



Inferência Estatística

Aula 4

Agosto de 2008

Mônica Barros



Conteúdo - Revisão de Probabilidade

- ❑ Esperança Matemática e Momentos
- ❑ A Função Geradora de Momentos
- ❑ A soma de duas variáveis aleatórias independentes
- ❑ A fórmula da convolução
- ❑ Combinações Lineares de Variáveis Aleatórias independentes
- ❑ A soma de variáveis aleatórias independentes
- ❑ A média amostral e suas propriedades
- ❑ Combinações Lineares de v.a. dependentes
- ❑ Portfolios (Carteiras)
- ❑ Retorno Aritmético e Geométrico
- ❑ Risco e Retorno

Esperança matemática



❑ Definição (k-ésimo momento)

- ❑ O k-ésimo momento de X, ou k-ésimo momento da distribuição de X, denotado por $E(X^k)$ é definido por:

$$E(X^k) = \begin{cases} \int_{-\infty}^{\infty} x^k \cdot f(x) dx & \text{se } X \text{ é v.a. contínua} \\ \sum_{\text{todo } x} x^k \cdot f(x) = \sum_{\text{todo } x} x^k \cdot \Pr(X = x) & \text{se } X \text{ é v.a. discreta} \end{cases}$$

- ❑ Acima **k é um inteiro maior ou igual a zero**. Em particular, se $k = 0$, $E(X^0) = E(1) = 1$.

Esperança matemática



❑ Definição (média ou valor esperado)

- ❑ A **média** (ou **valor esperado** ou primeiro momento) de uma variável aleatória é definida como:

$$\mu = E(X) = \begin{cases} \int_{-\infty}^{\infty} x \cdot f(x) dx & \text{se } X \text{ é v.a. contínua} \\ \sum_{\text{todo } x} x \cdot f(x) = \sum_{\text{todo } x} x \cdot \Pr(X = x) & \text{se } X \text{ é v.a. discreta} \end{cases}$$

- ❑ A média de uma variável aleatória é uma medida de tendência central da distribuição de probabilidade desta variável aleatória.

Esperança matemática



- Podemos combinar a definição do k -ésimo momento e a definição da média para produzir o **k -ésimo momento central**, como a seguir:

$$E((X - \mu)^k) = \begin{cases} \int_{-\infty}^{\infty} (x - \mu)^k \cdot f(x) dx & \text{se } X \text{ é v.a. contínua} \\ \sum_{\text{todo } x} (x - \mu)^k \cdot f(x) = \sum_{\text{todo } x} (x - \mu)^k \cdot \Pr(X = x) & \text{se } X \text{ é v.a. discreta} \end{cases}$$

- Em particular, se $k = 1$: $E(X - \mu) = 0$, ou seja, o **primeiro momento central é sempre nulo**.

Esperança matemática



- Se $k = 1$ então:

$$\begin{aligned} E(X - \mu) &= \int_{-\infty}^{\infty} (x - \mu) f(x) dx = \int_{-\infty}^{\infty} x f(x) dx - \int_{-\infty}^{\infty} \mu f(x) dx = \\ &= \int_{-\infty}^{\infty} x f(x) dx - \mu \int_{-\infty}^{\infty} f(x) dx = \int_{-\infty}^{\infty} x f(x) dx - \mu(1) = \\ &= \mu - \mu = 0 \end{aligned}$$

- (Idem para o caso discreto)

Esperança matemática



- Definição (Variância)**

- A **variância** de uma variável aleatória mede a dispersão da distribuição de probabilidade, e é definida como o **2o. momento central**:

$$\sigma^2 = \text{VAR}(X) = E((X - \mu)^2) = \begin{cases} \int_{-\infty}^{\infty} (x - \mu)^2 \cdot f(x) dx & \text{se } X \text{ contínua} \\ \sum_{\text{todo } x} (x - \mu)^2 \cdot f(x) = \sum_{\text{todo } x} (x - \mu)^2 \cdot \Pr(X = x) & \text{se } X \text{ discreta} \end{cases}$$

Função Geradora de Momentos



$$M(t) = E(e^{tx}) = \begin{cases} \int_{-\infty}^{\infty} e^{tx} f(x) dx & \text{se } X \text{ é v.a. contínua} \\ \sum_{\text{todo } x} e^{tx} \cdot f(x) = \sum_{\text{todo } x} e^{tx} \cdot \Pr(X = x) & \text{se } X \text{ é v.a. discreta} \end{cases}$$

- A função geradora de momentos é um dos objetos mais úteis em Probabilidade, mas esta função **nem sempre existe**. Por isso, em cursos mais avançados usa-se a função característica, que sempre existe. O uso da função característica é mais complicado que o da função geradora de momentos, pois envolve números complexos.

- Freqüentemente iremos abreviar “função geradora de momentos” por fgm.

Propriedades da Função Geradora de Momentos



1) A função geradora de momentos é **única** e determina completamente a distribuição da variável aleatória.

- Assim, se duas variáveis aleatórias têm a mesma função geradora de momentos, elas têm a *mesma* distribuição.

Propriedades da Função Geradora de Momentos



- Logo, se você tiver uma tabela de funções geradoras de momentos, você poderá **identificar** qual a densidade que corresponde a uma dada função geradora de momentos.
- Isso é análogo ao uso de uma **tabela de transformadas** de Laplace ou Fourier (dada a função, sabe-se qual a sua transformada, e vice-versa).

Propriedades da Função Geradora de Momentos



2) $M(0) = 1$

3) Se $M(t)$ existe para $t \in (-h, h)$ então as derivadas de todas as ordens existem em $t = 0$. Além disso, as derivadas de $M(t)$ em $t = 0$ fornecem os momentos de X .

$$M^{(k)}(0) = \left. \frac{d^k M(t)}{dt^k} \right|_{t=0} = E(X^k)$$

A existência do k -ésimo momento da distribuição implica na existência dos momentos de ordem menor que k . Em particular, a **existência da variância implica na existência da média** (mas a recíproca não é verdadeira).

Função Geradora de Momentos - exemplo



- Considere um jogo no qual você pode ganhar 0, 1 ou 2 reais, ou perder 2 ou 1 reais com as probabilidades especificadas na tabela a seguir.

x	Pr(X = x)
-2	0.20
-1	0.10
0	0.40
1	0.10
2	0.20

Calcule a função geradora de momentos de X e, a partir dela, encontre a média da distribuição (que representa o seu ganho esperado nesse jogo).

Verifique que a média encontrada por este procedimento é a mesma que a média encontrada pela definição.

Função Geradora de Momentos - exemplo



- Pela definição de média:

$$E(X) = \sum_{x=-2}^2 x \cdot \Pr(X=x) = \frac{-4}{10} + \left(\frac{-1}{10}\right) + 0 + \frac{1}{10} + \frac{4}{10} = 0$$

- Ou seja, o ganho esperado neste jogo é zero.
- A função geradora de momentos é:

$$M(t) = E(e^{tX}) = \sum_{x=-2}^2 e^{tx} \cdot \Pr(X=x) = \left(\frac{2}{10}\right)e^{-2t} + \left(\frac{1}{10}\right)e^{-t} + \left(\frac{4}{10}\right) + \left(\frac{1}{10}\right)e^t + \left(\frac{2}{10}\right)e^{2t}$$

- A primeira derivada da função geradora de momentos é:

$$\frac{dM(t)}{dt} = \left(\frac{-4}{10}\right)e^{-2t} + \left(\frac{-1}{10}\right)e^{-t} + \left(\frac{1}{10}\right)e^t + \left(\frac{4}{10}\right)e^{2t}$$

monica@mbarros.com

13

Função Geradora de Momentos - exemplo



- A média de X é a primeira derivada da função geradora de momentos em zero, isto é:

$$\left. \frac{dM(t)}{dt} \right|_{t=0} = \left(\frac{-4}{10}\right) + \left(\frac{-1}{10}\right) + \left(\frac{1}{10}\right) + \left(\frac{4}{10}\right) = 0$$

- O que concorda com o resultado encontrado antes (pela definição da média).

monica@mbarros.com

14

Função Geradora de Momentos - exemplo



- Nota: **Teorema Binomial**
- Na demonstração do próximo exemplo empregaremos um resultado conhecido como Teorema Binomial, que é apenas uma maneira de expandir um polinômio.

$$(a+b)^n = \sum_{k=0}^n \binom{n}{k} a^k b^{n-k} \quad \text{onde } a \text{ e } b \text{ são número reais e } k, n \text{ são inteiros } \geq 0$$

monica@mbarros.com

15

Função Geradora de Momentos - exemplo



- Seja X uma variável aleatória discreta com distribuição **Binomial** e parâmetros n e p, dada por:

$$\Pr(X=x) = f(x) = \binom{n}{x} p^x q^{n-x} \quad \text{onde } q=1-p \text{ e } x=0,1,2,\dots,n$$

- Calcule a função geradora de momentos e, a partir dela, encontre a média e a variância de X.
- Solução
- Pela definição da fgm:

$$M(t) = E(e^{tX}) = \sum_{x=0}^n \binom{n}{x} p^x q^{n-x} (pe^t)^x = \sum_{x=0}^n \binom{n}{x} (pe^t)^x q^{n-x} = (pe^t + q)^n = (pe^t + 1 - p)^n$$

- Onde, na penúltima igualdade acima, aplicamos diretamente o teorema Binomial.

monica@mbarros.com

16

Função Geradora de Momentos - exemplo



- A primeira derivada da fgm é:

$$M'(t) = n.(pe^t + q)^{n-1}.(pe^t)$$

- A média da distribuição é obtida avaliando-se esta derivada em $t = 0$, isto é:

$$M'(0) = E(X) = n(p + q)^{n-1}.(p) = np \rightarrow \text{Onde usamos o fato: } p + q = 1$$

- A segunda derivada de $M(t)$ é:

$$M''(t) = n.p.e^t.(q + npe^t)(q + pe^t)^{n-2}$$

Função Geradora de Momentos - exemplo



- Ao avaliarmos esta 2a. derivada em $t = 0$ encontramos o 2o. momento, $E(X^2)$:

$$M''(0) = E(X^2) = np.(q + np)(q + p)^{n-2} = np.(q + np)$$

- A variância é obtida a partir dos dois primeiros momentos:

$$\text{VAR}(X) = E(X^2) - \{E(X)\}^2 = npq + (np)^2 - (np)^2 = npq$$

Função Geradora de Momentos - exemplo



- Seja X uma variável aleatória com fgm
- $M(t) = \exp(t^2/2)$
- Podemos obter os momentos de X por diferenciação, mas neste caso há uma maneira mais inteligente de calculá-los, que nos fornece uma expressão geral para todos os momentos de X .
- A expansão de Taylor de $\exp(t^2/2)$ ao redor de zero é:

Função Geradora de Momentos - exemplo



$$\begin{aligned} e^{t^2/2} &= 1 + \frac{t^2}{2} + \frac{1}{2!} \cdot \left(\frac{t^2}{2}\right)^2 + \dots + \frac{1}{k!} \cdot \left(\frac{t^2}{2}\right)^k + \dots = \\ &= 1 + \frac{t^2}{2} + \frac{t^4}{8} + \dots + \frac{t^{2k}}{(k!)(2^k)} + \dots \end{aligned}$$

- Mas, em geral, a expansão de Taylor de uma função geradora de momentos $M(t)$ em torno de zero é:

$$E(e^{tX}) = 1 + t.E(X) + \frac{t^2.E(X^2)}{2!} + \dots + \frac{t^k.E(X^k)}{k!} + \dots$$

Função Geradora de Momentos – exemplo



- Igualando estas duas expressões termo a termo encontramos:

$$E(X^{2k}) = \frac{(2k!)}{(k!)(2^k)} \quad \text{potências pares}$$

$$E(X^{2k-1}) = 0 \quad \text{potências ímpares}$$

- onde $k = 1, 2, 3, \dots$
- Veremos que esta é a fgm de uma variável Normal com média 0 e variância 1.

Função Geradora de Momentos – exemplo (para casa)



- Seja X uma variável aleatória discreta com função de probabilidade:

$$f(x) = q \cdot p^{x-1}, \quad x=1,2,3,\dots \quad \text{e } q=1-p \quad \text{onde } 0 < p < 1$$

- Calcule a função geradora de momentos de X .
- A partir da função geradora de momentos, encontre a média e a variância de X .
- *Dica* - use a série geométrica, isto é:

$$\sum_{k=0}^{\infty} a^k = 1 + a + a^2 + a^3 + \dots = \frac{1}{1-a} \quad \text{desde que } |a| < 1$$

Função Geradora de Momentos – exemplo (para casa)



- Seja X uma variável aleatória com função de probabilidade Poisson com média λ .
- Encontre a função geradora de momentos e use-a para mostrar que:
 - $E(X) = \text{VAR}(X) = \lambda$
- *Dica*: lembre-se da série de Taylor da exponencial, isto é:

$$e^u = \sum_{k=0}^{\infty} \frac{u^k}{k!} = 1 + u + \frac{u^2}{2!} + \frac{u^3}{3!} + \frac{u^4}{4!} + \dots$$

A soma de duas variáveis aleatórias independentes



- *Este é um dos problemas mais importantes em Probabilidade. Por que?*
- Frequentemente iremos encontrar conjuntos de variáveis aleatórias que são independentes e identicamente distribuídas (isto é, variáveis que, num certo sentido, são “todas iguais” pois têm a mesma distribuição de probabilidade e uma não afeta as outras).

A soma de duas variáveis aleatórias independentes



- Este conjunto de variáveis é chamado de **variáveis iid**, ou de **amostra aleatória**.
- Suponha que a média de todos os X_i 's é desconhecida.
- Um estimador (ou “chute”) que parece bastante sensato para a média da distribuição dos X_i 's é:

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \quad \text{a média amostral}$$

- Mas, para calcularmos a média amostral precisamos saber qual a **distribuição da soma** dos X_i 's, o que é um problema ainda mais complicado do que o que estamos propondo agora!

A soma de duas variáveis aleatórias independentes



- **Teorema (Fórmula da Convolução)**
- Seja $Y = X_1 + X_2$ onde X_1 e X_2 são variáveis **independentes** com densidade conjunta $f(x_1, x_2) = f_1(x_1) \cdot f_2(x_2)$.
- Então a densidade de Y é dada por:

- **No caso contínuo**

$$g(y) = \int_{-\infty}^{\infty} f_1(x_1) \cdot f_2(y - x_1) dx_1 = \int_{-\infty}^{\infty} f_1(y - x_2) \cdot f_2(x_2) dx_2$$

- **No caso discreto**

$$g(y) = \sum_{\text{todo } x_1} f_1(x_1) \cdot f_2(y - x_1) = \sum_{\text{todo } x_2} f_1(y - x_2) \cdot f_2(x_2)$$

Exemplo



- Suponha que X e Y são independentes e identicamente distribuídas com densidade Exponencial(λ).
- Seja $Z = X + Y$. Encontre a densidade de Z .
- Solução
- A densidade de X é: $\lambda \cdot e^{-\lambda x}$, $x > 0$.
- A densidade de Y é: $\lambda \cdot e^{-\lambda y}$, $y > 0$.
- Como X e Y são independentes, a densidade conjunta é apenas o produto destas marginais.
- A densidade de $Z = X + Y$ é obtida através da fórmula da convolução.

Exemplo



$$g(z) = \int_0^{\infty} f_x(x) \cdot f_y(z - x) dx = \int_0^{\infty} \lambda \cdot e^{-\lambda x} \cdot \lambda \left(e^{-\lambda(z-x)} \right) dx$$

- Mas, o integrando acima é positivo se, e somente se, ambos os termos são positivos. Para que isto aconteça é necessário que $x > 0$ e, ao mesmo tempo, $z - x > 0$, isto é, $x < z$. Logo, os limites de integração são 0 e z na integral anterior.

$$g(z) = \int_0^z \lambda \cdot e^{-\lambda x} \cdot \lambda \cdot e^{-\lambda z} \cdot e^{+\lambda x} dx = \lambda^2 \cdot e^{-\lambda z} \int_0^z dx = \lambda^2 \cdot e^{-\lambda z} (x) \Big|_0^z = \lambda^2 \cdot z \cdot e^{-\lambda z}$$

- Ou seja, a soma de duas variáveis Exponenciais independentes **NÃO É** uma variável Exponencial.

Exemplo



- Sejam X e Y variáveis **independentes** discretas com distribuição Poisson com média k . Encontre a função de probabilidade de $Z=X+Y$.

$$f(x) = \Pr(X = x) = \frac{e^{-k} \cdot k^x}{x!} \text{ onde } x = 0, 1, 2, \dots$$

e

$$f(y) = \Pr(Y = y) = \frac{e^{-k} \cdot k^y}{y!} \text{ onde } y = 0, 1, 2, \dots$$

Exemplo



- Pela fórmula da convolução:

$$\begin{aligned} g(z) &= \sum_{x=0}^{\infty} \frac{e^{-k} \cdot k^x}{x!} \cdot \frac{e^{-k} \cdot k^{z-x}}{(z-x)!} = e^{-2k} \sum_{x=0}^z \frac{1}{x!(z-x)!} \cdot k^x \cdot k^{z-x} = \frac{e^{-2k}}{z!} \sum_{x=0}^z \frac{z!}{x!(z-x)!} \cdot k^x \cdot k^{z-x} = \\ &= \frac{e^{-2k}}{z!} \sum_{x=0}^z \binom{z}{x} k^x \cdot k^{z-x} = \frac{e^{-2k}}{z!} \cdot (k+k)^z = \frac{e^{-2k} \cdot (2k)^z}{z!} \end{aligned}$$

- Note que o somatório (que ia de $x = 0$ a ∞) passou a ser um somatório de $x = 0$ até $x = z$. Isto acontece por que precisamos garantir que ambas as funções de probabilidade no somatório sejam maiores que zero, o que só ocorre se **AMBOS** $x > 0$ e $z-x > 0$. Na penúltima igualdade à direita usamos o teorema Binomial para concluir que o somatório era igual a $(2k)^z$.

Exemplo



- O que existe de interessante neste exemplo?
- Note que, ao contrário do exemplo anterior, aqui “preservamos” a mesma “família” de funções de probabilidade.
- Em outras palavras: **a soma de duas Poisson independentes é Poisson**, mas a soma de duas Exponenciais independentes não é Exponencial!

Exemplo



- Sejam X e Y v.a. independentes com função de probabilidade Geométrica(p). Encontre a função de probabilidade de $Z = X+Y$.
- Solução
- Aqui novamente usamos a fórmula da convolução.

$$\begin{aligned} g(z) &= \sum_{x=1}^{\infty} p \cdot (1-p)^{x-1} \cdot p \cdot (1-p)^{(z-x)-1} = \\ &= \sum_{x=1}^{z-1} p^2 \cdot (1-p)^{z-2} = p^2 \cdot (1-p)^{z-2} \cdot \sum_{x=1}^{z-1} 1 = (z-1)p^2 \cdot (1-p)^{z-2} \end{aligned}$$

Exemplo



- No último passo acima o somatório não envolve x e existem $(z-1)$ termos no somatório.
- Note que os limites do somatório são 1 e $z-1$ pois precisamos satisfazer simultaneamente às condições $x > 1$ e $z - x > 1$.
- A função de probabilidade condicional de X dado Z é obtida pela razão entre a conjunta de X e Z e a marginal de Z , recém calculada. Mas, a conjunta de X e Z é a conjunta de X e $X + Y$, ou seja, é a mesma coisa que a conjunta de X e Y .

Exemplo



- Esta função de probabilidade conjunta é, pela independência de X e Y , apenas o produto das marginais. Logo a conjunta de X e Z é:

$$f(x, z) = p \cdot (1-p)^{x-1} \cdot p(1-p)^{(z-x)-1} = p^2(1-p)^{z-2}$$

- A função de probabilidade condicional de X dado $X+Y = z$ é então:

$$g(x|Z=z) = \frac{f(x, z)}{g(z)} = \frac{p^2 \cdot (1-p)^{z-2}}{(z-1) \cdot p^2 \cdot (1-p)^{z-2}} = \frac{1}{z-1}$$

onde $x = 1, 2, \dots, z-1$

- Ou seja, X dado a soma é Uniforme Discreta nos inteiros $1, 2, \dots, z-1$.

Para Casa (problemas de prova)



- 1) Considere o Exemplo da soma de Poissons
- Encontre a distribuição condicional de X dado $Z = X + Y$.
- 2) Sejam X e Y independentes e identicamente distribuídos $\text{Bin}(n, p)$. Mostre que $Z = X + Y$ é Binomial $(2n, p)$ e encontre a distribuição condicional de X dado $Z = X + Y$.

Combinações Lineares de v.a. Independentes



Objetivos

- Dados X_1, X_2, \dots, X_n **independentes** (mas não necessariamente identicamente distribuídos) tais que: $E(X_i) = \mu_i$ e $\text{VAR}(X_i) = \sigma_i^2$, encontrar a **média, variância e função geradora de momentos** de:

$$Y = a_0 + \sum_{i=1}^n a_i X_i$$

- em função dos momentos dos X_i 's. Note que, na definição de Y , os a_i 's são constantes.
- **Também, a independência dos X_i 's assegura que todas as covariâncias (e correlações) são nulas.**

Combinações Lineares de v.a. Independentes



- A média de Y é:

$$E(Y) = E\left(a_0 + \sum_{i=1}^n a_i \cdot X_i\right) = a_0 + \sum_{i=1}^n a_i \cdot E(X_i) = a_0 + \sum_{i=1}^n a_i \cdot \mu_i \quad \text{onde } \mu_i = E(X_i)$$

- A variância de Y é:

$$VAR(Y) = \sum_{i=1}^n a_i^2 \cdot VAR(X_i) = \sum_{i=1}^n a_i^2 \cdot \sigma_i^2$$

onde $VAR(X_i) = \sigma_i^2$

- **Note que a constante a_0 não afeta a variância, e os outros a_i 's aparecem ao quadrado (por que?).**

Combinações Lineares de v.a. Independentes



- A função geradora de momentos de Y é:

$$M_Y(t) = E(e^{tY}) = E(e^{t(a_0 + a_1 X_1 + \dots + a_n X_n)}) = E(e^{ta_0} e^{ta_1 X_1} \dots e^{ta_n X_n}) = e^{ta_0} E(e^{ta_1 X_1} \dots e^{ta_n X_n})$$

e como consequência da independência

$$= e^{ta_0} E(e^{ta_1 X_1}) E(e^{ta_2 X_2}) \dots E(e^{ta_n X_n}) = e^{ta_0} M_{X_1}(ta_1) M_{X_2}(ta_2) \dots M_{X_n}(ta_n)$$

Combinações Lineares de v.a. Independentes



- Um **caso particular** importante (e que veremos muitas vezes daqui em diante) é o da **soma de variáveis independentes**.
- O ponto importante aqui é: se pudermos associar a fgm de Y a alguma fgm conhecida, então automaticamente sabemos qual é a densidade (ou função de probabilidade) de Y, pela unicidade da fgm.

A soma de v.a. independentes



- Sejam X_1, X_2, \dots, X_n v.a. independentes mas não necessariamente identicamente distribuídas.

- Seja: $Y = \sum_{i=1}^n X_i$
- Então:

$$E(Y) = E\left(\sum_{i=1}^n X_i\right) = \sum_{i=1}^n E(X_i) = \sum_{i=1}^n \mu_i \quad \text{onde } \mu_i = E(X_i)$$

A soma de v.a. independentes



- A variância de Y é:

$$VAR(Y) = \sum_{i=1}^n VAR(X_i) = \sum_{i=1}^n \sigma_i^2 \text{ onde } VAR(X_i) = \sigma_i^2$$

- A fgm de Y é:

$$M_Y(t) = E(e^{tY}) = E(e^{t(X_1 + \dots + X_n)}) = E(e^{tX_1} \dots e^{tX_n}) =$$

e como consequência da independência

$$= E(e^{tX_1})E(e^{tX_2}) \dots E(e^{tX_n}) = M_{X_1}(t)M_{X_2}(t) \dots M_{X_n}(t)$$

- Ou seja, a expressão da fgm de Y é muito simples, apenas o produto das fgms das variáveis independentes que compõem a soma!

A Média Amostral



- Sejam X_1, X_2, \dots, X_n v.a. independentes e identicamente distribuídas (iid).
- Em particular, o fato dos X 's serem iid implica em $E(X_i) = \mu$, $VAR(X_i) = \sigma^2$ e $COV(X_i, X_j) = 0$ para todo par i, j .
- Considere a média amostral calculada a partir destes X_i 's, isto é:

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

A Média Amostral



- Para que serve a média amostral?
- Suponha que existe esta coleção de X_i 's, todos eles iid, ou seja, todos eles provêm da mesma densidade ou função de probabilidade.
- Suponha que a média desta densidade é μ , um número desconhecido.
- A média amostral é um estimador "sensato" para a média da distribuição (μ), quando esta última for desconhecida.

A Média Amostral



- Podemos encontrar a média, variância e fgm da média amostral como casos particulares dos resultados para combinações lineares de variáveis independentes.
- É fácil mostrar que:

$$E(\bar{X}) = \frac{1}{n} \sum_{i=1}^n E(X_i) = \frac{1}{n} \sum_{i=1}^n \mu = \frac{n\mu}{n} = \mu$$

(A mesma que a média de qualquer X_i)

A Média Amostral



- Mas, a variância da média amostral é:

$$VAR(\bar{X}) = \sum_{i=1}^n \frac{1}{n^2} VAR(X_i) = \frac{1}{n^2} \sum_{i=1}^n \sigma^2 = \frac{\sigma^2}{n}$$

(A variância de \bar{X} é menor que a de X_i , desde que usemos mais de uma observação !)

- **Moral da história: é vantajoso usar a média amostral para “chutar” a média da densidade dos X 's, pois ela implica numa redução da variância se comparada ao uso de um X_i sozinho.**

A Média Amostral



- Estes resultados justificam o uso da média amostral como um estimador “sensato” de μ .
- Note que, à medida que tomamos uma amostra cada vez maior (n cresce), a variância da média amostral decresce, ou seja, a “dispersão” do estimador decresce. Além disso, a média de \bar{X} é μ , que é a quantidade que ele pretende estimar.

A Média Amostral



- A fgm da média amostral também pode ser encontrada como um caso particular da combinação linear de v.a. independentes.
- Seja Y a soma de X_1, X_2, \dots, X_n , que são todos iid. Então:

$$M_{\bar{X}}(t) = E(e^{t\bar{X}}) = E(e^{tY/n}) = M_Y(t/n) = [M_{X_1}(t/n)]^n$$

Combinações Lineares de v.a. Dependentes



- Este é um caso mais geral (e mais complicado que o anterior).
- Suponha que $E(X_i) = \mu_i$, $VAR(X_i) = \sigma_i^2$, e $COV(X_i, X_j) = \rho_{ij} \cdot \sigma_i \cdot \sigma_j \neq 0$ para algum par i, j .
- Queremos encontrar a média, variância e fgm de Y definido como:

$$Y = a_0 + \sum_{i=1}^n a_i X_i$$

Combinações Lineares de v.a. Dependentes



- A expressão da média é a mesma que no caso anterior (variáveis independentes), isto é:

$$E(Y) = E\left(a_0 + \sum_{i=1}^n a_i \cdot X_i\right) = a_0 + \sum_{i=1}^n a_i \cdot E(X_i) =$$
$$= a_0 + \sum_{i=1}^n a_i \cdot \mu_i \quad \text{onde } \mu_i = E(X_i)$$

- A expressão para a **variância torna-se mais complicada**, pois deverá levar em conta as interdependências entre as variáveis. Pode-se mostrar que:

Combinações Lineares de v.a. Dependentes



$$VAR(Y) = \sum_{i=1}^n a_i^2 \cdot VAR(X_i) + \sum_{i=1}^n \sum_{j=1}^n a_i a_j COV(X_i, X_j)$$
$$= \sum_{i=1}^n a_i^2 \cdot \sigma_i^2 + \sum_{i=1}^n \sum_{j=1}^n a_i a_j \rho_{ij} \sigma_i \sigma_j \quad \text{onde no 2o. termo } i \neq j$$

onde ρ_{ij} é o coeficiente de correlação entre X_i e X_j

Ou seja, a dependência entre os X 's leva à presença de um **termo adicional no cálculo da variância**, devido às covariâncias entre os diversos X 's.

Combinações Lineares de v.a. Dependentes



- A expressão anterior, que nos dá a variância de uma combinação linear de variáveis dependentes, é essencial para medir o **risco** de um portfolio ou carteira, como veremos mais tarde.
- Na verdade, a dependência entre ativos financeiros (que são variáveis aleatórias) pode ser usada de maneira proveitosa para reduzir o risco de um portfolio, num processo que chamamos de **“diversificação”**.

Combinações Lineares de v.a. Dependentes



- A **função geradora de momentos de Y não pode, em geral, ser simplificada** como no caso anterior (em que os X 's eram independentes).

Portfolios (Carteiras)



- ❑ Considere uma coleção de n ativos financeiros. Um **portffolio** (ou **carteira**) é apenas uma combinação linear destes ativos na qual a soma dos pesos é 1 (ou 100%).
- ❑ Algumas vezes requer-se também que todos os pesos sejam positivos, mas isso não é estritamente necessário.

Retorno Aritmético



- ❑ Suponha que P_t seja o preço de um ativo no instante t . O retorno (aritmético) deste ativo entre os instantes $t-1$ e t é:

$$RA_t = \frac{P_t - P_{t-1}}{P_{t-1}}$$

- ❑ Em Finanças “quantitativas”, o retorno aritmético é pouco empregado, pois possui um grave inconveniente: como o preço de um ativo não pode ser menor que zero, o retorno aritmético tem um valor mínimo (quando $P_t = 0$), igual a -1 .

Retorno Geométrico



- ❑ Em Finanças, os retornos serão tratados como variáveis aleatórias, e um dos modelos mais simples supõe que os retornos são Normais (que iremos estudar no capítulo 7 do meu livro de Probabilidade). Mas, uma v.a. Normal é ilimitada. Então, o que fazer?
- ❑ Trabalhar com o retorno Geométrico, definido como:

$$R_t = \log\left(\frac{P_t}{P_{t-1}}\right) \quad \text{onde } \log \text{ denota o logaritmo na base "e"}$$

Retorno Geométrico



- ❑ O retorno geométrico é definido em toda a reta, então pode-se modelá-lo pela distribuição Normal.
- ❑ Retornos Geométricos são aditivos. Por exemplo, se queremos encontrar o retorno entre os dias 1 e 4:

$$R_{1,4} = \log\left(\frac{P_4}{P_1}\right) = \log\left(\frac{P_4}{P_3} \frac{P_3}{P_2} \frac{P_2}{P_1}\right) = \log\left(\frac{P_4}{P_3}\right) + \log\left(\frac{P_3}{P_2}\right) + \log\left(\frac{P_2}{P_1}\right)$$

- ❑ Ou seja, o retorno Geométrico entre os dias 1 e 4 é apenas a soma dos retornos geométricos diários no período.
- ❑ Se a variação do período é pequena, os retornos geométrico e aritmético são aproximadamente iguais.

Risco e Retorno de um Portfolio



- Sejam X_1, X_2, \dots, X_n os retornos de n ativos, tais que $E(X_i) = \mu_i$, $VAR(X_i) = \sigma_i^2$, e $COV(X_i, X_j) = \rho_{ij} \cdot \sigma_i \cdot \sigma_j \neq 0$.
- Seja P uma carteira, isto é:
$$P = \sum_{i=1}^n w_i X_i \quad \text{onde} \quad \sum_{i=1}^n w_i = 1$$
- Qual o retorno esperado da carteira, e qual o seu risco (medido pela sua variância ou desvio padrão)? Tudo isso pode ser encontrado a partir dos resultados mostrados nesta aula.

Risco e Retorno de um Portfolio



- O **retorno esperado** (ou retorno médio) do portfolio é:

$$E(P) = \sum_{i=1}^n w_i E(X_i) = \sum_{i=1}^n w_i \mu_i$$

- O **risco do portfolio** é dado pela sua variância (ou, preferencialmente, pelo seu desvio padrão, que está nas mesmas unidades que o retorno).

Risco e Retorno de um Portfolio



$$VAR(P) = \sum_{i=1}^n w_i^2 \cdot \sigma_i^2 + \sum_{i=1}^n \sum_{j=1}^n w_i w_j \rho_{ij} \sigma_i \sigma_j$$

onde ρ_{ij} é o coeficiente de correlação entre X_i e X_j

- Qual o efeito do segundo termo na equação acima? Imagine que conseguíssemos encontrar ativos com correlações negativas. O efeito destes termos seria a redução da variância do portfolio! Isto é o que está por trás da idéia de **diversificação**. A gente pode reduzir o risco sem, necessariamente, diminuir o retorno.

Risco e Retorno de um Portfolio



- A otimização de um portfolio é feita escolhendo-se os pesos w_i 's tal que alguma restrição é satisfeita.
- Um caso típico é: encontre os pesos tal que, para um retorno especificado, o risco é mínimo.
- Pode-se reescrever este problema como:
 - Dado $E(P) = \text{constante}$, encontre os pesos w_i ($i=1,2,\dots,n$) sujeitos à restrição $\sum_{i=1}^n w_i = 1$
 - e que minimizem $VAR(P)$.

Exemplo

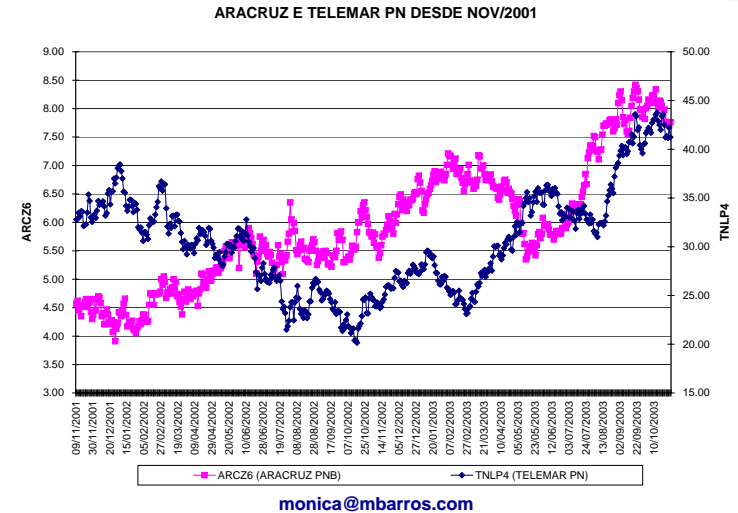


- ❑ A seguir trabalhamos com retornos diários e construímos portfólios compostos pelas seguintes ações:
 - ❑ TNL4 (Telemar PN)
 - ❑ ARCZ6 (Aracruz Celulose PN)
- ❑ Os retornos diários (geométricos) foram calculados entre 12/11/2001 e 29/10/2003.
- ❑ O gráfico a seguir apresenta a evolução dos **preços** das duas ações no período.

monica@mbarros.com

61

Exemplo

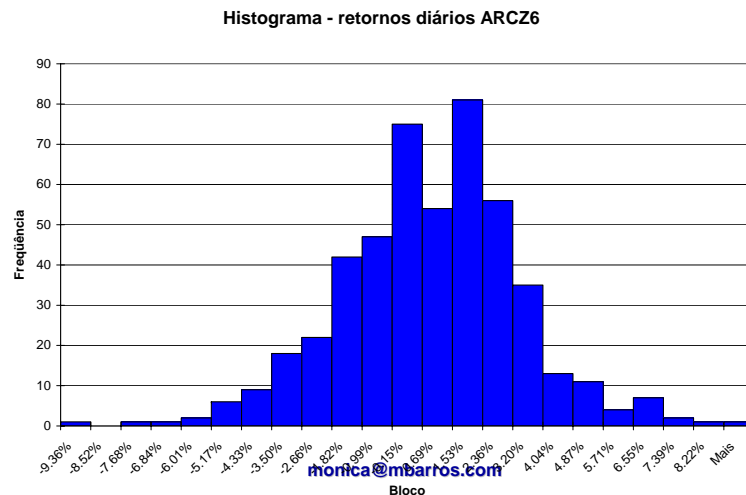


62

Exemplo



- ❑ O histograma dos retornos diários de ARCZ6 é:



63

Exemplo



- ❑ A correlação entre os retornos de TNL4 e ARCZ6 é 0.1153, e a média e o desvio padrão dos retornos de cada uma das séries é:

	Retornos	
	ARCZ6	TNL4
média	0.11%	0.05%
d.p.	2.48%	2.52%

- ❑ Seja $P = \alpha \cdot \text{ARCZ6} + (1-\alpha) \cdot \text{TNLP4}$ o portfólio formado por $\alpha\%$ de Aracruz e $(1-\alpha)\%$ de Telemar. **Como variam o retorno esperado e o risco do portfólio à medida que alteramos α ?**

monica@mbarros.com

64

Exemplo



α (% de ARCZ6 no portfólio)	retorno esperado	risco do portfólio (desvio padrão)
0.00	0.047%	2.52%
0.05	0.050%	2.41%
0.10	0.053%	2.31%
0.15	0.056%	2.22%
0.20	0.059%	2.13%
0.25	0.062%	2.06%
0.30	0.065%	1.99%
0.35	0.068%	1.94%
0.40	0.071%	1.90%
0.45	0.074%	1.88%
0.50	0.078%	1.87%
0.55	0.081%	1.87%
0.60	0.084%	1.89%
0.65	0.087%	1.92%
0.70	0.090%	1.97%
0.75	0.093%	2.03%
0.80	0.096%	2.10%
0.85	0.099%	2.18%
0.90	0.102%	2.27%
0.95	0.105%	2.37%
1.00	0.108%	2.48%

Estes são o retorno e o risco do portfólio computados ao longo de todo o período (isto é, usando todos os retornos diários disponíveis)

Na próxima página exibimos este gráfico em termos de α .

Qual o α que leva ao portfólio de menor risco? Você consegue enxergar que, no caso de um portfólio com 2 ativos, a solução para este problema pode ser obtida analiticamente, e de maneira bem simples?

Exemplo

