\begin{aligned} P(Y \leq X) &= \sum_{y=1}^{\infty} P(Y \leq X | Y = y)P(Y = y) = \\ &= \sum_{y=1}^{\infty} P(y - 1 < X | Y = y)P(Y = y) = \sum_{y=1}^{\infty} P(X > y - 1)P(Y = y) = \\ &= \sum_{x=1}^{\infty} (1 - p_1)^{y-1} p_2 (1 - p_2)^{y-1} = \\ &= p_2 \sum_{y=1}^{\infty} [(1 - p_1)(1 - p_2)]^{y-1} = \frac{p_2}{p_1 + p_2 - p_1 \cdot p_2}. \end{aligned}$$

Observe que, na primeira igualdade utilizamos a regra da probabilidade total.

C) a probabilidade $P(S = X + Y = k)$ é

$$P(S = k) = \sum_{x=1}^{k-1} P(X = x, Y = k - x) = \sum_{x=1}^{k-1} P(X = x)P(Y = k - x) =$$

$$p_1 p_2 \sum_{x=1}^{k-1} (1-p_1)^{x-1} (1-p_2)^{k-x-1} = p_1 p_2 (1-p_2)^{k-2} \sum_{x=1}^{k-1} \left[\frac{(1-p_1)}{(1-p_2)} \right]^{x-1} = \frac{p_1 p_2 [(1-p_2)^{k-1} - (1-p_1)^{k-1}]}{p_1 - p_2}.$$

Em geral se X e Y são variáveis aleatórias independentes, assumindo valores em $\{x_1, x_2, \dots, x_k, \dots\}$ e $\{y_1, y_2, \dots, y_k, \dots\}$ respectivamente, a soma $S = X + Y$ é uma variável aleatória assumindo valores $x_i + y_j, i = 1, 2, \dots, k, \dots, j = 1, 2, \dots, k, \dots$, com probabilidades

$$P(X+Y = k) = \sum_{x_i} P(X = x_i, Y = k-x_i) = \sum_{x_i} P(X = x_i)P(Y = k-x_i).$$

A função de probabilidade induzida pela variável aleatória $g(X, Y)$, com sua respectiva função de probabilidade permite definir:

Definição 1.13. Sejam X e Y variáveis aleatórias discretas que assumem valores x_1, \dots, x_n e y_1, \dots, y_m , respectivamente, com probabilidade conjunta $P(X = x_i, Y = y_j)$. Se $g(x, y)$ é uma função a valores reais, limitada, então

$$E[g(X, Y)] = \sum_{i=1}^n \sum_{j=1}^m g(x_i, y_j) P(X = x_i, Y = y_j).$$

Utilizando a definição acima podemos provar o teorema:

Teorema 1.14. Sejam X e Y variáveis aleatórias discretas que assumem valores x_1, \dots, x_n, \dots e y_1, \dots, y_m, \dots respectivamente, com probabilidade conjunta $P(X = x_i, Y = y_j)$. Se $E[X]$ e $E[Y]$ existem, então $E[X + Y]$ existe e

$$E[X + Y] = E[X] + E[Y].$$

Prova

Considerando, no Teorema 7.13, $g(x, y) = x + y$, obtemos

$$\begin{aligned} E[|X + Y|] &= \sum_{x_i} \sum_{y_j} |x_i + y_j| P(X = x_i, Y = y_j) \leq \\ &= \sum_{x_i} \sum_{y_j} |x_i| P(X = x_i, Y = y_j) + \sum_{x_i} \sum_{y_j} |y_j| P(X = x_i, Y = y_j) = \\ &= \sum_{x_i} |x_i| \sum_{y_j} P(X = x_i, Y = y_j) + \sum_{y_j} |y_j| \sum_{x_i} P(X = x_i, Y = y_j) = \end{aligned}$$

$$\sum_{x_i} |x_i| P(X = x_i) + \sum_{y_j}^m |y_j| P(Y = y_j) = E[|X|] + E[|Y|].$$

Portanto $E[|X + Y|] \leq E[|X|] + E[|Y|] < \infty$ e $E[X + Y]$ existe.

Contudo

$$\begin{aligned} E[X + Y] &= \sum_{x_i} \sum_{y_j} (x_i + y_j) P(X = x_i, Y = y_j) = \\ &= \sum_{x_i} \sum_{y_j} x_i P(X = x_i, Y = y_j) + \sum_{x_i} \sum_{y_j} y_j P(X = x_i, Y = y_j) = \\ &= \sum_{x_i} x_i \sum_{y_j} P(X = x_i, Y = y_j) + \sum_{y_j} y_j \sum_{x_i} P(X = x_i, Y = y_j) = \\ &= \sum_{x_i} x_i P(X = x_i) + \sum_{y_j} y_j P(Y = y_j) = E[X] + E[Y]. \end{aligned}$$

Exemplo 1.15. No exemplo 1.5, onde alocamos duas bolas em três urnas, consideramos as variáveis aleatórias

N : O número de urnas ocupadas;

X_1 : O número de bolas no primeiro compartimento, .

As distribuições conjuntas de (N, X_1) bem como suas marginais são

N, X_1	0	1	2	total
1	0,22	0	0,12	0,34
2	0,22	0,44	0	0,66
total	0,44	0,44	0,12	1

Portanto, $E[N] = 1.0, 34 + 2.0, 66 = 1,66$, $E[N^2] = 1.0, 34 + 4.0, 66 = 2,98$ e $Var(N) = 2,98 - (1,66)^2 = 0,23$.

$E[X_1] = 0,44 + 2.0,12 = 0,68$, $E[X_1^2] = 0,44 + 4.0,12 = 0,92$ e $Var(X_1) = 0,92 - (0,68)^2 = 0,46$.

A função de probabilidade de $S = N + X_1$ é

s	1	2	3	4
$P(S = s)$	0,22	0,22	0,56	0

Portanto

$$E[N + X_1] = 0,22 + 2.0,22 + 3.0,56 = 2,34 = 1,66 + 0,68 = E[N] + E[X_1].$$

$$E[(N + X_1)^2] = 0,22 + 4.0,22 + 9.0,56 = 6,14$$

$$\begin{aligned} Var(N + X_1) &= E[(N + X_1)^2] - (E[N + X_1])^2 = 6,14 - (2,34)^2 = \\ &= 0,67 \neq 0,23 + 0,46 = Var(N) + Var(X_1). \end{aligned}$$

Exemplo 1.16. No exemplo 1.10 em que observamos a variável aleatória X_j , a cor da bola retirada no j -ésimo ensaio, a distribuição conjunta de (X_1, X_2) é

X_2, X_1	1	2	3	total
1	$\frac{9}{81}$	$\frac{12}{81}$	$\frac{6}{81}$	$\frac{27}{81}$
2	$\frac{12}{81}$	$\frac{16}{81}$	$\frac{8}{81}$	$\frac{36}{81}$
3	$\frac{6}{81}$	$\frac{8}{81}$	$\frac{4}{81}$	$\frac{18}{81}$
total	$\frac{27}{81}$	$\frac{36}{81}$	$\frac{18}{81}$	1

indicando que X_1 e X_2 são variáveis aleatórias independentes e identicamente distribuídas com

$$E[X_1] = E[X_2] = \frac{27}{81} + \frac{72}{81} = \frac{54}{81} = \frac{153}{81}$$

$$E[X_1^2] = E[X_2^2] = \frac{27}{81} = \frac{144}{81} + \frac{162}{81} = \frac{333}{81} \text{ e}$$

$$Var(X_1) = Var(X_2) = \frac{333}{81} - \left(\frac{153}{81}\right)^2 = \frac{44}{81}.$$

A função de probabilidade de $S = X_1 + X_2$ é

s	2	3	4	5	6
$P(S = s)$	$\frac{9}{81}$	$\frac{24}{81}$	$\frac{28}{81}$	$\frac{16}{81}$	$\frac{4}{81}$

Portanto

$$E[X_1 + X_2] = \frac{9}{81} + \frac{72}{81} + \frac{112}{81} + \frac{80}{81} + \frac{24}{81} =$$

$$\frac{306}{81} = \frac{153}{81} + \frac{153}{81} + E[X_1] + E[X_2].$$

$$E[(X_1 + X_2)^2] = \frac{36}{81} + \frac{216}{81} + \frac{448}{81} + \frac{400}{81} + \frac{144}{81} = \frac{1244}{81} \text{ e}$$

$$Var(X_1 + X_2) = \frac{1244}{81} - \left(\frac{306}{81}\right)^2 = \frac{88}{81} = \frac{44}{81} + \frac{44}{81} = Var(X_1) + Var(X_2).$$

Teorema 1.17. *Sejam X e Y variáveis aleatórias discretas independentes que assumem valores x_1, \dots, x_n, \dots e y_1, \dots, y_m, \dots respectivamente, com probabilidade conjunta $P(X = x_i, Y = y_j)$. Se $E[X]$ e $E[Y]$ existem, então $E[X.Y]$ existe e*

$$E[X.Y] = E[X].E[Y].$$

Prova

Considerando a função $g(x, y) = x.y$, obtemos

$$E[|X.Y|] = \sum_{x_i} \sum_{y_j} |x_i.y_j| P(X = x_i, Y = y_j) =$$

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

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

$$\sum_{x_i} |x_i| P(X = x_i) \cdot \sum_{y_j} |y_j| P(Y = y_j) = E[|X|] \cdot E[|Y|].$$

Portanto $E[|X \cdot Y|] = E[|X|] \cdot E[|Y|] < \infty$ e $E[X \cdot Y]$ existe.

Contudo

$$E[X \cdot Y] = \sum_{x_i} \sum_{y_j} (x_i \cdot y_j) P(X = x_i, Y = y_j) =$$

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

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

$$\sum_{x_i} x_i P(X = x_i) \cdot \sum_{y_j} y_j P(Y = y_j) = E[X] \cdot E[Y].$$

Exemplo 1.18. No exemplo 1.10 as variáveis X_1 e X_2 são independentes com $E[X_1] = E[X_2] = \frac{153}{81}$

A função de probabilidade de $Z = X_1 \cdot X_2$ é

z	1	2	3	4	6	9
$P(Z = z)$	$\frac{9}{81}$	$\frac{24}{81}$	$\frac{12}{81}$	$\frac{16}{81}$	$\frac{16}{81}$	$\frac{4}{81}$

Portanto

$$E[X_1 \cdot X_2] = \frac{9}{81} + \frac{48}{81} + \frac{36}{81} + \frac{64}{81} + \frac{96}{81} + \frac{36}{81} = \frac{289}{81} = \frac{153}{81} \cdot \frac{153}{81} = E[X_1] \cdot E[X_2].$$

Observamos que o teorema prova que a independência de X e Y é condição necessária para que $E[X \cdot Y] = E[X] \cdot E[Y]$. A condição não é suficiente:

Exemplo 1.19. Se (X, Y) tem distribuição de probabilidade conjunta

X, Y	-1	0	1	total
-1	0	$\frac{1}{4}$	0	$\frac{1}{4}$
0	$\frac{1}{4}$	0	$\frac{1}{4}$	$\frac{1}{2}$
1	0	$\frac{1}{4}$	0	$\frac{1}{4}$
total	$\frac{1}{4}$	$\frac{1}{2}$	$\frac{1}{4}$	1

temos $E[X \cdot Y] = 0 = 0 \cdot 0 = E[X] \cdot E[Y]$ mas $P(X = 0, Y = 0) \neq \frac{1}{2} \cdot \frac{1}{2} = P(X = 0) \cdot P(Y = 0)$.

As propriedades nos teoremas 1.14 e 1.17 se estendem para um número finito de variáveis aleatórias. Se (X_1, X_2, \dots, X_n) é um vetor de variáveis aleatórias, então

$$E[X_1 + X_2 + \dots + X_n] = E[X_1] + E[X_2] + \dots + E[X_n].$$

Se, em adição as variáveis aleatórias são independentes

$$E[X_1 \cdot X_2 \cdot \dots \cdot X_n] = E[X_1] \cdot E[X_2] \cdot \dots \cdot E[X_n].$$

Em relação à distribuição de soma de variáveis aleatórias independentes, a função geradora de probabilidades torna-se uma ferramenta importante:

Em particular, se X e Y assumem valores nos números naturais, com funções geradoras de probabilidades $\varphi_X(s)$ e $\varphi_Y(s)$ respectivamente, temos

$$\varphi_{X+Y}(s) = E[s^{X+Y}] = E[s^X]E[s^Y] = \varphi_X(s)\varphi_Y(s)$$

Exemplo 1.20. Se consideramos n variáveis aleatórias, X_1, X_2, \dots, X_n independentes e identicamente distribuídas com distribuição de Bernoulli de parâmetro p temos $\varphi_{X_i}(s) = sp + (1 - p)$ e

$$\varphi_{\sum_{i=1}^n X_i}(s) = \pi_{i=1}^n \varphi_{X_i}(s) = [sp + (1 - p)]^n$$

Desde que a função geradora de probabilidade caracteriza completamente sua distribuição concluímos que $\sum_{i=1}^n X_i$ tem distribuição binomial de parâmetros n e p . Por outro lado, como $E[X_i] = p$, $E[\sum_{i=1}^n X_i] = \sum_{i=1}^n E[X_i] = np$.

Exemplo 1.21. Se consideramos n variáveis aleatórias, X_1, X_2, \dots, X_n independentes, onde X_i tem distribuição de Poisson com parâmetro λ_i , $i = 1, \dots, n$, temos

$$\varphi_{\sum_{i=1}^n X_i}(s) = \pi_{i=1}^n \varphi_{X_i}(s) = \pi_{i=1}^n e^{-\lambda_i(1-s)} = e^{-\sum_{i=1}^n \lambda_i(1-s)},$$

e concluímos que $\sum_{i=1}^n X_i$ tem distribuição de Poisson de parâmetro $\sum_{i=1}^n \lambda_i$. Assim $E[\sum_{i=1}^n X_i] = \sum_{i=1}^n E[X_i] = \sum_{i=1}^n \lambda_i$.

Exemplo 1.22. Seja $(X_n)_{n \geq 1}$ uma sequência de variáveis aleatórias de Bernoulli, independentes e identicamente distribuídas com parâmetro p e seja N uma variável aleatória com distribuição de Poisson de parâmetro λ , independente dos X_i 's. A função de probabilidade de $S_N = \sum_{i=1}^N X_i$ é

$$P(\sum_{i=1}^N X_i = k) = \sum_{n=k}^{\infty} P(\sum_{i=1}^n X_i = k, N = n) =$$

$$\begin{aligned}
& \sum_{n=k}^{\infty} P(\Sigma_{i=1}^N X_i = k | N = n) P(N = n) = \\
& \sum_{n=k}^{\infty} P(\Sigma_{i=1}^n X_i = k | N = n) \frac{e^{-\lambda} \lambda^n}{n!} = \\
& \sum_{n=k}^{\infty} P(\Sigma_{i=1}^n X_i = k) \frac{e^{-\lambda} \lambda^n}{n!} = \\
& \sum_{n=k}^{\infty} \binom{n}{k} p^k (1-p)^{n-k} \frac{e^{-\lambda} \lambda^n}{n!} = \\
& \frac{(\lambda p)^k e^{-\lambda}}{k!} \sum_{n=k}^{\infty} \frac{[(1-p)\lambda]^{n-k}}{(n-k)!} = \\
& \frac{(\lambda p)^k e^{-\lambda}}{k!} \sum_{m=0}^{\infty} \frac{[(1-p)\lambda]^m}{m!} = \\
& \frac{(\lambda p)^k e^{-\lambda}}{k!} e^{[(1-p)\lambda]} = \frac{(\lambda p)^k e^{-\lambda p}}{k!}
\end{aligned}$$

e concluímos que, neste caso particular, a soma aleatória das variáveis aleatórias tem distribuição de Poisson de parâmetro λp .

No caso geral temos:

Teorema 1.23. *Sejam X_1, X_2, \dots, X_n variáveis aleatórias independentes e identicamente distribuídas, com valores nos números naturais e N uma variável aleatória inteira, não negativa, independente dos X_i 's. $S_N = \Sigma_{i=1}^N X_i$ $S_0 = 0$ é a soma aleatória de variáveis aleatórias que também assume valores nos naturais. Então*

$$\varphi_{S_N}(s) = \varphi_N(\varphi_{X_1}(s)).$$

Prova

Observe que condicionado a $\{N = n\}$ temos

$$\begin{aligned}
E[s^{\Sigma_{i=1}^N X_i} | N = n] &= E[s^{\Sigma_{i=1}^n X_i} | N = n] = E[s^{\Sigma_{i=1}^n X_i}] = E[\pi_{i=1}^n s^{X_i}] = \\
& \pi_{i=1}^n E[s^{X_i}] = \pi_{i=1}^n \varphi_{X_i}(s) = \pi_{i=1}^n \varphi_{X_1}(s) = (\varphi_{X_1}(s))^n.
\end{aligned}$$

Portanto

$$\begin{aligned}
\varphi_{S_N}(s) &= E\{E[\varphi_{S_N}(s) | N]\} = E\{E[s^{\Sigma_{i=1}^N X_i} | N]\} = \\
& E\{(\varphi_{X_1}(s))^N\} = \varphi_N(\varphi_{X_1}(s)).
\end{aligned}$$

Exemplo 1.24. Seja $(X_n)_{n \geq 1}$ uma sequência de variáveis aleatórias de Bernoulli, independentes e identicamente distribuídas com parâmetro p , e função geradora de probabilidade é $\varphi_{X_1}(s) = ps + (1 - p)$. Seja N uma variável aleatória com distribuição de Poisson de parâmetro λ , com função geradora de probabilidade $\varphi_N(s) = e^{-\lambda(1-s)}$. Então

$$\varphi_{S_N}(s) = e^{-\lambda p(1-s)},$$

e concluímos que $S_N = \sum_{i=1}^N X_i$ tem distribuição de Poisson com parâmetro λp .

Em relação à distribuição de soma de variáveis aleatórias independentes, mas que não assumem valores inteiros positivos, a função geradora de momentos, que também caracteriza completamente a distribuição de probabilidade, é mais indicada:

Teorema 1.25. *Se X e Y são variáveis aleatórias independentes com funções geradoras de Momentos $M_X(t)$ e $M_Y(t)$ respectivamente, then*

$$M_{X+Y}(t) = M_X(t).M_Y(t).$$

Prova

$$\begin{aligned} M_{X+Y}(t) &= E[\exp[t(X + Y)]] = E[\exp[tX]. \exp[tY]] = \\ &E[\exp[tX]].E[\exp[tY]] = M_X(t).M_Y(t). \end{aligned}$$

Observação 1.26. Utilizando o teorema acima podemos afirmar que a distribuição da soma de n variáveis aleatórias, digamos X_1, X_2, \dots, X_n , independentes e identicamente distribuídas com distribuição geométrica de parâmetro p , $0 < p < 1$ é a distribuição binomial negativa de parâmetros n e p :

Observe que

$$\begin{aligned} M_{X_1}(t) &= E[e^{tX_1}] = \sum_{k=0}^{\infty} e^{tk} p(1-p)^k = \\ &p \sum_{k=0}^{\infty} [(e^t(1-p))^k] = \frac{p}{1 - (1-p)e^t}. \\ M_{X_1+\dots+X_n}(t) &= M_{X_1}(t) \dots M_{X_n}(t) = \\ &[\frac{p}{1 - (1-p)e^t}] \dots [\frac{p}{1 - (1-p)e^t}] = [\frac{p}{1 - (1-p)e^t}]^n. \end{aligned}$$

que é a função geradora de momentos da distribuição binomial negativa.

Um tipo de dependência entre duas variáveis X e Y muito importante nas aplicações é a associação linear entre X e Y . Esta medida de relação linear entre as variáveis é denominada covariância e denotada por $Cov(X, Y)$.

Definição 1.27. Sejam X e Y variáveis aleatórias. A covariância entre X e Y é definida pela esperança do produto dos desvios de X e Y em relação às suas respectivas médias, isto é

$$Cov(X, Y) = E[(X - E[X]).(Y - E[Y])].$$

Observação 1.28. De maneira mais fácil podemos escrever

$$\begin{aligned} Cov(X, Y) &= E[(X - E[X]).(Y - E[Y])] = \\ &E[XY - X.E[Y] - Y.E[X] + E[X].E[Y]] = E[XY] - E[X].E[Y]. \end{aligned}$$

Quando X e Y são variáveis aleatórias discretas que assumem valores x_1, \dots, x_n e y_1, \dots, y_n respectivamente, podemos escrever

$$Cov(X, Y) = \sum_{x_i} \sum_{x_j} (x_i - E[X]).(y_j - E[Y])P(X = x_i, Y = y_j).$$

Claramente, usando o Teorema 1.17, se X e Y são variáveis aleatórias independentes $Cov(X, Y) = 0$. Observamos também que, como no exemplo 1.19, a $Cov(X, Y)$ pode ser igual a zero quando X e Y são variáveis aleatórias dependentes.

Para o vetor aleatório (N, X_1) com distribuição conjunta

N, X_1	0	1	2	total
1	0,22	0	0,12	0,34
2	0,22	0,44	0	0,66
total	0,44	0,44	0,12	1

temos $E[N] = 1,66$ e $Var(N) = 2,98 - (1,66)^2 = 0,23$.

$E[X_1] = 0,68$ e $Var(X_1) = 0,92 - (0,68)^2 = 0,46$.

A função de probabilidade de $Z = N.X_1$ é

z	0	1	2	4
$P(Z = z)$	0,44	0	0	0,56

e $E[N.X_1] = 2,0,56 = 1,12$. Portanto

$$Cov(N, X_1) = E[N.X_1] - E[N].E[X_1] = 1,12 - 0,68.1,66 = -0,02.$$

No Teorema 1.14 demonstramos que o valor esperado da soma de variáveis aleatórias é a soma dos valores esperados. O que podemos dizer sobre a variância da soma segue do teorema

Teorema 1.29. *Sejam X e Y variáveis aleatórias, então*

$$Var(X + Y) = Var(X) + Var(Y) + 2.Cov(X, Y).$$

Se, em adição, X e Y forem independentes temos $Var(X + Y) = Var(X) + Var(Y)$.

Prova

A prova é imediata:

$$\begin{aligned} Var(X+Y) &= E\{[(X+Y)-E(X+Y)]^2\} = E\{[(X-E[X])+(Y-E[Y])]^2\} = \\ &= E[(X - E[X])^2 + E[(Y - E[Y])^2 + 2.E[(X - E[X]).(Y - E[Y])] = \\ &= Var(X) + Var(Y) + 2.Cov(X, Y). \end{aligned}$$

Se X e Y são independentes, $Cov(X, Y) = 0$ e temos

$$Var(X + Y) = Var(X) + Var(Y).$$

Exemplo 1.30. Para o vetor aleatório (N, X_1) do exemplo anterior temos que

$$Var(N) = 2,98 - (1,66)^2 = 0,23, Var(X_1) = 0,92 - (0,68)^2 = 0,46$$

e $Cov(N, X_1) = -0,0088$.

portanto

$$Var(N+X_1) = Var(N)+Var(X_1)+2.Cov(N, X_1) = 0,23+0,46-0,02 = 0,67$$

Observação 1.31. A extensão do resultado do Teorema 1.28 para uma soma de variáveis aleatórias, $\sum_{i=1}^n X_i$ é:

$$Var(\sum_{i=1}^n X_i) = \sum_{i=1}^n Var(X_i) + 2\sum_i \sum_{j:i < j} cov(X_i, X_j).$$

Exemplo 1.32. A distribuição Binomial com parâmetros n e p , $0 < p < 1$ é o número de sucessos quando realizamos n ensaios de Bernoulli com probabilidade de sucesso p , independentes e identicamente distribuídos. A função de probabilidade da variável aleatória, X , de Bernoulli é

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

Assim a média de X é $E[X] = p$ e sua variância $Var(X) = p(1 - p)$.

Podemos interpretar a variável aleatória Binomial, Y , como a soma $Y = \sum_{i=1}^n X_i$ de variáveis aleatórias, X_i , $1 \leq i \leq n$, de Bernoulli, independentes e identicamente distribuídas a X .

Portanto

$$E[Y] = E\left[\sum_{i=1}^n X_i\right] = \sum_{i=1}^n E[X_i] = \sum_{i=1}^n p = np$$

e

$$Var(Y) = Var\left(\sum_{i=1}^n X_i\right) = \sum_{i=1}^n Var(X_i) = \sum_{i=1}^n p(1 - p) = np(1 - p).$$

Exemplo 1.33. Suponha que temos uma urna com N bolas idênticas das quais K tem a cor branca e $N - K$ preta. Retiramos da urna uma amostra sem reposição de n bolas. Seja S_n o número de bolas brancas na amostra. Observe que S_n assume os valores $0, 1, 2, \dots, \min\{n, K\}$ com probabilidades

$$P(S_n = k) = \frac{\binom{K}{k} \binom{N-K}{n-k}}{\binom{N}{n}}$$

e tem distribuição hipergeométrica.

Entretanto, podemos interpretar S_n como $S_n = \sum_{i=1}^n X_i$ onde os X_i 's são variáveis aleatórias de Bernoulli:

$X_i = 1$ se a i -ésimo ensaio resultar em bola branca;

$X_i = 0$ se a i -ésimo ensaio resultar em bola preta.

Observe que $P(X_i = 1) = \frac{K}{N}$, $k = 1, 2, \dots, \min\{n, K\}$ e portanto são identicamente distribuídas e

$$E[S_n] = E\left[\sum_{i=1}^n X_i\right] = \sum_{i=1}^n E[X_i] = \sum_{i=1}^n \frac{K}{N} = n \frac{K}{N}.$$

Contudo, como cada ensaio modifica a quantidade de bolas na urna, as variáveis aleatórias X_i 's não são independentes.

Note que $E[X_i] = P(X_i = 1) = \frac{K}{N}$ e que $X_i^2 = X_i$, produzindo $E[X_i^2] = \frac{K}{N}$ e

$$Var(X_i) = \frac{K}{N} - \left(\frac{K}{N}\right)^2 = \frac{K}{N} \left(1 - \frac{K}{N}\right).$$

Por outro lado,

$$E[X_i \cdot X_j] = P(X_i = 1, X_j = 1) = P(X_i = 1 | X_j = 1)P(X_j = 1) = \frac{K}{N} \left(\frac{K-1}{N-1} \right)$$

e

$$Cov(X_i, X_j) = \frac{K(K-1)}{N(N-1)} - \left(\frac{K}{N} \right)^2 = \frac{K}{N} \left(\frac{K-1}{N-1} - \frac{K}{N} \right) = \frac{K}{N} \left(\frac{K-N}{N(N-1)} \right)$$

Portanto

$$\begin{aligned} Var(\Sigma_{i=1}^n X_i) &= \Sigma_{i=1}^n Var(X_i) + 2\Sigma_i \Sigma_{j:i < j} cov(X_i, X_j) = \\ &= n \frac{K}{N} \left(1 - \frac{K}{N} \right) + 2 \binom{n}{2} \frac{K}{N} \left(\frac{K-N}{N(N-1)} \right) = \\ &= n \frac{K}{N} \left(1 - \frac{K}{N} \right) \left(1 - \frac{n-1}{N-1} \right). \end{aligned}$$

Uma medida da relação linear entre duas variáveis aleatórias X e Y que não depende da unidade de medida é o coeficiente de correlação linear, denotado por $\rho = \rho(X, Y)$, que é a covariância padronizada pelos desvios padrões de X e de Y :

Definição 1.34. O coeficiente de correlação linear entre as variáveis aleatórias X e Y é definido por

$$\rho = \rho(X, Y) = \frac{Cov(X, Y)}{DP(X) \cdot DP(Y)}.$$

Exemplo 1.35. O coeficiente de correlação linear entre as variáveis aleatórias N e X_1 do exemplo é

$$\rho = \frac{Cov(N, X_1)}{DP(N) \cdot DP(X_1)} = \frac{-0,0088}{\sqrt{0,23.0,46}} = -0,03.$$

Proposição 1.36. Se existem números reais a e b tais que $Y = aX + b$, isto é, Y é uma função linear de X , então $|\rho| = 1$.

Prova:

Se $Y = aX + b$ temos $E[Y] = a.E[X] + b$, $Var(Y) = a^2.Var(X)$ e $E[XY] = E[X.(aX + b)] = a.E[X^2] + b.E[X] = a.Var(X) + a.E[X]^2 + b.E[X]$.

Portanto

$$Cov(X, Y) = a.Var(X) + a.E[X]^2 + b.E[X] = a.Var(X)$$

e

$$\rho(X, Y) = \frac{a \cdot \text{Var}(X)}{\sqrt{a^2 \text{Var}(X)^2}} = \frac{a}{|a|}.$$

Teorema 1.37. *Se X e Y são variáveis aleatórias com variâncias finitas, então $|\rho| \leq 1$. Em adição, se vale a igualdade, existem números reais a e b tais que, com probabilidade 1, $Y = a.X + b$. Prova:*

Consideramos a função f de \Re em \Re definida por

$$f(t) = E\{[(Y - E[Y]) + t.(X - E[X])]^2\}$$

que é maior ou igual a zero. Desenvolvendo o quadrado perfeito temos

$$f(t) = \text{Var}(X).t^2 + 2.t.\text{Cov}(X, Y) + \text{Var}(Y) \geq 0.$$

A função $f(t)$ é uma equação quadrática que é positiva se, e somente se, o seu discriminante $\Delta = 4.\text{Cov}(X, Y)^2 - 4.\text{Var}(X).\text{Var}(Y)$ é menor ou igual a zero. Portanto

$$\frac{\text{Cov}(X, Y)^2}{\text{Var}(X).\text{Var}(Y)} \leq 1 \Leftrightarrow \rho^2 \leq 1 \Leftrightarrow |\rho| \leq 1.$$

$|\rho| = 1$ se, e somente se, $E\{[(Y - E[Y]) + t.(X - E[X])]\} = 0$, o que implica, com probabilidade 1, $(Y - E[Y]) + t.(X - E[X]) = 0$, isto é, $Y = -t.X + t.E[X] + E[Y]$. Definindo $a = -t$ e $b = t.E[X] + E[Y]$ temos $Y = a.X + b$.

E-mail address: bueno@ime.usp.br

DEPARTAMENTO DE ESTATÍSTICA, INSTITUTO DE MATEMÁTICA E ESTATÍSTICA,
UNIVERSIDADE DE SÃO PAULO, CAIXA POSTAL 66281, CEP 05311-970, SÃO
PAULO, BRAZIL