

# Aula 8 – Introdução aos modelos lineares

Teste  $t$  de Student


# Ao final desta aula, vocês serão capazes de:

- Identificar situações em que o Teste  $t$  de Student é o teste apropriado
- Diferenciar entre o Teste  $t$  para uma amostra, para duas amostras independentes e para dados pareados
- Formular hipóteses nula ( $H_0$ ) e alternativa ( $H_1$ ) para diferentes cenários biológicos
- Compreender os pressupostos do teste: normalidade e homogeneidade de variâncias
- Interpretar o resultado de um Teste  $t$  (valor de  $p$  e estatística de teste) para tomar uma decisão e redigir uma conclusão contextualizada


Esta aula está baseada em




Cap 10 e 11



Cap 9



Cap 12 e 13



Cap 7, 8 e 9

# Perguntas comuns

- Um novo fertilizante realmente aumenta o crescimento médio das plantas em comparação com o fertilizante antigo?
- A concentração de um poluente em um rio está, em média, acima do limite de segurança estabelecido por lei?
- Um medicamento para baixar a pressão arterial realmente funciona? Como podemos provar isso comparando a pressão *antes* e *depois* do tratamento?

# O que é um teste $t$

*Ferramenta estatística que permite comparar médias de uma ou duas populações. Ele avalia se as médias são significativamente diferentes, levando em conta a média, o desvio padrão, e o tamanho da amostra.*

# Os 4 Passos do Teste de Hipóteses:

Construir as hipóteses ( $H_0$  e  $H_1$ ).

Especificar o nível de significância ( $\alpha$ ).

Calcular o valor do teste (a estatística  $t$ ).

Interpretar o resultado e tomar uma decisão

# Hipótese nula e alternativa(s)

- **Hipótese Nula ( $H_0$ ):** A hipótese da "não diferença" ou da "nulidade".
  - Ela sempre contém o sinal de igualdade ( $=$ ,  $\leq$ , ou  $\geq$ ). Ex: "A média de peso dos filhotes é igual a 25 kg" ( $H_0: \mu = 25$ ).
- **Hipótese(s) Alternativa(s) ( $H_1$ ,  $H_A$ ):** contradiz a hipótese nula. É geralmente o que o pesquisador quer apoiar. Ex. A média de peso é diferente de 25 Kg ( $H_1: \mu \neq 25$ )

# Nível de significância e erros

<b>Decisão</b>	<b><math>H_0</math> é Verdadeira</b>	<b><math>H_0</math> é Falsa</b>
Não Rejeitar $H_0$	Decisão Correta	Erro do Tipo II ( $\beta$ )
Rejeitar $H_0$	Erro do Tipo I ( $\alpha$ )	Decisão Correta (Poder)

Tabela 1. Sugestão de alguns testes estatísticos a empregar de acordo com o tipo de variável observada. Entre parênteses alguns testes não-paramétricos.

Variável Dependente	Variável Independente	Teste
Quantitativa	1 Categórica com 2 níveis	Teste t (teste U)
Quantitativa	1 Categórica com + 2 níveis	ANOVA 1-fator (Kruskall-Wallis)
Quantitativa	2 Categóricas	ANOVA 2-fatores (Friedman <sup>1</sup> )
Quantitativa	1 Quantitativa	Regressão simples (correlação Spearman)
Quantitativa	2 ou mais quantitativas	Regressão múltipla
Quantitativa	1 categórica e 1 ou mais quantitativas	ANCOVA
Categórica	1 Categórica	Qui-quadrado <sup>2</sup> ; Teste G <sup>2</sup>
Categórica	2 ou mais categóricas	Log-linear <sup>2</sup>

(1) No caso de amostras dependentes, (2) Esses testes eventualmente verificam não a relação de dependência entre variáveis, mas sim a associação entre elas, descaracterizando, portanto a classificação de variáveis dependentes e independentes.

# Teste $t$ para uma amostra

- **Quando usar:** para comparar a média de uma amostra com um valor de referência específico ( $\mu_0$ )
- **Exemplos biológicos:**
- A OMS preconiza uma taxa de cesáreas de 15%. Um pesquisador coleta dados de uma maternidade para verificar se a taxa média é diferente desse valor de referência.
- Verificar se a quantidade média de flúor em uma marca de dentifrício corresponde ao valor especificado na embalagem

# Hipóteses uni- e bicaudais

- Bicaudal

$$H_0: \mu = \mu_0 \text{ vs. } H_1: \mu \neq \mu_0$$

- Unicaudal

$$H_0: \mu \geq \mu_0 \text{ vs. } H_1: \mu < \mu_0 \text{ (ou } H_0: \mu \leq \mu_0 \text{ vs. } H_1: \mu > \mu_0)$$

# Cálculo da estatística $t$

$$t = \frac{\bar{x} - \mu_0}{s/\sqrt{n}}$$

- Média da amostra ( $\bar{x}$ )
- Valor de referência ( $\mu_0$ )
- Desvio padrão ( $s$ )
- Tamanho da amostra ( $n$ )

# Tomada de decisão

Compare o  $t$  calculado com o  $t$  crítico da tabela (com  $n-1$  graus de liberdade)

Ou, de forma mais moderna, observe o **valor-p** fornecido pelo software




FIGURE 7.1: The  $t$  distribution for various degrees of freedom,  $\nu$ . For  $\nu = \infty$ , the  $t$  distribution is identical to the normal distribution.

# Atividade prática 1 – Pense-pareie-compartilhe (10 min)

- **Cenário:** "Um biólogo sabe que, historicamente, uma espécie de peixe em um lago tem um comprimento médio de 15 cm. Após a introdução de uma nova espécie invasora, ele mede o comprimento de 30 peixes da espécie nativa e suspeita que o tamanho médio diminuiu. Quais são as hipóteses  $H_0$  e  $H_1$  para este estudo?"
- **Instruções:**
  1. Pensem individualmente por 1 minuto
  2. Discutam com um colega ao lado por 2 minutos
  3. 2-3 duplas compartilham suas respostas

# Teste $t$ para duas amostras

- **Amostras Independentes:** Os valores de uma amostra não estão relacionados ou pareados com os da outra. Os grupos são distintos
  - **Exemplos:** Comparar o nível de ansiedade entre um grupo de meninos e um grupo de meninas ; comparar o tempo de alívio da dor entre um grupo que recebeu um anti-inflamatório e *outro* grupo que recebeu laser.
- **Amostras Dependentes (Dados Pareados):** Os valores da amostra são pareados. Cada dado numa amostra está ligado a outro na segunda amostra.
  - **Exemplos:** Medir uma variável nos mesmos indivíduos *antes* e *depois* de uma intervenção (ex: peso em setembro vs. abril) ; comparar uma característica entre mãe e filho, ou em gêmeos.

# Teste t para amostras independentes

- **Objetivo:** Comparar as médias de dois grupos completamente separados.
- **Pressuposto Chave:** As variâncias dos dois grupos devem ser aproximadamente iguais (**Homogeneidade de Variâncias**)
  - Como verificar? Usa-se um **Teste F** para comparar as duas variâncias. A hipótese nula do Teste F é que as variâncias são iguais ( $H_0: \sigma_1^2 = \sigma_2^2$ )

# Caso 1: variâncias homogêneas


- Calcula-se a **variância combinada** (*pooled variance*,  $s_p^2$ ), que é uma média das duas variâncias de amostra, ponderada pelos graus de liberdade

$$t = \frac{\bar{x}_1 - \bar{x}_2}{\sqrt{s_p^2 \left( \frac{1}{n_1} + \frac{1}{n_2} \right)}}$$


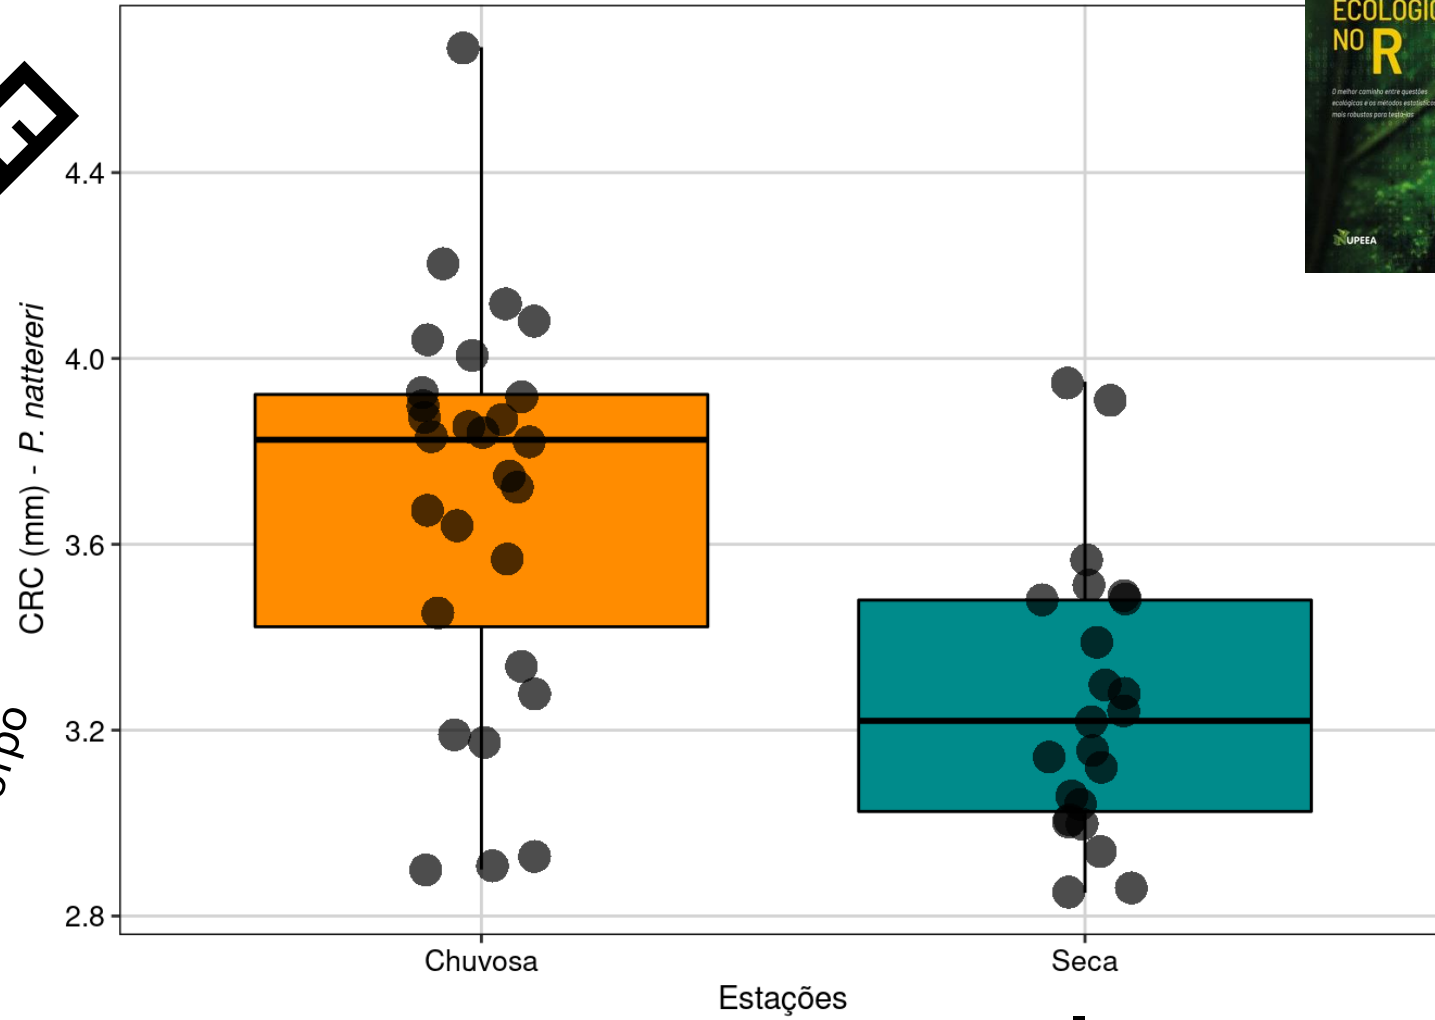
- Graus de liberdade

$$v = n_1 + n_2 - 2$$

# Exemplo



Tamanho do corpo



## Caso 2 – Variâncias heterogêneas

- Se o Teste F indica que as variâncias são diferentes, uma versão modificada do Teste  $t$  é usada (conhecido como Teste  $t$  de Welch).
- Não se calcula a variância ponderada

$$t = \frac{\bar{x}_1 - \bar{x}_2}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}}$$

Graus de liberdade: cálculo feito por programa

# Teste t para dados pareados

- **Lógica** : Este teste reduz um problema de duas amostras a um problema de uma amostra. Ele não analisa os dados originais, mas sim a **diferença (d)** dentro de cada par.
- **Procedimento**:
  1. Para cada par, calcule a diferença:  $d = x_{antes} - x_{depois}$
  2. Calcule a média das diferenças (d) e o desvio padrão das diferenças (sd)
  3. Execute um Teste t para *uma amostra* nessas diferenças, testando se a média das diferenças é igual a zero.


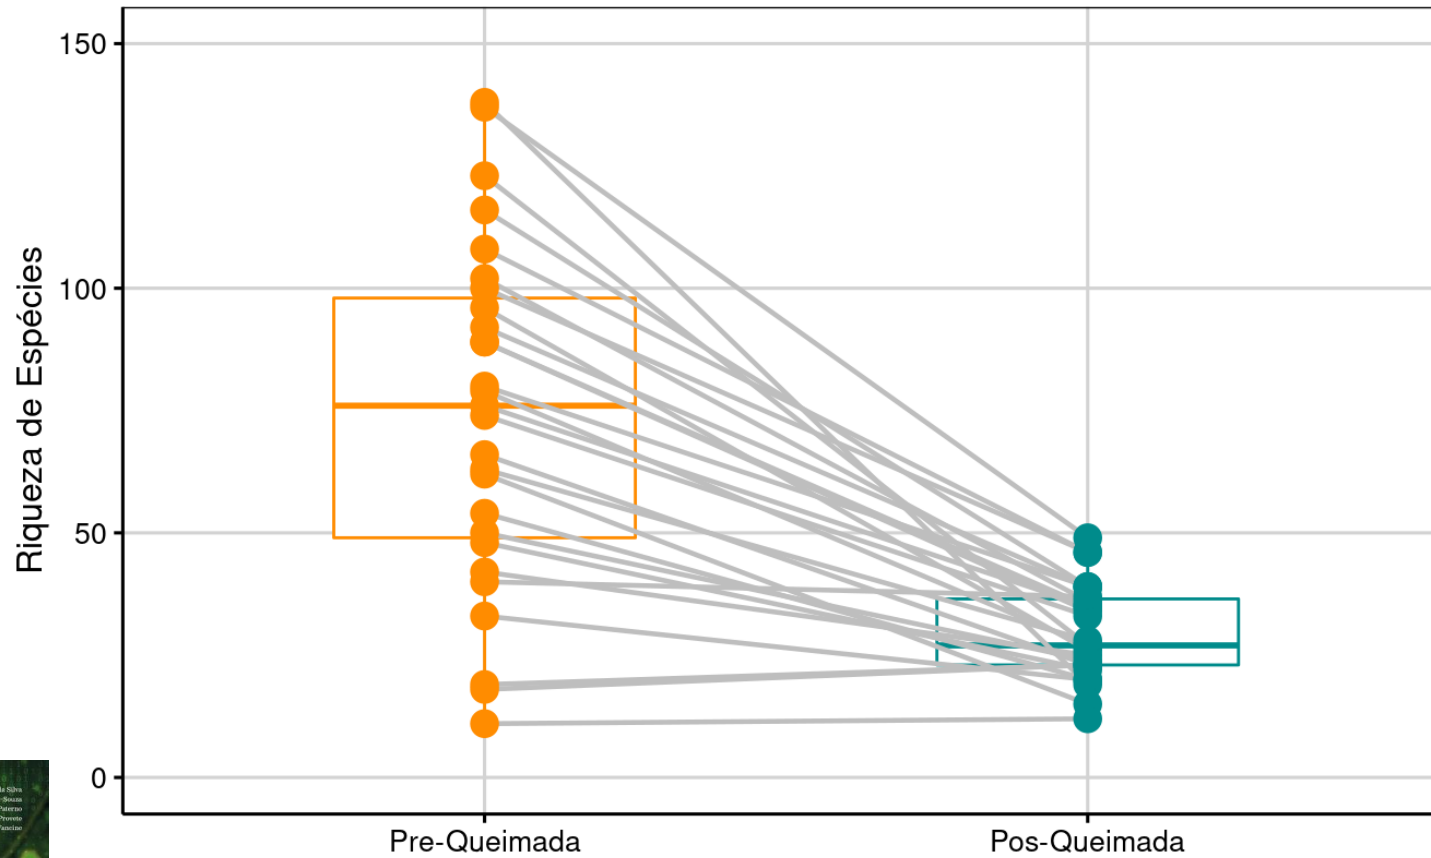
# Teste t para dados pareados

- Hipóteses:  $H_0: \mu_d = 0$  vs.  $H_1: \mu_d \neq 0$


- Fórmula: 
$$t = \frac{\bar{d} - 0}{s_d / \sqrt{n}}$$

- Graus de liberdade:  $\nu = n - 1$  (n = número de pares)


# Exemplo



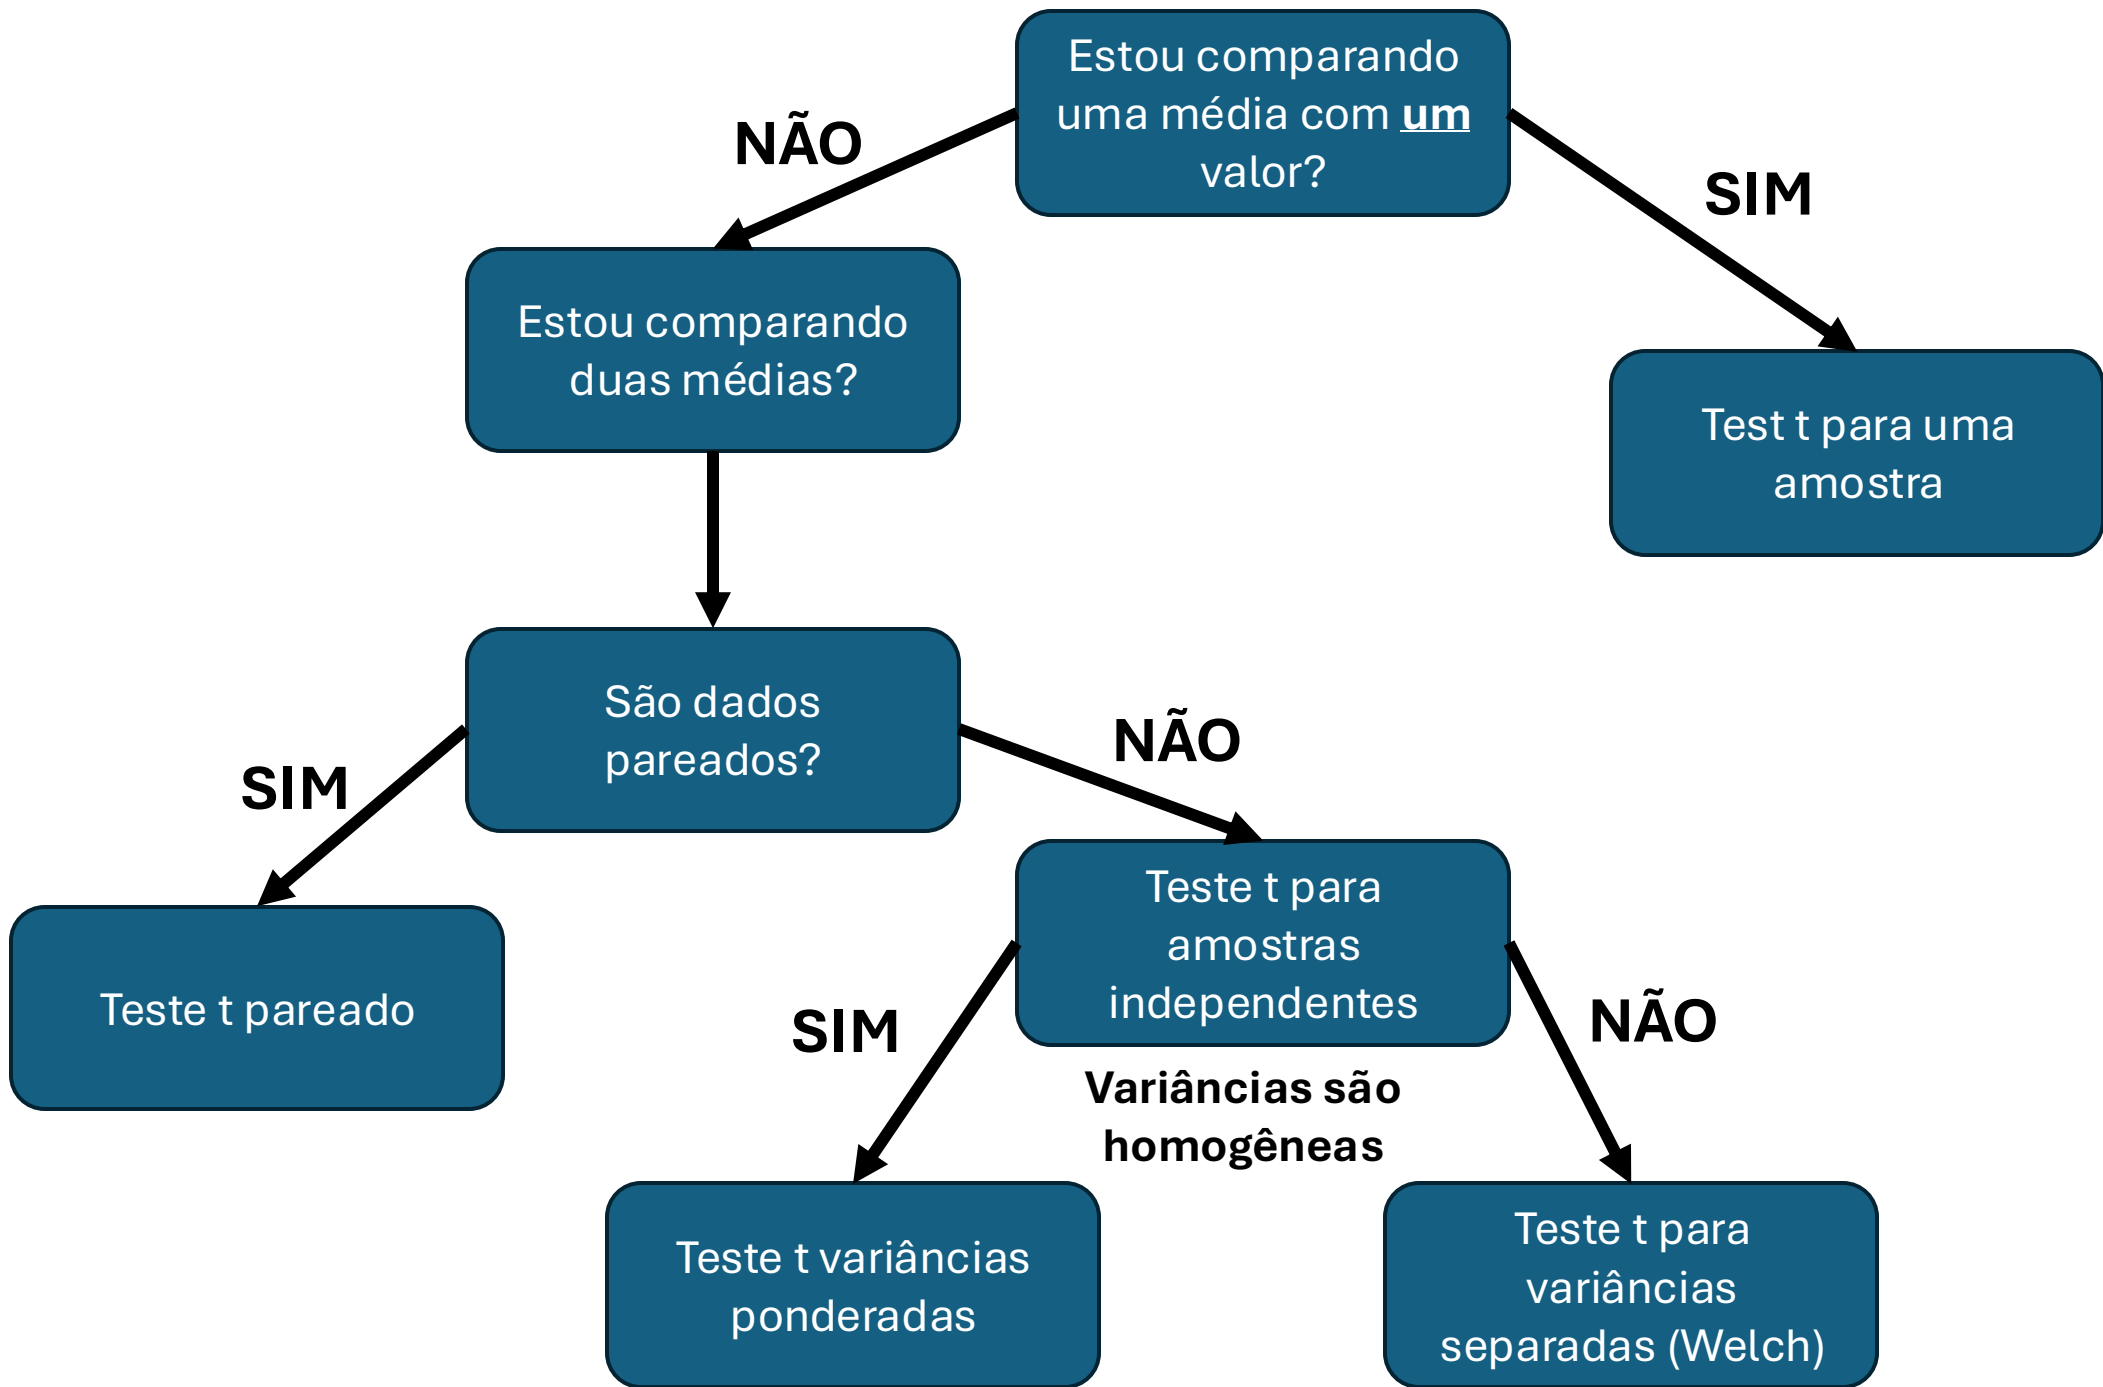
Riqueza de artrópodes  
de 27 áreas  
comparadas antes e  
depois de queimada



# Atividade prática 2 – Qual teste usar? (5 min)



<https://play.kahoot.it/v2/lobby?quizId=095cb8f0-fc9f-437a-9449-105b02de0750>



# Como interpretar o resultado do teste

- A conclusão nunca “prova” que  $H_1$  é verdadeira (Lembrem-se do Popper). Usamos frases como: “Há evidência estatística suficiente para rejeitar a hipótese nula...” ou “Não há evidência estatística para concluir que as médias são diferentes...”.
- A conclusão deve sempre se referir ao contexto do problema original. Exemplo: “Não foi encontrada evidência de que os oito ratos machos (...) tinham peso médio diferente do especificado (70 g)”

# E se os pressupostos não forem atendidos?

- **Normalidade:** O Teste  $t$  é considerado **robusto** a desvios da normalidade, especialmente com amostras maiores ( $n > 30$ ) ou de tamanhos iguais. No entanto, se os dados forem muito assimétricos ou contiverem outliers, os resultados podem não ser confiáveis.
- **Possível solução:** testes não paramétricos ou transformações nos dados

- Até aqui aprendemos três versões do Teste t de Student: para uma amostra, para duas amostras independentes e para dados pareados. Cada um parecia ter sua própria fórmula e seu próprio procedimento.
- Isso pode parecer uma 'coleção de testes', uma receita de bolo para cada situação.
- Mas e se eu dissesse que todos eles são, na verdade, **a mesma ideia estatística fundamental** disfarçada de maneiras diferentes?

**Médias amostrais são  
estimadores não  
enviesados de médias  
populacionais**

---

**Posso comparar  
médias de duas  
populações**

---

**Existem vários tipos  
de teste t**

---

**Diferentes teste t são  
tipos particulares de  
um modelo linear  
unificado**





- Agora, vamos revisitar o Teste t, mas sob uma nova ótica: a de **modelagem linear**.
- Vamos ver como todos os testes t são, na essência, modelos lineares simples.
- Entender isso não só unifica o conhecimento, mas abre as portas para quase todas as técnicas estatísticas que vocês usarão na carreira, como a ANOVA.

# Equação de um modelo linear passo-a-passo

Variável resposta = modelo + erro

# Equação de um modelo linear passo-a-passo

$$y_i = \alpha + \beta x_i + \varepsilon$$

# Equação de um modelo linear passo-a-passo

$$y_i = \alpha + \beta x_i + \varepsilon$$

# Equação de um modelo linear passo-a-passo

$$y_i = \alpha + \beta x_i + \varepsilon$$

Variável resposta



Variável preditora




# Equação de um modelo linear passo-a-passo

$$y_i = \alpha + \beta x_i + \varepsilon$$

intercepto

Inclinação (slope)



# Exemplo

Altura dos filhos =  $\alpha + \beta * \text{altura dos pais} + \text{resíduos}$

Pressão arterial =  $\alpha + \beta * \text{grupo de tratamento} + \text{resíduos}$

# Parâmetros do modelo

- Intercepto = valor médio da variável resposta quando a variável preditora é zero
- Inclinação (slope, coeficiente angular) = inclinação da reta predita pelo modelo. Representa o efeito de  $X$  sobre  $Y$ . Mede o quanto a variável resposta ( $Y$ ) muda em unidades de  $\beta$ .
  - Pode-se calcular o IC95% para o slope
- Resíduo (erro): Representa a variabilidade biológica natural e tudo mais que não conseguimos explicar com nosso modelo.



# Preditores categóricos

- Até agora, parece uma equação de reta da 8ª série. Mas o grande poder do modelo linear é que a variável preditora, X, **não precisa ser numérica**
- Podemos usar uma variável categórica, como 'grupo tratado'. E a maneira de fazer isso é com algo chamado **variáveis Dummy**
  - Se temos dois grupos (ex: Controle e Tratamento), criamos uma variável X que assume o valor **0** para um grupo (o grupo de referência, ex: Controle) e **1** para o outro (ex: Tratamento).

# Variáveis *dummy* como “tradutores”

- Mas e se o nosso preditor não for um número e sim uma categoria? Por exemplo:
  - **Grupo:** Tratamento vs. Controle
  - **Sexo:** Macho vs. Fêmea
  - **Local:** Área Preservada vs. Área Poluída
- Não podemos colocar a palavra “Tratamento” na equação e multiplicá-la por  $\beta$ . Precisamos de uma forma de “traduzir” essas categorias para uma linguagem numérica que o modelo linear entenda.
- A variável dummy é um “tradutor” que converte categorias em números (0 e 1), permitindo que usemos preditores categóricos em modelos matemáticos como o modelo linear.

# Solução para o problema

- A **variável *dummy*** (também chamada de variável fictícia, indicadora ou binária) é a solução para este problema. Ela é uma variável numérica que representa uma informação categórica.
- **Como funciona?** A forma mais comum é a **codificação 0/1**:
- **Escolha um “Grupo de Referência”**: Um dos seus grupos será a base de comparação. A escolha é arbitrária, mas afeta a interpretação dos resultados. Geralmente, o grupo "Controle" ou o grupo mais comum é escolhido como referência.
- **Atribua os Códigos**:
  - O grupo de referência recebe o código **0**.
  - O outro grupo recebe o código **1**.
- Essa simples codificação transforma nossa variável categórica em um número que pode ser usado na equação do modelo linear. Ela atua como um “interruptor”: está “desligada” (0) para o grupo de referência e “ligada” (1) para o outro grupo.

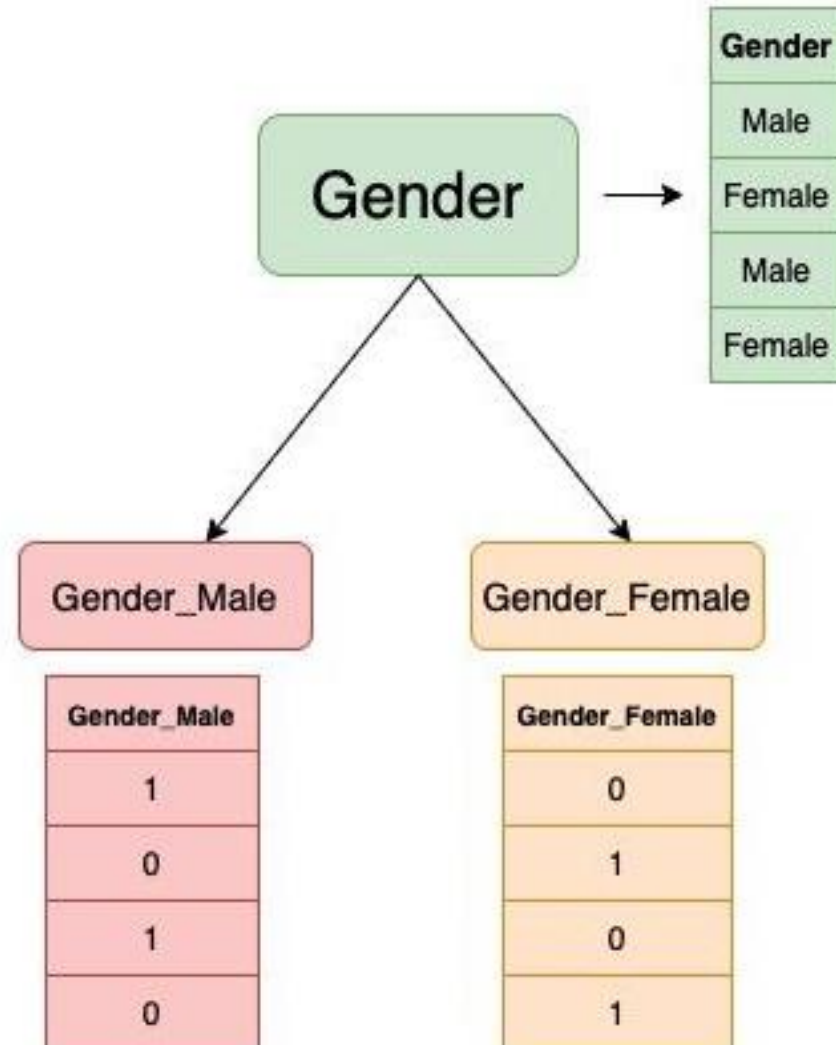
# Codificando um fator como *dummy*

- Vamos usar um cenário biológico: um experimento para testar o efeito de um suplemento na dieta de ratos.
- **Variável Categórica Original:** Grupo (com os níveis "Controle" e "Suplemento")
- **Variável Resposta (Y):** Peso\_Final (em gramas)

Rato	Grupo	Peso_Final (g)
1	Controle	205
2	Controle	215
3	Suplemento	230
4	Suplemento	240
5	Controle	210

Rato	Grupo	Peso_Final (g)	Suplemento_dummy
1	Controle	205	0
2	Controle	215	0
3	Suplemento	230	1
4	Suplemento	240	1
5	Controle	210	0

# Dummy para um fator com 2 níveis



# A mágica na interpretação do modelo

- Agora, vamos ver o que acontece quando colocamos essa variável dummy na nossa equação:

$$Peso\_Final_i = \alpha + \beta \cdot (Suplemento\_dummy_i)$$

- **Para um rato do grupo Controle (Suplemento\_dummy=0):** A equação se torna:

$$Peso\_Final_{Controle} = \alpha + \beta \cdot (0) = \alpha$$

- **Interpretação:** O coeficiente  $\alpha$  (o intercepto) é a **média de peso do grupo de referência** (o grupo Controle)
- **Para um rato do grupo Suplemento (Suplemento\_dummy=1):** A equação se torna:

$$Peso\_Final_{Suplemento} = \alpha + \beta \cdot (1) = \alpha + \beta$$

- **Interpretação:** A média de peso do grupo Suplemento é a média do grupo Controle ( $\alpha$ ) **mais** o valor de  $\beta$ .

# Ligando os pontos

- Isso significa que o coeficiente  $\beta$  representa exatamente a **diferença entre a média do grupo “1” e a média do grupo “0”**

$$\beta = \text{Média}_{\text{Suplemento}} - \text{Média}_{\text{Controle}}$$

- Portanto, fazer um **Teste t para amostras independentes** para testar se as médias dos dois grupos são iguais ( $H_0: \mu_{\text{Suplemento}} = \mu_{\text{Controle}}$ ) é matematicamente idêntico a fazer um **modelo linear** e testar se o coeficiente da variável *dummy* é igual a zero ( $H_0: \beta = 0$ )

# E se tivermos mais de 2 grupos?

- A beleza dessa abordagem é que ela se expande facilmente. Se você tiver  $k$  grupos, precisará de  $k-1$  variáveis *dummy*
- **Exemplo com 3 grupos:** “Controle”, “Tratamento A”, “Tratamento B”
- **Referência:** “Controle”
- **Variáveis *Dummy* (precisamos de  $3 - 1 = 2$ ):**
  - **Trat\_A\_dummy:** É 1 se o grupo for "Tratamento A", 0 se for o contrário.
  - **Trat\_B\_dummy:** É 1 se o grupo for "Tratamento B", 0 se for o contrário.

## *Dummy* para um fator com 3 níveis

Grupo	Trat_A_dummy	Trat_B_dummy
Controle	0	0
Tratamento A	1	0
Tratamento B	0	1

# E se tivermos mais de 2 grupos?

- O modelo seria

$$y = \alpha + \beta_1 * \left( \text{Trat}_{A \text{ dummy}} \right) + \beta_2 \left( \text{Trat}_{B \text{ dummy}} \right)$$

- $\alpha$  seria a média do grupo Controle.
- $\beta_1$  seria a diferença entre a média do Tratamento A e o Controle.
- $\beta_2$  seria a diferença entre a média do Tratamento B e o Controle.
- Isso é, fundamentalmente, como a **Análise de Variância (ANOVA)** funciona!

# Construindo o modelo passo-a-passo

- Queremos comparar o teor de sódio em duas marcas de sopa. Nossa variável resposta (Y) é “teor de sódio”. Nossa variável preditora (X) é a “marca da sopa”



# Modelo

Marca de Sopa	Codificação
Knor (Referência)	0
Vono	1

- $Sódio = \alpha + \beta * Marca + \varepsilon_i$
- Interpretando os Coeficientes:
- Para a Knor (X=0):  **$Média(Sódio_{Knor}) = \alpha + \beta * (0) = \alpha$** 
  - Conclusão: é simplesmente a média do teor de sódio do grupo de referência (Marca Knor)!
- Para a Vono (X=1):  **$Média(Sódio_{Vono}) = \alpha + \beta * (1) = \alpha + \beta$** 
  - Conclusão: A média da Vono é a média da Knor mais o valor de  $\beta$ .
- Se  **$Média(Sódio_{Vono}) = Média(Sódio_{Knor}) + \beta$** , então  **$\beta = Média(Sódio_{Vono}) - Média(Sódio_{Knor})$**
- $\beta$  é exatamente a diferença entre as médias dos grupos!



# Conectando com o teste de hipótese

- A hipótese nula do Teste t para amostras independentes é  $H_0: \mu_A = \mu_B$
- Isso é o mesmo que dizer que a diferença entre as médias é zero:  $H_0: \mu_B - \mu_A = 0$
- Vimos que  $\beta$  é a diferença entre as médias. Portanto, a hipótese nula do Teste t é **exatamente a mesma** que testar se o coeficiente  $\beta$  é igual a zero no modelo linear:  **$H_0: \beta = 0$**
- A estatística  $t$  e o valor-p que você obtém ao testar se  $\beta = 0$  num programa são idênticos aos que você obtém com um Teste t para amostras independentes

# Atividade – Desafio do coeficiente

- **Cenário:** Pesquisadores testaram um novo fármaco para inibir o crescimento de tumores em ratos. Um grupo recebeu o fármaco (Tratado) e outro, um placebo (Controle). Eles rodaram um modelo linear e obtiveram a seguinte saída de computador:

```
Variável Resposta: Tamanho_Tumor (mm3)
```

```
-----  
Coeficiente | Estimativa | Erro Padrão | t-valor | p-valor  
-----  
(Intercepto) | 52.5 | 3.1 | 16.9 | < 0.001  
GrupoTratado | -15.3 | 4.5 | -3.4 | 0.003  
-----
```

```
(Grupo de Referência: Controle)
```

# Atividade – Desafio do coeficiente

1. Qual é o tamanho médio do tumor no grupo Controle?
2. Qual é a *diferença* no tamanho médio do tumor entre o grupo Tratado e o Controle?
3. Qual era a hipótese nula que o Teste t estaria avaliando? E qual a hipótese nula correspondente no modelo linear?
4. Com um nível de significância de  $\alpha=0.05$ , o fármaco teve um efeito estatisticamente significativo? Por quê?

# Atividade – Desafio do coeficiente

1. Qual é o tamanho médio do tumor no grupo Controle?  
a)  $52.5 \text{ mm}^3$ , o valor do intercepto  $\alpha$
2. Qual é a *diferença* no tamanho médio do tumor entre o grupo Tratado e o Controle?  
a)  $-15.3 \text{ mm}^3$ , o valor de  $\beta$ . O sinal negativo indica que o grupo tratado teve um tumor menor
3. Qual era a hipótese nula que o Teste t estaria avaliando?  
a)  $H_0: \mu_{\text{Controle}} = \mu_{\text{Tratado}}$
4. E qual a hipótese nula correspondente no modelo linear?  
a)  $H_0: \beta = 0$
5. Com um nível de significância de  $\alpha=0.05$ , o fármaco teve um efeito estatisticamente significativo? Por quê?

# Test t pareado: o modelo mais simples

- **Lógica:** Como vimos, o Teste t pareado funciona calculando a **diferença** ( $d_i$ ) para cada par. Isso cria uma *nova e única variável*.
- **O Modelo:** Estamos simplesmente testando se a média dessa nova variável é zero.  $d_i = \beta + \varepsilon_i$
- **A Hipótese:** A hipótese nula  $H_0: \mu_d = 0$  é idêntica a testar se o intercepto desse modelo é zero:  **$H_0: \alpha = 0$** .
- **Conexão:** Um Teste t pareado é apenas um modelo linear com um único parâmetro (o intercepto), aplicado aos dados de diferença

# Teste t para uma amostra

- **Lógica:** Queremos testar se a média da nossa amostra é igual a um valor de referência,  $\mu_0$ .
- **O Modelo:** Em vez de modelar  $Y$ , vamos modelar a diferença para o valor de referência:  $Y'_i = Y_i - \mu_0$ .
- Se a média original ( $E[Y_i]$ ) for igual a  $\mu_0$ , então a média da nossa nova variável ( $E[Y'_i]$ ) = 0
- **Equação do Modelo:**  $(Y_i - \mu_0) = \alpha + \varepsilon_i$
- **A Hipótese:** A hipótese nula  $H_0: \mu = \mu_0$  se torna um teste para saber se o intercepto (que é a média da variável transformada) é zero:  
 **$H_0: \alpha = 0$**

# Por que pensar em modelos?

Tipos de teste $t$	Pergunta	Modelo linear	Hipótese nula
Uma amostra	A média da população é $\mu_0$ ?	$(Y - \mu_0) \sim \alpha$	$H_0: \alpha = 0$
Pareado	A média das diferenças é 0?	$Y_{diferença} \sim \alpha$	$H_0: \alpha = 0$
Amostras independentes	As médias dos dois grupos são iguais?	$Y \sim \alpha + \beta X_{grupo}$	$H_0: \beta = 0$

# Vantagens da abordagem de modelagem

- **Escalabilidade:** E se tivermos 3 grupos ou mais? Não precisamos de um novo teste “do zero”. Apenas adicionamos mais preditores *dummy* ao nosso modelo linear. Isso é a **ANOVA**.
- **Flexibilidade:** E se quisermos comparar dois grupos, mas também controlar o efeito de uma variável contínua (como a idade do paciente)? Apenas adicionamos outra variável preditora ao modelo. Isso é a **ANCOVA**.
  - $Y \sim \alpha + \beta_1 X_{grupo} + \beta_2 X_{idade}$
- **Compreensão profunda:** Em vez de decorar uma lista de testes, você aprende um único arcabouço para formular e responder perguntas científicas

*O Teste t, a ANOVA e a regressão não são ferramentas diferentes; são variações de um mesmo tema: os modelos lineares.*

*Ao entender essa conexão, vocês estão se preparando não apenas para usar a estatística, mas para pensar como estatístico(a)!*