

# Introdução aos Modelos Lineares em Ecologia

Prof. Adriano Sanches Melo - Dep. Ecologia – UFG  
asm.adrimelo no gmail.com

Página do curso: [www.ecologia.ufrgs.br/~adrimelo/lm/](http://www.ecologia.ufrgs.br/~adrimelo/lm/)

Livro-texto: Crawley, M.J. 2005. Statistics: An Introduction using R.  
John Wiley & Sons.

Página do livro na internet:

<http://www3.imperial.ac.uk/naturalsciences/research/statisticsusingr>

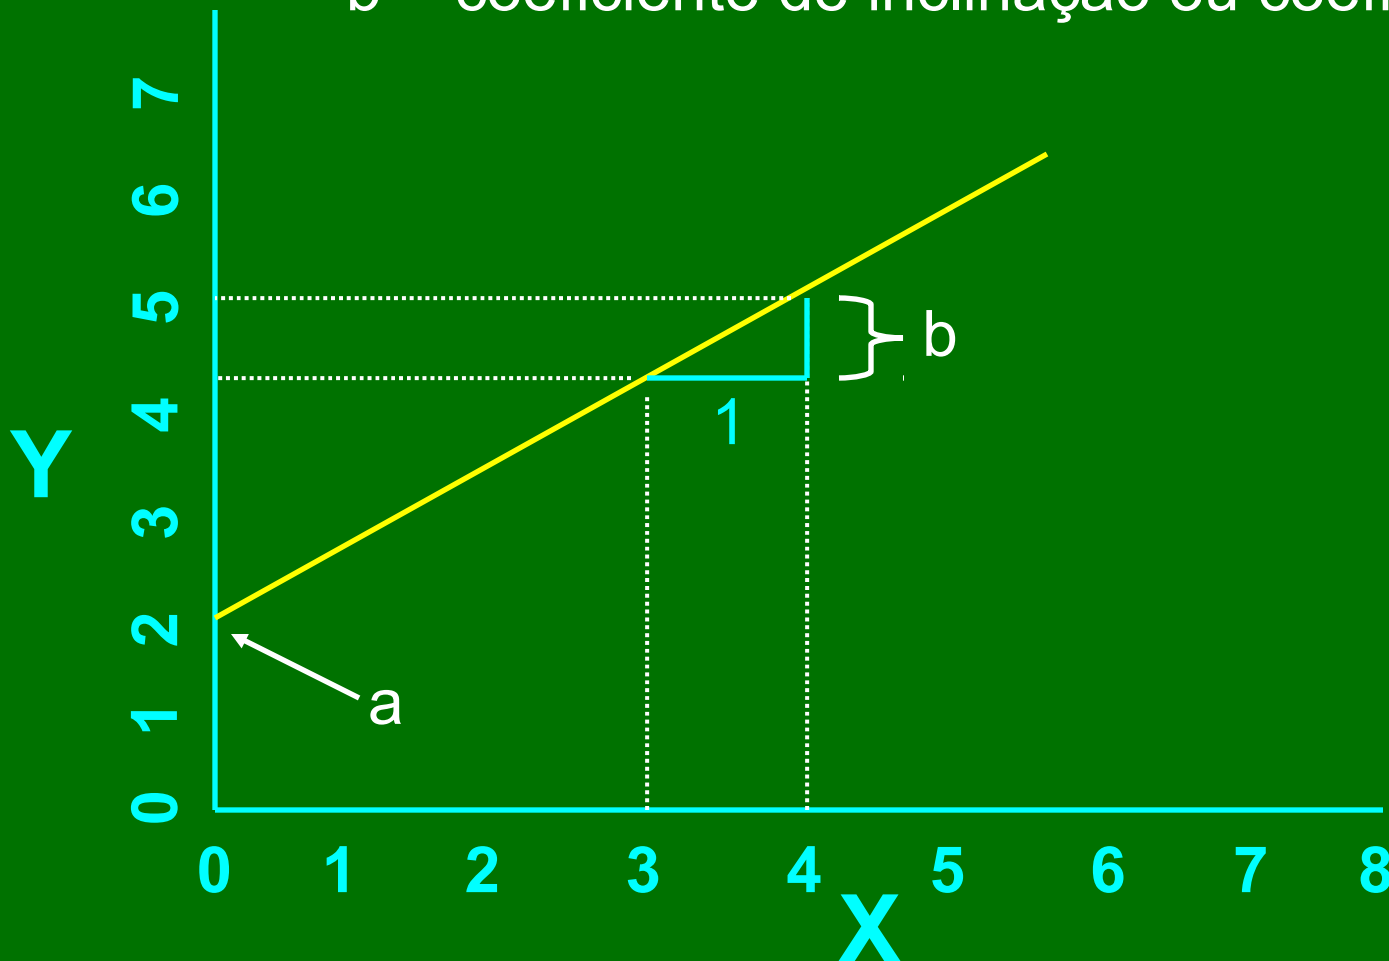
# AULA 3

## A equação da reta

$$Y = a + b \cdot X$$

a = intercepto

b = coeficiente de inclinação ou coeficiente angular



## Exemplos:

Valor pago (Y) = Tarifa\*Número de unidades de produto (X)

Valor pago (Y) = Taxa de entrada + Tarifa\* Distância em km (X)

## O modelo de regressão

$$Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i$$

onde:

$Y_i$  é o valor da variável resposta na observação  $i$ ;

$\beta_0$  and  $\beta_1$  são parâmetros;

$X_i$  é um valor conhecido da variável explanatória;

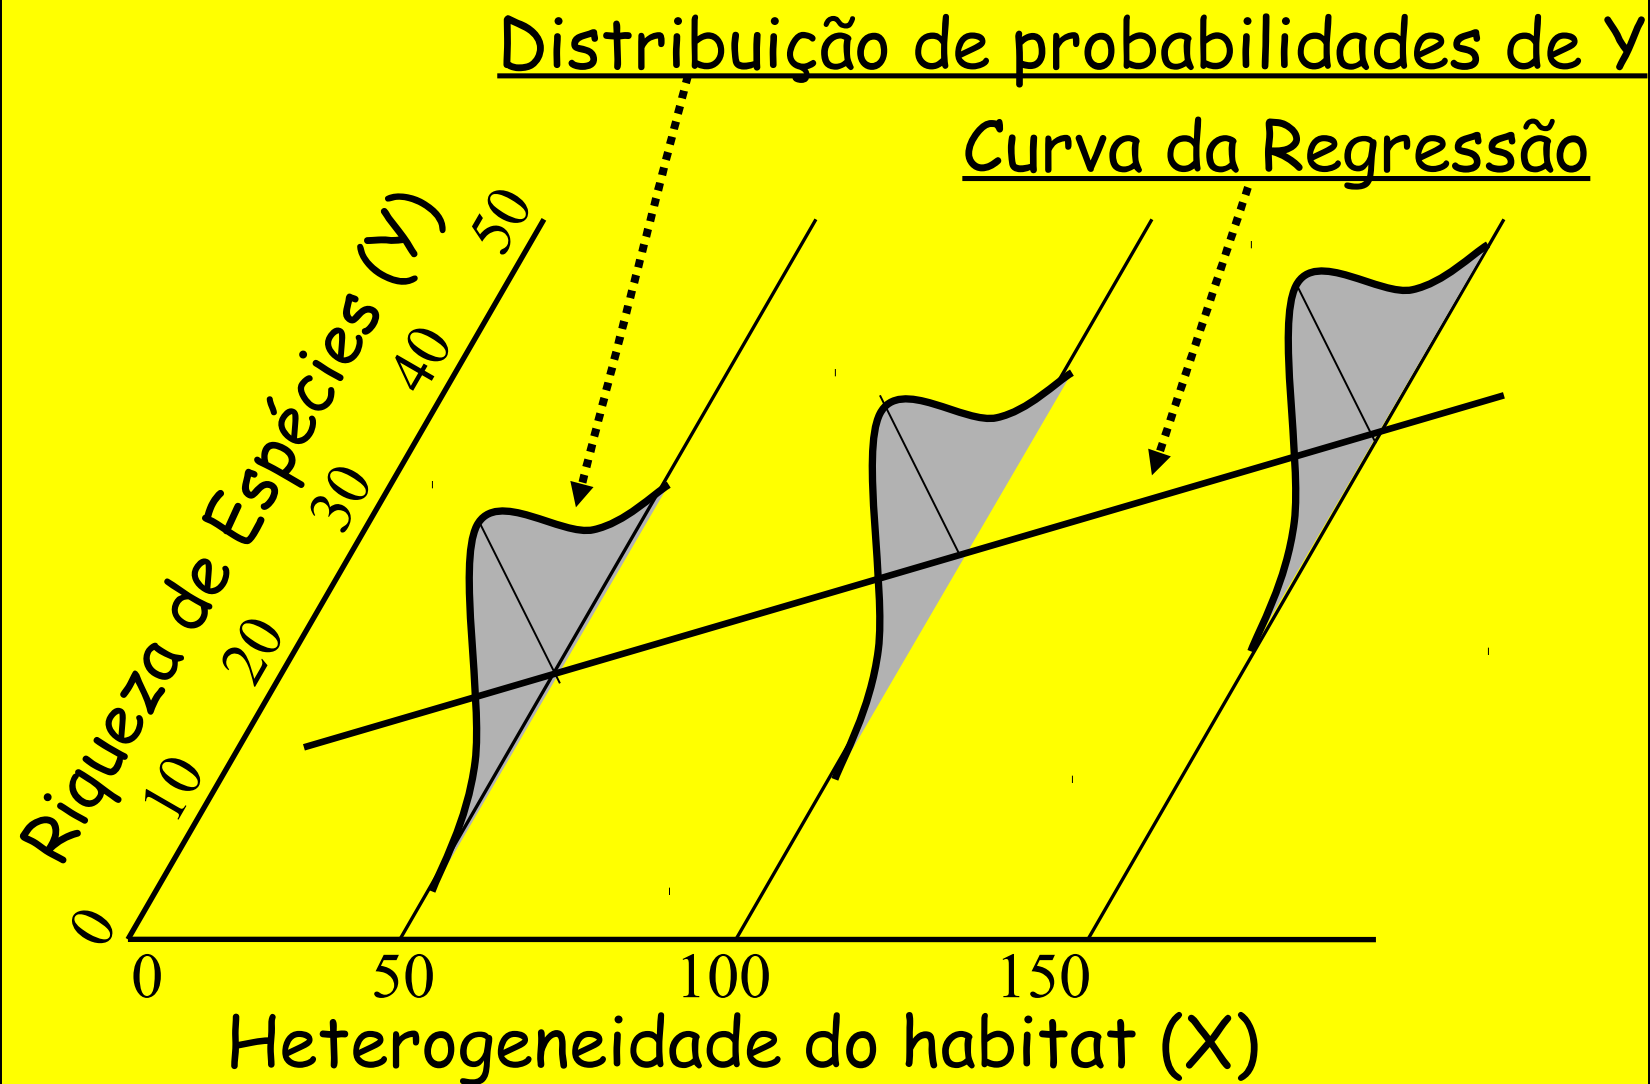
$\varepsilon_i$  termo relacionado ao erro, e que possui média  $E\{\varepsilon_i\}=0$  e

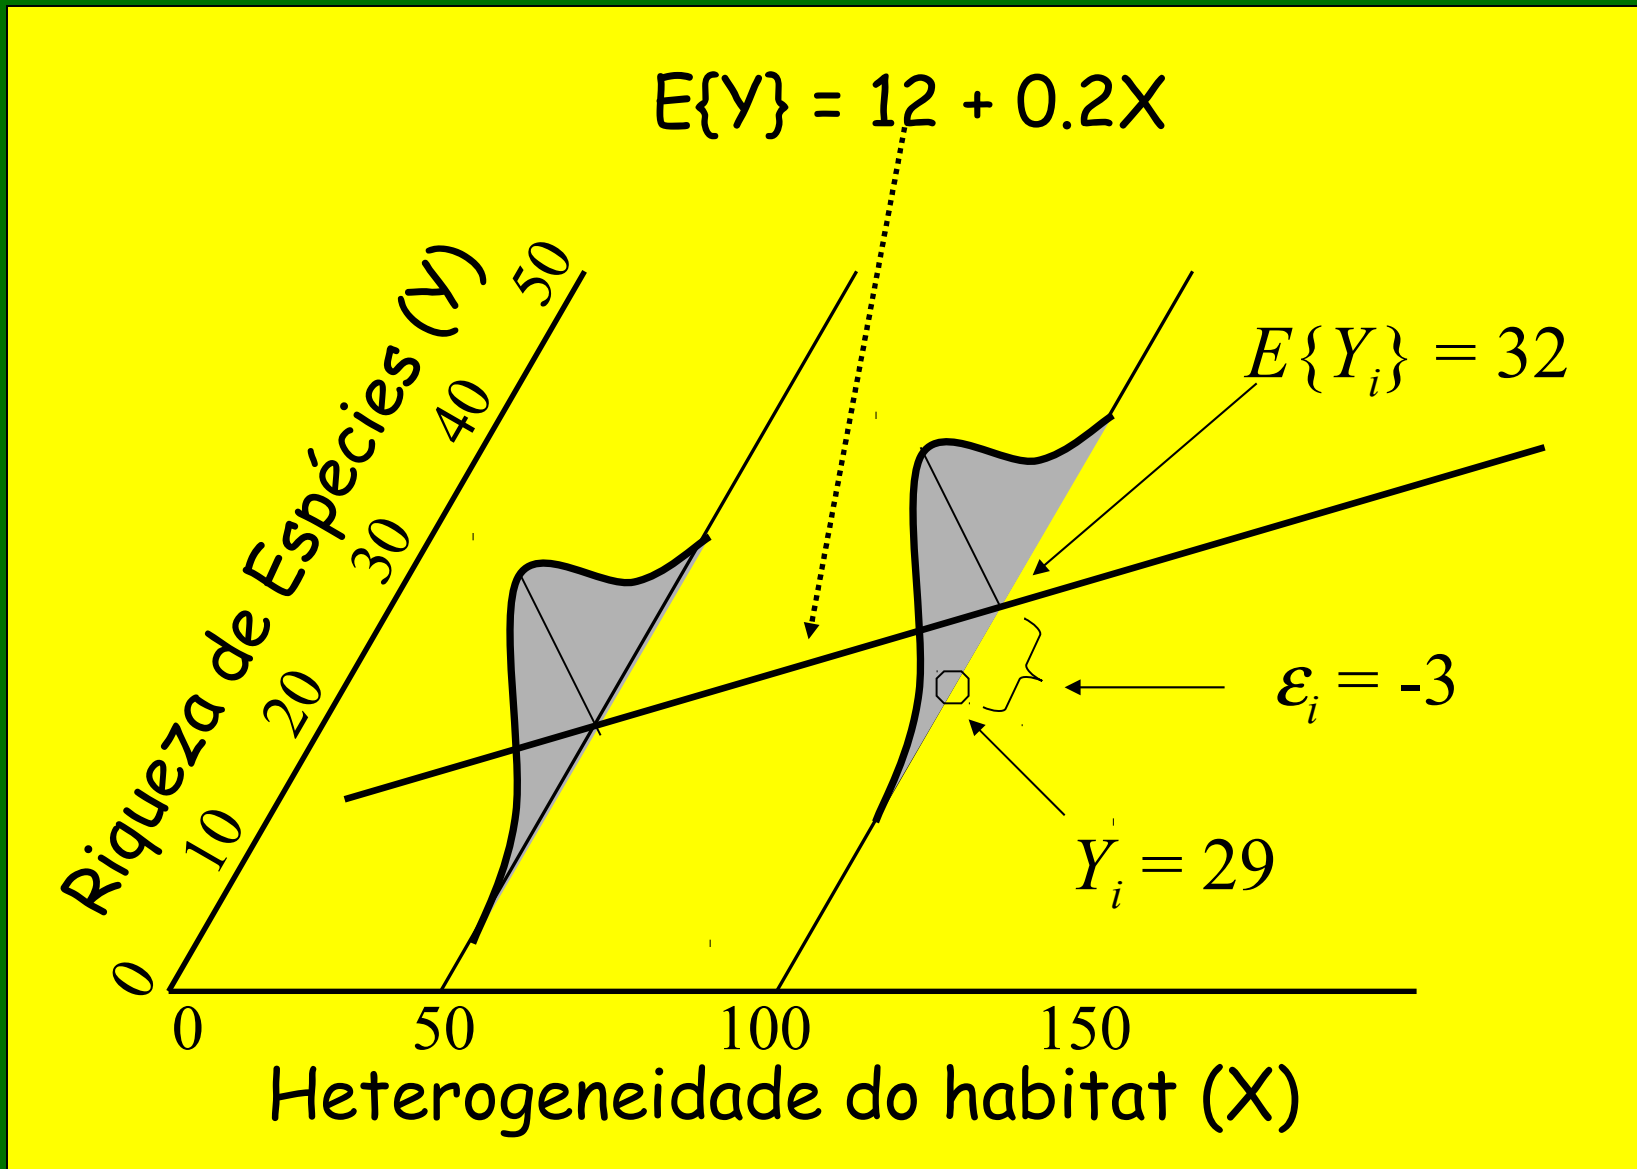
variância  $\sigma^2\{\varepsilon_i\} = \sigma^2$ ;

$\varepsilon_i$  e  $\varepsilon_j$  não são correlacionados fazendo com que sua

covariância seja zero (i.e.  $\sigma\{\varepsilon_i, \varepsilon_j\}=0$  para todos  $i, j; i \neq j$ ).

$i = 1, 2, \dots, n.$





--O modelo é *simples*, pois possui apenas 1 variável explanatória.

--O modelo é *linear nos parâmetros*, pois nenhum parâmetro aparece como expoente, nem é multiplicado ou dividido por outro parâmetro.

--O modelo é *linear na variável explanatória*, pois esta variável aparece apenas na primeira potência.

## O critério de Quadrados Mínimos (Least Squares)

$$\text{Definição de SS} = \sum ( Y_i - [ \beta_0 + \beta_1 X_i ] )^2$$

Exemplo com média de uma população (aula anterior)

Exemplo “regressão” com apenas a constante (= média; idem exemplo acima)

Exemplo com regressão com apenas um coeficiente de regressão




## Como encontrar a e b ?

1. Por iteração (tentativa e erro)

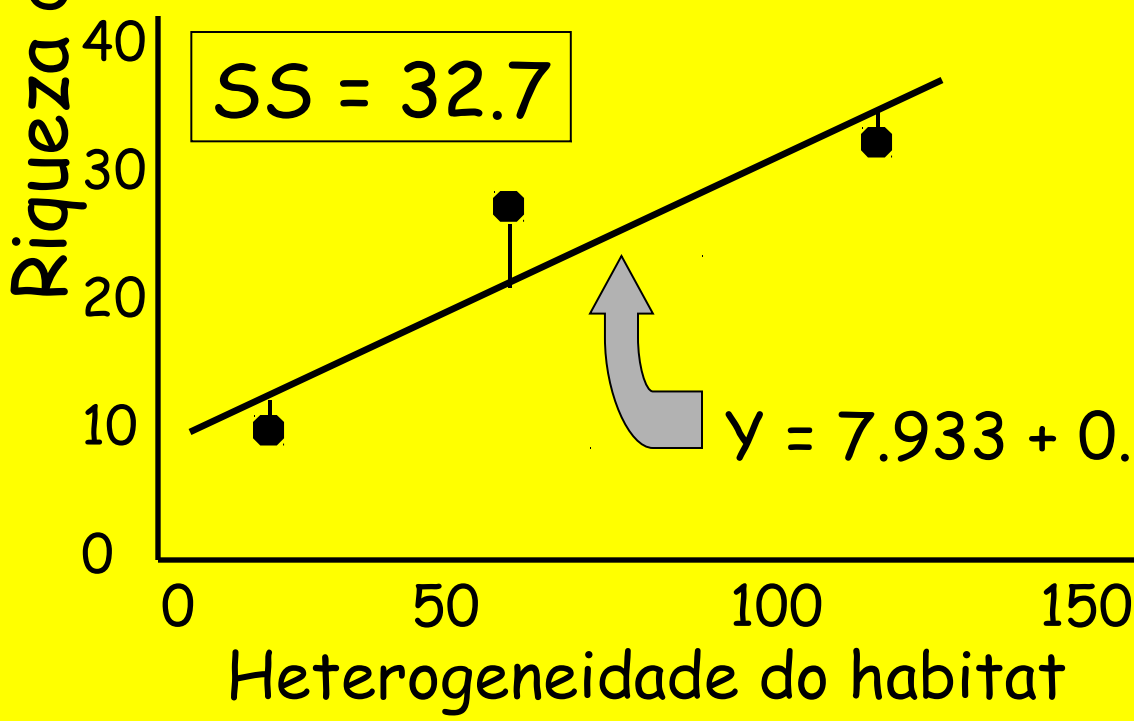
2. De forma analítica

$$b = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sum (X_i - \bar{X})^2}$$

$$a = \frac{1}{n} \left( \sum Y_i - b \sum X_i \right) = \bar{Y} - b \bar{X}$$



$Y_1 = 10$	$X_1 = 20$
$Y_2 = 28$	$X_2 = 70$
$Y_3 = 32$	$X_3 = 120$



$$b = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sum (X_i - \bar{X})^2}$$

$$a = \bar{Y} - b \bar{X}$$

SS Total (SST) = SS Regressão (SSR) + SS Resíduo (SSE)

$$Y_i - \bar{Y} = (\hat{Y}_i - \bar{Y}) + (Y_i - \hat{Y}_i)$$

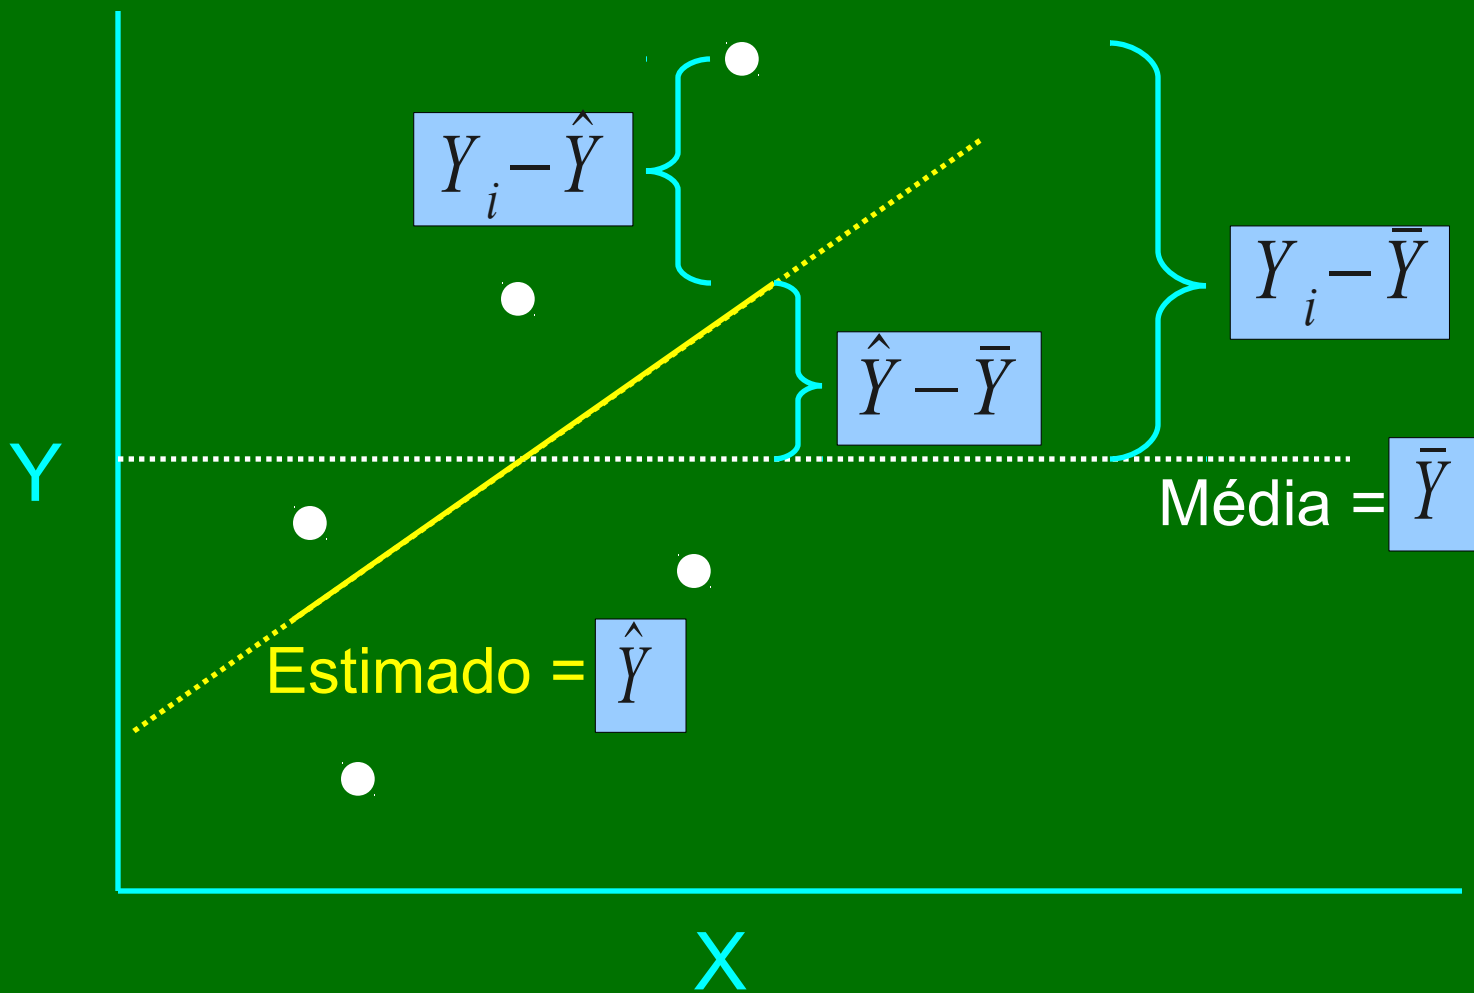
$$SST = \sum (Y_i - \bar{Y})^2$$

$$SSR = \sum (\hat{Y}_i - \bar{Y})^2$$

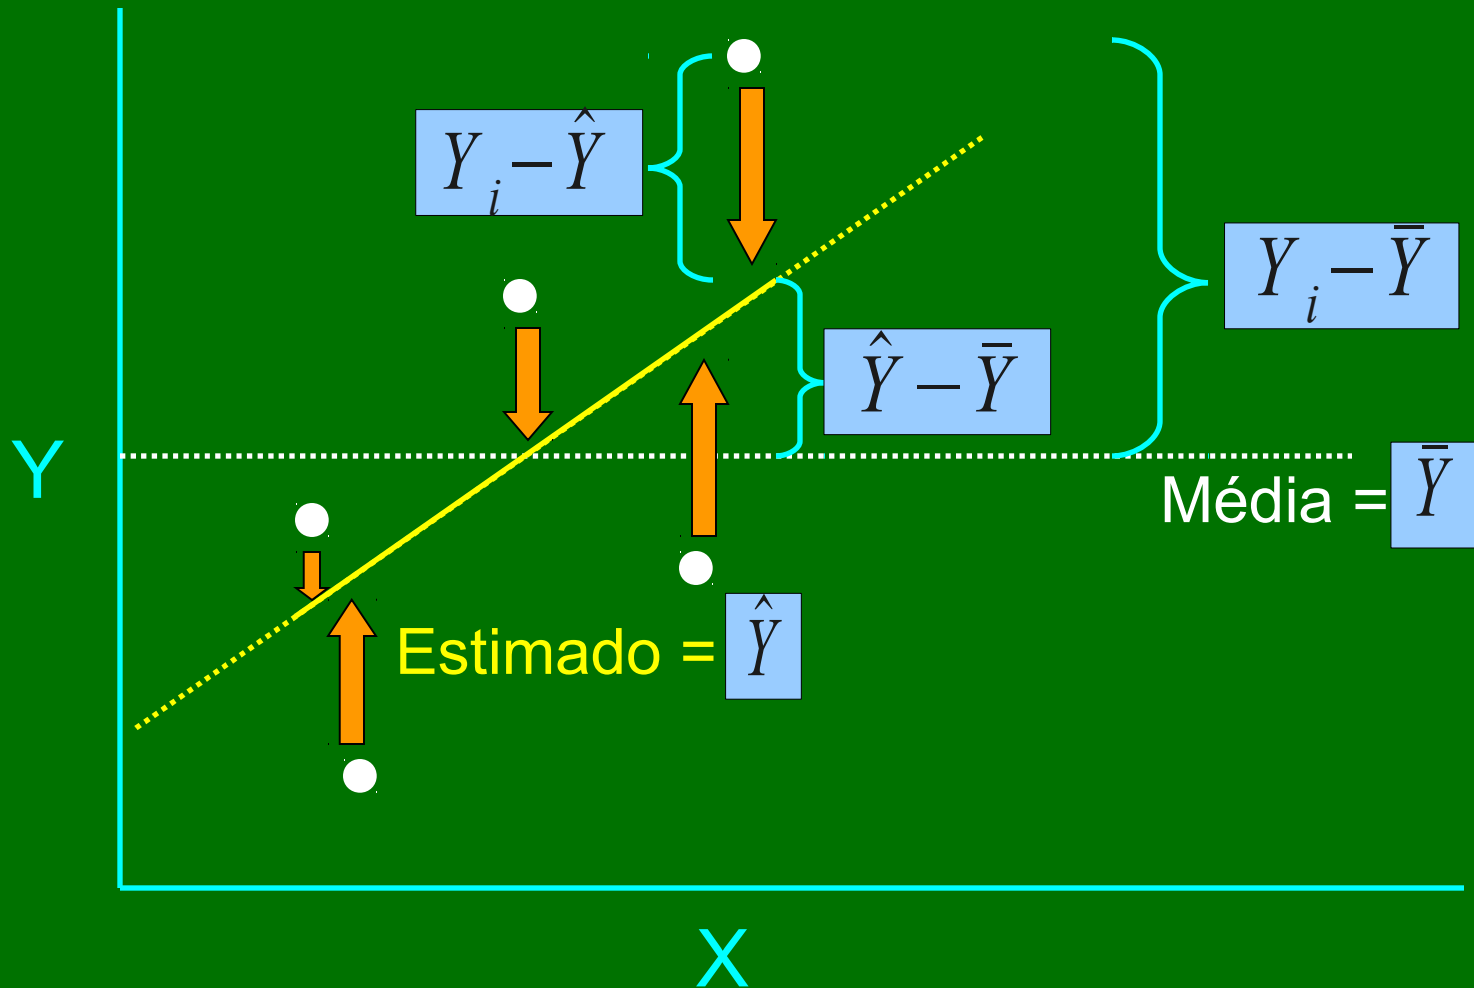
$$SSE = \sum (Y_i - \hat{Y}_i)^2$$

$SS_{\text{Total}} (SST) = SS_{\text{Regressão}} (SSR) + SS_{\text{Resíduo}} (SSE)$

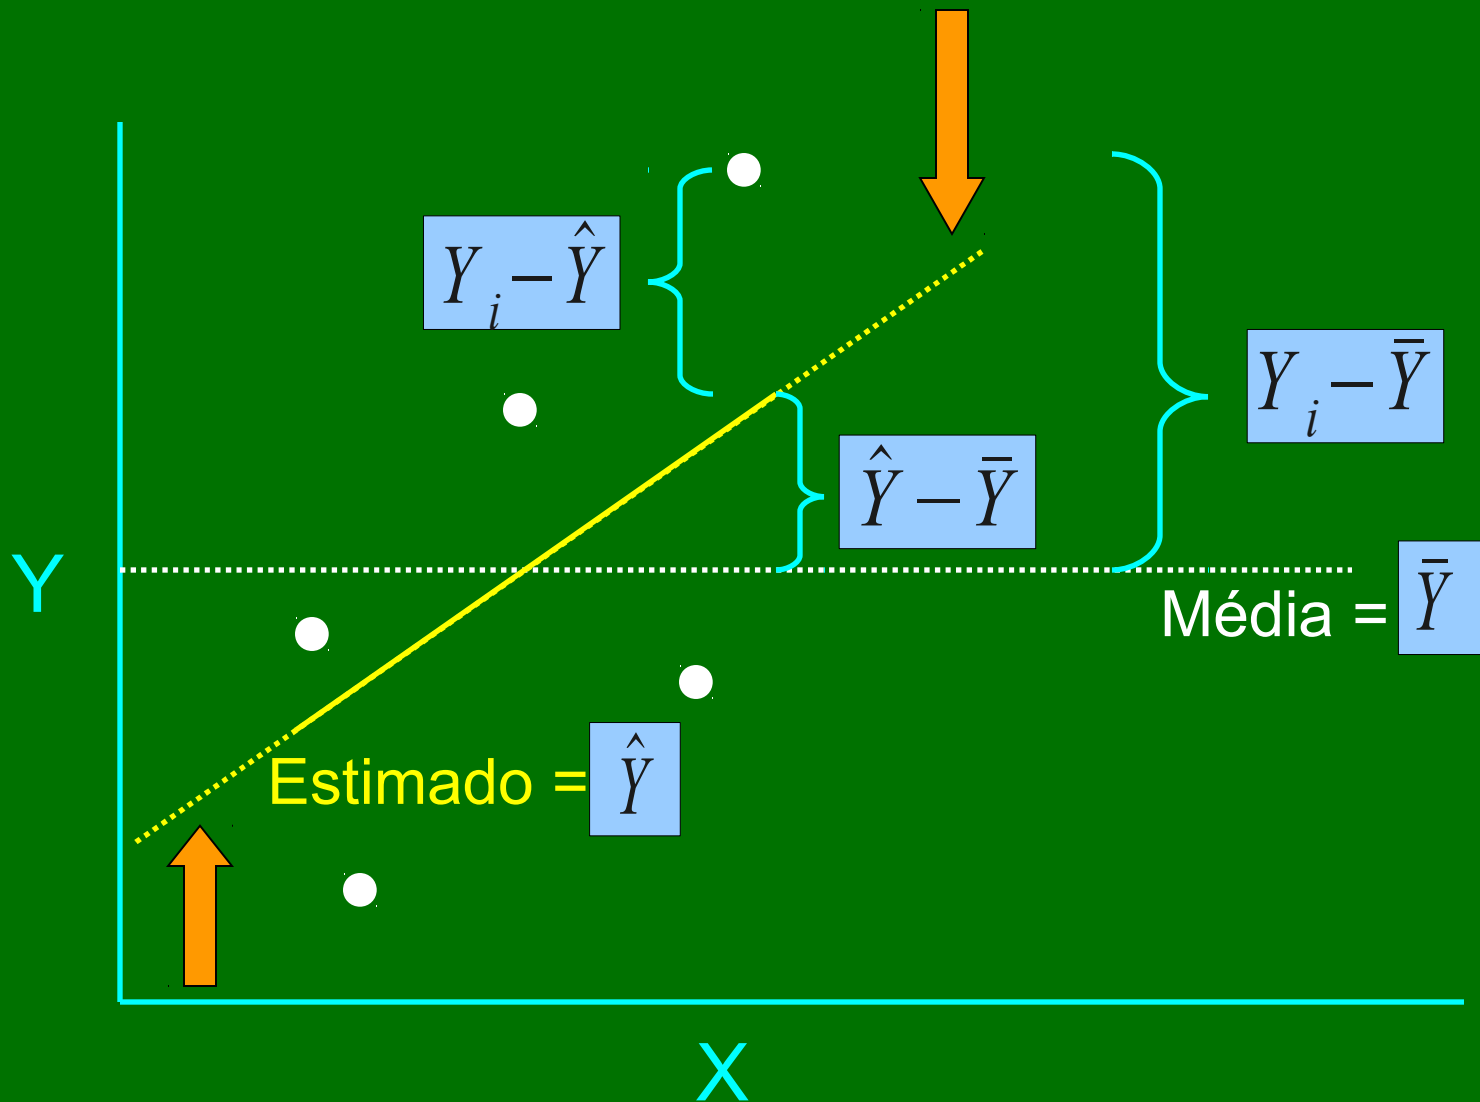
$$\underbrace{Y_i - \bar{Y}}_{SST} = \underbrace{\hat{Y}_i - \bar{Y}}_{SSR} + \underbrace{Y_i - \hat{Y}_i}_{SSE}$$



O que acontece com  $Y_i - \hat{Y}$  quando os pontos, mantendo a mesma média, se aproximam da reta?



O que acontece com  $Y_i - \hat{Y}$  quando a reta de ajuste é igual à média?



Coeficiente de determinação

$$R^2 = \frac{SSR}{SST}$$

Coeficiente de Correlação

$$r = \pm \sqrt{R^2}$$

Um sinal de + ou – é anexado ao valor de acordo com a inclinação da reta

**Relação entre b e r:** o coeficiente angular é o coeficiente de correlação 're-escalado' em relação aos desvios padrão de Y e X

$$b = r \left( \frac{s_y}{s_x} \right)$$



$SST_{Total} (SST) = SSR_{Regress\tilde{a}o} (SSR) + SSE_{Res\tilde{a}duo} (SSE)$

$$\underbrace{Y_i - \bar{Y}}_{SST} = \underbrace{\hat{Y}_i - \bar{Y}}_{SSR} + \underbrace{Y_i - \hat{Y}_i}_{SSE}$$

---

$$SST = \sum (Y_i - \bar{Y})^2 \longrightarrow MST = Var = \frac{\sum (Y_i - \bar{Y})^2}{n-1}$$

$$SSR = \sum (\hat{Y}_i - \bar{Y})^2 \longrightarrow MSR = \frac{SSR}{1}$$

$$SSE = \sum (Y_i - \hat{Y}_i)^2 \longrightarrow MSE = \frac{SSE}{n-2}$$

SS Total (SST) = SS Regressão (SSR) + SS Resíduo (SSE)

$$Y_i - \bar{Y} = (\hat{Y}_i - \bar{Y}) + (Y_i - \hat{Y}_i)$$

$$SST = \sum (Y_i - \bar{Y})^2$$

$$SSR = \sum (\hat{Y}_i - \bar{Y})^2$$

$$SSE = \sum (Y_i - \hat{Y}_i)^2$$

Quadrados Médios (MS) = variância =  $SS/df$  , onde  $df = n-1$

Soma de Quadrados da Regressão (SSR)

Quadrados Médios da Regressão (MSR) =  $SSR/df$  , onde  $df = 1$

Soma de Quadrados dos Resíduos (SSE)

Quadrados Médios dos Resíduos (MSE) =  $SSE/df$ , onde  $df = n-2$

# Inferências

## Inferências (usando distribuição $t$ )

“Quando uma estatística é padronizada (dividida pelo desvio padrão), mas o denominador é uma estimativa e não o valor verdadeiro, ela é chamada de uma *estatística estudentizada*.”

Um importante teorema em estatística diz que:

$(b - \beta) / s\{b\}$  é distribuída como  $t(n-2)$  para um modelo de regressão linear.”

$$s^2\{b\} = \frac{MSE}{\sum (X_i - \bar{X})^2}$$

*Intervalo de Confiança para  $\beta$  :  $b \pm t(1-(\alpha/2); n-2)s\{b\}$*

Para saber  $t(1-(\alpha/2); n-2)$  no R: `qt (.975, 23)` para  $\alpha=0.05$  e  $n-2=23$

*Teste sobre  $\beta$*

*Teste bicaudal:*

$$H_0: \beta = 0$$

$$H_1: \beta \neq 0$$

*Erro Tipo I em  $\alpha = 0.05$*

*A conclusão pode ser obtida observando o intervalo de confiança 95% acima. Se o intervalo não incluir o 0, conclui-se  $H_1$ .*

Um teste direto das duas alternativas é baseado na estatística:

$$t^* = b/s\{b\}$$

A decisão neste teste para o nível de significância em  $\alpha$  é:

Se  $|t^*| \leq t(1-(\alpha/2); n-2)$ , conclui-se  $H_0$  [Notar que é modulo da estatística  $t^*$ ]

Se  $|t^*| > t(1-(\alpha/2); n-2)$ , conclui-se  $H_a$

Para achar  $t$  crítico no R:  $qt(1-(0.05/2), n-2)$

Podemos também achar a probabilidade exata:

$pt(t^*, df) * 2$ , onde  $t^*$  é o valor de  $t$  observado.

No caso de teste bicaudal deve-se multiplicar a probabilidade encontrada por 2

## Teste Unicaudal:

$$H_0: \beta \leq 0$$

$$H_1: \beta > 0$$

Se  $|t^*| \leq t(1-\alpha; n-2)$ , conclui-se  $H_0$

Se  $|t^*| > t(1-\alpha; n-2)$ , conclui-se  $H_a$

Para  $\alpha=0.05$ , obtemos  $t(0.95,23) = 1.714$  {no R: `qt(0.95, 23)` }.

Se, por exemplo  $t^* = 10.29 > 1.714$ , concluimos por  $H_a$ , que  $\beta > 0$ .

## Teste F para $\beta = 0$ versus $\beta \neq 0$

$$F^* = MSR / MSE$$

Regras de decisão: visto que o teste é feito apenas para a cauda superior (*upper-tail*) e  $F^*$  é distribuído como  $F(1, n-2)$  quando  $H_0$  é verdadeiro, temos:

Se  $F^* \leq F(1-\alpha; 1; n-2)$ , conclui-se  $H_0$

Se  $F^* > F(1-\alpha; 1; n-2)$ , conclui-se  $H_a$

onde  $F(1-\alpha; 1; n-2)$  é o  $(1-\alpha)100$  percentil da distribuição F apropriada.

Exemplo:

Para  $\alpha = 0.05$  e  $n = 25$ , obtemos  $F(0.95; 1; 23) = 4.28$

No R: `qf(0.95, 1, 23)`

## *Equivalência do teste F e do teste t*

$$F^* = (t^*)^2$$

$$[t(1-\alpha/2; n-2)]^2 = F(1-\alpha; 1, n-2)$$

NO R:

```
qf(0.95, 1, 23)
```

```
qt(0.975, 23)^2
```

O teste *t*, entretanto, é mais flexível pois pode ser usado para testes unicaudais



## Tabela de Análise de Variância

Fonte	d.f.	SS	MS	F	p
Regressão	1	$SSR = \sum (\hat{Y}_i - \bar{Y})^2$	SSR/1	$\frac{MSR}{MSE}$	1-pf(F,1,n-2)
Resíduo	n-2	$SSE = \sum (Y_i - \hat{Y})^2$	SSE/n-2		
Total	n-1	$SST = \sum (Y_i - \bar{Y})^2$	SST/n-1		

## Testes Generalizados de Modelos Lineares

*Modelo Completo (Full Model) (ou não restrito)*

$$SSE(F) = \sum [Y_i - (a + b X_i)]^2 = \sum (Y_i - \hat{Y}_i)^2 = SSE$$

*Modelo Reduzido (Reduced Model) (ou modelo restrito)*

$$SSE(R) = \sum (Y_i - a)^2 = \sum (Y_i - \bar{Y})^2 = SSTO$$

A lógica é comparar  $SSE(F)$  e  $SSE(R)$ .

Observe que  $SSE(F)$  nunca é maior que  $SSE(R)$ :

$$SSE(F) \leq SSE(R)$$

A razão é que conforme temos mais parâmetros no modelo, mais flexível ele é e portanto melhor se ajustará às observações.

Consequentemente, os desvios em relação à reta serão menores.

Quando  $SSE(F)$  não é muito menor que  $SSE(R)$ , o uso do Modelo Completo não reduz muito mais a variabilidade de  $Y_i$  em relação ao

Modelo Reduzido. Neste caso, o Modelo Reduzido (mais simples) é tido como adequado (i.e. que  $H_0$  é adequada).

A estatística do teste é:

$$F = \frac{SSE(R) - SSE(F)}{df_R - df_F} \div \frac{SSE(F)}{df_F}$$

No caso de testar se  $\beta = 0$ , temos para o caso do modelo com 1 variável independente:

$$SSE(R) = SST(F)$$

Note que o modelo *Full* é o modelo COM  $\beta$

Note que o modelo *Reduced* é o modelo SEM  $\beta$

Substituindo na formula, fica MSR/MSE, que é idêntico ao teste por análise de variância. Em análises a serem vistas em aulas posteriores usaremos intensivamente este teste.

$$F = \frac{SST - SSE}{df_T - df_E} \div \frac{SSE}{df_E}$$

## Exercícios e estudo individual:

- Lista em sala de aula
- Crawley: Cap. 8
- Gotelli & Ellison: Cap. 9 (pp. 239-257)