

# Estatística e Análise de Dados em Zootecnia

## Aulas Teóricas

Elsa Gonçalves  
Secção de Matemática (DCEB)  
Instituto Superior de Agronomia (ULisboa)

2024-25

# Pressupostos

Admite-se que houve frequência numa disciplina introdutória de Estatística no primeiro ciclo (semelhante à existente no ISA) e que são conhecidos:

- principais indicadores descritivos (média, variância, covariância, coeficiente de correlação linear, etc.) e suas propriedades;
- conceitos básicos de probabilidades;
- variáveis aleatórias e sua caracterização;
- principais distribuições de probabilidades (Normal, t-Student,  $\chi^2$ , F, etc.);
- conceitos de intervalos de confiança e testes de hipóteses.

# Programa

A UC Estatística e Delineamento Experimental é uma disciplina de aprofundamento, que procura **relacionar uma variável de interesse com outras variáveis**.

O programa da UC consiste no estudo do principal **modelo estatístico**: o **Modelo Linear**, que inclui como casos particulares:

- **Regressão Linear** (Simples e Múltipla);
- **Regressão Polinomial**;
- **Análise de Variância** (ANOVA), de efeitos fixos e de efeitos aleatórios;
- **Análise de Covariância** (ANCOVA).

## **Delineamento Experimental**

# Modelo Linear

# Modelação de relações entre variáveis

Importância central da recolha de **informação (dados)**.

Nas disciplinas introdutórias de Estatística aprende-se a trabalhar com dados relativos a **uma variável**.

Nesta disciplina: **relações (modelos) entre duas ou mais variáveis**.

Variáveis podem ser:

- **numéricas** (medições, rendimentos, contagens, etc.) **ou** **categóricas (factores)** (espécies, locais, tratamentos, etc.);
- **foco de interesse (variável resposta)** **ou** **auxiliares para explicar uma variável resposta (variável preditora ou explicativa)**.

# Modelos determinísticos e modelos estatísticos

Uma relação (modelo) entre duas ou mais variáveis pode ser:

- essencialmente exacta (como na Mecânica:  $F = ma$ ).  
Trata-se de **modelos determinísticos**.

Ou

- apenas uma tendência de fundo, sabendo-se que existe variabilidade das observações em torno dessa tendência de fundo. Trata-se de **modelos estatísticos** ou probabilísticos.

# Modelação Estatística

**Objectivo** (informal): Descrever a **relação de fundo** entre

- uma **variável resposta** (ou **dependente**)  $y$ ; e
- uma ou mais **variáveis preditoras** (**variáveis explicativas** ou **independentes**),  $x_1, x_2, \dots, x_p$ .

**Informação**: A identificação da relação de fundo é feita com base em  $n$  observações do conjunto de variáveis envolvidas na relação.

Vamos inicialmente considerar o contexto de **um único preditor numérico**, para modelar **uma única variável resposta numérica**.

Motivamos a discussão com **dois exemplos**.

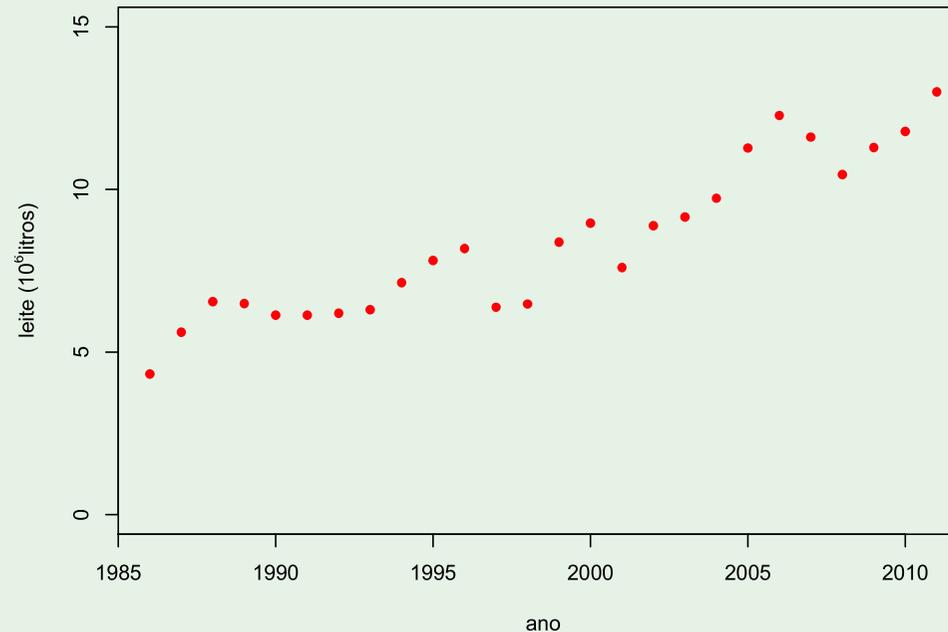
# O Modelo Linear

- O **Modelo Linear** é um caso particular de modelação estatística;
- engloba um grande número de modelos específicos:  
Regressão Linear (Simples e Múltipla) , Regressão Polinomial,  
Análise de Variância, Análise de Covariância;
- é o mais completo e bem estudado tipo de modelo;
- serve de base para numerosas extensões  
(Regressão não linear, Modelos Lineares Generalizados, Modelos Lineares Mistos, etc.).

# Exemplo 1

## Produção de leite de cabra em Portugal, 1986 a 2011 (INE)

Produção ( $y$ ) vs. Anos ( $x$ ),  $n = 26$  pares de valores,  $\{(x_i, y_i)\}_{i=1}^{26}$ .



Existe uma tendência de fundo e é aproximadamente **linear**.

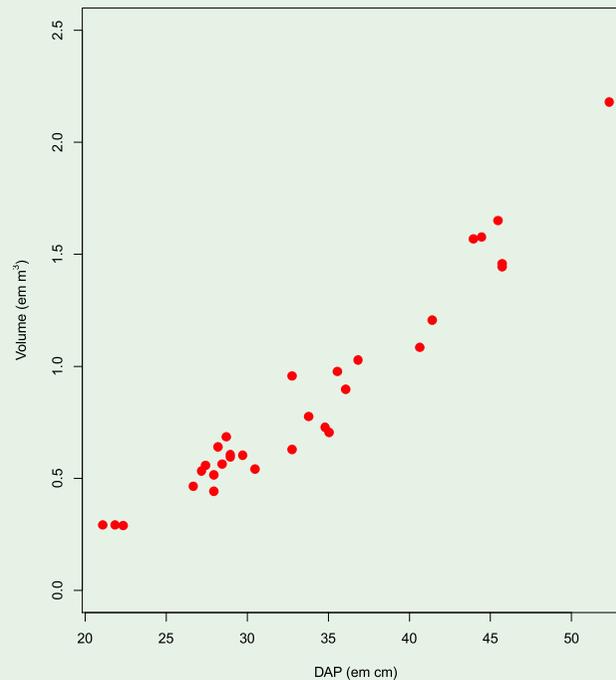
O coeficiente de correlação linear é  $r_{xy} = 0.9348$ .

Qual a “melhor” equação de recta,  $y = b_0 + b_1 x$ , para descrever as  $n$  observações (e que critério de “melhor”)?

# Exemplo 2 - relação linear

## Volume de tronco vs. DAP em cerejeiras

DAP (Diâmetro à altura do peito, variável  $x$ ) e Volume de troncos ( $y$ ) de cerejeiras. Existem  $n = 31$  pares de medições:  $\{(x_i, y_i)\}_{i=1}^{31}$ .



A tendência de fundo é aproximadamente **linear**. O coeficiente de correlação linear é  $r_{xy} = 0.9671$ . Mas os  $n = 31$  pares de observações são apenas uma amostra aleatória duma população mais vasta. Interessa o **contexto inferencial**: o que se pode dizer sobre a **recta populacional**  $y = \beta_0 + \beta_1 x$ ?

# Regressão Linear - Abordagem Descritiva

# Regressão Linear Simples - contexto descritivo

**Revisão:** Estudado nas disciplinas introdutórias de Estatística.

Se  $n$  pares de observações  $\{(x_i, y_i)\}_{i=1}^n$  têm relação linear de fundo, a **recta de regressão de  $y$  sobre  $x$**  define-se como:

Recta de Regressão Linear de  $y$  sobre  $x$

$$y = b_0 + b_1 x$$

com

$$\text{Declive} \quad b_1 = \frac{\text{COV}_{xy}}{s_x^2}$$

$$\text{Ordenada na origem} \quad b_0 = \bar{y} - b_1 \bar{x}$$

sendo

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad \bar{y} = \frac{1}{n} \sum_{i=1}^n y_i \quad s_x^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 \quad \text{cov}_{xy} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}).$$

# Regressão Linear Simples - contexto descritivo

## Exemplo das cerejeiras

$n = 31$  pares de medições,  $\{(x_i, y_i)\}_{i=1}^{31}$ .

DAP ( $x$ ) e Volume de troncos ( $y$ ) de cerejeiras.

$$cov_{xy} = 3.5881929$$

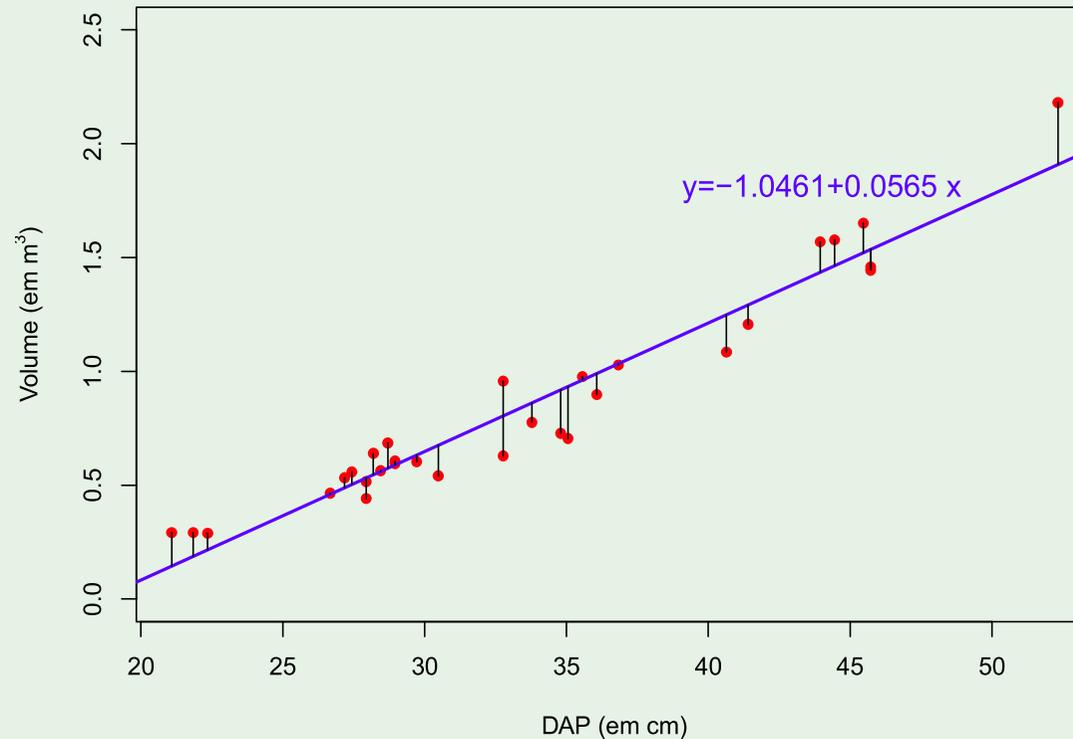
$$s_x^2 = 63.5348018$$

$$\bar{x} = 33.6509032$$

$$\bar{y} = 0.8543468$$

$$b_1 = \frac{cov_{xy}}{s_x^2} = 0.056476$$

$$b_0 = \bar{y} - b_1 \bar{x} = -1.046122$$



# Como se chegou à equação da recta?

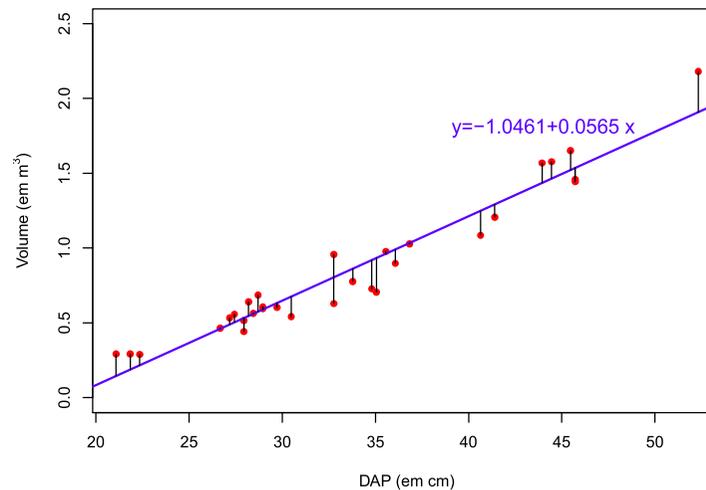
## Valores ajustados e Resíduos

Dada uma recta, valores de  $y$  podem ser previstos a partir de valores de  $x$ , obtendo-se os “valores de  $y$  ajustados pela recta”,  $\hat{y}_i$ :

$$\hat{y}_i = b_0 + b_1 x_i .$$

Os **resíduos** são as diferenças entre os valores de  $y$  observados e ajustados ou seja, são as diferenças **na vertical** entre pontos e recta ajustada:

$$e_i = y_i - \hat{y}_i = y_i - (b_0 + b_1 x_i) ,$$



# O Critério de Mínimos Quadrados

Critério: minimizar a Soma de Quadrados dos Resíduos

$$SQRE = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n [y_i - (b_0 + b_1 x_i)]^2 .$$

Determinar  $b_0$  e  $b_1$  que minimizam  $SQRE$  é um problema de minimizar uma função ( $SQRE$ ) de duas variáveis (aqui chamadas  $b_0$  e  $b_1$ ).

# Regressão Linear Simples - contexto descritivo

O critério de minimizar Soma de Quadrados dos Resíduos tem, subjacente, um pressuposto:

O papel das 2 variáveis,  $x$  e  $y$ , não é simétrico.

$y$  – **variável resposta** (“dependente”)

- variável que se deseja modelar, prever a partir da variável  $x$ .

$x$  – **variável preditora** (“independente”)

- variável com base na qual se pretende tirar conclusões sobre  $y$ .

# Regressão Linear Simples - contexto descritivo

O  $i$ -ésimo resíduo é o desvio (com sinal) da observação  $y_i$  face à sua previsão a partir da recta:

$$e_i = y_i - \hat{y}_i = y_i - (b_0 + b_1 x_i)$$

## Interpretação do Critério de Mínimos Quadrados

Minimizar a soma de quadrados dos resíduos corresponde a minimizar a soma de quadrados dos “erros de previsão”.

O critério tem subjacente a preocupação de **prever o melhor possível a variável  $y$** , a partir da sua relação com o preditor  $x$ .

# Revisão: Propriedades dos parâmetros da recta

## Propriedades dos parâmetros da recta de regressão

- A ordenada na origem  $b_0$ :
  - ▶ é o valor de  $y$  (na recta) associado a  $x = 0$ ;
  - ▶ tem unidades de medida iguais às de  $y$ .
- O declive  $b_1$ :
  - ▶ é a variação (**média**) de  $y$  associada a um aumento de uma unidade em  $x$ ;
  - ▶ tem unidades de medida iguais a  $\frac{\text{unidades de } y}{\text{unidades de } x}$ .

## Exemplo das cerejeiras

$$b_1 = 0.05648 \frac{m^3}{cm}$$

por cada cm a mais no DAP, o volume do tronco aumenta, **em média**,  $0.05648 m^3$ .

# Revisão: Propriedades da recta de regressão

## Propriedades da recta de regressão

- A recta de regressão passa sempre no centro de gravidade da nuvem de pontos, isto é, no ponto  $(\bar{x}, \bar{y})$ , como é evidente a partir da fórmula para a ordenada na origem:

$$b_0 = \bar{y} - b_1 \bar{x} \quad \Leftrightarrow \quad \bar{y} = b_0 + b_1 \bar{x} .$$

- $\bar{y}$  é simultaneamente a média dos  $y_i$  observados e dos  $\hat{y}_i$  ajustados.
- Embora não tenha sido explicitamente exigido, a média dos resíduos  $e_i$  é nula, ou seja,  $\bar{e} = 0$ .

# Revisão: RLS - As três Somas de Quadrados

Recordar:  $s_y^2 = \frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2$  a variância amostral das observações  $y_i$ .

## Soma de Quadrados Total (SQT)

$$\text{SQ Total} \quad SQT = \sum_{i=1}^n (y_i - \bar{y})^2 = (n-1) s_y^2$$

Tem-se:  $s_{\hat{y}}^2 = \frac{1}{n-1} \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$  a variância amostral dos  $\hat{y}_i$  ajustados.

## Soma de Quadrados da Regressão (SQR)

$$\text{SQ Regressão} \quad SQR = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 = (n-1) s_{\hat{y}}^2$$

## Soma de Quadrados Residual (SQRE) - já dado

$$\text{SQ Residual} \quad SQRE = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = (n-1) s_e^2$$

# Revisão: RLS - Fórmula fundamental e $R^2$

## Fórmula Fundamental da Regressão

Prova-se a seguinte Fórmula Fundamental (ver Exercício RLS 5):

$$SQT = SQR + SQRE \quad \Leftrightarrow \quad s_y^2 = s_{\hat{y}}^2 + s_e^2$$

## Definição: Coeficiente de Determinação

$$R^2 = \frac{SQR}{SQT} = \frac{s_{\hat{y}}^2}{s_y^2}, \quad (s_y^2 \neq 0)$$

$R^2$  mede a proporção da variabilidade total da variável resposta  $Y$  que é explicada pela regressão. Quanto maior, melhor.

# Propriedades do Coeficiente de Determinação

## Propriedades de $R^2 = \frac{SQR}{SQT}$

- $0 \leq R^2 \leq 1$  (Todas as SQs são não negativas e  $SQT = SQR + SQRE$ )

- $R^2 = 1$  se, e só se, os  $n$  pontos são colineares. (“ideal”)

$$(SQT = SQR \Leftrightarrow SQRE = \sum_{i=1}^n e_i^2 = 0 \Rightarrow e_i = 0, \text{ para todo o } i.)$$

Logo, todos os resíduos são nulos: os pontos estão todos em cima da recta.)

- $R^2 = 0$  se, e só se, a recta de regressão for horizontal. (“inútil”)

( $SQR = 0 \Leftrightarrow SQRE = SQT$  . Toda a variabilidade de  $y$  é residual.

$SQR = 0$  implica  $\hat{y}_i = \bar{y}$ , para todo o  $i$ . A recta é  $y = \bar{y} \Leftrightarrow b_1 = 0$ )

- Numa regressão linear **simples**,  $R^2$  é o quadrado do coeficiente de correlação linear entre  $x$  e  $y$ :

$$R^2 = r_{xy}^2 = \left( \frac{COV_{xy}}{S_x S_y} \right)^2 \quad \text{se } s_x \neq 0 \text{ e } s_y \neq 0$$

# Algumas ideias prévias sobre modelação

- Todos os modelos são apenas **aproximações** da realidade.
- Pode haver mais do que um modelo adequado a uma relação. Um dado modelo pode ser melhor num aspecto, mas pior noutro.
- O **princípio da parcimónia** na modelação: de entre os modelos considerados **adequados**, é preferível o **mais simples**.
- Os modelos **estatísticos** apenas descrevem **tendência de fundo**: há **variação** das observações em torno da tendência de fundo.
- Num modelo estatístico **não há necessariamente uma relação de causa e efeito entre variável resposta e preditores**. Há apenas **associação**. A eventual existência de uma relação de causa e efeito só pode ser **justificada por argumentos extra-estatísticos**.

# Transformações linearizantes

Nalguns casos, a relação de fundo entre  $x$  e  $y$  é não-linear, mas pode ser linearizada caso se proceda a transformações numa ou em ambas as variáveis.

Tais transformações podem permitir utilizar a Regressão Linear Simples, apesar de a relação original ser não-linear.

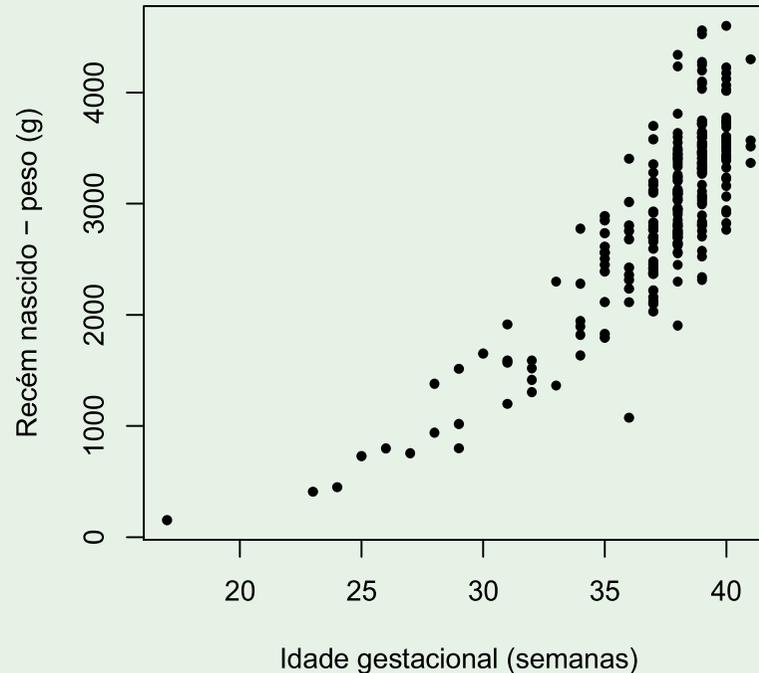
Vamos ver alguns exemplos particularmente frequentes de relações não-lineares que são linearizáveis através de transformações da variável resposta e, nalguns casos, também do preditor.

# Exemplo 3 - Uma relação não linear

## Peso de bebês à nascença

$n = 251$  pares de observações

Idade gestacional ( $x$ ) e peso de bebê à nascença  $y$ ,  $\{(x_i, y_i)\}_{i=1}^{251}$ .



A tendência de fundo é **não-linear**:  $y = f(x)$ .

## Exemplo 3 (cont.)

Neste caso, há uma **questão adicional**:

- Qual a **forma da relação** (qual a natureza da função  $f$ )?
  - ▶  $f$  exponencial ( $y = c e^{dx}$ )?
  - ▶  $f$  função potência ( $y = c x^d$ )?
  - ▶ outra?

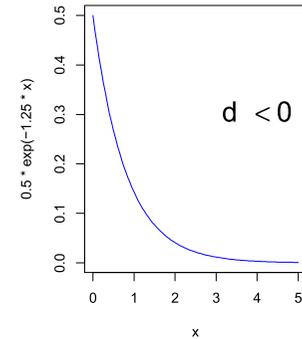
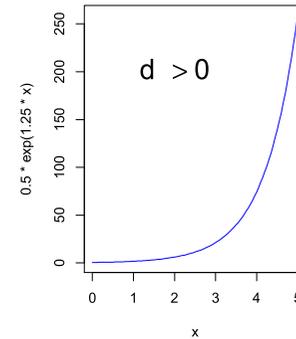
Além das perguntas análogas ao caso linear:

- Como determinar os “melhores” **parâmetros  $c$  e  $d$** ?
- E, se os dados forem amostra aleatória, **o que se pode dizer sobre os respectivos parâmetros populacionais?**

A **Regressão Não Linear** **não** faz parte do programa da disciplina. Mas **transformações linearizantes** de uma ou ambas as variáveis podem criar uma relação linear, que permita usar o Modelo Linear.

# Relação exponencial

Relação exponencial :  $y = ce^{dx}$   
( $y > 0$  ;  $c > 0$ )



Transformação : Logaritmizando, obtém-se:

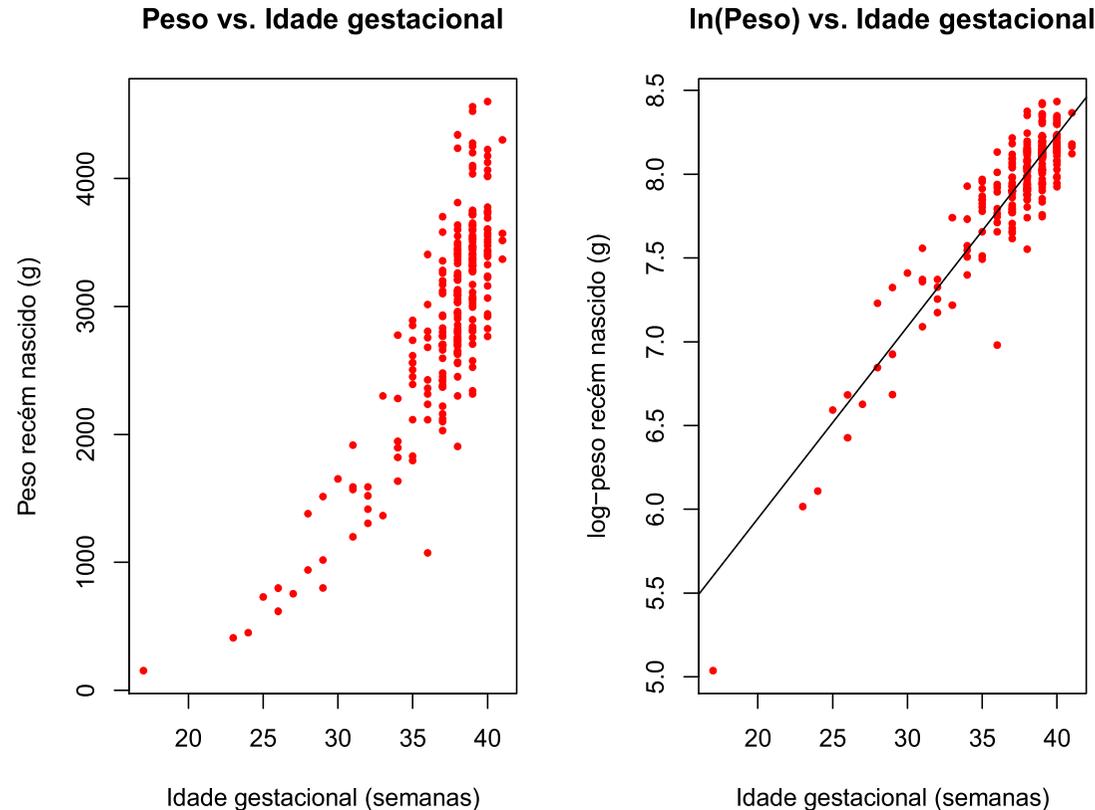
$$\begin{aligned} \ln(y) &= \ln(c) + dx \\ \Leftrightarrow y^* &= b_0 + b_1 x \end{aligned}$$

que é uma **relação linear entre  $y^* = \ln(Y)$  e  $x$** , com declive  $b_1 = d$  e ordenada na origem  $b_0 = \ln(c)$ .

O sinal do declive da recta indica se a relação exponencial original é crescente ( $b_1 > 0$ ) ou decrescente ( $b_1 < 0$ ).

# Uma linearização no Exemplo 3

O gráfico de **log-pesos** dos recém-nascidos contra idade gestacional produz uma relação de fundo linear:



Esta linearização da relação significa que a relação original (peso vs. idade gestacional) pode ser considerada exponencial.

# Ainda a relação exponencial

Uma relação exponencial resulta de admitir que  $y$  é função de  $x$  e que a **taxa de variação de  $y$** , ou seja, a derivada  $y'(x)$ , é proporcional a  $y$ :

$$y'(x) = d \cdot y(x) ,$$

isto é, que a taxa de variação **relativa** de  $y$  é constante:

$$\frac{y'(x)}{y(x)} = d .$$

Primitivando (em ordem a  $x$ ), tem-se:

$$\ln(y(x)) = \underbrace{d}_{=b_1} x + \underbrace{C}_{=b_0} \quad \Leftrightarrow \quad y(x) = e^C e^{dx} .$$

Repare-se que o declive  $b_1$  da recta é o valor (constante)  $d$  da taxa de **variação relativa de  $y$** . A constante de primitivação  $C$  é a ordenada na origem da recta:  $C = b_0$ .

# Modelo exponencial de crescimento populacional

Um modelo exponencial é frequentemente usado para descrever o **crescimento de populações**, numa fase inicial onde não se faz ainda sentir a escassez de recursos limitantes.

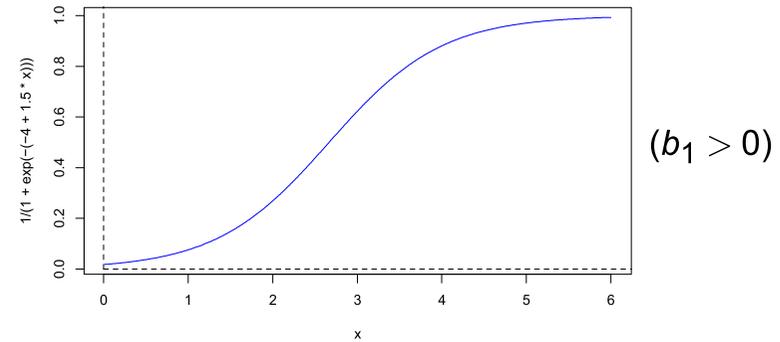
Mas nenhum crescimento populacional exponencial é sustentável a longo prazo.

Em 1838 Verhulst propôs uma **modelo de crescimento populacional alternativo**, prevendo os efeitos resultantes da escassez de recursos: o **modelo logístico**.

Considera-se aqui uma versão simplificada (com 2 parâmetros) desse modelo. Pode pensar-se que a variável  **$y$  mede a dimensão duma população, relativa a um máximo possível**, sendo assim uma proporção.

# Relação Logística (com 2 parâmetros)

$$\text{Relação Logística : } y = \frac{1}{1 + e^{-(c+dx)}}$$



Transformação : Como  $y \in ]0, 1[$ , tem-se uma relação linear entre a transformação *logit* de  $Y$ , i.e.,  $y^* = \ln\left(\frac{y}{1-y}\right)$ , e  $x$ :

$$\begin{aligned} \Rightarrow 1 - y &= \frac{e^{-(c+dx)}}{1 + e^{-(c+dx)}} \\ \Rightarrow \frac{y}{1-y} &= \frac{1}{e^{-(c+dx)}} = e^{c+dx} \\ \Rightarrow \underbrace{\ln\left(\frac{y}{1-y}\right)}_{=y^*} &= \underbrace{c}_{=b_0} + \underbrace{d}_{=b_1} x \end{aligned}$$

# Ainda a Logística

A relação logística resulta de admitir que  $y$  é função de  $x$  e que a taxa de variação relativa de  $y$  diminui com o aumento de  $y$ :

$$\frac{y'(x)}{y(x)} = d \cdot [1 - y(x)] .$$

De facto, a expressão anterior equivale a:

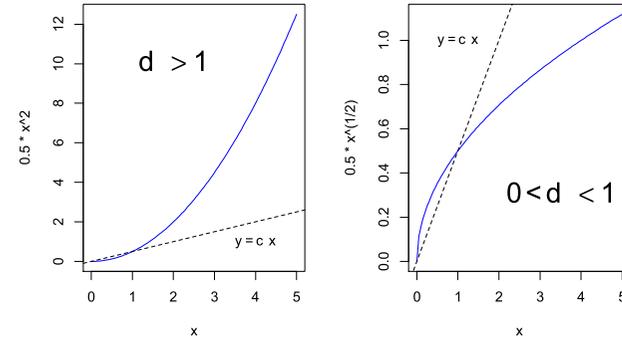
$$\frac{y'(x)}{y(x) \cdot (1 - y(x))} = d \quad \Leftrightarrow \quad \frac{y'(x)}{1 - y(x)} + \frac{y'(x)}{y(x)} = d$$

Primitivando (em ordem a  $x$ ), tem-se:

$$\begin{aligned} -\ln(1 - y(x)) + \ln y(x) &= d x + C \\ \Leftrightarrow \ln \left( \frac{y}{1 - y} \right) &= b_1 x + b_0 . \end{aligned}$$

# Relação potência ou alométrica

Relação potência :  $y = cX^d$   
( $x, y > 0$  ;  $c, d > 0$ )



Transformação : Logaritmizando, obtém-se:

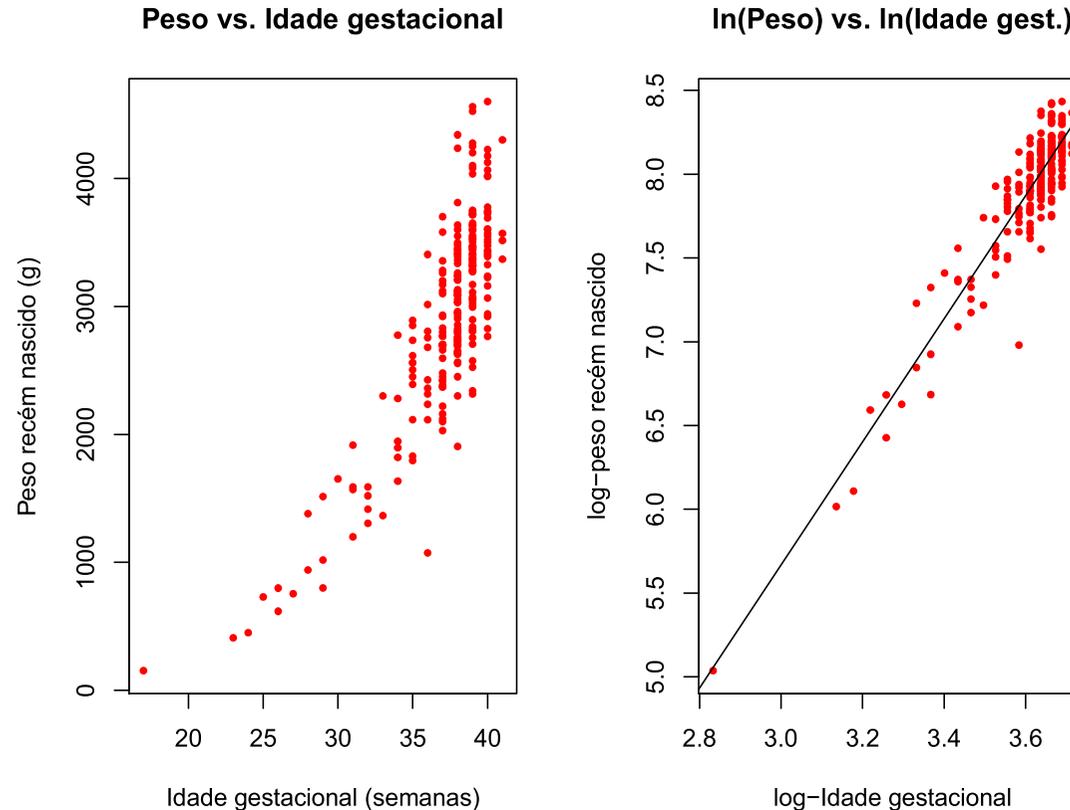
$$\ln(y) = \ln(c) + d \ln(x)$$
$$\Leftrightarrow y^* = b_0 + b_1 x^*$$

que é uma **relação linear entre  $y^* = \ln(y)$  e  $x^* = \ln(x)$ .**

O declive  $b_1$  da recta é o expoente  $d$  na relação potência original.  
Mas  $b_0 = \ln(c)$ .

# Outra linearização no Exemplo 3

O gráfico de **log-pesos** dos recém-nascidos contra **log-idade gestacional** produz outra relação de fundo linear:



Esta linearização significa que a relação original (peso vs. idade gestacional) **também** pode ser considerada uma relação potência.

# Ainda a relação potência

Uma relação potência resulta de admitir que  $y$  e  $x$  são funções duma terceira variável  $t$  e que a taxa de variação relativa de  $y$  é proporcional à taxa de variação relativa de  $x$ :

$$\frac{y'(t)}{y(t)} = d \cdot \frac{x'(t)}{x(t)} .$$

De facto, primitivando (em ordem a  $t$ ), tem-se:

$$\ln y = d \ln x + C$$

e exponenciando,

$$y = x^d \cdot \underbrace{e^C}_{=c}$$

A relação potência é muito usado em estudos de **alometria**, que comparam o crescimento de partes diferentes dum organismo.

A **isometria** corresponde ao valor  $d = 1$ .

# Advertência sobre transformações linearizantes

A regressão linear simples **não** modela **directamente** relações **não lineares** entre  $x$  e  $y$ . Pode modelar **uma relação linear** entre as **variáveis transformadas**.

**Transformações da variável-resposta  $y$**  têm um impacto grande no ajustamento: **a escala dos resíduos é alterada**.

**Nota:** Linearizar, obter os parâmetros  $b_0$  e  $b_1$  da recta e depois desfazer a transformação linearizante **não** produz os mesmos parâmetros ajustados que resultariam de minimizar a soma de quadrados dos resíduos **directamente** na relação não linear. Esta última abordagem corresponde a efectuar uma **regressão não linear**, metodologia não englobada nesta disciplina.