


Fundamentos Estatísticos para Ciência dos Dados

Exemplos e Propriedades da Normal multivariada

Renato Martins Assunção

DCC, UFMG



Normal bivariada




Figura: Densidade da normal bivariada

Normal bivariada

- Importante distribuição para um vetor aleatório $\mathbf{Y} = (Y_1, Y_2)$
- Cada uma das v.a's separadamente segue uma gaussiana com sua própria esperança μ_j e variância σ_j^2
- Isto é, $Y_1 \sim N(\mu_1, \sigma_1^2)$ e $Y_2 \sim N(\mu_2, \sigma_2^2)$
- As amostras de \mathbf{Y} formam nuvens de pontos em forma de elipses centradas em (μ_1, μ_2) .
- Além disso, elas não são (em geral) independentes: A distribuição de Y_2 MUDA SE SOUBERMOS O VALOR DE Y_1 .
- Um único parâmetro $\rho \in [-1, 1]$ controla o grau de associação ou correlação entre Y_1 e Y_2 .

Densidade e amostra





Figura: Normal bivariada com $Y_1 \sim N(\mu_1 = 0, \sigma_1^2 = 1)$ e $Y_2 \sim N(\mu_2 = 0, \sigma_2^2 = 1)$ e com correlação $\rho = 0$

Densidade e amostra





Figura: Normal bivariada com $Y_1 \sim N(\mu_1 = 0, \sigma_1^2 = 1)$ e $Y_2 \sim N(\mu_2 = 0, \sigma_2^2 = 1)$ e com correlação $\rho = 0.80$

Uma amostra de uma normal bivariada

- $n = 100$ instâncias do vetor aleatório $\mathbf{Y} = (Y_1, Y_2)$.
- Existem os valores MARGINAIS:
 - $\mathbb{E}(Y_1) = \mu_1$
 - $\sqrt{\mathbb{V}(Y_1)} = \sigma_1$
 - e também $\mathbb{E}(Y_2) = \mu_2$
 - e $\sqrt{\mathbb{V}(Y_2)} = \sigma_2$
- Estes valores são facilmente estimados a partir das MARGENS do gráfico.
- Por exemplo:
 - $\mathbb{E}(Y_1) = \mu_1 \approx 10$
 - $\sigma_1 \approx 2.5$
- Agora você: $\mathbb{E}(Y_2) = \mu_2 \approx ???$ e $\sigma_2 \approx ???$




Figura: Amostra de normal bivariada

Uma amostra de uma normal bivariada

- Temos $\mathbb{E}(Y_2) = \mu_2 \approx 50$
- E $\sigma_2 \approx 15$
- Os valores de Y_1 e Y_2 medidos num mesmo ω não são independentes.
- O valor de Y_1 dá informação sobre o valor de Y_2 .
- Como assim?
- Vamos ser mais específicos...




Figura: Amostra de normal bivariada

Distribuição de Y DADO QUE $Y_1 = 14$?

- Qual a distribuição de Y_2 DADO QUE $Y_1 = 14$?
- O que podemos dizer do valor esperado de Y_2 DADO QUE $Y_1 = 14$?
- Este valor esperado continua igual à esperança marginal $\mu_2 = 50$?




Figura: Amostra de normal bivariada

$$\mathbb{E}(Y_2|Y_1 = 14)$$

- Queremos ter uma ideia de $\mathbb{E}(Y_2|Y_1 = 14)$.
- Temos $\mu_2 = 50$ mas $\mathbb{E}(Y_2|Y_1 = 14)$ deve ser $> 50 = \mu_2$
- Qual a sua estimativa para $\mathbb{E}(Y_2|Y_1 = 14)$ no olhometro?
- Suponha que um ponto aleatório será escolhido da distribuição CONDICIONAL de Y_2 dados $Y_1 = 14$.
- \rightarrow o ponto estará na linha vertical $(14, y_2)$.




Figura: Amostra de normal bivariada

Distribuição de $(Y_2 | Y_1 = 14)$

- Os pontos (y_1, y_2) da amostra que possuem $y_1 \approx 14$ indicam o que deve ser o comportamento probabilístico da v.a. Y_2 DADO que $Y_1 = 14$.
- Vemos que $\mathbb{E}(Y_2 | Y_1 = 14) \approx 70$
- Veja que $70 \gg 50 = \mathbb{E}(Y_2) = \mu_2$.
- μ_2 é a esperança MARGINAL de Y_2 .
- A esperança condicional $\mathbb{E}(Y_2 | Y_1 = 14)$ é bem maior que a marginal $\mathbb{E}(Y_2)$.




Figura: Amostra de normal bivariada

Distribuição de $(Y_2|Y_1 = 14)$

- Se $\mathbb{E}(Y_2|Y_1 = 14) \approx 70$, quanto é $\sqrt{V(Y_2|Y_1 = 14)}$?
- Olhando os pontos (y_1, y_2) que possuem $y_1 \approx 14$, qual o tamanho médio dos desvios de Y_2 EM TORNO DE SUA ESPERANÇA $\mathbb{E}(Y_2|Y_1 = 14) \approx 70$??
- Os pontos estão no intervalo de $[50, 80]$ grosseiramente.
- Eu chutaria (ou estimaria) que $\sqrt{V(Y_2|Y_1 = 14)} \approx (80 - 30)/4 = 7.5$
- Veja que $7.5 \ll 15 = \sqrt{V(Y_2)}$, que é o DP marginal de Y_2 .




Figura: Amostra de normal bivariada

Dos momentos para a distribuição

- Estes são os dois primeiros MOMENTOS condicionais da v.a. $Y_2|Y_1 = 14$, a esperança e variância condicionais.
- Eles são RESUMOS da distribuição de probabilidade de $Y_2|Y_1 = 14$.
- E qual é a distribuição de probabilidade de $Y_2|Y_1 = 14$?
- Normal? Gama? Uniforme?
- É UMA NORMAL.
- Isto é, $(Y_2|Y_1 = 14) \approx N(70, 7.5^2)$

Dos momentos para a distribuição

- E que tal $Y_2|Y_1 = y$ com y genérico?
- Conseguimos obter uma fórmula geral para expressar qual é esta distribuição genérica.
- Ela depende do coeficiente de correlação ρ que neste exemplo vale $\rho = 0.8$.
- Temos

$$(Y_2|Y_1 = y) \sim N(\mu_{Y_2|Y_1=y}, \sigma_{Y_2|Y_1=y}^2)$$

com

$$\mu_{Y_2|Y_1=y} = \mu_2 + \frac{\rho\sigma_2}{\sigma_1}(y - \mu_1)$$

e

$$\sigma_{Y_2|Y_1=y} = \sigma_2\sqrt{1 - \rho^2}$$

- Por exemplo, com $y_2 = 14$ temos

$$\mu_{Y_2|Y_1=14} = \mu_2 + \frac{\rho\sigma_2}{\sigma_1}(14 - \mu_1) = 50 + \frac{0.8 * 15}{2.5}(14 - 10) = 69.2$$

e

$$\sigma_{Y_2|Y_1=y} = \sigma_2\sqrt{1 - \rho^2} = 15\sqrt{1 - 0.8^2} = 9$$

e portanto

$$(Y_2|Y_1 = 14) \sim N(69.2, 9^2)$$

Como sabemos essa fórmula?

- Fazendo o cálculo matemático da densidade condicional:

$$f_{Y_2|Y_1}(y_2|y_1 = a) = \frac{f_Y(a, y_2)}{f_{Y_1}(a)}$$

a partir da densidade conjunta da normal bivariada.

- Para entender esta importante expressão, vamos começar definindo a matriz 2×2 simétrica de covariância Σ dada por

$$\Sigma = \begin{bmatrix} \sigma_1^2 & \rho\sigma_x\sigma_y \\ \rho\sigma_x\sigma_y & \sigma_y^2 \end{bmatrix}$$

- onde $\rho \in [-1, 1]$ e σ_x e σ_y são os desvios padrões de cada marginal.

Como sabemos essa fórmula?

- Seja o vetor-COLUNA 2×1 das esperanças marginais:

$$\boldsymbol{\mu} = (\mu_1, \mu_2)' = (\mathbb{E}(Y_1), \mathbb{E}(Y_2))$$

- A fórmula geral de uma normal bivariada é igual a

$$f_{\mathbf{Y}}(\mathbf{y}) = \text{cte} \times \exp\left(-\frac{1}{2} d^2(\mathbf{y}, \boldsymbol{\mu})\right)$$

onde $d^2(\mathbf{y}, \boldsymbol{\mu})$ é uma medida de distância entre o ponto \mathbf{y} e o vetor esperado $\boldsymbol{\mu}$.

- Esta medida de distância é MUITO importante e não é a distância euclidiana:

$$d^2(\mathbf{y}, \boldsymbol{\mu}) = (\mathbf{y} - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{y} - \boldsymbol{\mu})$$

Vamos estudá-la a seguir.

Resumo: densidade de normal multivariada



- Em resumo, um vetor normal multivariado tem uma densidade conjunta que é proporcional à exponencial de MENOS uma medida de distância ao quadrado.

$$f_{\mathbf{Y}}(\mathbf{y}) = \text{cte} \times \exp\left(-\frac{1}{2} d^2(\mathbf{y}, \boldsymbol{\mu})\right)$$

- Densidade decai exponencialmente à medida que a distância AO QUADRADO entre \mathbf{y} e $\boldsymbol{\mu}$ aumenta.


Decaimento exponencial

- Veja o efeito de decair exponencialmente e de decair com exponencialmente AO QUADRADO.
- Decai mais depressa com a distância e o pico é mais suave



Resumos teóricos

- Considere uma única variável aleatória Y .
- Sua distribuição de probabilidade fica determinada por:
 - **Caso Contínuo:** função densidade de probabilidade $f(y)$
 - **Caso Discreto:** função de probabilidade $p(y) = \mathbb{P}(Y = y)$





Resumos teóricos

- Podemos **resumir** a sua distribuição de probabilidade com os resumos numéricos (e teóricos) esperança $\mathbb{E}(Y)$ e desvio-padrão $DP_Y = \sqrt{\mathbb{V}(Y)}$.
- Os resumos $\mathbb{E}(Y)$ e $DP_Y = \sqrt{\mathbb{V}(Y)}$ não DEPENDEM de dados estatísticos.
- São resultados de cálculos matemáticos e resumem a DISTRIBUIÇÃO teórica de uma v.a.
- Vamos agora passar a olhar DADOS ESTATÍSTICOS.
- Suponha que temos uma amostra aleatória de Y .
- Isto é, v.a.'s Y_1, Y_2, \dots, Y_n i.i.d. com a mesma distribuição que Y .
- Estes n números ficam numa das colunas de nossa tabela de dados.

Resumos empíricos, a partir dos dados

- Para ter uma idéia de TODA A distribuição de probabilidade de Y :
 - **Caso Contínuo: histograma.** A altura do histograma em y é $\approx f(y)$.
 - **Caso Discreto: gráfico de barras** com as frequências empíricas n_k/n onde n_k é o número de elementos da amostra iguais a k . Temos $n_k/n \approx \mathbb{P}(Y = k)$.



Contraparte empírica dos resumos

- Podemos ESTIMAR os resumos TEÓRICOS $\mathbb{E}(Y)$ e $\sigma = DP_Y = \sqrt{\mathbb{V}(Y)}$ a partir dos dados.
- Pela Lei dos Grandes Números, se o tamanho n da amostra é grande, temos
 - A média aritmética $\bar{Y} = (Y_1 + \dots + Y_n) \approx \mathbb{E}(Y)$
 - O DP **amostral** $S = \sqrt{\sum_i (Y_i - \bar{Y})^2 / n} \approx \sigma$
- Às vezes, define-se S usando $n - 1$ no denominador. A diferença é mínima a não ser que n seja muito pequeno.
- Note que $\bar{Y} \neq \mathbb{E}(Y)$
- E que $S \neq \sigma$
- \bar{Y} e S dependem dos dados e variam de amostra para amostra, MESMO QUE O MECANISMO GERADOR DOS DADOS NÃO MUDE.

Desvio padronizado

- Um **desvio** em relação a $\mu = \mathbb{E}(Y)$: é a v.a. $Y - \mu$
- **Desvio padronizado**: $Z = (Y - \mu)/\sigma$
- Desvio padronizado é medido relativamente ao desvio-padrão σ da v.a. Y .
- Um desvio padronizado $Z = 2$ significa um afastamento de 2 DPs em relação a μ
- Qualquer que seja a distribuição de Y , termos $Z > 4$ é muito raro (pela desigualdade de Tchebyshev).

Duas variáveis

- Como medir a associação entre duas variáveis Y_1 e Y_2 medidas num MESMO item.
- Estas variáveis poderiam ser qualquer par de colunas da nossa tabela de dados.
- Seja $Z_1 = (Y_1 - \mu_1)/\sigma_1$ o desvio padronizado de Y_1
- e $Z_2 = (Y_2 - \mu_2)/\sigma_2$ o desvio padronizado de Y_2
- Quando Z_1 é grande existe alguma TENDÊNCIA de também termos Z_2 grande?
- Se sim, diremos que Y_1 e Y_2 possuem um grau de associação ou correlação.
- Como formalizar este conceito?

Duas variáveis

- Vamos começar com a versão EMPÍRICA da associação.
- Amostra de 147 pessoas (os itens) trabalhando em ocupações fisicamente demandantes.
- Em cada item, medimos o par de variáveis (Y_1 , Y_2).
- Y_1 é a força do aperto de mão (ou *grip strength*)
- Y_2 é a força do braço (ou *arm strength*)

Duas variáveis: scatterplot




Figura: Relação entre força de preensão (do aperto de mão) e força do braço para 147 pessoas que trabalham em empregos fisicamente extenuantes.

Duas variáveis: scatterplot




Figura: Linhas verticais indicando aproximadamente μ_1 e μ_2 . A maioria dos pontos está nos quadrantes 1 e 3. Quando $Z_1 > 0$, em geral, temos $Z_2 > 0$.

Produto dos desvios

- Existem várias formas intuitivas de medir a associação entre Y_1 e Y_2 .
- Uma forma não intuitiva mas que tem excelentes propriedades teóricas é o índice de correlação de Pearson.
- Considere o produto dos desvios padronizados:

$$Z_1 Z_2 = \frac{Y_1 - \mu_1}{\sigma_1} \times \frac{Y_2 - \mu_2}{\sigma_2}$$

- Se desvios grandes e positivos de Y_1 tendem a ocorrer com desvios grandes e positivos de Y_2 , seu produto será maior ainda.
- Ao mesmo tempo, se os desvios grandes e negativos de Y_1 tendem a ocorrer com desvios grandes e positivos de Y_2 , seu produto será maior ainda.

Produto dos desvios




Figura: Tipicamente, em média, o produto dos desvios padronizados Z_1Z_2 é positivo (esquerda), próximo de zero (centro) e negativo (direita).

Natureza de Z_1Z_2

- (Y_1, Y_2) é um vetor aleatório: duas v.a.'s são medidas no mesmo item.
- Considere

$$Z_1Z_2 = \frac{Y_1 - \mu_1}{\sigma_1} \times \frac{Y_2 - \mu_2}{\sigma_2}$$

- O que é μ_1 ? Uma constante? Uma v.a.?
- O mesmo vale para μ_2 , σ_1 e σ_2 .
- E o produto Z_1Z_2 ?
- É uma constante?
- Uma v.a.?

Correlação

- O produto $Z_1 Z_2$ é uma v.a. !!
- Como resumir esta v.a. num único número?
- Já sabemos fazer isto com QUALQUER v.a.: tome o seu valor esperado.
- Isto é, vamos calcular

$$\rho = \text{Corr}(Y_1, Y_2) = \mathbb{E}(Z_1 Z_2) = \mathbb{E}\left(\frac{Y_1 - \mu_1}{\sigma_1} \times \frac{Y_2 - \mu_2}{\sigma_2}\right)$$

- Este resumo é o índice de correlação de Pearson.

Propriedades de ρ

- ρ está SEMPRE entre -1 e 1.
- Esta é uma das razões para usar ρ como medida de associação entre Y_1 e Y_2 : uma escala fixa em qualquer problema.
- Além disso, pela definição,

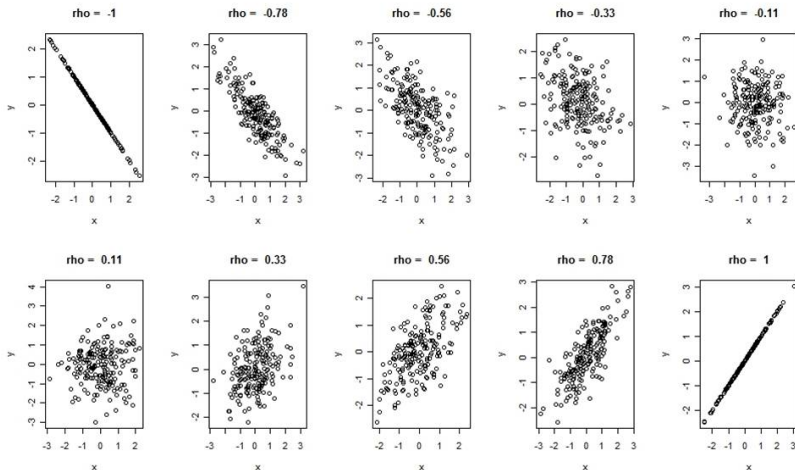
$$\text{Corr}(Y_1, Y_2) = \mathbb{E}(Z_1 Z_2) = \text{Corr}(Y_2, Y_1)$$

- Também temos que $\text{Corr}(Y, Y) = 1$: a correlação de uma v.a. consigo mesma é 1.

Propriedades de ρ

- Se Y_1 é uma v.a. independente da v.a. Y_2 então $\rho = 0$.
- Neste caso, uma amostra de valores do vetor (Y_1, Y_2) formará um gráfico de dispersão com forma indistinta, uma nuvem sem inclinação.
- Se $\rho \approx \pm 1$ então Y_2 é aproximadamente uma função linear perfeita de Y_1 .
- Isto é, uma amostra de valores do vetor (Y_1, Y_2) formará um gráfico de dispersão na forma aproximada de uma linha reta.

Amostras do vetor (Y_1, Y_2) com diferentes ρ



Correlation Matrix

- Correlação é uma medida de associação entre DUAS v.a.'s
- E quando tivermos p v.a.'s simultaneamente, todas medidas no mesmo item?
- Suponha que tenhamos um vetor (Y_1, Y_2, \dots, Y_p) de v.a.'s
- Podemos fazer uma matriz $p \times p$ de correlação.
- Na posição (i, j) teremos

$$\rho_{ij} = \text{Corr}(Y_i, Y_j) = \mathbb{E} \left(\frac{Y_i - \mu_i}{\sigma_i} \times \frac{Y_j - \mu_j}{\sigma_j} \right)$$

- Como $\text{Corr}(Y_i, Y_j) = \text{Corr}(Y_j, Y_i)$ a matriz é simétrica.
- E como $\text{Corr}(Y_i, Y_i) = 1$ a diagonal principal é toda de 1's.

Exemplo: Correlation Matrix

- Temos um vetor aleatório (Y_1, Y_2, \dots, Y_9) .
- As 9 variáveis aleatórias são escores obtidos em 9 testes de habilidade cognitiva, todos aplicados num mesmo indivíduo.
- As v.a.'s são as seguintes:
 - 3 v.a.'s medindo habilidade verbal: Word Meaning, Sentence Completion, and Odd words;
 - 3 v.a.'s medindo habilidade quantitativa: Mixed Arithmetic, Remainders, and Missing numbers;
 - 3 v.a.'s medindo habilidade espacial: Gloves, Boots, and Hatchets.
- Como poderia ser a matriz de correlação 9×9 entre estas v.a.'s?

Matriz de correlação 9×9

Variable	1	2	3	4	5	6	7	8	9
WrdMean	1								
SntComp	0.75	1							
OddWrds	0.78	0.72	1						
MxdArit	0.44	0.52	0.47	1					
Remndrs	0.45	0.53	0.48	0.82	1				
MissNum	0.51	0.58	0.54	0.82	0.74	1			
Gloves	0.21	0.23	0.28	0.33	0.37	0.35	1		
Boots	0.30	0.32	0.37	0.33	0.36	0.38	0.45	1	
Hatchts	0.31	0.30	0.37	0.31	0.36	0.38	0.52	0.67	1

WrdMean, word meaning; *SntComp*, sentence completion; *OddWrds*, odd words;
MxdArit, mixed arithmetic; *Remndrs*, remainders; *MissNum*, missing numbers,
Hatchts, hatchets.

Figura: Correlações entre pares formados a partir de 9 medidas feitas num mesmo indivíduo em um teste de personalidade

Visualizando a matriz de correlação




Figura: Amostra de 244 indivíduos e scatterplots dos pares de suas 9 medidas no teste de habilidade cognitiva

Visualizando outra matriz de correlação

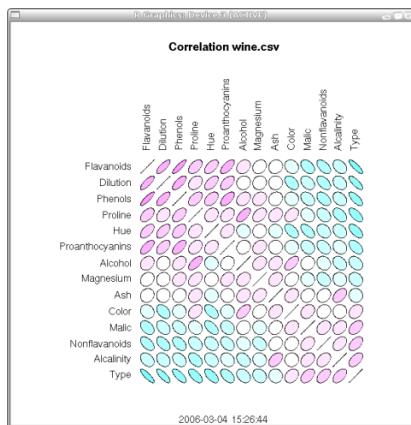


Figura: A partir de dados amostrais mostra-se o FORMATO da nuvem de pontos de uma amostra de VINHOS com 14 variáveis medidas em cada um dos vinhos. Gráfico em R + rattle

Mais uma visualização



Figura: Mais uma visualização com R + rattle

Uma visualização com MUITAS v.a.'s: rede




Figura: Uma visualização com qgraph: v.a.'s são vértices e correlações são arestas. Verde = correlação positiva e vermelha = negativa. As arestas mais grossas e saturadas tem $|\rho|$ grande.

Nem sempre, os gráficos são simples

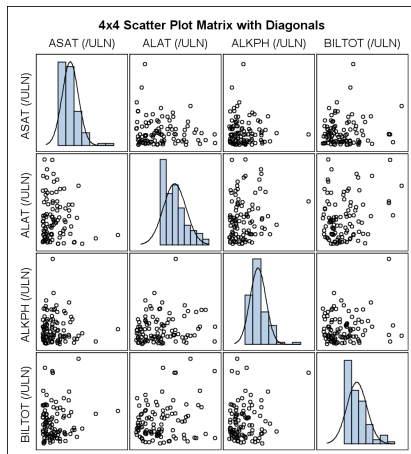


Figura: Scatterplot matrix of 4 lab variables to test liver functioning commonly used in clinical research

Misturas de diferentes populações

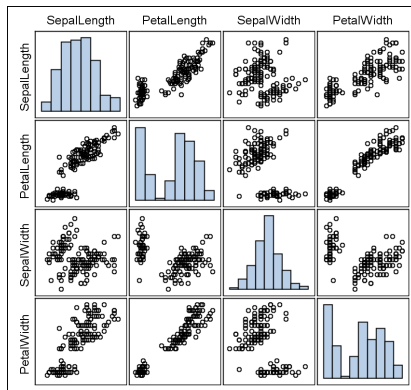


Figura: Scatterplot matrix de 4 variáveis medidas numa flor: comprimento de pétala, largura de pétala, comprimento de sétala, largura de sétala. Três espécies distintas misturadas. Relação entre as variáveis é diferente, ela depende da espécie.

Propriedades de ρ

- Se $\rho = -1$ ou $\rho = +1$, podemos prever o valor de Y_2 como função linear de Y_1 , sem erro, de forma perfeita.
- Isto é, se $\rho = \pm 1$, temos $Y_2 = \alpha + \beta Y_1$
- Se $\rho = 0$ *pode acontecer* que Y_1 seja fortemente relacionada a Y_2 de uma forma não-linear. São casos raros na prática.

Propriedades de ρ

- ρ é invariante por mudança linear de escala.
- Por ex, Y_1 é o estoque de café num certo mês e Y_2 é o preço do café em reais no mesmo mês.
- Seja $\rho = \text{Corr}(Y_1, Y_2)$.
- Suponha que outra variável seja usada: o preço Y_3 do café em dólares e que $Y_3 = 2.3Y_2$.
- Neste caso,

$$\text{Corr}(Y_1, Y_3) = \text{Corr}(Y_1, 2.3Y_2) = \text{Corr}(Y_1, Y_2)$$

- Do mesmo modo, se medirmos em graus centígrados (Y_2) ou em graus Fahrenheit ($Y_3 = 32 + 1.8Y_2$), a correlação com outra variável Y_1 é

$$\text{Corr}(Y_1, Y_3) = \text{Corr}(Y_1, 32 + 1.8Y_2) = \text{Corr}(Y_1, Y_2)$$

Estimando ρ

- ρ é um resumo teórico da distribuição CONJUNTA de duas v.a.'s
- Ele não depende de dados para ser obtido, é uma conta matemática.
- Relembre a definição:

$$\rho = \text{Corr}(Y_1, Y_2) = \mathbb{E} \left(\frac{Y_1 - \mu_1}{\sigma_1} \times \frac{Y_2 - \mu_2}{\sigma_2} \right)$$

- Precisa de $\mu_1 = \mathbb{E}(Y_1)$, $\sigma_1^2 = \mathbb{V}(Y_1)$, etc.
- Em seguida precisa calcular (usando teoria de probabilidade) o valor esperado do produto dos desvios.
- Para várias distribuições, esta conta matemática é inviável (não-analítica).
- No entanto, com dados, podemos estimar ρ .

Estimando ρ

- Como $\bar{Y} \approx \mathbb{E}(Y)$
- e como $S = \sqrt{\sum_i (Y_i - \bar{Y})^2 / n} \approx \sigma$
- podemos aproximar

$$\rho = \mathbb{E} \left(\frac{Y_1 - \mu_1}{\sigma_1} \times \frac{Y_2 - \mu_2}{\sigma_2} \right) \approx \mathbb{E} \left(\frac{Y_1 - \bar{Y}_1}{S_1} \times \frac{Y_2 - \bar{Y}_2}{S_2} \right)$$

- onde \bar{Y}_1 é a média aritmética dos n valores da variável 1, etc.
- é, \bar{Y}_1 é média aritmética da coluna associada com a variável 1 na tabela de dados.
- Mas ainda precisaríamos calcular uma esperança matemática que é inviável na maioria das distribuições.

Desvio padronizado empírico

- Solução: calcule o desvio realizado de cada um dos n valores das duas variáveis.
- Para a variável 1 com os n valores y_{11}, \dots, y_{n1} da coluna 1 da tabela, calcule a nova coluna formada por

$$z_{i1} = \frac{y_{i1} - \bar{y}_1}{s_1}$$

- Faça o mesmo para a coluna 2, criando uma outra coluna de desvios padronizados empíricos:

$$z_{i2} = \frac{y_{i2} - \bar{y}_2}{s_2}$$

- A seguir, multiplique as duas colunas de desvios padronizados e tire a sua média aritmética calculando

$$r = \frac{1}{n} \sum_{i=1}^n z_{i1} z_{i2} = \frac{1}{n} \sum_{i=1}^n \left(\frac{y_{i1} - \bar{y}_1}{s_1} \right) \left(\frac{y_{i2} - \bar{y}_2}{s_2} \right)$$

Pressão sistólica

- A pressão sistólica mede a força do sangue nas artérias, à medida que o coração contrai para impulsionar o sangue através do corpo.
- Se alta, ela pode levar a doença de coração, angina e doenças vasculares nas pernas.
- Pressão sistólica saudável: entre 120 e 140 mm Hg
- Pressão sistólica > 140 mm Hg: não saudável
- Pressão diastólica: deve ficar em torno de 80.
- Acima de 100 não é saudável.

Pressão sistólica e diastólica em amostra

- Amostra de 250 indivíduos (instâncias)
- Pressão em duas medições (atributos):
 - Diastólica
 - sistólica
- Como fica o gráfico dos atributos dessas 250 instâncias?

Pressão de 250 indivíduos




Figura: Amostra de (y_{i1}, y_{i2}) com $i = 1, 2, \dots, 250$.

Médias para referência

- 250 instâncias do vetor aleatório: $\mathbf{Y} = (Y_1, Y_2)$
- Vetor com os valores esperados de cada variável do vetor:

$$\mathbb{E}(\mathbf{Y}) = \mathbb{E}(Y_1, Y_2) = (\mathbb{E}(Y_1), \mathbb{E}(Y_2)) = (\mu_1, \mu_2) = \boldsymbol{\mu}$$





Figura: Amostra de (y_{i1}, y_{i2}) com $i = 1, 2, \dots, 250$.

Quem está distante do centro?

- Centro $\mu = (\mu_1, \mu_2)$ é o perfil esperado ou típico.
- Quem está longe do perfil típico? Quem é anômalo?
- Medida baseada na distância euclidiana

$$d(y_1, y_2) = \sqrt{(y_1 - 120)^2 + (y_2 - 80)^2}$$
- É razoável?



Exagerando um pouco...

- E se o segundo atributo for assim? Fazendo o $\text{aspect}/\text{raio} = 1$.
- Centro $\mu = (\mu_1, \mu_2)$ continua o mesmo.
- Mas quem está distante do centro agora? Quem é anômalo?




Figura: Amostra de (y_{i1}, y_{i2}) com $i = 1, 2, \dots, 250$.

Distantes são óbvios, não?

- Mas qualé a medida de distância que estamos usando implicitamente, sem nem mesmo perceber?
- Não é a distância euclidiana!





Figura: Amostra de (y_{i1}, y_{i2}) com $i = 1, 2, \dots, 250$.

Pontos à igual distância?

- Todos os pontos do círculo estão à mesma distância euclidiana do centro da nuvem de pontos.
- Queremos os dois pontos em vermelho à igual distância ESTATÍSTICA do centro que os pontos em azul?
- NÃO!!! Pontos vermelhos estão ESTATISTICAMENTE muito mais distantes do centro (μ_1, μ_2) do que os pontos azuis.



Pontos vermelhos mais distantes

- Como fazer os pontos vermelhos mais distantes que os pontos azuis?
- Andar poucas unidades na direção norte-sul te leva para fora da nuvem de pontos (vira anomalia).
- Precisa andar MAIS unidades na direção leste-oeste para sair fora da nuvem de pontos.




Figura: Amostra de (y_{i1}, y_{i2}) com $i = 1, 2, \dots, 250$.

Pontos vermelhos mais distantes

- Então N unidades euclidianas na direção leste-oeste VALEM O MESMO que N/k na direção norte-sul (onde $k > 1$).
- Como achar este k ?
- Como equalizar as distâncias?
- RESPOSTA: Medindo distâncias em unidades de DESVIOS-PADRÃO.




Figura: Amostra de (y_{i1}, y_{i2}) com $i = 1, 2, \dots, 250$.

Medida de dispersão

- Desvio-padrão DP: um para cada eixo, um DP para cada atributo.
- DP mede quanto, em média, um atributo aleatório desvia-se de seu valor esperados
- Por exemplo, $DP = 10$ significa:
 - Em geral, observações desviam-se de 10 unidades em torno de seu valor esperado
 - Às vezes mais de 10 unidades; às vezes, menos de 10 unidades
 - Em média, um afastamento de 10 unidades: isto é o DP.

Qual o desvio padrão de cada variável?

- Centro $\mathbb{E}(\mathbf{Y}) = \boldsymbol{\mu} = (\mu_1, \mu_2) = (120, 80)$
- $DP_1 = \sigma_1 = ??$
- $DP_2 = \sigma_2 = ??$




Figura: Amostra de (y_{i1}, y_{i2}) com $i = 1, 2, \dots, 250$.

Qual o desvio padrão de cada variável?

- Centro $\mathbb{E}(\mathbf{Y}) = \boldsymbol{\mu} = (\mu_1, \mu_2) = (120, 80)$
- $DP_1 = \sigma_1 = 10$
- $DP_2 = \sigma_2 = 2$





Figura: Amostra de (y_{i1}, y_{i2}) com $i = 1, 2, \dots, 250$.

Distância medida em DP

- $(\mu_1, \mu_2) = (120, 80)$ e $(\sigma_1, \sigma_2) = (10, 2)$
- AZUL: afastou-se do centro apenas ao longo do eixo 1 e afastou-se 15 unidades ou $1.5\sigma_1$)
- VERMELHO: afastou-se do centro apenas ao longo do eixo 2 e afastou-se 15 unidades ou $7.5\sigma_2$)
- O ponto VERMELHO está muito mais distante do centro em termos de DPs.
- Mas como fazer com pontos que afastam-se do centro não somente ao longo de um dos eixos?



Distância medida em DP

- $(\mu_1, \mu_2) = (120, 80)$ e $(\sigma_1, \sigma_2) = (10, 2)$
- Andar $n\sigma_1$ ao longo do eixo 1 É EQUIVALENTE a andar $n\sigma_2$ no eixo 2.
- Por exemplo, 20 unidades ao longo do eixo 1 (ou $2\sigma_1$) é ESTATISTICAMENTE EQUIVALENTE a 4 unidades ao (ou $2\sigma_2$) longo do eixo 2.




Figura: Amostra de (y_{i1}, y_{i2}) com $i = 1, 2, \dots, 250$.

Distância medida em DP

- Vamos medir o desvio em cada eixo EM UNIDADES DE SEU DESVIO-PADRÃO e calcular a distância com estes desvios padronizados.
- DESVIO PADRONIZADO ao longo do eixo 1: $z_1 = \frac{y_1 - \mu_1}{\sigma_1} = \frac{y_1 - 120}{10}$
- DESVIO PADRONIZADO ao longo do eixo 2: $z_2 = \frac{y_2 - \mu_2}{\sigma_2} = \frac{y_2 - 80}{2}$
- Distância:


$$\begin{aligned}
 d(\mathbf{y}, \boldsymbol{\mu}) &= \sqrt{z_1^2 + z_2^2} \\
 &= \sqrt{\left(\frac{y_1 - 120}{10}\right)^2 + \left(\frac{y_2 - 80}{2}\right)^2} \\
 &= \sqrt{\left(\frac{y_1 - \mu_1}{\sigma_1}\right)^2 + \left(\frac{y_2 - \mu_2}{\sigma_2}\right)^2}
 \end{aligned}$$

Pontos a igual distância

- NESTA NOVA MÉTRICA, quais os pontos (y_1, y_2) que estão a uma MESMA distância do centro (μ_1, μ_2) ?
- Tome uma distância fixa (por exemplo, 1).
- Eles formam uma ELIPSE centrada em (μ_1, μ_2) e com eixos paralelos aos eixos coordenados.

$$d(\mathbf{y}, \boldsymbol{\mu}) = \sqrt{\left(\frac{y_1 - 120}{10}\right)^2 + \left(\frac{y_2 - 80}{2}\right)^2} = 1$$

- Os pontos que satisfazem a equação acima formam uma elipse (esta é a equação de uma elipse).



Tamanhos dos eixos

- Distância $c > 0$ do centro: pontos satisfazem a equação

$$d(\mathbf{y}, \boldsymbol{\mu}) = \sqrt{\left(\frac{y_1 - 120}{10}\right)^2 + \left(\frac{y_2 - 80}{2}\right)^2} = c$$

- Os eixos têm comprimentos iguais a $c\sigma_1$ e $c\sigma_2$. O eixo maior da elipse: variável com maior DP.
- Quantas vezes maior é o eixo maior em relação ao eixo menor?
- Se σ_1 é o maior DP,

$$\frac{\text{eixo maior}}{\text{eixo menor}} = \frac{c\sigma_1}{c\sigma_2} = \frac{\sigma_1}{\sigma_2}$$

- Não depende da distância c : variando c , teremos elipses concêntricas.

Variando a distância




Figura: Pontos (y_1, y_2) que estão a uma distância c igual a 1, 2 ou 3 do centro (μ_1, μ_2) . Isto é, os pontos de cada elipse satisfazem $d(\mathbf{y}, \boldsymbol{\mu}) = c$ para diferentes c 's.

Jogando fora a raiz quadrada

- Preferimos trabalhar com a distância AO QUADRADO
- E se podemos complicar, por quê simplificar?

$$\begin{aligned}
 d^2(\mathbf{y}, \boldsymbol{\mu}) &= \left(\frac{y_1 - \mu_1}{\sigma_1} \right)^2 + \left(\frac{y_2 - \mu_2}{\sigma_2} \right)^2 \\
 &= (y_1 - \mu_1, y_2 - \mu_2) \begin{bmatrix} 1/\sigma_1^2 & 0 \\ 0 & 1/\sigma_2^2 \end{bmatrix} \begin{pmatrix} y_1 - \mu_1 \\ y_2 - \mu_2 \end{pmatrix} \\
 &= (y_1 - \mu_1, y_2 - \mu_2) \begin{bmatrix} \sigma_1^2 & 0 \\ 0 & \sigma_2^2 \end{bmatrix}^{-1} \begin{pmatrix} y_1 - \mu_1 \\ y_2 - \mu_2 \end{pmatrix} \\
 &= \begin{pmatrix} y_1 - \mu_1 \\ y_2 - \mu_2 \end{pmatrix}' \boldsymbol{\Sigma}^{-1} \begin{pmatrix} y_1 - \mu_1 \\ y_2 - \mu_2 \end{pmatrix} \\
 &= (\mathbf{y} - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{y} - \boldsymbol{\mu})
 \end{aligned}$$

Elipses e distâncias

- Vimos que

$$d^2(\mathbf{y}, \boldsymbol{\mu}) = \left(\frac{y_1 - \mu_1}{\sigma_1} \right)^2 + \left(\frac{y_2 - \mu_2}{\sigma_2} \right)^2 = (\mathbf{y} - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{y} - \boldsymbol{\mu})$$

onde

$$\boldsymbol{\Sigma} = \begin{bmatrix} \sigma_1^2 & 0 \\ 0 & \sigma_2^2 \end{bmatrix}$$

é a equação de uma elipse centrada no vetor $\boldsymbol{\mu} = (\mu_1, \mu_2)$.

- Quando a matriz $\boldsymbol{\Sigma}$ é DIAGONAL com elementos positivos (com as variâncias σ_i 's), então a elipse tem eixos paralelos aos eixos e o tamanho de cada eixo é proporcional ao σ_i da variável associada.

Caso mais realista

- Variáveis são associadas, não são independentes
- Dizemos que são correlacionadas: redundância da informação
- O valor de uma variável dá informação sobre o valor da variável
- Pode-se prever (com algum erro) uma variável em função da outra





Figura: Amostra de (y_{i1}, y_{i2}) com $i = 1, 2, \dots, 250$.

Distância elíptica, e não circular

- Pelo mesmo raciocínio intuitivo que fizemos antes, os pontos na ELIPSE abaixo tendem a estar a igual distância do perfil esperado $\mathbb{E}(\mathbf{Y}) = \boldsymbol{\mu} = (\mu_1, \mu_2)$.
- Pontos estatisticamente equidistantes de $\boldsymbol{\mu}$ NÃO estão mais numa elipse paralela aos eixos.
- A elipse está inclinada seguindo a associação entre as variáveis.



Forma Quadrática

- Medida de distância é uma FORMA QUADRÁTICA.

$$d^2(\mathbf{y}, \boldsymbol{\mu}) = (\mathbf{y} - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{y} - \boldsymbol{\mu})$$

- É a mesma expressão matricial de distância que usamos antes MAS...
- ...a matriz $\boldsymbol{\Sigma}$ não é mais DIAGONAL




Figura: Amostra de (y_{i1}, y_{i2}) com $i = 1, 2, \dots, 250$.

Quem é Σ ?

- Medida de distância é uma FORMA QUADRÁTICA:

$$d^2(\mathbf{y}, \boldsymbol{\mu}) = (\mathbf{y} - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{y} - \boldsymbol{\mu})$$

- Matriz Σ é matriz 2×2 simétrica chamada de matriz de covariância

$$\Sigma = \begin{bmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{bmatrix}$$

onde $\rho = \text{Corr}(Y_1, Y_2)$ é o índice de correlação de Pearson entre Y_1 e Y_2 .

- Temos sempre $-1 \leq \rho \leq 1$.
- Os elementos fora da diagonal, $\rho\sigma_1\sigma_2$, são chamados de Covariância entre Y_1 e Y_2 .
- Costumamos escrever $\text{Cov}(Y_1, Y_2) = \rho\sigma_1\sigma_2 = \sigma_{12}$

Relação entre Σ e a elipse


- Distância é

$$d^2(\mathbf{y}, \boldsymbol{\mu}) = (\mathbf{y} - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{y} - \boldsymbol{\mu})$$

onde a matriz $\boldsymbol{\Sigma}$ é 2×2 simétrica e dada por

$$\boldsymbol{\Sigma} = \begin{bmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{bmatrix}$$

- Pontos equidistantes de $\boldsymbol{\mu} = (\mu_1, \mu_2)$ estão numa elipse.
- Eixos da elipse: na direção dos AUTOVETORES da matriz $\boldsymbol{\Sigma}^{-1}$.
- O tamanho de cada eixo é proporcional à raiz do AUTOVALOR correspondente.



Autovetor e autovalor de Σ^{-1}

- Definição: autovetor de uma matriz quadrada A é um vetor \mathbf{y} tal que

$$A \cdot \mathbf{y} = \lambda \mathbf{y}$$

onde λ é uma constante (pode até ser um número complexo).

- A constante λ é chamada de autovalor associado ao autovetor \mathbf{y} .
- Na nossa situação de distância estatística em que usamos a inversa da matriz de covariância como Σ^{-1} temos dois resultados especiais:
 - sempre temos dois autovetores ORTOGONAIS entre si.
 - autovalores são sempre REAIS E POSITIVOS (e portanto podemos tomar sua raiz ou invertê-los).
- Voltaremos a este importante resultado daqui a pouco.

Autovetores de Σ e Σ^{-1}

- Os autovetores de Σ e Σ^{-1} são os mesmos.
- Prova: Suponha que \mathbf{v} é autovetor de Σ com autovalor $\lambda > 0$:

$$\Sigma \cdot \mathbf{v} = \lambda \mathbf{v}$$

- Multiplique dos dois lados (pela esquerda) por Σ^{-1} :

$$\Sigma^{-1}\Sigma \cdot \mathbf{v} = \Sigma^{-1}(\lambda \mathbf{v})$$

ou seja

$$\mathbf{v} = \lambda \Sigma^{-1} \mathbf{v}$$

ou ainda, como $\lambda > 0$,

$$\frac{1}{\lambda} \mathbf{v} = \Sigma^{-1} \mathbf{v}$$



Distância estatística em k dimensões

- Seja $\mathbf{Y} = (Y_1, \dots, Y_k)$ um vetor aleatório de dimensão k .
- Seja $\boldsymbol{\mu} = (\mu_1, \dots, \mu_k)$ seu VETOR-COLUNA de valores esperados
- Seja Σ a matriz $k \times k$ com a covariância $\sigma_{ij} = \rho_{ij}\sigma_i\sigma_j$ onde ρ_{ij} é a correlação entre Y_i e Y_j .
- Distância estatística:

$$d^2(\mathbf{y}, \boldsymbol{\mu}) = (\mathbf{y} - \boldsymbol{\mu})' \Sigma^{-1} (\mathbf{y} - \boldsymbol{\mu})$$

- Pontos equidistantes de $\boldsymbol{\mu}$ formam um elipsóide em k dimensões com eixos nas direções dos autovetores de Σ e com tamanhos proporcionais aos seus respectivos autovetores.

Caso 3-dim



Distância estatística em k dimensões

- Σ é a matriz de covariância $k \times k$ de um vetor aleatório \mathbf{Y} de dimensão k , temos:
 - sempre temos k autovetores ORTOGONAIS entre si.
 - autovalores são sempre REAIS E POSITIVOS.
- Esta afirmação é uma consequência do teorema espectral de álgebra linear.
- Para todo ponto \mathbf{y} que não seja o vetor esperado $\boldsymbol{\mu}$, queremos que a distância $d^2(\mathbf{y}, \boldsymbol{\mu})$ seja > 0 .
- Uma matriz com esta propriedade é chamada de *positiva definida*.

Resumo de normal multivariada

- O vetor aleatório $\mathbf{Y} = (Y_1, \dots, Y_k)$ segue uma distribuição normal (ou gaussiana) multivariada se sua densidade conjunta for da forma

$$f_{\mathbf{Y}}(\mathbf{y}) = \text{cte} \times \exp\left(-\frac{1}{2} d^2(\mathbf{y}, \boldsymbol{\mu})\right)$$

onde

$$d^2(\mathbf{y}, \boldsymbol{\mu}) = (\mathbf{y} - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{y} - \boldsymbol{\mu})$$

e $\boldsymbol{\Sigma}$ é a matriz de covariância entre as variáveis e $\boldsymbol{\mu}$ é o vetor de valores esperados.

- Notação: $\mathbf{Y} \sim N_k(\boldsymbol{\mu}, \boldsymbol{\Sigma})$
- A densidade decresce com d^2 . As superfícies de nível da densidade são elipsoides concêntricos centrados em $\boldsymbol{\mu}$.
- Os eixos do elipsóide estão na direção dos autovetores de $\boldsymbol{\Sigma}$ e com comprimentos proporcionais à raiz do autovalor.

Simulando uma normal multivariada

- Sabemos gerar gaussiana univariada $N(0, 1)$ com média $\mu = 0$ e DP $\sigma = 1$.
- Basta usar o algoritmo de Box-Muller (já vimos).
- Então sabemos gerar $\mathbf{Z} = (Z_1, \dots, Z_k)$ INDEPENDENTES e IDENTICAMENTE DISTRIBUÍDOS onde cada $Z_i \sim N(0, 1)$.
- Podemos passar de \mathbf{Z} para um vetor $\mathbf{Y} \sim N_k(\mu, \Sigma)$ apenas manipulando matrizes.
- Seja L uma matriz $k \times k$ tal que $LL^t = \Sigma$.
- Calcule $\mathbf{Y} = \mu + L\mathbf{Z}$.
- Temos $\mathbf{Y} \sim N_k(\mu, \Sigma)$

Como achar L

- Precisamos achar uma matriz L que seja $k \times k$ e tal que $LL^t = \Sigma$.
- É como se estivéssemos achando uma espécie de raiz quadrada de Σ .
- Quem é esta L ? Qualquer uma que satisfaça $LL^t = \Sigma$.
- OK, mas como achar uma dessas?
- Pela *decomposição de Cholesky*: uma matriz *simétrica* e *postiva definida* Σ possui uma matriz L triangular inferior tal que $LL^t = \Sigma$.
- Em R: `t(cho1(A))` (precisa transpor pois a saída de `cho1` é triangular superior)

Algoritmo para decomposição de Cholesky

$$\begin{aligned}
 A = LL^t &= \begin{pmatrix} l_{11} & 0 & 0 \\ l_{21} & l_{22} & 0 \\ l_{31} & l_{32} & l_{33} \end{pmatrix} \begin{pmatrix} l_{11} & l_{21} & l_{31} \\ 0 & l_{22} & l_{32} \\ 0 & 0 & l_{33} \end{pmatrix} \\
 &= \begin{pmatrix} l_{11}^2 & l_{21}l_{11} & l_{31}l_{11} \\ l_{21}l_{11} & l_{21}^2 + l_{22}^2 & l_{31}l_{21} + l_{32}l_{22} \\ l_{31}l_{11} & l_{31}l_{21} + l_{32}l_{22} & l_{31}^2 + l_{32}^2 + l_{33}^2 \end{pmatrix}
 \end{aligned}$$

- O que deve ser o valor l_{11} ?
- Iguale o elemento 11 da matriz A e o elemento 11 da matriz produto LL^t .
- Vemos que $l_{11}^2 = a_{11}$, ou seja, $l_{11} = \sqrt{a_{11}}$.

Algoritmo para decomposição de Cholesky

$$\begin{aligned}
 A = LL^t &= \begin{pmatrix} l_{11} & 0 & 0 \\ l_{21} & l_{22} & 0 \\ l_{31} & l_{32} & l_{33} \end{pmatrix} \begin{pmatrix} l_{11} & l_{21} & l_{31} \\ 0 & l_{22} & l_{32} \\ 0 & 0 & l_{33} \end{pmatrix} \\
 &= \begin{pmatrix} l_{11}^2 & * & * \\ l_{21}l_{11} & l_{21}^2 + l_{22}^2 & * \\ l_{31}l_{11} & l_{31}l_{21} + l_{32}l_{22} & l_{31}^2 + l_{32}^2 + l_{33}^2 \end{pmatrix}
 \end{aligned}$$

- Iguale o elemento 21 de A com o elemento 21 de L^tL .
- Temos $l_{21}l_{11} = a_{21}$. Como já obtivemos $l_{11} = \sqrt{a_{11}}$, encontramos $l_{21} = a_{21}/\sqrt{a_{11}}$.

Algoritmo para decomposição de Cholesky

$$\begin{aligned}
 A = LL^t &= \begin{pmatrix} l_{11} & 0 & 0 \\ l_{21} & l_{22} & 0 \\ l_{31} & l_{32} & l_{33} \end{pmatrix} \begin{pmatrix} l_{11} & l_{21} & l_{31} \\ 0 & l_{22} & l_{32} \\ 0 & 0 & l_{33} \end{pmatrix} \\
 &= \begin{pmatrix} l_{11}^2 & & \\ l_{21}l_{11} & l_{21}^2 + l_{22}^2 & \\ l_{31}l_{11} & l_{31}l_{21} + l_{32}l_{22} & l_{31}^2 + l_{32}^2 + l_{33}^2 \end{pmatrix}
 \end{aligned}$$

- De maneira idêntica, obtemos $l_{31} = a_{31}/\sqrt{a_{11}}$.
- Primeira coluna de L está pronta. Vamos agora obter a segunda coluna de L .
- Igualamos o elemento a_{22} e o elemento 22 do produto LL^t :
 $a_{22} = l_{21}^2 + l_{22}^2$.
- Assim, $l_{22} = \sqrt{a_{22} - l_{21}^2} = \sqrt{a_{22} - a_{21}^2/a_{11}}$.

Algoritmo para decomposição de Cholesky

$$\begin{aligned}
 A = LL^t &= \begin{pmatrix} l_{11} & 0 & 0 \\ l_{21} & l_{22} & 0 \\ l_{31} & l_{32} & l_{33} \end{pmatrix} \begin{pmatrix} l_{11} & l_{21} & l_{31} \\ 0 & l_{22} & l_{32} \\ 0 & 0 & l_{33} \end{pmatrix} \\
 &= \begin{pmatrix} l_{11}^2 & l_{21}l_{11} & l_{31}l_{11} \\ l_{21}l_{11} & l_{21}^2 + l_{22}^2 & l_{31}l_{21} + l_{32}l_{22} \\ l_{31}l_{11} & l_{31}l_{21} + l_{32}l_{22} & l_{31}^2 + l_{32}^2 + l_{33}^2 \end{pmatrix}
 \end{aligned}$$

- Tendo obtido $l_{11}, l_{21}, l_{31}, l_{22}$, passamos agora a l_{32}
- Iguale o elemento a_{32} e o elemento 32 do produto LL^t
- E assim sucessivamente.

$$\begin{pmatrix} 25 & 15 & -5 \\ 15 & 18 & 0 \\ -5 & 0 & 11 \end{pmatrix} = \begin{pmatrix} l_{11} & 0 & 0 \\ l_{21} & l_{22} & 0 \\ l_{31} & l_{32} & l_{33} \end{pmatrix} \begin{pmatrix} l_{11} & l_{21} & l_{31} \\ 0 & l_{22} & l_{32} \\ 0 & 0 & l_{33} \end{pmatrix}$$

- primeira coluna de L

$$\begin{pmatrix} 25 & 15 & -5 \\ 15 & 18 & 0 \\ -5 & 0 & 11 \end{pmatrix} = \begin{pmatrix} 5 & 0 & 0 \\ 3 & l_{22} & 0 \\ -1 & l_{32} & l_{33} \end{pmatrix} \begin{pmatrix} 5 & 3 & -1 \\ 0 & l_{22} & l_{32} \\ 0 & 0 & l_{33} \end{pmatrix}$$

- conclusão:

$$\begin{pmatrix} 25 & 15 & -5 \\ 15 & 18 & 0 \\ -5 & 0 & 11 \end{pmatrix} = \begin{pmatrix} 5 & 0 & 0 \\ 3 & 3 & 0 \\ -1 & 1 & 3 \end{pmatrix} \begin{pmatrix} 5 & 3 & -1 \\ 0 & 3 & 1 \\ 0 & 0 & 3 \end{pmatrix}$$

Exemplo - simulando $N_4(\boldsymbol{\mu}, \boldsymbol{\Sigma})$

- Suponha que queremos gerar uma amostra de 200 instâncias de um vetor \mathbf{Y} gaussiano multivariado de dimensão 4 tal que $\mathbf{Y} \sim N_4(\boldsymbol{\mu}, \boldsymbol{\Sigma})$.
- $\boldsymbol{\mu} = (\mu_1, \dots, \mu_4) = (0, 10, 0, 1020)$
- A matriz de covariância:

$$\boldsymbol{\Sigma} = \begin{pmatrix} 1.0 & -0.1 & 0 & -0.7 \\ -0.1 & 16 & -0.4 & 20 \\ 0 & -0.4 & 0.04 & -0.1 \\ -0.7 & 20 & -0.1 & 64 \end{pmatrix}$$

- Veja que a raiz quadrada da diagonal fornece os desvios-padrão:

$$\sqrt{\text{diag}(\boldsymbol{\Sigma})} = \sqrt{(1.0, 16, 0.04, 64)} = (1.0, 4, 0.2, 8)$$

Exemplo - simulando $N_4(\mu, \Sigma)$

- Como a covariância está associada com a correlação e os desvios-padrão,

$$\sigma_{ij} = \rho_{ij} \sigma_i \sigma_j$$

podemos escrever a matriz de covariância como resultado de manipular matricialmente a matriz de correlação:

$$\Sigma = \mathbf{V}^{1/2} \rho \mathbf{V}^{1/2}$$

onde \mathbf{V} é uma matriz diagonal com as variâncias $(\sigma_1^2, \dots, \sigma_k^2)$ e ρ é uma matriz quadrada com as correlações ρ_{ij} .

- Portanto, podemos também escrever

$$\rho = \left(\mathbf{V}^{1/2}\right)^{-1} \Sigma \left(\mathbf{V}^{1/2}\right)^{-1}$$

Exemplo - simulando $N_4(\mu, \Sigma)$

- No nosso exemplo:

$$\Sigma = \begin{pmatrix} 1.0 & -0.1 & 0 & -0.7 \\ -0.1 & 16 & -0.4 & 20 \\ 0 & -0.4 & 0.04 & -0.1 \\ -0.7 & 20 & -0.1 & 64 \end{pmatrix} = \mathbf{V}^{1/2} \boldsymbol{\rho} \mathbf{V}^{1/2}$$

onde

$$\mathbf{V}^{1/2} = \begin{pmatrix} \sqrt{1} & 0 & 0 & 0 \\ 0 & \sqrt{16} & 0 & 0 \\ 0 & 0 & \sqrt{0.04} & 0 \\ 0 & 0 & 0 & \sqrt{64} \end{pmatrix}$$

e

$$\boldsymbol{\rho} = \begin{pmatrix} 1.0000 & -0.0250 & 0.0000 & -0.0875 \\ -0.0250 & 1.0000 & -0.5000 & 0.6250 \\ 0.0000 & -0.5000 & 1.0000 & -0.0625 \\ -0.0875 & 0.6250 & -0.0625 & 1.0000 \end{pmatrix}$$

Exemplo - simulando $N_4(\mu, \Sigma)$

- Na direção inversa

$$\rho = \begin{pmatrix} 1.0000 & -0.0250 & 0.0000 & -0.0875 \\ -0.0250 & 1.0000 & -0.5000 & 0.6250 \\ 0.0000 & -0.5000 & 1.0000 & -0.0625 \\ -0.0875 & 0.6250 & -0.0625 & 1.0000 \end{pmatrix} = \mathbf{V}^{-1/2} \Sigma \mathbf{V}^{-1/2}$$

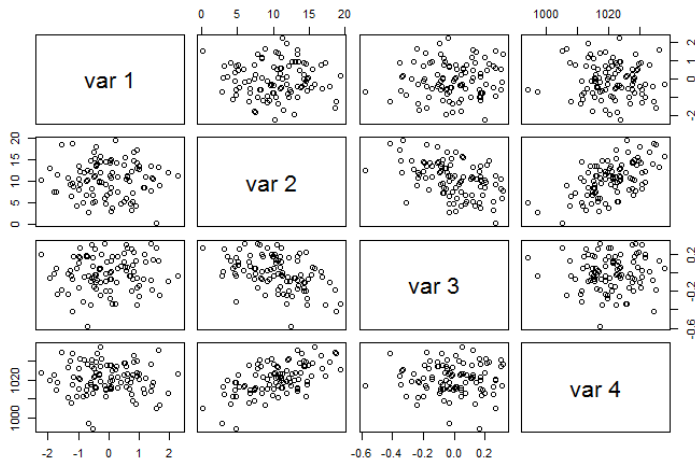
onde $\mathbf{V}^{-1/2} = (\mathbf{V}^{1/2})^{-1}$ é dada por

$$\begin{pmatrix} \sqrt{1} & 0 & 0 & 0 \\ 0 & \sqrt{16} & 0 & 0 \\ 0 & 0 & \sqrt{0.04} & 0 \\ 0 & 0 & 0 & \sqrt{64} \end{pmatrix}^{-1} = \begin{pmatrix} 1.000 & 0 & 0 & 0 \\ 0 & 0.250 & 0 & 0 \\ 0 & 0 & 5.000 & 0 \\ 0 & 0 & 0 & 0.125 \end{pmatrix}$$

- A partir da matriz de correlação ρ vemos que Y_1 é praticamente não-correlacionada com as outras três.
- Já Y_2 possui uma correlação moderada com Y_3 (negativa) e com Y_4 (positiva).
- Apesar disso, curiosamente, Y_3 e Y_4 são praticamente não-correlacionadas.

Exemplo - simulando $N_4(\mu, \Sigma)$


```
nsims = 100
mu = matrix(c(0, 10, 0, 1020), ncol=1)
S = matrix(c(1, -0.1, 0, -0.7,
             -0.1, 16, -0.4, 20,
             0, -0.4, 0.04, -0.1,
             -0.7, 20, -0.1, 64), ncol=4)
L = t(chol(S))
Z = matrix(rnorm(4*nsims), nrow=4)
Y = mu + L %*% Z    # matriz 4 x nsims
pairs(t(Y)) # ver proximo slide
```

Exemplo - simulando $N_4(\mu, \Sigma)$ 

Exemplo - simulando $N_4(\mu, \Sigma)$

- Podemos criar scatterplots TRI-dimensionais com os vetores que simulamos.
- Como os vetores são 4-dim, vamos escolher três das 4 variáveis para fazer o plot.
- Precisamos do pacote `scatterplot3d`.
- Usamos a função `scatterplot3d(x, y, z)`.


```
library(scatterplot3d)  
scatterplot3d(Y[2,], Y[3,], Y[4,])
```

Exemplo - simulando $N_4(\mu, \Sigma)$ 

Exemplo - simulando $N_4(\mu, \Sigma)$

- Scatterplot 3-dim com cores e linhas ajudando a localizar os pontos no espaço.
- Pontos são desenhados com cores diferentes de acordo com sua coordenada y (de outra forma, fica difícil ver que pontos estão mais à frente ou atrás no cubo 3-dim).

```
library(scatterplot3d)
scatterplot3d(Y[2,], Y[3,], Y[4,], pch=16,
  highlight.3d=TRUE, type="h", main="3D Scatterplot")
```




Exemplo - simulando $N_4(\mu, \Sigma)$

- Um scatter 3-dim dinâmico: `plot3D(x, y, z)` do pacote `rgl`.
- Cria um catter 3-dim que pode ser rotacionado com o mouse.
- `col=` e `size=` controlam a cor e tamanho dos pontos.

```
library(rgl)
```

```
plot3d(Y[2,], Y[3,], Y[4,], col="red", size=3)
```



Forma quadrática

- Seja $\mathbf{y} = (y_1, \dots, y_k)$ um VETOR-COLUNA em \mathbb{R}^k .
- Seja A uma matriz $k \times k$.
- Forma quadrática é qualquer expressão assim:

$$\mathbf{y}' A \mathbf{y} = \sum_{ij} A_{ij} y_i y_j$$

- Por exemplo, se $\mathbf{y} = (y_1, y_2)$ e A for 2×2 :

$$(y_1, y_2) A \begin{pmatrix} y_1 \\ y_2 \end{pmatrix}$$

que são iguais a

$$A_{11}y_1^2 + A_{12}y_1y_2 + A_{21}y_2y_1 + A_{22}y_2^2$$

- Envolver combinações lineares dos produtos de pares de variáveis (produto de duas variáveis distintas ou produto de uma variável por ela mesma).

Exemplos de formas quadráticas

- Exemplos bi-dimensionais:

$$(y_1, y_2) \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \begin{pmatrix} y_1 \\ y_2 \end{pmatrix} = y_1^2 + y_2^2$$

$$(y_1, y_2) \begin{bmatrix} 9 & 0 \\ 0 & 4 \end{bmatrix} \begin{pmatrix} y_1 \\ y_2 \end{pmatrix} = 9y_1^2 + 4y_2^2$$

$$(y_1, y_2) \begin{bmatrix} 9 & 3 \\ 3 & 4 \end{bmatrix} \begin{pmatrix} y_1 \\ y_2 \end{pmatrix} = 9y_1^2 + 4y_2^2 + 3y_1y_2 + 3y_2y_1 = 9y_1^2 + 4y_2^2 + 6y_1y_2$$

Formas quadráticas simétricas

- A matriz A na forma quadrática

$$\mathbf{y}' A \mathbf{y} = \sum_{ij} A_{ij} y_i y_j$$

pode ser SEMPRE tomada como simétrica.

- Por exemplo, no caso bi-dimensional

$$\begin{aligned} \mathbf{y}' A \mathbf{y} &= (y_1, y_2) \begin{bmatrix} 9 & 2 \\ 4 & 4 \end{bmatrix} \begin{pmatrix} y_1 \\ y_2 \end{pmatrix} \\ &= 9y_1^2 + 4y_2^2 + 2y_1y_2 + 4y_2y_1 \\ &= 9y_1^2 + 4y_2^2 + 6y_1y_2 \\ &= (y_1, y_2) \begin{bmatrix} 9 & 3 \\ 3 & 4 \end{bmatrix} \begin{pmatrix} y_1 \\ y_2 \end{pmatrix} \end{aligned}$$

- Caso geral: ver lista de exercícios.
- De agora em diante, A em formas quadráticas é sempre simétrica.

Matrizes positivas definidas

- Queremos que uma medida de distância mais geral que a euclidiana.
- Se a distância ao quadrado de \mathbf{y} até a origem $\mathbf{0} = (0, \dots, 0)$ for uma forma quadrática, precisamos garantir que, PARA TODO VETOR \mathbf{y} que não seja nulo tenhamos

$$d^2(\mathbf{y}, \mathbf{0}) = \mathbf{y}' A \mathbf{y} = \sum_{ij} A_{ij} y_i y_j > 0$$

- Matrizes que atendem esta condição são chamadas de matrizes definidas positivas.

Exemplos de matrizes positivas definidas

- Exemplos de positiva definida em que $\mathbf{y}'A\mathbf{y} > 0$ para todo $\mathbf{y} \neq \mathbf{0}$:

$$(y_1, y_2) \begin{bmatrix} 9 & 0 \\ 0 & 4 \end{bmatrix} \begin{pmatrix} y_1 \\ y_2 \end{pmatrix} = 9y_1^2 + 4y_2^2 > 0$$

- Outro exemplo:

$$(y_1, y_2) \begin{bmatrix} 9 & -3 \\ -3 & 4 \end{bmatrix} \begin{pmatrix} y_1 \\ y_2 \end{pmatrix} = 9y_1^2 + 4y_2^2 - 3y_1y_2 - 3y_2y_1 = 9y_1^2 + 4y_2^2 - 6y_1y_2 > 0$$

- Não é óbvio que esta última matriz seja dp. E é apenas um caso 2-dim!!

Exemplos de matrizes que NÃO SÃO positiva definida

- Um exemplo:

$$(y_1, y_2) \begin{bmatrix} 9 & 0 \\ 0 & -4 \end{bmatrix} \begin{pmatrix} y_1 \\ y_2 \end{pmatrix} = 9y_1^2 - 4y_2^2$$

- pois é menor que zero se $(y_1, y_2) = (0, 1)$, por exemplo.
- Outro exemplo:

$$(y_1, y_2) \begin{bmatrix} 1 & -2 \\ -2 & 1 \end{bmatrix} \begin{pmatrix} y_1 \\ y_2 \end{pmatrix} = y_1^2 + y_2^2 - 4y_1y_2$$

- É menor que zero se tomarmos $(y_1, y_2) = (1, 1)$, por exemplo.

Checando se matriz é positiva definida

- Como verificar, em geral, se uma matriz simétrica A de dimensão $k \times k$ é definida positiva?
- Difícil se k for grande.
- Checando todos os infinitos \mathbf{y} ??
- Não...
- A é definida positiva se, e somente se, todos os seus autovalores forem positivos.
- Algoritmos para encontrar autovalores são custosos, especialmente se a matriz é grande.
- A é definida positiva se, e somente se, existir a sua decomposição de Cholesky.
- Este é algoritmo simples e rápido.
- Vamos ver um exemplo

Nossa matriz é positiva definida

- Nossa matriz A será de um tipo especial: será uma matriz de covariância.
- Neste caso, A será sempre def pos (a não ser em exemplos patológicos, que não ocorrem na prática).


Qual a relação entre Σ e a elipse?

- Suponha que a medida de distância do valor aleatório \mathbf{y} até o perfil esperado $\boldsymbol{\mu}$ é dada por

$$d^2(\mathbf{y}, \boldsymbol{\mu}) = (\mathbf{y} - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{y} - \boldsymbol{\mu})$$

onde $\boldsymbol{\Sigma}$ é uma matriz de covariância simétrica e definida positiva.

- Os pontos \mathbf{y} que são equidistantes de $\boldsymbol{\mu}$ formam uma elipse centrada em $\boldsymbol{\mu}$ e com eixos na direção dos autovetores da matriz $\boldsymbol{\Sigma}$. Os tamanhos dos semi-eixos da elipse são proporcionais a (raiz quadrada) dos seus respectivos autovalores.



Autovetores de matrizes simétricas

- Autovetor e autovalor de matriz QUADRADA A .
- Definição: $A\mathbf{v} = \lambda\mathbf{v}$
- Autovalor λ pode ser um número complexo.
- Se A for simétrica então λ é real.
- Só nos interessam as matrizes simétricas.

Imagine a matriz como uma transformação

- O que é um autovetor de uma matriz A de dimensão $p \times p$?
- Olhe a definição de novo: $A\mathbf{v} = \lambda\mathbf{v}$
- Um autovetor é uma direção muito especial em \mathbb{R}^p .
- É uma direção \mathbf{v} tal que, quando A é aplicado a \mathbf{v} , temos apenas \mathbf{v} espichado (se $\lambda > 1$) ou encolhido (se $0 < \lambda < 1$)
- Se $\lambda < 0$, a direção muda de sentido.

Imagine a matriz como uma transformação

- Matriz real e simétrica A de dimensão $p \times p$.
- Pense na transformação de \mathbb{R}^p para \mathbb{R}^p pela aplicação da matriz A .
- Isto é, considere a transformação linear $T: \mathbb{R}^p \mapsto \mathbb{R}^p$ tal que $T(\mathbf{v}) = A\mathbf{v}$.
- Por exemplo, pense numa imagem em \mathbb{R}^2 , um desenho feito com linhas e curvas.
- Cada ponto do desenho será identificado com um vetor de \mathbb{R}^2 .
- Cada ponto será transformado através de uma matriz simétrica A de dimensão 2×2 .
- O que será o novo desenho?

Imagine a matriz como uma transformação

- Em geral, a imagem $A\mathbf{v}$ de um ponto não tem uma relação geométrica simples com \mathbf{v} .
- Em geral, é difícil antecipar qual será o resultado de aplicar A em \mathbf{v} .
- A seguir, veremos o efeito de


$$A = \begin{pmatrix} 1 & 1.2 \\ 1.2 & 5 \end{pmatrix}$$

- Em p dimensões não teremos uma imagem para olhar...

Imagine a matriz como uma transformação

- Matriz

$$A = \begin{pmatrix} 1 & 1.2 \\ 1.2 & 5 \end{pmatrix}$$




- O ponto-estrela da esquerda é levado por A no ponto-estrela da direita.
- O ponto-bolinha da direita é levado por A no ponto-bolinha da direita.
- Podemos ANTECIPAR o efeito de A num ponto arbitrário (x, y) ?
- Onde ele será levado?
- Isto parece ser uma tarefa difícil.

Imagine a matriz como uma transformação

- Se A for $p \times p$, teremos vetores em p dimensões: não teremos uma imagem para olhar...
 - Antecipar onde o vetor $x \in \mathbb{R}^p$ será levado por A parece uma tarefa impossível.
 - E no entanto...
-
- Ao longo de ALGUMAS DIREÇÕES \mathbf{v} , o comportamento da transformação por A é facilmente entendido.
 - Pense num vetor que esteja numa destas direções especiais.
 - Então A simplesmente espicha ou encolhe o ponto-vetor, SEM ALTERAR A SUA DIREÇÃO.



Cara Engraçada



Espichando verticalmente

- Espichando verticalmente com



$$A = \begin{pmatrix} 1 & 0 \\ 0 & 2 \end{pmatrix}$$



Espichando lateralmente

- Espichando lateralmente com

$$A = \begin{pmatrix} 2 & 0 \\ 0 & 1 \end{pmatrix}$$



E se o desenho estiver rotacionado?





Figura: Queremos espichar apenas lateralmente o desenho da face mas mantendo a sua orientação. Como fazer?


Direções especiais

- Existem duas direções especiais associadas com a transformação linear T que desejamos fazer na figura.
- Ao longo dessas duas direções especiais, basta espichar lateralmente ao longo de UMA delas para fazer a face ficar mais “gordinha”.
- Basta espichar ou contrair a projeção do vetor ao longo dessa direção para obter o efeito desejado.



Direções especiais

- Então $A\mathbf{v}$ pode ser pensado assim: expresse \mathbf{v} com coordenadas na base ortogonal formada pelas duas direções especiais.
- Espiche ou contraia cada uma das coordenadas dessas direções especiais.
- Volte para o sistema de coordenadas original.
- Se esta história de espichar a cara não ficou muito clara, não se preocupe. O que você REALMENTE precisa saber está resumido a seguir.



Autovetor = Direção especial

- O que é um autovetor \mathbf{v} de uma matriz simétrica A de dimensão $p \times p$?
- Por definição: $A\mathbf{v} = \lambda\mathbf{v}$
- Um autovetor é uma direção muito especial em \mathbb{R}^p .
- É uma direção \mathbf{v} tal que, quando A é aplicado a \mathbf{v} , temos apenas \mathbf{v} espichado (se $\lambda > 1$) ou encolhido (se $0 < \lambda < 1$).

Teorema Espectral - 1

- Seja A uma matriz $p \times p$ simétrica e *positiva definida*.
- Existem p autovalores associados com A .
- Estes p autovalores são números reais pois A é simétrica
- Estes autovalores são POSITIVOS pois A é positiva definida.
- A cada autovalor corresponde um autovetor ou direção em \mathbb{R}^p .
- O que podemos falar desses autovetores?

Teorema Espectral - 2

- Os p autovetores são ortogonais entre si.
- Tomando todos esses autovetores com comprimento 1 e colocando-os como p colunas de uma matriz P , teremos $P^t P = I$ pois eles são ortogonais entre si.
- Seja D uma matriz diagonal $p \times p$ com os autovalores (na mesma ordem que as colunas de P).
- Teorema Espectral: $A = P D P^t$
- O que isto significa: A age simplesmente como uma matriz diagonal D (que é fácil de ser entendida) se trabalharmos no sistema de coordenadas dos autovetores (que são as colunas de P) !!
- Dizemos que A é diagonalizável.

Coordenadas

- No sistema de coordenadas dos autovetores, a matriz A funciona como uma matriz diagonal.
- \mathbf{x} no novo sistema de coordenadas dos autovetores é $\mathbf{x}^* = P\mathbf{x}$.
- Se \mathbf{x}^* é o conjunto de coordenadas no sistema de autovetores, para voltar ao sistema original simplesmente multiplique pela inversa de P que é ... P^t .
- Lembre-se que $P^t P = I$.

Resumindo...

- Pontos na ELIPSE tendem a estar a igual distância do perfil esperado $\boldsymbol{\mu} = (\mu_1, \mu_2)$
- A maneira correta de medir distância ao perfil esperado $\boldsymbol{\mu} = (\mu_1, \mu_2)$ é pela forma quadrática

$$d^2(\mathbf{y}, \boldsymbol{\mu}) = (\mathbf{y} - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{y} - \boldsymbol{\mu})$$

- A elipse é determinada pelos autovetores e autovalores de $\boldsymbol{\Sigma}^{-1}$, a inversa da matriz de covariância das v.a.'s envolvidas.
- Os autovetores de $\boldsymbol{\Sigma}^{-1}$ e de $\boldsymbol{\Sigma}$ são os mesmos
- Os autovalores de $\boldsymbol{\Sigma}^{-1}$ são os inversos $1/\lambda$ dos autovalores de λ

Um exemplo de normal multivariada

- O retorno diário de uma ação é a variação percentual no seu preço de um dia para o outro.
- Seja $S(t)$ o preço no dia t
- O retorno da ação no dia $t + 1$ é dado por

$$Z(t + 1) = \frac{S(t + 1) - S(t)}{S(t)}$$

- É a diferença no preço da ação entre hoje e ontem
RELATIVAMENTE ao preço de ontem.

Quatro ações

- Assim, se $Z(t+1) = 0.1$ isto significa que


$$Z(t+1) = \frac{S(t+1) - S(t)}{S(t)} = 0.1 \Rightarrow S(t+1) = (1 + 0.1)S(t)$$

- Ou seja, um aumento de 10% no preço.
- Se $Z(t+1) = -0.1$, temos então $S(t+1) = (1 - 0.1)S(t)$, uma diminuição de 10% no preço.
- Uma suposição muito comum é que os retornos diários de uma ação segue uma normal.
- E que os retornos de várias ações num mesmo dia seguem uma normal multivariada


Quatro ações

- Vamos olhar os dados dos retornos diários de algumas das principais ações da Bolsa do Estado de São Paulo (BOVESPA).
- Dados diários do período de 4/Nov/1996 a 18/Junho/1998
- Vamos olhar apenas 4 ações, como ilustração:
 - Eletrobrás,
 - Vale do Rio Doce,
 - Petrobrás,
 - Suzano (empresa de papel e celulose)


Telebrás no tempo




Telebrás no tempo




Vale no tempo







Petrorás no tempo







Suzano no tempo



As quatro no tempo

Telebras**Vale do Rio Doce****Petrobras****Suzano**

Histogramas e ajustes gaussianos

Telebras**Vale****Petrobras****Suzano**

Scatterplot dos pares de ações

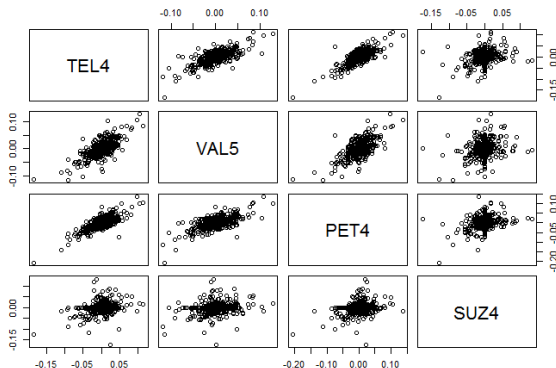


Figura: Tele, Vale e Pet são bem correlacionadas. Quando uma sobe muito, as outras duas também sobem. Suzano não parece ser muito correlacionada com estas outras.

Correlação no tempo

- E a correlação de UMA MESMA ação em dias sucessivos?
- Por exemplo, se a ação da Vale subir bastante hoje, o que podemos esperar para seu movimento amanhã?
- Surpreendente: quase não existe correlação.
- Não uma tendência detectável na VARIAÇÃO dos preços das ações em dias sucessivos.
- Não acredita? Veja os próximos gráficos.

Correlação no tempo




Figura: Gráfico de y_{t+1} versus y_t para as quatro ações. Não existe correlação entre os retornos de uma mesma ação em dias sucessivos.

Matriz de correlação

- Seja $\mathbf{Y}_t = (Y_{1t}, Y_{2t}, Y_{3t}, Y_{4t})$ os retornos das quatro ações no dia t .
- Vamos calcular empiricamente o coeficiente de correlação de Pearson para os pares de ações.
- Temos 401 instâncias de \mathbf{Y}_t correspondentes a 401 dias.
- O vetor esperado pode ser estimado a partir dos dados

$$\boldsymbol{\mu} = (\mu_1, \mu_2, \mu_3, \mu_4) \approx (\bar{y}_1, \bar{y}_2, \bar{y}_3, \bar{y}_4) = \bar{\mathbf{y}} = (1.094, 0.276, 1.038, -1.459) \times 10^{-3}$$

onde \bar{x}_j é a média aritmética

$$\bar{x}_j = \frac{1}{401} \sum_t Y_{tj}$$

- Assim, o retorno diário no período é pequeno, ligeiramente positivo pra as três primeiras, e negativo para SUZ.
- Quanto ao desvio padrão para cada uma delas, estimando dos dados encontramos

$$(\sigma_1, \sigma_2, \sigma_3, \sigma_4) \approx (s_1, s_2, s_3, s_4) = (0.030, 0.030, 0.032, 0.028)$$

Matriz de correlação

- Seja $\mathbf{Y}_t = (Y_{1t}, Y_{2t}, Y_{3t}, Y_{4t})$ os retornos das quatro ações no dia t .
- Vamos calcular empiricamente o coeficiente de correlação de Pearson para os pares de ações.
- Temos 401 instâncias de \mathbf{Y}_t correspondentes a 401 dias.
- Matriz de correlação:

$$\rho = \begin{pmatrix} & \text{Tel4} & \text{Val5} & \text{Pet4} & \text{Suz4} \\ \text{Tel4} & 1.00 & 0.72 & 0.79 & 0.30 \\ \text{Val5} & 0.72 & 1.00 & 0.68 & 0.24 \\ \text{Pet4} & 0.79 & 0.68 & 1.00 & 0.33 \\ \text{Suz4} & 0.30 & 0.24 & 0.33 & 1.00 \end{pmatrix}$$

- De fato, TEL, PET e VALE são bem correlacionadas (positivamente) enquanto SUZ mostra pouca correlação com estas outras três ações.

Matriz de covariância

- Matriz de covariância:

$$\Sigma \approx \mathbf{S} = 10^{-4} \begin{pmatrix} & \text{Tel4} & \text{Val5} & \text{Pet4} & \text{Suz4} \\ \text{Tel4} & 9.08 & 6.58 & 7.49 & 2.53 \\ \text{Val5} & 6.58 & 9.27 & 6.53 & 2.00 \\ \text{Pet4} & 7.49 & 6.53 & 10.01 & 2.86 \\ \text{Suz4} & 2.53 & 2.00 & 2.86 & 7.69 \end{pmatrix}$$

- Veja que, ao contrário da matriz de correlação, os números dessa matriz de covariância são difíceis de interpretar.
- Como uma primeira aproximação, podemos dizer que os retornos das quatro ações num dado dia seguem $\mathbf{Y}_t \sim N_4(\boldsymbol{\mu}, \Sigma)$
- com $\boldsymbol{\mu} \approx \bar{\mathbf{y}}$ e $\Sigma \approx \mathbf{S}$.

Marginais da normal multivariada

- Suponha que $\mathbf{Y} = (Y_1, \dots, Y_k) \sim N_k(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ seja um vetor aleatório com distribuição gaussiana multivariada.
- A distribuição de cada uma das entradas Y_i do vetor \mathbf{Y} é uma gaussiana.
- Além disso, a esperança e variância da distribuição são extraídos diretamente dos parâmetros de \mathbf{Y} sem necessidade de nenhum cálculo.
- $Y_i \sim N(\mu_i, \Sigma_{ii})$ onde μ_i é a i -ésima entrada do vetor $\boldsymbol{\mu}$ e Σ_{ii} a i -ésima entrada da diagonal de $\boldsymbol{\Sigma}$.

Exemplo: marginais de $N_k(\mu, \Sigma)$

- $\mathbf{Y} = (Y_1, Y_2, Y_3, Y_4)$ tem vetor esperado $\mu = (4, 3, -2, 2)$ e matriz de covariância

$$\Sigma = \begin{pmatrix} 3 & 0 & 2 & 2 \\ 0 & 1 & 1 & 0 \\ 2 & 1 & 9 & -2 \\ 2 & 1 & 9 & -2 \\ 2 & 0 & -2 & 4 \end{pmatrix}$$

- Então a distribuição marginal é diretamente obtida desta conjunta:

$$Y_3 \sim N(\mu_3, \Sigma_{33}) = N(-2, 9)$$

Marginais de $N_k(\mu, \Sigma)$

- Obtemos não apenas a distribuição de cada entrada individual de \mathbf{Y} mas a distribuição marginal de qualquer sub-vetor de \mathbf{Y} .
- Por exemplo, se $\mathbf{Y} = (Y_1, Y_2, Y_3, Y_4)$ tem vetor esperado $\mu = (4, 3, -2, 2)$ e matriz de covariância

$$\Sigma = \begin{pmatrix} 3 & 0 & 2 & 2 \\ 0 & 1 & 1 & 0 \\ 2 & 1 & 9 & -2 \\ 2 & 1 & 9 & -2 \\ 2 & 0 & -2 & 4 \end{pmatrix}$$

- Então a distribuição marginal do sub-vetor (Y_1, Y_3) é dada por

$$(Y_1, Y_3) \sim N_2 \left(\begin{pmatrix} \mu_1 \\ \mu_3 \end{pmatrix}, \begin{pmatrix} \Sigma_{11} & \Sigma_{13} \\ \Sigma_{31} & \Sigma_{33} \end{pmatrix} \right) = N_2 \left(\begin{pmatrix} 4 \\ -2 \end{pmatrix}, \begin{pmatrix} 3 & 2 \\ 2 & 9 \end{pmatrix} \right)$$

A importância desta propriedade

- Aparentemente, esta propriedade é boba.
- Da conjunta que é normal multivariada chegamos a marginais que também são normais.
- Isto não é óbvio?
- Não, não é.
- Acontece que é muito difícil e raro que a gente consiga saber quais são as marginais apenas mirando a fórmula da conjunta.
- Na maioria dos casos, a única maneira de obter as marginais é integrando ou somando sobre os valores das demais variáveis.

A importância desta propriedade

- Por exemplo, suponha que

$$f_{XY}(x, y) = \text{cte} (yx^2 + \sqrt{y} \exp(-xy + x^2))$$

com suporte em $[0, 1]^2$.

- Não é possível saber quais são as marginais $f_X(x)$ e $f_Y(y)$ diretamente a partir da expressão da conjunta.
- A única maneira de obter $f_X(x)$ é integrando $f_{XY}(x, y)$ com respeito a y :

$$f_X(x) = \int_0^1 \text{cte} (yx^2 + \sqrt{y} \exp(-xy + x^2)) \, dy$$

- Este não é caso da normal multivariada.
- Para escrever a densidade conjunta precisamos de μ e de Σ .
- Com estes dois elementos temos também todas as marginais.

Combinação linear de normais

- Suponha que $\mathbf{Y} = (Y_1, \dots, Y_k) \sim N_k(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ seja um vetor aleatório com distribuição gaussiana multivariada.
- Queremos criar um indicador baseado nestas variáveis, uma nova variável aleatória:

$$X = c_1 Y_1 + \dots + c_k Y_k$$

- Por exemplo, podemos criar um índice para o movimento no mercado de ações.
- Usando apenas os retornos das quatro ações que vimos antes, poderíamos estabelecer o índice

$$X_t = 0.2\text{PET}_t + 0.2\text{VALE}_t + 0.2\text{TEL}_t + 0.4\text{SUZ}_t$$

- Os coeficientes c_i não precisam somar 1 ou serem positivos.
- Por exemplo, por alguma razão, poderíamos querer

$$X_t = 1.2\text{PET}_t + 2.0\text{VALE}_t + 4.3\text{TEL}_t - 3.5\text{SUZ}_t$$

Combinação linear de normais

- Se $\mathbf{Y} = (Y_1, \dots, Y_k) \sim N_k(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ qual é a distribuição de probabilidade do indicador X ?
- Note que este tipo de indicador pode ser escrito em forma vetorial:

$$X = c_1 Y_1 + \dots + c_k Y_k = \mathbf{c}'\mathbf{Y} = (c_1, \dots, c_k) \begin{pmatrix} Y_1 \\ Y_2 \\ Y_3 \\ Y_4 \end{pmatrix}$$

- Adivinhe: X continua gaussiano.
- Isto é, temos que $X \sim N(??, ??) = N(\mu_X, \sigma_X^2)$
- Como X é univariado, basta acharmos o seu valor esperado μ_X e sua variância σ_X^2 .
- Estes momentos são facilmente obtidos a partir dos momentos $\boldsymbol{\mu}$ e $\boldsymbol{\Sigma}$ da normal multivariada, como veremos a seguir.

Momentos de $\mathbf{c}'\mathbf{Y}$

- O cálculo do valor esperado $\mathbb{E}(X) = \mathbb{E}(\mathbf{c}'\mathbf{Y})$ e da variância $\mathbb{V}(X) = \mathbb{V}(\mathbf{c}'\mathbf{Y})$ *não depende da distribuição do vetor \mathbf{Y}* .
- Qualquer que seja a distribuição do vetor \mathbf{Y} , gaussiana ou não, contínua ou discreta, podemos obter $\mathbb{E}(X) = \mathbb{E}(\mathbf{c}'\mathbf{Y})$ e $\mathbb{V}(X) = \mathbb{V}(\mathbf{c}'\mathbf{Y})$ facilmente.
- Isto tem relevância pois é muito comum criar indicadores que são combinações lineares de algumas variáveis.
- Portanto, o cálculo a seguir usa apenas as propriedades de esperança e variância, sem recorrer à especificação de uma distribuição conjunta para o vetor \mathbf{Y} .

$\mathbb{E}(\mathbf{c}'\mathbf{Y})$

- Começando com o valor esperado:

$$\begin{aligned}
 \mathbb{E}(X) &= \mathbb{E}(c_1 Y_1 + c_2 Y_2 + \dots + c_k Y_k) \\
 &= c_1 \mathbb{E}(Y_1) + c_2 \mathbb{E}(Y_2) + \dots + c_k \mathbb{E}(Y_k) \\
 &= c_1 \mu_1 + c_2 \mu_2 + \dots + c_k \mu_k \\
 &= \mathbf{c}'\boldsymbol{\mu}
 \end{aligned}$$

- Isto é,

$$\mathbb{E}(\mathbf{c}'\mathbf{Y}) = \mathbf{c}'\mathbb{E}(\mathbf{Y})$$

- O vetor de constantes \mathbf{c} vai para fora do símbolo de esperança.

$\mathbb{V}(\mathbf{c}'\mathbf{Y})$

- Agora a variância.

$$\mathbb{V}(X) = \mathbb{V}(c_1 Y_1 + c_2 Y_2 + \dots + c_k Y_k)$$

- Basta usar a definição de variância (e um pouco de paciência):

$$\begin{aligned}
 \mathbb{V}(X) &= \mathbb{E}(X - \mathbb{E}(X))^2 \\
 &= \mathbb{E}((c_1 Y_1 + c_2 Y_2 + \dots + c_k Y_k) - (c_1 \mu_1 + c_2 \mu_2 + \dots + c_k \mu_k))^2 \\
 &= \mathbb{E}((c_1(Y_1 - \mu_1) + c_2(Y_2 - \mu_2) + \dots + c_k(Y_k - \mu_k)))^2 \\
 &= \mathbb{E}\left(\sum_i c_i^2 (Y_i - \mu_i)^2 + \sum_{i \neq j} c_i c_j (Y_i - \mu_i)(Y_j - \mu_j)\right) \quad (\text{abrindo o quadrado}) \\
 &= \sum_i \mathbb{E}(c_i^2 (Y_i - \mu_i)^2) + \sum_{i \neq j} \mathbb{E}(c_i c_j (Y_i - \mu_i)(Y_j - \mu_j)) \quad (\text{linearidade da esperança}) \\
 &= \sum_i c_i^2 \mathbb{E}(Y_i - \mu_i)^2 + \sum_{i \neq j} c_i c_j \mathbb{E}((Y_i - \mu_i)(Y_j - \mu_j)) \quad (\text{linearidade de novo}) \\
 &= \sum_i c_i^2 \mathbb{V}(Y_i) + \sum_{i \neq j} c_i c_j \text{Cov}(Y_i, Y_j) \quad (\text{pela def de Var e Cov})
 \end{aligned}$$

$\mathbb{V}(\mathbf{c}'\mathbf{Y})$

- Assim, temos

$$\begin{aligned}\mathbb{V}(\mathbf{c}'\mathbf{Y}) &= \mathbb{V}(c_1 Y_1 + c_2 Y_2 + \dots + c_k Y_k) \\ &= (c_1, \dots, c_k) \sum \begin{pmatrix} c_1 \\ \vdots \\ c_k \end{pmatrix} \\ &= \mathbf{c}'\Sigma\mathbf{c}\end{aligned}$$

onde Σ é matriz de covariância do vetor \mathbf{Y} .

- Veja que no caso univariado tínhamos a fórmula

$$\mathbb{V}(cY) = c^2 \mathbb{V}(Y) = c \mathbb{V}(Y) c,$$

que é versão univariada de $\mathbb{V}(\mathbf{c}'\mathbf{Y}) = \mathbf{c}'\Sigma\mathbf{c}$

Enfatizando

- Mais uma vez, repetimos:
- Seja $\mathbf{Y} = (Y_1, \dots, Y_k)$ um vetor aleatório com QUALQUER distribuição.
- Seja $\mathbb{E}(\mathbf{Y}) = \boldsymbol{\mu}$ com matriz de covariância $\mathbb{V}(\mathbf{Y}) = \boldsymbol{\Sigma}$.
- Então

$$\mathbb{E}(\mathbf{c}'\mathbf{Y}) = \mathbf{c}'\boldsymbol{\mu}$$

e

$$\mathbb{V}(\mathbf{c}'\mathbf{Y}) = \mathbf{c}'\boldsymbol{\Sigma}\mathbf{c}$$

- Estes resultados são válidos mesmo no caso em que \mathbf{Y} não é normal multivariado.
- Caso $\mathbf{Y} \sim N_k(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ então $\mathbf{c}'\mathbf{Y} \sim N(\mathbf{c}'\boldsymbol{\mu}, \mathbf{c}'\boldsymbol{\Sigma}\mathbf{c})$

Retorno de portfólio de ações

- Seja $\mathbf{Y}_t = (Y_{1t}, Y_{2t}, Y_{3t}, Y_{4t})$ os retornos das quatro ações no dia t .
- Suponha que $\mathbf{Y} \sim N_4(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ com

$$\boldsymbol{\mu} = 10^{-3} \times (1.10.31.0 - 1.5)$$

e

$$\boldsymbol{\Sigma} = 10^{-4} \begin{pmatrix} & \text{Tel4} & \text{Tel5} & \text{Pet4} & \text{Suz4} \\ \text{Tel4} & 9.08 & 6.58 & 7.49 & 2.53 \\ \text{Tel5} & 6.58 & 9.27 & 6.53 & 2.00 \\ \text{Pet4} & 7.49 & 6.53 & 10.01 & 2.86 \\ \text{Suz4} & 2.53 & 2.00 & 2.86 & 7.69 \end{pmatrix}$$

- Vamos criar um portfólio com 30% de ações da Telebrás, 20% da Vale, 30% da Petrobrás e 20% da Suzano.
- O retorno deste mix de ações será o mix dos retornos das ações.
- Isto é, o retorno do portfólio é a v.a.

$$X = 0.3Y_1 + 0.2Y_2 + 0.3Y_3 + 0.2Y_4$$

- Qual a distribuição do retorno deste portfólio?

Retorno de portfólio de ações

- Temos

$$X = 0.3Y_1 + 0.2Y_2 + 0.3Y_3 + 0.2Y_4 \sim N(\mu_x, \sigma_x^2) = N(0.00039, (0.0247)^2)$$

onde

$$\mu_x = (0.3, 0.2, 0.3, 0.2) 10^{-3} \begin{pmatrix} 1.1 \\ 0.3 \\ 1.0 \\ -1.5 \end{pmatrix} = 0.00039$$

e

$$\sigma_x^2 = (0.3, 0.2, 0.3, 0.2) \Sigma \begin{pmatrix} 0.3 \\ 0.2 \\ 0.3 \\ 0.2 \end{pmatrix} = 6.1247 \times 10^{-4} = (0.0247)^2$$

Mais propriedades

- Podemos encontrar a distribuição conjunta de vários índices simulatêneos
- Seja $\mathbf{Y} \sim N_k(\boldsymbol{\mu}, \boldsymbol{\Sigma})$
- Seja \mathbf{A} um matriz $q \times k$ de constantes e usada para gerar q índices:

$$\begin{aligned}
 \underset{q \times k}{\mathbf{A}} \underset{k \times 1}{\mathbf{Y}} &= \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1k} \\ a_{21} & a_{22} & \dots & a_{2k} \\ & & \ddots & \\ a_{q1} & a_{q2} & \dots & a_{qk} \end{bmatrix} \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_k \end{bmatrix} \\
 &= \begin{bmatrix} a_{11}Y_1 + a_{12}Y_2 + \dots + a_{1k}Y_k \\ a_{21}Y_1 + a_{22}Y_2 + \dots + a_{2k}Y_k \\ \vdots \\ a_{q1}Y_1 + a_{q2}Y_2 + \dots + a_{qk}Y_k \end{bmatrix} = \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_q \end{bmatrix}
 \end{aligned}$$

- Qual a distribuição CONJUNTA dos q índices no vetor \mathbf{X} ?
- Uma maneira intuitiva de ver isto é pensar que, se duas linhas de \mathbf{A} forem muito parecidas, esperamos que os dois índices associados sejam muito correlacionados.

Distribuição e combinações lineares

- RESULTADO: Se $\mathbf{Y} \sim N_k(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ então

$$\underset{q \times k}{\mathbf{A}} \underset{k \times 1}{\mathbf{Y}} \sim N_q(\mathbf{A}\boldsymbol{\mu}, \mathbf{A}\boldsymbol{\Sigma}\mathbf{A}')$$

- Além disso, $\mathbf{Y} + \mathbf{c}$, onde \mathbf{c} é um vetor $k \times 1$ de constantes, é distribuído como

$$\mathbf{Y} + \mathbf{c} \sim N_k(\boldsymbol{\mu} + \mathbf{c}, \boldsymbol{\Sigma})$$

Independência e covariância

Result 4.5.

(a) If \mathbf{X}_1 and \mathbf{X}_2 are independent, then $\text{Cov}(\mathbf{X}_1, \mathbf{X}_2) = \mathbf{0}$, a $q_1 \times q_2$ matrix of zeros.

(b) If $\begin{bmatrix} \mathbf{X}_1 \\ \mathbf{X}_2 \end{bmatrix}$ is $N_{q_1+q_2}\left(\begin{bmatrix} \boldsymbol{\mu}_1 \\ \boldsymbol{\mu}_2 \end{bmatrix}, \begin{bmatrix} \boldsymbol{\Sigma}_{11} & \boldsymbol{\Sigma}_{12} \\ \boldsymbol{\Sigma}_{21} & \boldsymbol{\Sigma}_{22} \end{bmatrix}\right)$, then \mathbf{X}_1 and \mathbf{X}_2 are independent if and only if $\boldsymbol{\Sigma}_{12} = \mathbf{0}$.

(c) If \mathbf{X}_1 and \mathbf{X}_2 are independent and are distributed as $N_{q_1}(\boldsymbol{\mu}_1, \boldsymbol{\Sigma}_{11})$ and $N_{q_2}(\boldsymbol{\mu}_2, \boldsymbol{\Sigma}_{22})$, respectively, then $\begin{bmatrix} \mathbf{X}_1 \\ \mathbf{X}_2 \end{bmatrix}$ has the multivariate normal distribution

$$N_{q_1+q_2}\left(\begin{bmatrix} \boldsymbol{\mu}_1 \\ \boldsymbol{\mu}_2 \end{bmatrix}, \begin{bmatrix} \boldsymbol{\Sigma}_{11} & \mathbf{0} \\ \mathbf{0}' & \boldsymbol{\Sigma}_{22} \end{bmatrix}\right)$$

Distribuição condicional

- Outra propriedade fantástica da normal multivariada é a facilidade de obter a distribuição condicional de um sub-vetor dados os valores dos outros elementos do vetor aleatório \mathbf{Y} .
- Em geral, para uma distribuição conjunta arbitrária, isto não é possível.
- Dada a conjunta $f(y_1, \dots, y_k)$ dificilmente conseguimos saber qual é a distribuição de Y_1 dados os valores das demais variáveis.
- Temos a fórmula para obter esta distribuição condicional,

$$f_{Y_1|Y_2, \dots, Y_k}(y_1|y_2, \dots, y_k) = \frac{f_{Y_1, Y_2, \dots, Y_k}(y_1, y_2, \dots, y_k)}{f_{Y_2, \dots, Y_k}(y_2, \dots, y_k)}$$

mas não é óbvio de antemão qual será o resultado desta fórmula.

- Este não é o caso da normal multivariada.
- Podemos obter imediatamente e sem muitas contas a distribuição condicional.

Distribuição condicional

Result 4.6. Let $\mathbf{X} = \begin{bmatrix} \mathbf{X}_1 \\ \mathbf{X}_2 \end{bmatrix}$ be distributed as $N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ with $\boldsymbol{\mu} = \begin{bmatrix} \boldsymbol{\mu}_1 \\ \boldsymbol{\mu}_2 \end{bmatrix}$, $\boldsymbol{\Sigma} = \begin{bmatrix} \boldsymbol{\Sigma}_{11} & \boldsymbol{\Sigma}_{12} \\ \boldsymbol{\Sigma}_{21} & \boldsymbol{\Sigma}_{22} \end{bmatrix}$, and $|\boldsymbol{\Sigma}_{22}| > 0$. Then the conditional distribution of \mathbf{X}_1 , given that $\mathbf{X}_2 = \mathbf{x}_2$, is normal and has

$$\text{Mean} = \boldsymbol{\mu}_1 + \boldsymbol{\Sigma}_{12}\boldsymbol{\Sigma}_{22}^{-1}(\mathbf{x}_2 - \boldsymbol{\mu}_2)$$

$$\text{Covariance} = \boldsymbol{\Sigma}_{11} - \boldsymbol{\Sigma}_{12}\boldsymbol{\Sigma}_{22}^{-1}\boldsymbol{\Sigma}_{21}$$

Note that the covariance does not depend on the value \mathbf{x}_2 of the conditioning variable.

Condicional: exemplo

- Seja $\mathbf{Y}_t = (Y_{1t}, Y_{2t}, Y_{3t}, Y_{4t})$ os retornos das quatro ações no dia t .
- Suponha que $\mathbf{Y} \sim N_4(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ com

$$\mathbf{Y} \sim N_4(\boldsymbol{\mu}, \boldsymbol{\Sigma}) = N_4 \left(\begin{pmatrix} 0.001 \\ 0.003 \\ -0.001 \\ -0.001 \end{pmatrix}, 10^{-4} \begin{pmatrix} \text{Tel4} & \text{Vale5} & \text{Pet4} & \text{Suz4} \\ \text{Tel4} & 9.08 & 6.58 & 7.49 \\ \text{Vale5} & 6.58 & 9.27 & 6.53 \\ \text{Pet4} & 7.49 & 6.53 & 10.01 \\ \text{Suz4} & 2.53 & 2.00 & 2.86 \end{pmatrix} \right)$$

- Suponha que, de alguma forma, antecipamos o retorno das duas últimas ações, PET4 e SUZ4, no dia seguinte.
- Estima-se que PET4 e SUZ4 terão ambas um aumento de 5% (isto é, $Y_{3t} = Y_{4t} = 0.05$).
- O que podemos dizer sobre os valores mais prováveis para TEL4 e VALE5?

Condicional: exemplo

- Distribuição de (Y_{1t}, Y_{2t}) dado que $Y_{3t} = 0.05$ e $Y_{4t} = 0.05$: Como

$$\mu = \begin{pmatrix} 0.001 \\ 0.003 \\ 0.001 \\ -0.001 \end{pmatrix} \quad \text{e} \quad \Sigma = 10^{-4} \begin{pmatrix} - & \text{Tel4} & \text{Vale5} & \text{Pet4} & \text{Suz4} \\ \text{Tel4} & 9.08 & 6.58 & 7.49 & 2.53 \\ \text{Vale5} & 6.58 & 9.27 & 6.53 & 2.00 \\ \text{Pet4} & 7.49 & 6.53 & 10.01 & 2.86 \\ \text{Suz4} & 2.53 & 2.00 & 2.86 & 7.69 \end{pmatrix}$$

- sabemos que (Y_{1t}, Y_{2t}) será uma normal bivariada $N_2(\mathbf{m}, \Phi)$ com os seguintes parâmetros:

$$\begin{aligned} \mathbf{m} &= \mu_{12} + \Sigma_{12} \Sigma_{22}^{-1} \begin{pmatrix} y_3 - \mu_3 \\ y_4 - \mu_4 \end{pmatrix} \\ &= \begin{pmatrix} 0.001 \\ 0.003 \end{pmatrix} + \begin{pmatrix} 7.49 & 2.53 \\ 6.53 & 2.00 \end{pmatrix} \begin{pmatrix} 10.01 & 2.86 \\ 2.86 & 7.69 \end{pmatrix}^{-1} \begin{pmatrix} 0.05 - 0.001 \\ 0.05 + 0.001 \end{pmatrix} \\ &= \begin{pmatrix} 0.040 \\ 0.036 \end{pmatrix} \end{aligned}$$

Condicional: exemplo

- A matriz de covariância de (Y_{1t}, Y_{2t}) dado que $Y_{3t} = 0.05$ e $Y_{4t} = 0.05$:

$$\begin{aligned}
 \Phi &= \Sigma_{11} - \Sigma_{12} \Sigma_{22}^{-1} \Sigma_{21} \\
 &= 10^{-4} \left(\begin{pmatrix} 9.08 & 6.58 \\ 6.58 & 9.27 \end{pmatrix} - \begin{pmatrix} 7.49 & 2.53 \\ 6.53 & 2.00 \end{pmatrix} \begin{pmatrix} 10.01 & 2.86 \\ 2.86 & 7.69 \end{pmatrix}^{-1} \begin{pmatrix} 7.49 & 6.53 \\ 2.53 & 2.00 \end{pmatrix} \right) \\
 &= 10^{-4} \begin{pmatrix} 3.45 & 1.69 \\ 1.69 & 5.01 \end{pmatrix}
 \end{aligned}$$

- Assim, olhando diretamente as duas marginais CONDICIONADAS ao evento $Y_{3t} = 0.05$ e $Y_{4t} = 0.05$ e a correlação condicional:

$$(Y_{1t} | Y_{3t} = 0.05, Y_{4t} = 0.05) \sim N(0.040, (0.019)^2)$$

$$(Y_{2t} | Y_{3t} = 0.05, Y_{4t} = 0.05) \sim N(0.036, (0.022)^2)$$

Condicional: exemplo

- Assim, antes de saber o valor de Y_{3t} e Y_{4t} , sabíamos que

$$Y_{1t} \sim N(0.001, (0.0301)^2) \quad \text{e} \quad Y_{2t} \sim N(0.003, (0.0304)^2)$$

- Isto é, espera-se uma valorização de 0.1% ao dia para PET4 e de 0.3% para VALE5.
- Agora que somos informados de que as ações PET4 e SUZ4 tiveram uma grande valorização de 5% de um dia para o outro, podemos revisar o que esperamos para as outras duas ações, PET4 e VALE5:

$$(Y_{1t} | Y_{3t} = 0.05, Y_{4t} = 0.05) \sim N(0.040, (0.019)^2)$$

$$(Y_{2t} | Y_{3t} = 0.05, Y_{4t} = 0.05) \sim N(0.036, (0.022)^2)$$

- Note que agora esperamos uma valorização de 4% para PET4 (40 vezes maior que antes) e de 3.6% para VALE5 (ou 12 vezes maior que antes).
- Note também como o DP diminuiu nos dois casos.

Condicional: exemplo

- Marginalmente, Y_{1t} e Y_{3t} são correlacionadas e $\rho_{12} = 0.72$.
- A correlação condicional $\text{Cor}(Y_{1t}, Y_{2t} | Y_{3t} = 0.05, Y_{4t} = 0.05)$ entre estas duas ações PET4 e VALE5 é dada por


$$\frac{\text{Cov}(Y_{1t}, Y_{2t} | Y_{3t} = 0.05, Y_{4t} = 0.05)}{\sqrt{\text{V}(Y_{1t} | Y_{3t} = 0.05, Y_{4t} = 0.05) \text{V}(Y_{2t} | Y_{3t} = 0.05, Y_{4t} = 0.05)}}$$

$$\frac{1.69 \times 10^{-4}}{0.019 \times 0.022} = 0.40$$

- Assim, conhecer o evento $Y_{3t} = 0.05$ e $Y_{4t} = 0.05$) DIMINUI a correlação entre as variáveis Y_{1t} e Y_{4t} de 0.70 para 0.40.
- Em resumo: as distribuições de Y_{1t} e Y_{4t} bem como sua correlação são bastante impactadas pelo evento $Y_{3t} = 0.05$ e $Y_{4t} = 0.05$).

Condicional: exemplo

- Elipse vermelha: região em que (Y_1, Y_2) cai com probabilidade 95%.
- Elipse azul: dado que $Y_3 = 0.05$ e $Y_4 = 0.05$, esta é a região em que (Y_1, Y_2) cai com probabilidade 95%.



Propriedades: resumo

The following are true for a random vector \mathbf{X} having a multivariate normal distribution:

1. Linear combinations of the components of \mathbf{X} are normally distributed.
2. All subsets of the components of \mathbf{X} have a (multivariate) normal distribution.
3. Zero covariance implies that the corresponding components are independently distributed.
4. The conditional distributions of the components are (multivariate) normal.

Distância estatística e anomalias

- Seja $\mathbf{Y} \sim N_k(\boldsymbol{\mu}, \boldsymbol{\Sigma})$.
- Considere a distância estatística de um ponto aleatório \mathbf{Y} até seu vetor médio $\boldsymbol{\mu}$:

$$D^2 = (\mathbf{Y} - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{Y} - \boldsymbol{\mu})$$


- Se \mathbf{Y} é um ponto aleatório, a distância D^2 também é aleatória.
- Algumas vezes esta distância é grande, algumas vezes ela é pequena.
- Qual a distribuição de probabilidade desta distância?
- Quando um ponto aleatório \mathbf{Y} poderá ser considerado anômalo?
- Quando sua distância poderá ser considerada excessiva?

Uma coordenada por vez?

- Basta olhar cada coordenada, não?
- Sabemos que cada coordenada Y_i segue uma normal.
- Neste caso, a chance de cada coordenada Y_i se afastar de sua média μ_i por mais de 2DPs σ_i é aproximadamente 5%.
- E de se afastar mais de 3 DPs σ_i é 0.3% enquanto se afastar mais de 4 DPs é apenas 0.006%.
- Assim, temos um critério para determinar se um ponto é moderadamente ou muito anômalo olhando uma coordenada de cada vez.
- Acontece que podemos fazer melhor.
- Podemos ter um ponto muito anômalo n espaço k -dimensional mas NENHUMA de suas coordenadas é anômala!!

Anomalias em k dimensões

- Para ilustrar este fenômeno, vamos considerar apenas o caso bi-dimensional.
- Veja o gráfico abaixo de uma amostra de uma normal bi-variada $N_2(\mathbf{0}, \Sigma)$ onde o valor esperado de cada variável é zero, a variância é 1 e a correlação é $\rho = 0.85$.
- O ponto vermelho é claramente uma anomalia mas olhando-se os valores de *cada uma de suas coordenadas isoladamente* não nenhuma evidência de que seja uma anomalia.



Distribuição de D^2




- Como usar o resultado abaixo?

Result 4.7. Let \mathbf{X} be distributed as $N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ with $|\boldsymbol{\Sigma}| > 0$. Then




- (a) $(\mathbf{X} - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{X} - \boldsymbol{\mu})$ is distributed as χ_p^2 , where χ_p^2 denotes the chi-square distribution with p degrees of freedom.
- (b) The $N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ distribution assigns probability $1 - \alpha$ to the solid ellipsoid $\{\mathbf{x}: (\mathbf{x} - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu}) \leq \chi_p^2(\alpha)\}$, where $\chi_p^2(\alpha)$ denotes the upper (100α) th percentile of the χ_p^2 distribution.

- Calcule a distância estatística d^2 para cada ponto \mathbf{y} .
- Plote estes distância versus um certo valor esperado sob a hipótese de normalidade.
- O plot deveria se parecer com uma linha reta com inclinação 1 e passando pela origem.
- Uma curva sistematicamente desviando-se da reta indica que a distribuição não é normal multivariada.
- Apenas um ou dois pontos desviando-se muito acima da reta indicam grandes distâncias ou anomalias.

Exemplo: N_2 sem outliers



Exemplo: N_2 com dois outliers



2-dim ou k -dim

- O mais relevante é o QQ-plot, o terceiro plot.
- Se os vetores são 2-dim, um simples scatterplot das duas variáveis mostra quais são as anomalias: QQ-plot não ajuda muito.
- A principal utilidade dos QQ-plots é quando a dimensão do vetor for maior que 2.
- Não conseguimos visualizar todas as dimensões ao mesmo tempo.
- Em R:

```
d2 = mahalanobis(x, center = mu, cov=S)
qqplot(qchisq(ppoints(length(d2))), df = ncol(x)), d2)
```

Distribuição qui-quadrado

- Vimos que D^2 segue uma distribuição qui-quadrado com k graus de liberdade quando o vetor $\mathbf{Y} \sim N_k(\boldsymbol{\mu}, \boldsymbol{\Sigma})$.
- Já encontramos esta distribuição no teste qui-quadrado.
- Esta distribuição só depende da dimensão do vetor.
- Não interessa os valores típicos nem a escala dos elementos do vetor \mathbf{Y} .
- Ela é uma métrica universal para desvios em k dimensões quando os dados são gaussianos.
- Como é a cara desta distribuição qui-quadrado?
- Ela é uma distribuição contínua com uma densidade

$$f(x) = \text{cte } x^{k/2-1} e^{-x/2}$$


Distribuição qui-quadrado

- Por exemplo:

$$f(x) = \text{cte } e^{-x/2} \quad \text{com } k = 2 \text{ degrees of freedom}$$

$$f(x) = \text{cte } x e^{-x/2} \quad \text{com } k = 4 \text{ d.f.}$$

$$f(x) = \text{cte } x^9 e^{-x/2} \quad \text{com } k = 20 \text{ d.f.}$$



Quantil de qui-quadrado

- Como $D^2 \sim \chi^2(k)$, achamos o valor de x que deixa uma proporção p da área da $\chi^2(k)$ abaixo dele.
- Este valor é chamado de quantil e denotado por $q(p)$.

quantil $p = q(p)$ tal que $\mathbb{P}(\chi^2(k) \leq q(p)) = p$

- Por exemplo, para a proporção $p = 0.65$, queremos

quantil $0.65 = q(0.65)$ tal que $\mathbb{P}(\chi^2(k) \leq q(0.65)) = 0.65$


- Sendo mais específicos, suponha que a dimensão do vetor é $k = 4$.
- Então queremos

quantil $0.65 = q(0.65)$ tal que $\mathbb{P}(\chi^2(4) \leq q(0.65)) = 0.65$

- Esta valor é $q(0.65) = 4.438$ e facilmente encontrado em R com `qchisq(0.65, 4)`.

Quantil de qui-quadrado

- Dois quantis de uma qui-quadrado com 4 graus de liberdades.
- Seta vermelha: com $p = 0.65$, o quantil $q(0.65)$
- Seta azul: com $p = 0.90$, o quantil $q(0.90)$
- Estes quantis são valores TEÓRICOS, não precisam de dados para serem obtidos, apenas da densidade de probabilidade.



Os quantis $q(p)$

- Para fazer o QQ-plot com uma amostra de tamanho n , os quantis $q(p)$ de interesse são os valores p no conjunto

$$p \in \left\{ \frac{1-0.5}{n}, \frac{2-0.5}{n}, \frac{3-0.5}{n}, \dots, \frac{n-0.5}{n} \right\}$$

- Por exemplo, se $n = 137$ então calculamos os quantis $q(p)$ para p no conjunto

$$p \in \left\{ \frac{1-0.5}{137}, \frac{2-0.5}{137}, \frac{3-0.5}{137}, \dots, \frac{137-0.5}{137} \right\} = \{0.0036, 0.0109, 0.0182, \dots, 0.9963\}$$

- A subtração de 0.5 no numerador é para evitar problemas nos extremos: não queremos o quantil associado com a proporção $p = n/n = 1$. Para manter a consistência, 0.5 é subtraído de todos os elementos.
- Se a dimensão do vetor é $k = 4$, estes quantis são obtidos em R com os comandos

```
prop = ppoints(nsim) # conjunto de pontos p
qp = qchisq(prop, df = 4)
```

Os quantis $q(p)$ e a amostra

- Sabemos que o valor teórico $q(p)$ para a distância estatística é aquele valor que deixaria aproximadamente $p100\%$ das distâncias de uma amostra abaixo dele.
- Isto é, como

$$\mathbb{P}(D^2 \leq q(p)) = p$$

então esperamos $p100\%$ dos pontos com uma distância estatística menor que $q(p)$.

- Por exemplo, com um vetor de dimensão $k = 4$, o quantil $q(0.65) = 4.438$ pois

$$\mathbb{P}(\chi^2(4) \leq 4.438) = 0.65$$

- Assim, ao calcular a distância estatística D^2 para cada ponto da amostra, esperamos que 65% deles tenham distância menor que 4.438 .

Quantil teórico e empírico

- Podemos obter uma boa estimativa do valor TEÓRICO $q(p)$ a partir da amostra.
- Calcular a distância estatística D^2 para cada ponto da amostra e *ordene os valores*:

$$D_{(1)}^2 \leq D_{(2)}^2 \leq \dots \leq D_{(n)}^2$$

- O símbolo (i) no sub-índice indica a i -ésima *estatística de ordem*.
- Considere uma proporção $p = i/n$.
- Por exemplo, suponha que $k = 4$, $n = 100$ e queremos $p = 76/100 = 0.76$.
- Temos $q(0.76) = 5.4969 = \text{qchisq}(0.76, 4)$:

$$\mathbb{P}(D^2 \leq 5.4969) = 0.76$$

Quantil teórico e empírico

- A 76-ésima estatística de ordem D_{76}^2 deixa 76% dos pontos abaixo ou igual a ela.
- Assim, se quisermos uma estimativa *EMPÍRICA* (baseada nos dados) do valor teórico $q(0.76) = 5.4969$ (obtido da densidade da χ^2), o valor D_{76}^2 é um bom candidato.
- Esperamos $D_{(76)}^2 \approx q(0.76) = 5.4969$ pois como

$$\mathbb{P}(D^2 \leq 5.4969) = 0.76 ,$$

esperamos 76% da amostra abaixo do valor teórico $q(0.76) = 5.4969$.

- Como temos exatamente 76% abaixo do valor EMPÍRICO $D_{(76)}^2$,

$$\text{proporção das variáveis } \text{leq} D_{(76)}^2 = 76/100 ,$$

podemos esperar $D_{(76)}^2 \approx q(0.76) = 5.4969$.

Então, fazendo o QQ-plot

- Tome a proporção $p = (i - 0.5)/n$ e ache o quantil TEÓRICO

$$\text{quantil } \frac{i - 0.5}{n} = q_i \text{ tal que } \mathbb{P}(\chi^2(k) \leq q_i) = \frac{i - 0.5}{n}$$

- Variamos i calculamos os quantis q_i para $i = 1, 2, \dots, n$.
- Para cada i , pareamos q_i e a i -ésima distância ordenada $D_{(i)}^2$.
- Devemos ter $q_i \approx D_{(i)}^2$ para todo i .
- Portanto, os pares $(q_i, D_{(i)}^2)$ devem cair ao longo da reta $y = x$ se os pontos são uma amostra aleatória de uma normal multivariada.

Checando em R

- Vamos simular alguns dados de uma normal multivariada e verificar que seu QQ-plot segue o padrão esperado.
- Seja $\mathbf{Y} \sim N_4(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ onde $\boldsymbol{\mu} = (4, 3, 2, 1)$ e matriz de covariância

$$\boldsymbol{\Sigma} = \begin{pmatrix} 3 & 0 & 2 & 2 \\ 0 & 1 & 1 & 0 \\ 2 & 1 & 9 & -2 \\ 2 & 0 & -2 & 4 \end{pmatrix}$$

- Vamos gerar uma amostra de `nsims=200` vetores i.i.d. desta distribuição e fazer o QQ-plot com as distâncias estatísticas.
- NOTE QUE: Na prática, temos APENAS a amostra, sem os valores teóricos $\boldsymbol{\mu}$ e $\boldsymbol{\Sigma}$, que devem ser estimados a partir dos dados.

Script R


```
require(MASS); nsims=200; set.seed(1)
Sigma = matrix(c(3,0,2,2,0,1,1,0,2,1,9,-2,2,0,-2,4),4,4)
pts = mvrnorm(nsims, c(4,3,2,1), Sigma)
m = apply(pts, 2, mean)
round(m, 3) # [1] 3.863 2.997 1.909 0.998
S = cov(pts); round(S, 2)
#      [,1] [,2] [,3] [,4]
# [1,] 2.97 -0.09 1.50 2.17
# [2,] -0.09 1.16 0.98 -0.02
# [3,] 1.50 0.98 7.87 -1.66
# [4,] 2.17 -0.02 -1.66 3.96
d2 = mahalanobis(pts, m, S)
# Passamos m e S, as ESTIMATIVAS de mu e Sigma
```

Script R


```
par(mfrow=c(1,2))
hist(d2, n=15, prob=T, main = "Histograma de D2")
rug(d2)
aux = seq(0, 15, by=0.01)
yaux = dchisq(xaux, df=ncol(pts))
lines(xaux, yaux, , lwd=2, col="blue")
qqplot(qchisq(ppoints(nrow(pts))), df = ncol(pts)), d2,
      main = expression("Q-Q plot:" * ~D^2 *
                        " x quantiles " * ~ chi[2]^2))
abline(0, 1, col = 'gray')
```


Amostra de $N_4(\mu, \Sigma)$

Histograma de D2



Q-Q plot: D^2 x quantiles χ^2_2



Amostra com outliers




Figura: Adicionando dois outliers

Script: mais dois outliers

```
set.seed(1)
pts = mvrnorm(nsim, c(4,3,2,1), Sigma)
pts = rbind(pts, c(4,3,-3,-5), c(10,6,2,4))
m = apply(pts, 2, mean); S = cov(pts)
d2 = mahalanobis(pts, m, S)
par(mfrow=c(1,2))
hist(d2, n=15, prob=T, main = "Histograma de D2"); rug(d2)
aux = seq(0, 15, by=0.01); yaux = dchisq(xaux, df=ncol(pts))
lines(xaux, yaux, , lwd=2, col="blue")
qqplot(qchisq(ppoints(nrow(pts))), df = ncol(pts)), d2,
       main = expression("Q-Q plot:" * ~D^2 *
       " x quantiles " * ~ chi[2]^2))
abline(0, 1, col = 'gray')
```