



## FUJA DE ESTATÍSTICA - P2 (NA SEMANA DA P3!)

Para a P2, a matéria é o resto do Costa Neto que não caiu na P1, ou seja, a partir do Capítulo 6.

Acredito que a matéria dessa prova é mais "mecânica" do que a da P1, por isso, as fugas serão exercícios misturados a/ explicação.

P2 - 2015

Questão 1) (2 pontos) Um experimento foi realizado visando avaliar o efeito de 2 fatores na conversão (produtividade) de um processo químico: temperatura e pressão. Por falta de tempo, não foi possível fazer o experimento com repetição. Um funcionário desatencioso deixou cair café sobre a tabela, perdendo alguns de seus valores. Felizmente, alguns cálculos já haviam sido realizados. Os resultados obtidos foram:

	1 atm	2 atm	3 atm	Soma dos $X_{ij}$ valores da linha	Soma dos $(X_{ij})^2$ valores da linha			
220 °C	5,4	29	36	17,1	97,65			
250 °C	3,2		38,99	13,8	68,04			
270 °C	3,8		34,81	13,9	66,89			
300 °C	4,6	21,16	5,2	27,04	6,1	32,21	15,9	85,41
Soma dos $X_{ij}$ valores da coluna	17	19,5	25,2					
Soma dos $(X_{ij})^2$ valores da coluna	75	96,53	146,46					

a) Ao nível de significância de 5%, existem diferenças significativas entre os fatores pressão e temperatura? (1,0)

b) Para responder à questão anterior, que hipóteses você deve que assumir? (1,0)

### Resolução

Veja que a ideia do exercício não é que você saiba fazer infinitas contas, certo? Por isso, o enunciado já deu os valores das somatórias. Esse exercício, por tratar de duas "classificações" sem repetição (7.4 - pg. 156 do Costa Neto), é similar ao exemplo da pg. 160 do C.N. (Costa Neto, para não ficar repetindo :)). Vamos dar uma olhada:

#### Exemplo (CN - pg. 160)

Numa experiência agrícola, foram usados 6 diferentes fertilizantes em 2 variedades de milho, tendo sido obtidas as colheitas dadas a seguir, em sacas, por os vários canteiros de mesma área que foram plantados:

Fertilizantes    A    B    C    D    E    F

Variedade 1:    5,4    3,2    3,8    4,6    5,0    4,4

Variedade 2:    5,7    4,0    4,2    4,5    5,3    5,0

Utilizar a Análise de Variancia para verificar se



existem diferenças significativas entre os fertilizantes e entre as variedades ao nível de 1% de significância.

Viv a semelhança? Sim, essa é a matéria do Capítulo 7, Computação de várias médias. Como o próprio nome já diz, iremos comparar várias médias através de uma técnica chamada Análise de Variância.

Para realizarmos esse estudo, partimos de uma Hipótese inicial,  $H_0$ , de que as médias são iguais:

$$H_0: \mu_1 = \mu_2 = \dots = \mu_k$$

em oposição à hipótese alternativa, que é de pelo menos uma das médias serem diferentes.

### Hipóteses do MODELO

Para usar a Análise de Variância, adotamos as seguintes hipóteses implícitas básicas:

\* As populações tenham a mesma variância (homocedasticidade)

em outras palavras...

$H_0$  é a hipótese de que todos os valores experimentais são igualmente distribuídos

\* A variável de interesse seja normalmente distribuída em todas as populações

Notamos que a ideia é analisar se há efeito na aplicação de diferentes tratamentos na população!

2) Notação

- $T_i = \sum_{j=1}^n x_{ij} =$  soma dos valores da  $i$ -ésima amostra,
  - $Q_i = \sum_{j=1}^n x_{ij}^2 =$  soma das quadrados dos valores da  $i$ -ésima amostra,
  - $T = \sum_{i=1}^k T_i = \sum_{i=1}^k \sum_{j=1}^n x_{ij} =$  soma total dos valores,
  - $Q = \sum_{i=1}^k Q_i = \sum_{i=1}^k \sum_{j=1}^n x_{ij}^2 =$  " " dos quadrados,
  - $\bar{x}_i = \frac{T_i}{n} =$  média da amostra  $i$
  - $\bar{x} = T/nk =$  média de todos os valores
  - $k =$  nº de amostras
  - $n =$  tamanho de uma amostra
  - $SQT =$  soma de quadrados total
  - $s_T^2 =$  estimativa total
  - $s_{AE}^2 =$  estimativa-entre amostras (tamanho  $\odot$ )
  - $SQE =$  soma de quadrados entre amostras
  - $s_R^2 =$  (estimativa) residual (tamanho  $\odot$ )  $SQT$
  - $SQR =$  soma de quadrados residual  $nk - 1$
  - $SQC =$  soma de quadrados entre colunas
  - $SQ_L =$  " " " " linhas
  - $SQT_v =$  " " " " tratamentos
- } Aparece só em algumas!



## TIPOLOGIA

\*Uma Classificação - Amostras de mesmo tamanho

$$S_T^2 = \frac{Q - (T^2/nk)}{nk - 1} \quad \cdot \quad SQT = Q - (T^2/nk)$$

$$S^2 = \frac{\sum_{i=1}^k T_i^2}{n} \quad \cdot \quad SQE = \frac{\sum_{i=1}^k T_i^2}{n} - \frac{T^2}{nk}$$

$$S^2_E = \frac{\sum_{i=1}^k T_i^2 / n - T^2 / nk}{k - 1}$$

$$S^2_R = \frac{Q - (\sum_{i=1}^k T_i^2 / n)}{k(n-1)} \quad \cdot \quad SQR = Q - (\sum_{i=1}^k T_i^2 / n)$$

$$SQT = SQE + SQR$$

$$F_{\text{calculado}} = \frac{S^2_E}{S^2_R} \quad \cdot \quad F_{\text{critico}} = F_{k-1, k(n-1), \alpha}$$

### ANOVA

Fonte de Variação	Soma dos quadrados	Graus de liberdade	Quadrado médio	$F_{\text{calc}}$	$F_{\alpha}$
Entre amostras	SQE	$k - 1$	$S^2_E$	$F_{\text{calc}}$	$F_{\text{crit}}$
Residual	SQR	$k(n - 1)$	$S^2_R$		
Total	SQT	$nk - 1$			

\*Uma Classificação - Amostras de tamanho diferentes

$$S^2_T = \frac{Q - \left( \frac{T^2}{\sum_{i=1}^k n_i} \right)}{\sum_{i=1}^k n_i - 1}$$

$$SQT = Q - \left( \frac{T^2}{\sum_{i=1}^k n_i} \right)$$

CANSEI de copiar de novo (haha).

$$S^2_E = \frac{\sum_{i=1}^k (T_i^2 / n_i) - \left( \frac{T^2}{\sum_{i=1}^k n_i} \right)}{k - 1} = \frac{SQE}{k - 1}$$

$$S^2_R = \frac{Q - \sum_{i=1}^k (T_i^2 / n_i)}{\left( \sum_{i=1}^k n_i \right) - k} = \frac{SQR}{\left( \sum_{i=1}^k n_i \right) - k}$$

$$SQT = SQE + SQR$$

$$F_{calculado} = \frac{S^2_E}{S^2_R}$$

$$F_{critico} = F_{k-1, (\sum n_i) - k, \alpha}$$

ANOVA

Fonte de variação	Soma dos Quadrados	Graus de Liberdade	Quadrado médio	$F_c$ / $F_{cal}$
Entre as amostras	SQE	$k - 1$	$S^2_E$	$F_{cal}$ / $F_{crit}$
Residual	SQR	$(\sum n_i) - k$	$S^2_R$	
Total	SQT	$(\sum n_i) - 1$		



\* Duas classificações - SEM REPETIÇÃO

↳ classificações cruzadas, tipo ao Ex. da P2 de 2015!

Agora são duas hipóteses, reais:


$$H_{01}: \mu_{1.} = \mu_{2.} = \dots = \mu_{k.} \quad (\text{linhas})$$

$$H_{02}: \mu_{.1} = \mu_{.2} = \dots = \mu_{.n} \quad (\text{colunas})$$

para  $nk$  observações

A aceitação de uma não influencia na aceitação da outra

Agora fica mais difícil! Devemos considerar a interação entre as classificações.



Nota que a interação influencia na parte residual. Por isso, é válido saber do que estamos tratando:

- MODELO FIXO:  $k$  são populações → hipótese de inexistência de interação
- MODELO ALEATÓRIO:  $k$  são  $z$  variáveis → sem hipóteses adicionais aleatórias

Agora será preciso adotar mais algumas notações:

" NOTAÇÕES ADICIONAIS "

•  $T_i = \sum_{j=1}^k x_{ij}$  = soma dos valores da  $i$ -ésima linha

•  $T_j = \sum_{i=1}^n x_{ij}$  = " " "  $j$ -ésima coluna

•  $Q_i = \sum_{j=1}^k (x_{ij})^2$  = soma dos quadrados dos valores da  $i$ -ésima linha

•  $Q_j = \sum_{i=1}^n (x_{ij})^2$  = " " " da  $j$ -ésima coluna

•  $T = \sum_{i=1}^n T_i = \sum_{j=1}^k T_j$  •  $\bar{x}_i = T_i/n$  = média da  $i$ -ésima linha

•  $Q = \sum_{j=1}^k Q_j = \sum_{i=1}^n Q_i$  •  $\bar{x}_j = T_j/k$  = média da  $j$ -ésima coluna

•  $\bar{\bar{x}} = T/nk$  = média de todos os valores.

Agora sim podemos ver a esquerda de fórmulas e ANOVA deste caso

•  $S^2_L$  = estimativa entre linhas

•  $S^2_C$  = " " " colunas



$$S_T^2 = \frac{Q \cdot (T^2 / nk)}{nk - 1} = \frac{SQT}{nk - 1}$$

$$S_L^2 = \frac{\sum_{i=1}^k T_i^2 / n - T^2 / nk}{k - 1} = \frac{SQL}{k - 1}$$

$$S_C^2 = \frac{\sum_{j=1}^n T_j^2 / k - T^2 / nk}{n - 1} = \frac{SQC}{n - 1}$$

$$S_R^2 = \frac{Q - \frac{\sum_{i=1}^k T_i^2}{n} - \frac{\sum_{j=1}^n T_j^2}{k} + T^2}{nk - n - k + 1} = \frac{SQR}{(n-1)(k-1)}$$

$$SQT = SQL + SQC + SQR$$

$$F_{\text{calc de linha}} = F_L = \frac{S_L^2}{S_R^2} \cdot F$$

$$F_{\text{calc de coluna}} = F_C = \frac{S_C^2}{S_R^2}$$

$$F_{\text{crítico para linha}} = F_{\text{crit}, l} = F_{k-1, (k-1)(n-1), \alpha}$$

$$F_{\text{crítico para coluna}} = F_{\text{crit}, c} = F_{n-1, (k-1)(n-1), \alpha}$$

MODELO FIXO  
 AQUI CONSIDERAMOS SEM  
 INTERAÇÃO!

ANOVA

Fonte de Variação	Soma de Quadrados	Graus de Liberdade	Quadrado médio	F	F <sub>α</sub>
Entre linhas	S <sub>QL</sub>	k-1	s <sup>2</sup> <sub>L</sub>	F <sub>L</sub>	F <sub>crit, L</sub>
Entre colunas	S <sub>QC</sub>	n-1	s <sup>2</sup> <sub>C</sub>	F <sub>C</sub>	F <sub>crit, C</sub>
Resíduo	S <sub>QR</sub>	(k-1)(n-1)	s <sup>2</sup> <sub>R</sub>		
Total	S <sub>QT</sub>	nk-1			

\* Duas classificações - COM REPETIÇÃO

Agora o total de observações é igual a rkn,  
 para r sendo as repetições.

Para cada um dos (n.k) tratamentos, é possível  
 ter uma estimativa de  $\sigma^2$ . Logo, surge uma nova  
 parcela a ser considerada, S<sub>QTr</sub>. Como a soma  
 dos quadrados é s<sup>2</sup><sub>T</sub>, como estimativa

$$SQT = SQT_r + SQR$$

$$nkr - 1 = (nk - 1) + nk(r - 1)$$

Para testar a igualdade de todos os nk tratamentos,  
 usar o modelo de "Uma classificação - Amostras de



mesmo tamanho. Caso não aceite, prova-se que  $S^2_T$  e  $S^2_R$  são independentes.

Decompondo em tratamentos por linhas e colunas:

$$SQL = \frac{\sum_{i=1}^k T_i^2}{nr} - \frac{T^2}{nkr}$$

$$SQC = \frac{\sum_{j=1}^n T_j^2}{kv} - \frac{T^2}{nkr}$$

$$SQT_r = \frac{\sum_{i=1}^k \sum_{j=1}^n T_{ij}^2}{r} - \frac{T^2}{nkr}$$

Através dessa fórmula que se acha  $SQT$

$$SQT_r = SQL + SQC + SQT$$

$$F_I = F_{\text{calculado da interação}} = \frac{S_I^2}{S^2_R}$$

$$F_{Tr} = F_{\text{calculado entre tratamentos}} = \frac{S_{Tr}^2}{S^2_R}$$

$$F_{\text{crit}, I} = F_{\text{crítico da interação}} = F_{(k-1)(n-1), nk(r-1), \alpha}$$

$$F_{\text{crit}, Tr} = F_{\text{crítico entre tratamentos}} = F_{k-1, nk(r-1), \alpha}$$

Aqui testamos a interação!

### ANOVA

Fonte de Variação	Soma de Quadrados	Graus de liberdade	Quadrado médio	F	F <sub>α</sub>
Entre Linhas	SQ <sub>L</sub>	k-1	S <sub>L</sub> <sup>2</sup>	F <sub>L</sub>	
Entre colunas	SQ <sub>C</sub>	n-1	S <sub>C</sub> <sup>2</sup>	F <sub>C</sub>	
Interação	SQ <sub>I</sub>	(k-1)(n-1)	S <sub>I</sub> <sup>2</sup>	F <sub>I</sub>	F <sub>α, I</sub>
Entre tratamentos	SQ <sub>T<sub>v</sub></sub>	nk-1	S <sub>T<sub>v</sub></sub> <sup>2</sup>	F <sub>T<sub>v</sub></sub>	F <sub>α, T<sub>v</sub></sub>
Residual	SQ <sub>R</sub>	nk(v-1)	S <sub>R</sub> <sup>2</sup>		
Total	SQ <sub>T</sub>	nkv-1	S <sub>T</sub> <sup>2</sup>		

•  $SQ_R = SQ_T - SQ_{T_v}$

•  $SQ_T = Q - \frac{T^2}{nk}$

•  $S_R^2 = \frac{SQ_R}{nk(v-1)}$

**Atenção:** O teste para interação deve ser realizado quando for modelo aleatório em "duas classificações - sem repetição"!

O teste anterior foi realizado para a verificação de interação e entre os tratamentos!



Se o resultado desse teste der que há interação,  
para testar se há influência de linhas e colunas,  
utilizamos:

$$F_C = \left| F_{\text{calculado entre linhas}} = \frac{S^2_L}{S^2_I} \right|$$

$$F_L = \left| F_{\text{calculado entre colunas}} = \frac{S^2_C}{S^2_I} \right|$$

$$F_{\text{crit. L}} = \left| F_{\text{crítico entre linhas}} = F_{K-1, (K-1)(n-1), \alpha} \right|$$

$$F_{\text{crit. C}} = \left| F_{\text{crítico entre colunas}} = F_{n-1, (K-1)(n-1), \alpha} \right|$$

Se NAO <sup>~</sup>haver interação, usamos no denominador  
o  $S^2_R$  mesmo.

Veja que, caso haja influência da interação, não  
faz sentido testar a influência global da classifica-  
ção entre linhas e entre colunas!

Agora que já vimos os casos com a aplicação  
de ANOVA, podemos resolver o exercício 1 e  
o exemplo!

Q1- P1-2015)

a)  $\alpha = 5\%$ , verificar se existe diferenças significativas entre pressão e temperatura?

Veja que este é um exercício de 2 classificações cruzadas sem repetição (FOLHA 4 deste Resumo/Resolução DA P2+2015)! Veja que NAO é preciso ficar fazendo contas eternas de somatória! Porquê? Simples! A ideia da prova foi avaliar o conceito da questão, e não se sua calculadora é boa ou se você tem paciência e a ênfase em fazer infinitas contas.

Na tabela  $d_1 d_2$ , as números que usamos estão intactos, são eles:

TAUTO FAZ!

$$\begin{aligned} Q &= 75 + 96,53 + 146,6 = 317,99 \\ T &= 17 + 19,5 + 24,2 = 60,7 \\ Q &= 97,65 + 68,04 + 66,89 + 85,41 = 317,99 \\ T &= 17,1 + 13,8 + 13,9 + 15,9 = 60,7 \end{aligned}$$

Veja que, para  $(T_j)^2$  e  $(T_i)^2$ , temos que elevar ao quadrado os valores de  $T_i$  e  $T_j$  da tabela dada. Logo.

PARA $(T_j)^2$ :	1 <sup>o</sup> tm	2 <sup>o</sup> tm	3 <sup>o</sup> tm	$\Sigma$
$T_j$	17	19,5	24,2	60,7
$(T_j)^2$	289	380,25	585,64	1254,89



PARA $(T_i)^2$	220°C	250°C	270°C	300°C	$\Sigma$
$T_i$	17,1	13,8	13,9	15,9	60,7
$(T_i)^2$	292,41	190,44	193,21	252,81	928,87

Calculando as estimativas:

$$s_T^2 = \frac{Q - (T^2/n.k)}{nk-1} = \frac{SQT}{nk-1} = \frac{317,99 - (60,7^2/3,4)}{3,4-1}$$

$$s_T^2 = 10,949167$$

(1) → grau de liberdade

$$s_L^2 = \frac{\sum_{i=1}^k T_i^2/n - T^2/n.k}{k-1} = \frac{SQL}{k-1}$$

$$= \frac{928,87/3 - (60,7)^2/3,4}{4-1} = 2,5825$$

(3) → grau de liberdade

$$s_L^2 = 0,8608$$

$$s_C^2 = \frac{\sum_{j=1}^n T_j^2/k - T^2/n.k}{n-1} = \frac{SQC}{n-1}$$

$$= \frac{1254,89/4 - (60,7)^2/3,4}{3-1} = 6,6817$$

(2) → grau de liberdade

$$s_C^2 = 3,3408$$

$$s_r^2 = Q - \frac{\sum_{i=1}^k T_i^2}{n} = \frac{\sum_{j=1}^m T_j^2}{k} - \frac{T^2}{nk}$$

$$= \frac{SQR}{(n-1)(k-1)}$$

Dá para resolver o SQR desse jeito ou do jeito "traquinês". Temos SQT, SQC e SQL. Sabemos que:

$$SQR = SQL + SQC + SQR$$

$$10,949167 = 2,5825 + 6,6812 + SQR$$

$$SQR \approx 1,685$$

Logo:

$$s_r^2 = \frac{1,685}{(3-1)(3-1)} = \frac{1,685}{2 \cdot 3} = 0,2808$$

→ 6 - grau de liberdade

CONSTRUINDO NOSSA ANOVA:

FONTE de VARIAÇÃO	SOMA DE QUADRADOS	GRAUS DE LIBERDADE	QUADRADO MÉDIO	F	F <sub>α</sub>
Entre linhas	SQL = 2,5825	3	0,8608 (s <sub>L</sub> <sup>2</sup> )	3,02	4,76
Entre colunas	SQC = 1,68	2	3,3408 (s <sub>C</sub> <sup>2</sup> )	11,90	5,14
Residual	SQR = 1,685	6	0,2808 (s <sub>R</sub> <sup>2</sup> )		
Total	SQT = 10,949167	11			

vja como encontramos  
na prói. pag!



CALCULADOS

$$F_{\text{entre Linhas}} = \frac{S^2_i}{S^2_R} = \frac{0,8608}{0,2808} \approx 3,07 \downarrow$$

$$F_{\text{entre colunas}} = \frac{S^2_c}{S^2_R} = \frac{3,3408}{0,2808} \approx 11,90 \downarrow$$

CRÍTICOS

$F_{\text{crítico entre Linhas}} = F_{3, 6, 5\%} = 9,76 \downarrow$

grau de liberdade de SQL  $\uparrow$  nível de significância  
grau de liberdade de SQL  $\downarrow$

$F_{\text{crítico entre colunas}} = F_{2, 6, 5\%} = 14,54 \downarrow$

grau de liberdade de SQL  $\uparrow$  nível de significância  
grau de liberdade de SQL  $\downarrow$


COMO VER UMA TABELA DE F de Snedecor

Para um  $F_{v_1, v_2, \alpha}$

1º passo  $\Rightarrow$  Achar a tabela referente ao seu nível de significância ( $\alpha$ ).

$P = \alpha \downarrow$

2º passo  $\Rightarrow v_1$  é a coluna e  $v_2$  é a linha. Você achou um valor. Esse é seu valor!



Logo:

$F_{critico} < F_{calc} \rightarrow$  fator apresenta diferença  
para o  $\alpha$  especificado  $\rightarrow$  Rejeita  $H_0$

(Temp)  $4,76 > 3,07 \rightarrow$  Aceita  $H_0$

(pres.)  $5,14 < 11,90 \rightarrow$  Rejeita  $H_0$

À um nível de significância de 5%, é possível averiguar que o fator pressão apresenta diferença.

b) Populações com mesma variância (homocedasticidade)

- Variável de interesse seja normalmente distribuída em todas as populações.

Essas duas garantem que  $H_0$  seja a hipótese de que os usuários experimentais são igualmente distribuídos!

Questão 2) (3 pontos) A 1ª prova de PRO 3200 ocorreu no dia 19/10/15, às 7:30 da manhã (Nota do Autor do resumo/resolução de P2-2015: de fato ocorreu e, infelizmente, não foi pouco...). "Acesso" aqui quer dizer um clique de algum aluno online em um dos recursos do AVA.

Nessa hora, percebi que era mais fácil simplesmente anexar uma cópia da prova do que copiá-la... Sim, mulher não comentamos... Os enunciados estão em anexo.

Resolução


Sim, agora o assunto é Regressão e Correlação (CN - Capítulo 8).



Este é um dos assuntos mais fáceis de visualizar em exemplos do nosso cotidiano, como os gráficos de dispersão de pontos e análises gráficas de Laboratório Experimental de Física.

Aideia é, com um conjunto de dados, analisar um comportamento médio.

## • Correlação Linear



Via os gráficos acima. A ideia é que, para um conjunto de pares de dados, é possível averiguar uma correlação, ou seja, a tendência de comportamento das variáveis consideradas. Positiva se a reta é ascendente, ou seja,  $x$  cresce com o  $y$ , ou negativa, se a reta é descendente, ou seja,  $x$  decresce com o  $y$ .

Você já usou a função gráfico do Excel? É possível fazer a linha de tendência (sim, a correlação linear seria a linha linear) com um coeficiente  $r$ . Sim, o  $r$  é o coeficiente de correlação linear de Pearson.

$$r = \frac{S_{xy}}{S_x \cdot S_y} = \frac{\text{cov}(x, y)}{S_x \cdot S_y}$$

→ covariância entre  $x$  e  $y$   
 → produto dos desvios padrões de  $x$  e  $y$  (amostras)

$$S_x = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}} \quad S_y = \sqrt{\frac{\sum_{i=1}^n (y_i - \bar{y})^2}{n-1}}$$

$$S_{xy} = \text{cov}(x, y) = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{n-1}$$

Vale a pena lembrar que:

$$S_{xx} = \sum_{i=1}^n (x_i - \bar{x})^2 = \sum x_i^2 - \frac{(\sum x_i)^2}{n}$$

$$S_{yy} = \sum_{i=1}^n (y_i - \bar{y})^2 = \sum y_i^2 - \frac{(\sum y_i)^2}{n}$$

$$S_{xy} = \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = \sum x_i y_i - \frac{\sum x_i \sum y_i}{n}$$

Então,  $r$  pode ser:

$$r = \frac{S_{xy}}{S_x \cdot S_y} = \frac{S_{xy} / (n-1)}{\sqrt{\frac{S_{xx}}{n-1}} \cdot \sqrt{\frac{S_{yy}}{n-1}}} = \frac{(1/(n-1)) S_{xy}}{(1/(n-1)) \sqrt{S_{xx} S_{yy}}}$$

$$r = \frac{S_{xy}}{\sqrt{S_{xx} \cdot S_{yy}}}$$

Acho legal saber usar as diferentes notações, porque o exercício pode te dar um dado que só usado em um dos métodos ou por questão de tempo mesmo.



## • TESTES DO $r$

Na pegada da  $P1$ , o  $r$  é o coef. de correlação amostral. Mas, e se quisermos testar a validade de  $r$  para uma população? Por isso, há o teste para  $\rho$ , o coeficiente de correlação populacional.

Para verificar se há correlação linear:

$$\left. \begin{array}{l} H_0: \rho = 0 \\ H_1: \rho \neq 0 \end{array} \right\} t_{\text{cal}} = r \sqrt{\frac{n-2}{1-r^2}}$$

$$t_{\text{crit}} = t_{n-2} \quad \left( \begin{array}{l} \text{pode ser} \\ \text{feito} \\ \text{unilateral-} \\ \text{mente} \end{array} \right)$$

Para a hipótese de  $\rho$  igual a outro valor, há uma fórmula de Fisher, mas zero pouco provável de cair.

$$r_{\text{fisher}} = \frac{1}{2} \ln \frac{1+r}{1-r}, \text{ sendo } \mu(r) = \frac{1}{2} \ln \frac{1+\rho}{1-\rho}$$

$$\sigma(r) = \sqrt{\frac{1}{n-3}}$$


Vantagem dessa abordagem é que a distribuição é próxima da normal. Essa abordagem é usada p/ intervalos de confiança.

$$P(d_1 - z_{\alpha/2} \cdot \sigma(r) < \mu(r) < d_1 + z_{\alpha/2} \cdot \sigma(r)) = 1 - \alpha$$

## • Regressão

Determinar uma função que exprima o relacionamento entre as variáveis (graficamente, a linha de regressão).

Analisar que



há variações  
residuais em torno  
da regressão  
teórica

Aqui, iremos tratar da regressão linear

$$y = \alpha + \beta x + \psi$$

componente aleatório  
de variação de  $y$

EQUAÇÃO TEÓRICA  
 DA REGRESSÃO  
 LINEAR

$\alpha$  e  $\beta$  } coeficientes de  
 regressão  
 linear

Na prática, testamos  $\frac{a}{2}$  e  $\frac{b}{2}$  teóricos

como coeficientes que são parâmetros de  $\alpha$  e  $\beta$ , respectivamente ( $\hat{y} = a + bx$ ), para a estimativa

### • Métodos PARA DETERMINAR $a$ e $b$ .

1º - "O MAIS COXA" - TRAÇAR UMA RETA

↳ Sim, simplesmente traçar uma reta no gráfico de dispersão = fim de reduzir as distâncias desta em relação aos pontos. (NÃO CAI - óbvio...)

2º - Mínimos quadrados - reduzir ao mínimo os valores das variâncias.

$$\min \sum d_i^2 = \min \sum (y_i - \hat{y}_i)^2 = \min \sum (y_i - a - bx_i)^2$$

derivando em  $a$  e  $b$  e igualando a 0:

$$-2 \sum (y_i - a - bx_i) = 0$$

$$-2 \sum x_i (y_i - a - bx_i) = 0$$



Desenvolvendo o sistema, chegamos em:

$$\begin{cases} b = \frac{\sum (x_i - \bar{x})y_i}{\sum (x_i - \bar{x})^2} = \frac{S_{xy}}{S_{xx}} \\ a = \bar{y} - b\bar{x} \end{cases}$$

IMPORTANTE

Veja que saber calcular  $S_{xy}$ ,  $S_{xx}$  e  $S_{yy}$  é essencial para esta parte.

Para reta passando pela origem, basta estimar  $b$  como  $\frac{\sum x_i y_i}{\sum x_i^2}$ .

## INDUÇÃO QUANTO AOS PARÂMETROS DA RETA

$H_0: \beta = 0$  (Não há regressão) } Hipótese iniciais  
 $H_1: \beta \neq 0$

### CONSIDERAÇÕES

$$s^2_R = \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

$n-2$   
↳ ( $\alpha$  e  $\beta$ )

$$\hat{y}_i = \bar{y} - b\bar{x} + bx_i$$

$$\sum (\hat{y}_i - \bar{y})^2 = b^2 \sum (x_i - \bar{x})^2$$

$$\sum (\hat{y}_i - \bar{y})^2 = b^2 \cdot S_{xx} = b S_{xy} = \frac{S_{xy}^2}{S_{xx}}$$

$$\bullet \sum (y_i - \hat{y}_i)^2 = S_{yy} - b S_{xy}$$

$$\begin{aligned}
 S_R^2 &= \frac{S_{yy} - b S_{xy}}{n-2} = \frac{S_{yy} - b^2 S_{xx}}{n-2} \\
 &= \frac{S_{yy} - S_{xy}^2 / S_{xx}}{n-2} \\
 &= \frac{S_{yy} (1 - r^2)}{n-2}
 \end{aligned}$$

*Importante!*

$$\bullet S_{yy} = \sum (y_i - \bar{y})^2 = \sum (y_i - \hat{y}_i)^2 + \sum (\hat{y}_i - \bar{y})^2$$

$$\bullet r^2 = \frac{b \cdot S_{xy}}{S_{yy}} = \frac{S_{xy}}{S_{xx}} \frac{S_{xy}}{S_{yy}} = \frac{S_{xy}^2}{S_{xx} S_{yy}} = \text{coeficiente de determinação}$$

$$\bullet (1 - r^2) = \text{coeficiente de indeterminação}$$

↳ em geral, para  $|r| \geq 0,9$ , a regressão explica a maioria da variação.

## Estimacões e teste de parâmetros da reta de regressão

• Estimador  $b$

$$\begin{aligned}
 \mu(b) &= \beta & \sigma^2(b) &= \frac{\sigma_R^2}{S_{xx}} \quad \begin{array}{l} \rightarrow \text{não conhecemos} \\ \sigma_R^2 \end{array} \\
 & & & \rightarrow \text{estima-se} \Rightarrow s^2(b) = \frac{S_R^2}{S_{xx}}
 \end{aligned}$$



- Testando  $H_0: \beta = \beta_0$  ↙ distribuição normal

$$t_{calc} = \frac{b - \beta_0}{SR / \sqrt{S_{xx}}} \quad t_{crit} = t_{n-2}$$

↳ pl  $\beta = 0$  na hipótese

$$t_{crit} = r \sqrt{\frac{n-2}{1-r^2}}$$

- Analogamente, para  $a$ :

$$\mu(a) = \alpha \quad \sigma^2(a) = \frac{\sigma^2 R^2 \sum x_i^2}{n S_{xx}}$$

↘ Não sabemos

↳ estimar  $\sigma^2 = S^2(a) = \frac{S_R^2 \sum x_i^2}{S_{xx} n}$

- Testando  $H_0: \alpha = \alpha_0$

$$t_{calc} = \frac{a - \alpha_0}{\sqrt{S^2(a)}}$$

↙ distribuição normal

Intervalos de confiança pl  $\alpha + \beta x'$  e  $y'$

- IC pl  $\alpha + \beta x'$  o/base na estimativa  $\hat{y}'$

$$\mu(\hat{y}') = \alpha + \beta x'$$

$$\sigma^2(\hat{y}') = \sigma^2 R^2 \left[ \frac{1}{n} + \frac{(x' - \bar{x})^2}{S_{xx}} \right]$$

↳ estimar pl  $SR^2$

$x'$  = um valor de  $x$   
 $\hat{y}'$  = valor de  $y$  para  $x'$

$$\hat{y}' \pm t_{n-2, \alpha/2} \cdot SR \sqrt{\frac{1}{n} + \frac{(x' - \bar{x})^2}{S_{xx}}}$$

$$\hat{y}' = a + bx'$$

Se variarmos  $x'$ , podemos determinar a "região de confiança" para  $\alpha + \beta x'$ .

• Para o intervalo de previsão:

$$\hat{y}' \pm t_{n-2, \alpha/2} \cdot SR \sqrt{1 + \frac{1}{n} + \frac{(x' - \bar{x})^2}{S_{xx}}}$$

Analogamente, variando  $x'$ , teremos a "região de previsão para  $y'$ ".

MAS QUAL É A DIFERENÇA??

- Intervalo de confiança de  $\alpha + \beta x'$  →

↳ Você parte de um  $x'$  (determinado  $x$ ) para estimar e/ou prever  $y'$  (valor da reta de regressão estimado p/ um  $x'$ ).

- Intervalo de previsão de  $y'$ .

↳ Você determina o intervalo no qual o  $Y$  experimental  $x$  encontra p/ um  $\alpha$  determinada significância.  
vc usa

Q2-P2 - 2015)



a) Determinar a reta de regressão

Tradução... ⇒ determine os valores de  $a$  e  $b$ .

$$b = \frac{S_{xy}}{S_{xx}} \Rightarrow S_{xy} = \sum x_i y_i - \frac{\sum x_i \sum y_i}{n}$$

$$S_{xx} = \sum x_i^2 - \frac{(\sum x_i)^2}{n} = 39939 - \frac{147 \cdot 4921}{14}$$

$$= 1771 - \frac{(147)^2}{14} = -11.736,5$$

$$= 227,5$$

$$b = \frac{S_{xy}}{S_{xx}} = -\frac{11.736,5}{227,5}$$

$$= -51,59$$

$$a = \bar{y} - b\bar{x} = 351,50 - (-51,59) \cdot (10,50)$$

$$a = 893,195$$

$$\hat{y} = 893,195 - 51,59x$$

b)  $\alpha = 5\%$ , é possível averiguar com certeza negativa?

Hipóteses Iniciais

$$\begin{aligned}
 H_0: \beta &= 0 \\
 H_1: \beta &< 1
 \end{aligned}$$

$$t_{\text{calc}} = \frac{b - \beta_0}{SR \cdot A \cdot S_{xx}}$$

$$* S_R = \frac{S_{yy} - b S_{xy}}{n - 2}$$

$$\bullet S_{yy} = \sum y_i^2 - \frac{(\sum y_i)^2}{n} =$$

$$2360653 - \frac{(9921)^2}{14} = 630921,5$$

$$\bullet S_{xy} = \text{item anterior} = -11736,5$$

$$* S_R^2 = \frac{630921,5 - (-51,59) \cdot (-11736,5)}{14 - 2}$$

$$S_R^2 = 2119,62$$

$$t_{\text{calc}} = \frac{-51,59}{\sqrt{\frac{2119,62}{222,5}}} = 16,902$$

$$t_{\text{critico}} = t_{n-2, \alpha_2} = t_{12, 5\%} = -1,782$$



$t_{calc} < t_{crit} \Rightarrow$  Rejeita  $H_0$ .

Anível de 5% de significância, o possível é afirmar que há correlação negativa.

c) Intervalo de confiança p/  $\alpha$  e  $\beta$  da nota teórica.

•  $\beta$

$$b - t_{2,5\%, 12} \cdot \sqrt{\frac{SR^2}{S_{xx}}} \leq \beta \leq b + t_{2,5\%, 12} \cdot \sqrt{\frac{SR^2}{S_{xx}}}$$

•  $b = -51,59$

•  $t_{2,5\%, 12} = 2,179$

•  $SR^2 = 2119,62$

•  $S_{xx} = 227,50$

IC de  $\beta$ :

$$-58,24 \leq \beta \leq -44,94$$

Ver folha (13)

Estas fórmulas são as mesmas de  $\alpha$  e  $\beta$  mas só que não testamos hipótese.

•  $\alpha$

$$a - t_{2,5\%, 12} \cdot \sqrt{\frac{SR^2}{S_{xx}}} \leq \alpha \leq a + t_{2,5\%, 12} \cdot \sqrt{\frac{SR^2}{S_{xx}}}$$

$$S^2(\alpha) = \frac{SR^2}{S_{xx}} \cdot \frac{\sum x_i^2}{n} = \frac{2119,62}{227,50} \cdot \frac{7771}{14} = 1178,60$$

IC de  $\alpha$ :

$$818,39 \leq \alpha \leq 968,01$$

Q3 - P2 - 2015 -> Continuação de matéria de Regressão e correlação linear.

• REGRESSÃO POLINOMIAL

•  $y = a + \beta x + \gamma x^2$  (função de regressão)

$\hat{y} = a + bx + cx^2$  (estimativa)

$$\begin{cases} \sum y_i = na + c \sum (x_i - \bar{x})^2 \\ \sum (x_i - \bar{x}) y_i = b \sum (x_i - \bar{x})^2 \\ \sum (x_i - \bar{x})^2 y_i = a \sum (x_i - \bar{x})^2 + c \sum (x_i - \bar{x})^4 \end{cases}$$

Este sistema provém das derivadas parciais do sistema original que considera as  $k+1$  estimativas.

Esses 4 tópicos são básicos de cálculo por fórmula

• REGRESSÃO LINEAR MÚLTIPLA

•  $\hat{y} = a + b_1 x_1 + b_2 x_2$   
MMD

$x_{1j}, x_{2j}$

$$\begin{cases} \sum y_j = na + b_1 \sum x_{1j} + b_2 \sum x_{2j} \\ \sum x_{1j} y_j = a \sum x_{1j} + b_1 \sum x_{1j}^2 + b_2 \sum x_{1j} x_{2j} \\ \sum x_{2j} y_j = a \sum x_{2j} + b_1 \sum x_{1j} x_{2j} + b_2 \sum x_{2j}^2 \end{cases}$$

$S_{1y} = b_1 S_{11} + b_2 S_{12} + \dots + b_k S_{1k}$

$S_{2y} = b_1 S_{21} + b_2 S_{22} + \dots + b_k S_{2k}$

⋮

$S_{ky} = b_1 S_{k1} + b_2 S_{k2} + \dots + b_k S_{kk}$

$S_{iy} = \sum_{l=1}^k b_l S_{il} \quad (i=2, 2, \dots, k)$



• Correlação linear múltipla:

$$R = \sqrt{\frac{b_1 S_{xy} + b_2 S_{xy} + \dots + b_k S_{xy}}{S_{yy}}} \quad \left( \begin{array}{l} \text{coef. de} \\ \text{correlação} \\ \text{linear} \end{array} \right)$$

$$S_M^2 = \frac{S_{yy} - \sum_{i=1}^k b_i S_{xy}}{n - k - 1} \quad \left( \begin{array}{l} \text{VARIÂNCIA} \\ \text{RESIDUAL} \end{array} \right)$$

• Correlação parcial e variáveis fictícias.

↳ não contemplei esses assuntos pq me faltavam que não foi passado...

ANÁLISE DE VARIÂNCIA APLICADA À REGRESSÃO

• teste de regressão linear

$$\sum (y_i - \bar{y})^2 = \sum (\hat{y}_i - \bar{y})^2 + \sum (y_i - \hat{y}_i)^2$$

$$S_y^2 = \frac{\sum (y_i - \bar{y})^2}{n-1} = \frac{S_{yy}}{n-1} \quad \left( \begin{array}{l} \text{variância Ajustada} \\ \text{de } y \end{array} \right)$$

$$S_R^2 = \frac{\sum (y_i - \hat{y}_i)^2}{n-2} = \frac{S_{yy} - b^2 S_{xx}}{n-2}$$

↳ Considerando mais el quis desen volver mas...

$$F_{calc} = \frac{b^2 S_{xx}}{S_R^2}$$

TESTE SERÁ SEMPRE UNILATERAL

$$F_{\text{crit}} = F_{v_1, v_2, \alpha}$$

### ANOVA

Fonte de variação	Soma de quadrados	Grau de liberdade	Quadrado médio	F	F <sub>α</sub>
Regressão	$b^2 S_{xx}$	1	$b^2 S_{xx}$	$F = \frac{b^2 S_{xx}}{S_R^2}$	$F_{1, n-2, \alpha}$
Residual	$S_{yy} - b^2 S_{xx}$	$n - 2$	$\frac{S_{yy} - b^2 S_{xx}}{n-2}$ (SQR)		
Total	$S_{yy}$	$n - 1$			

Se  $F_{\text{calc}} > F_{\text{crit}}$ , rejeita-se  $H_0$ .

### ANÁLISE DE MELHORIA

A ideia central é analisar se ocorreu uma melhoria significativa perdendo-se um grau de liberdade e assim tornando um grau acima.

• Reta x Parábola

#### ANOVA

Fonte de variação	Soma dos quadrados	Grau de liberdade	Quadrado médio	F	F <sub>α</sub>
Melhoria do ajuste	$\textcircled{1} = \sum (\hat{y}_i - y_i)^2$	1	$\textcircled{1}$	$F = \frac{\textcircled{1}}{S_p^2}$	$F_{1, n-3, \alpha}$
Residual s/ a parábola	$\textcircled{2} = \sum (y_i - \hat{y}_i)^2$	$n - 3$	$S_p^2 = \frac{\textcircled{2}}{n-3}$		
Residual s/ a reta	$S_{yy} - b^2 S_{xx}$	$n - 2$			



## ANÁLISE de VARIÂNCIA NA Regressão linear múltipla

ANOVA					
Fonte de Variação	Soma de quadrados	Graus de liberdade	Quadrado médio	F	F <sub>α</sub>
Regressão	$\sum_{i=1}^k b_i S_{iy}$	k	$\frac{①}{k} = ②$	$F = \frac{①}{S_{M}^2}$	$F_{k, n-k-1, \alpha}$
Resíduos	$SQM = S_{yy} - ①$	n - k - 1	$SM^2 = \frac{SQM}{n-k-1}$		
Total	S <sub>yy</sub>	n - 1			

### Resolução de Q3 - P2 - 2015

#### a) ANOVA

Fonte	Soma Quad.	Graus Lib.	Quad. Méd.	F <sub>calc.</sub>	F <sub>tab</sub>
Regressão	① 421200	2 ③	$\frac{①}{③} = ⑥$	$\frac{⑥}{⑦}$	⑧
Resíduos plano	② - ① = ④	7 - ③ = ⑤	$\frac{④}{⑤} = ⑦$		
Total	② 2750521	7			

↳ não muda!

$$\textcircled{4} = \textcircled{2} \cdot \textcircled{1} = 450521 - 421200 = \underline{\underline{29321}}$$

$$7 - \textcircled{3} = \textcircled{5} = 7 - 2 = \underline{\underline{5}}$$

$$\frac{\textcircled{1}}{\textcircled{3}} = \textcircled{6} = \frac{421200}{2} = \underline{\underline{210600}}$$

$$\frac{\textcircled{4}}{\textcircled{5}} = \textcircled{7} = \frac{29321}{5} = \underline{\underline{5864,2}}$$

$$F_{calc} = \frac{\textcircled{6}}{\textcircled{7}} = \frac{210600}{5864,2} = \underline{\underline{35,91}}$$

$$F_{crit.} = F_{\textcircled{3}, \textcircled{5}, \alpha} = F_{2, 5, 5\%} = \underline{\underline{5,79}}$$

### b) ANÁLISE DE MELHORIA

Fonte	Soma Quad.	Graus Lib.	Quad. Méd	F <sub>calc</sub>	F <sub>tab</sub>
Linear	353969 (dado no enunciado)	1	353969	60,36	6,61
Melhoria MCM	67231	1	67231	11,46	
Residual Puro	29321 (tem inteiro)	7 - 1 - 1 = 5	5864,2		
Total	450521	7			



$$\textcircled{1} \rightarrow \text{SQT} = \text{SQ Linear} + \underbrace{\text{SQ melhoria} + \text{SQ plano}}_{\text{SQ Residual da meta}}$$

$$\textcircled{1} \rightarrow 450521 = 353969 + \text{SQ melhoria} + 29321$$

$$\text{SQ melhoria} = 67.231$$

$$\textcircled{2} = \frac{67231}{1} = 67231$$

$$\textcircled{3} = \frac{29321}{5} = 5864,2$$

$$\textcircled{4} = \frac{353969}{5864,2} = 60,36$$

$$\textcircled{5} = \frac{67231}{5864,2} = 11,46$$

PARA OS F's calculados, você divide pelo Residual (O único caso que isto não ocorre é para Análise de Variância com Duas Classificações de Repetição!).

$$\textcircled{6} = F_{\text{crit}} = (F_{\text{tabelado}}) = F_{r_1, r_2, \alpha} = F_{1, 5, 5\%} = 6,61$$

Como o F calculado da melhoria (11,46) é maior que o F crítico, você rejeita e conclui que a melhoria é significativa.

$$\text{c) Coeficiente de Determinação} = R^2 = \frac{\text{SQ reg}}{\text{SQT}} = \frac{421200}{450521} = 0,9349$$

Sim, o mesmo do Excel!

↳ a ideia dessa razão é expressar o quanto a regressão "explica" seus dados (SQ da regressão) sobre o total (SQT).

## Q4) PAPEL DE PROBABILIDADE

Este é um dos chamados testes de aderência.

O papel de probabilidade é um procedimento relativamente simples e aproximado, ou seja, não possui um rigor muito grande.

Ele testa o quanto a sua amostra se aproxima de uma distribuição normal.

### PASSOS

- 1) Dada uma amostra, ver qual o maior e o menor valor para achar a amplitude. A ideia é que no eixo das abscissas, você utilize uma escala adequada a fim de cobrir todos os valores e que seja fácil de traçar os pontos. No caso do enunciado da prova, o menor é 13 e o maior 52.

Uma escala adequada no caso da questão é de 10 até 60.

- 2) Organize seus dados de forma crescente.  
Ex. da Prova:

13 15 21 22 26 28 32 38 40 52

- 3) Dado que você já tem os valores de  $x$ , falte as probabilidades. A ideia é que você distribua os pontos de sua amostra simetricamente, através da fórmula:



$$\frac{50(2i-1)}{n}$$

sendo  $n$  o nº de elementos da amostra e  $i$  o índice do elemento já com a amostra ordenada de forma crescente.

Da prova:  $n=10$

$x$	13	15	21	22	26	28	32	38	40	52
$i$	1	2	3	4	5	6	7	8	9	10
$y$	5%	15%	25%	35%	45%	55%	65%	75%	85%	95%

esse valor nada mais é do que a frequência relativa acumulada!

4) Agora basta plotar seus pontos e traçar uma reta que aproxime ao máximo os pontos. Essa etapa é bem abstrata, indo do bom senso da pessoa. Veja na folha do exercício anexada no final.

5) Agora, o grande final! Veja que do lado direito, há  $\mu$  (média) e  $-1\sigma$  (menos desvio padrão) e  $+1\sigma$  (mais desvio padrão). Siga a reta horizontal de cada um dos três e, quando cruzar com a reta que você traçou, rebata para o eixo das abscissas. Assim você chegará a 3 valores

$$\begin{aligned} \mu - \sigma &\approx 18,17 & \mu &\approx 29 & \mu + \sigma &\approx 40,41 \Rightarrow \mu \approx 29 \\ & \approx 11,12 & & & & \sigma \approx 11 \text{ ou } 12 \end{aligned}$$

aqui nos pontos  
basta  
procurar!

Veja o que foi feito no anexo de prova, em cores e azul!



Programa de Iniciação Científica

Bom, se você chegou até aqui, agradeço a presença!  
Mantenha a concentração e organize bem  
seu formulário.

Acredito em você! 😊

Bom Trabalho!

Castro Medeiros



ESCOLA POLITÉCNICA DA UNIVERSIDADE DE SÃO PAULO  
DEPARTAMENTO DE ENGENHARIA DE PRODUÇÃO  
PRO 3200 – ESTATÍSTICA – P2 (23/11/2015)

Aluno: \_\_\_\_\_

NUSP: \_\_\_\_\_

Assinatura: \_\_\_\_\_

Professor: \_\_\_\_\_

Turma: \_\_\_\_\_

QUESTAO	NOTA
1	
2	
3	
4	
TOTAL	

**Questão 01 (2 pontos)**

Um experimento foi realizado visando avaliar o efeito de dois fatores na conversão (produtividade) de um processo químico: temperatura e pressão. Por falta de tempo, não foi possível fazer o experimento com repetição. Um funcionário descuidado deixou cair café sobre a tabela, perdendo alguns de seus valores. Felizmente, alguns cálculos já haviam sido realizados. Os resultados obtidos foram:

	1 atm		2 atm		3 atm		Soma dos $X_{ij}$ valores da linha	Soma dos $(X_{ij})^2$ valores da linha	
220 °C	5,4	29,7				36	17,1	97,65	
250 °C	3,2					38,44	13,8	68,04	
270 °C	3,8	14,7				14,9	34,81	13,9	66,89
300 °C	4,6	21,16	5,2	27,04	6,1	37,21	15,9	85,41	
Soma dos $X_{ij}$ valores da coluna	17		19,5		24,2				
Soma dos $(X_{ij})^2$ valores da coluna		75		96,53		146,6			

- Ao nível de significância de 5%, existem diferenças significativas entre os fatores pressão e temperatura? (1 Ponto)
- Para responder à questão anterior, que hipóteses você teve que assumir? (1 Ponto)



**Questão 02 (3 pontos)**

A primeira prova de PRO3200 ocorreu no dia 19 de outubro de 2015 as 7:30 da manhã. A tabela com os acessos nos intervalos medidos está abaixo. "Acesso" aqui quer dizer um clique de algum aluno online em um dos recursos do AVA.

Período	Tempo Faltante para Prova (Horas)	Número de Acessos
18/10 - 14:00 a 14:59	17	37
18/10 - 15:00 a 15:59	16	96
18/10 - 16:00 a 16:59	15	
18/10 - 17:00 a 17:59		
18/10 - 18:00 a 18:59		
18/10 - 19:00 a 19:59		
18/10 - 20:00 a 20:59		
18/10 - 21:00 a 21:59		
18/10 - 22:00 a 22:59	9	490
18/10 - 23:00 a 23:59	8	557
19/10 - 00:00 a 00:59	7	542
19/10 - 01:00 a 01:59	6	558
19/10 - 02:00 a 02:59	5	621
19/10 - 03:00 a 03:59	4	703

Novamente o funcionário descuidado deixou cair café sobre a tabela, perdendo alguns de seus valores, mas felizmente, alguns cálculos já haviam sido realizados.

$$\begin{aligned}\sum x_i &= 147 & \sum y_i &= 4921 \\ \sum x_i^2 &= 1771 & \sum y_i^2 &= 2360653 \\ \bar{x} &\cong 10,50 & \bar{y} &\cong 351,50 \\ n &= 14 & \sum x_i \cdot y_i &= 39934\end{aligned}$$

- Determine a reta de regressão. (1 Ponto)
- Ao nível de significância de 5%, é possível verificar correlação negativa entre proximidade da prova e número de acessos? (1 Ponto)
- Determine o Intervalo com 95% de confiança para os parâmetros Alfa e Beta da reta teórica. (1 Ponto)

**Questão 03 (3 pontos)**

O consumo de energia por um ser humano para se manter vivo é denominado Taxa Metabólica Basal ou TBM. Reflete o consumo mínimo diário de kcal para o corpo se manter em repouso. Um pesquisador estudou o TBM e quer correlacionar o TBM com a Massa Corporal Magra e a Massa de Gordura, medidas por bioimpedância. Obteve os seguintes dados:

Y	1745,3	1684,3	2095,1	1645,2	1803,3	1774,5	2395,3	1985,4
MG	10	5	21	16	18	7,5	44	16
MCM	60	55	72	45	62	63	56	67

Y-TBM kcal; MG-massa gorda kg; MCM-massa magra kg.

Avaliando a relação entre Y e MG encontrou a reta média  $\hat{Y} = 1573 + 18,5 \text{ MG}$  com a seguinte tabela de ANOVA:

Fonte	Soma Quad.	Graus Lib.	Quad. Médio	F calc	F tab
Regressão	353969	1	353969	22,00	5,99
Residual reta	96552	6	16092		
Total	450521	7			

Para melhorar o modelo resolveu incluir a variável MCM e encontrou o modelo (plano) para média  $\hat{Y} = 853 + 11,9 \text{ MCM} + 18,7 \text{ MG}$  com a tabela ANOVA.

Fonte	Soma Quad.	Graus Lib.	Quad. Médio	F calc	F tab
Regressão	421200	2			
Residual plano					
Total	450521				

- Complete a tabela de ANOVA preenchendo os valores faltantes nos espaços vazios. (1 ponto)
- Faça a análise de melhoria e verifique se a introdução da variável MCM no modelo traz melhoria significativa. (1 ponto)
- Qual o valor do coeficiente de determinação para o modelo de Regressão Linear Múltipla (plano)? (1 ponto)

Adote  $\alpha=5\%$ .



**Questão 04 (2 pontos)**

Dada a seguinte amostra:

13 – 28 – 15 – 32 – 21 – 38 – 22 – 40 – 26 – 52

- a) Mediante o uso do papel de probabilidade normal (fornecido na próxima página), verificar se uma distribuição normal se ajusta bem a estes dados. (1 ponto)
- b) Obter **através deste mesmo papel** uma estimativa para a média e o desvio-padrão da população. (1 ponto)

Ao traçar a reta, tenha bom senso!

### Papel de Probabilidade Normal

