

Estimativas



- Como estimar a média de glicemia (de animais saudáveis) de uma população?
- Como estimar a proporção de pacientes que morrem de uma dada doença?


Algumas notações

Parâmetro	População	Amostra
Média	μ	\bar{x}
Desvio-padrão	σ	s
Variância	σ^2	s^2
Proporção	p	\hat{p}
Tamanho	N	n


Variáveis quantitativas

Estimativa de média


- População tem média μ desconhecida
- Como, a partir de uma amostra, é possível estimar μ ?



GLICEMIA



Histograma de uma amostra (100 animais).




Exemplo
População: $\mu = ?$

Amostra: $\bar{x} = 91,08$


Animal	Glicemia
1	95,00
2	88,50
3	99,70
...	...
100	85,40

GLICEMIA




População: $\mu = ?$

Histograma de uma amostra (100 animais).




Amostra 1: $\bar{x} = 91,08$

Histograma de outra amostra (100 animais).




Amostra 2: $\bar{x} = 88,79$

GLICEMIA




População: $\mu = ?$

Histograma de uma amostra (100 animais).




Amostra 1: $\bar{x} = 91,08$

Histograma de outra amostra (100 animais).




Amostra 2: $\bar{x} = 88,79$

Histograma de alda outra amostra (100 animais).




Amostra 3: $\bar{x} = 90,61$


Com 20 amostras



Com 20 amostras




Com 20 amostras




Com 20 amostras

Médias amostrais




Glicemia

Médias amostrais




Com 20 amostras


Médias amostrais



Glicemia





Médias amostrais



As médias amostrais têm distribuição normal

Do Teorema do Limite Central

População




Médias
amostrais

É possível calcular as médias amostrais prováveis que podem ser obtidas a partir de uma população com média populacional conhecida


Do Teorema do Limite Central

De maneira análoga, é possível calcular as médias populacionais prováveis que podem ter gerado uma amostra com dada média amostral

População



Médias amostrais



Intervalo de confiança



Médias Populacionais mais prováveis



Média amostral

Do Teorema do Limite Central

Intervalo de confiança:


(Para 95% de confiança)

Limite inferior: $\bar{x} - 1,96 * \sigma_{\bar{x}}$

Limite superior: $\bar{x} + 1,96 * \sigma_{\bar{x}}$

Temos 95% de confiança de que a média populacional
está entre estes dois valores

Com Intervalo de Confiança (95%)




Para cada amostra, calculamos IC:

$$\text{Lim sup} = \bar{x} + 1,96 \sigma_{\bar{x}} = \\ \bar{x} + 1,96 (\sigma / \sqrt{n})$$


$$\text{Lim inf} = \bar{x} - 1,96 \sigma_{\bar{x}} = \\ \bar{x} - 1,96 (\sigma / \sqrt{n})$$

Qual era μ ?




Alguém errou?

Médias amostrais + IC



Alguém errou?




95% de confiança
Logo, $P(\text{erro}) = 5\%$, do IC não incluir a média verdadeira.

$$5\% = 1 / 20$$


Ou seja, é esperado que 1 experimento a cada 20 erre.

Se quiser diminuir P(erro)




Confiança	P(erro)	Valor (z)
90%	10%	1.64
95%	5%	1.96
98%	2%	2.33
99%	1%	2.58

Com 99% confiança



IC (95%):

$$\text{Lim sup} = \bar{x} + 1,96 (\sigma / \sqrt{n})$$
$$\text{Lim inf} = \bar{x} - 1,96 (\sigma / \sqrt{n})$$





IC (99%):

$$\text{Lim sup} = \bar{x} + 2,58 (\sigma / \sqrt{n})$$
$$\text{Lim inf} = \bar{x} - 2,58 (\sigma / \sqrt{n})$$



Impacto do σ

$$\varepsilon = 1,96 \frac{\sigma}{\sqrt{n}}$$

População 1: $\sigma = 5$




População 2: $\sigma = 10$




Impacto do tamanho da amostra


$$\varepsilon = 1,96 \frac{\sigma}{\sqrt{n}}$$

Amostras com $n = 25$




Amostras com $n = 100$





Histograma de uma amostra (100 animais).



Exemplo
População: $\mu = ?$

Amostra: $\bar{x} = 90,71$

$$IC(\mu, 95\%) = \bar{x} \pm 1,96 (\sigma / \sqrt{n})$$

$$IC(\mu, 95\%) = 89,73 ; 91,69$$

Sei quanto é a média? Não.

Mas sei que ela deve estar nessa faixa de valores.

Legal, mas...

- Utilizamos \bar{x} para estimar μ
- Mas pra isso, precisamos de σ , que é o desvio-padrão populacional
- E o que fazemos se não conhecemos σ ? Situação muito comum

$$IC(\mu, 95\%) = \bar{x} \pm 1,96 (\sigma / \sqrt{n})$$

Sem saber σ

Duas soluções:

1 – Se o tamanho da amostra for grande, pode usar o s (desvio-padrão da amostra), pois nesses casos: $s \sim \sigma$

- O que é tamanho grande?

Uns dizem 100 observações, outros 300. É mais ou menos daí pra cima.

2 – Usar a distribuição t de Student (ao invés da distribuição normal)

- Funciona pra qualquer tamanho, quando você não conhece a variância
- Na prática, todo mundo usa essa, que é mais prático.

Distribuição t de Student



William Gosset:
Mestre cervejeiro da Guinness
(também era estatístico e químico)


Pra fazer o controle de qualidade da matéria-prima da cerveja, trabalhava com amostras pequenas.

Descobriu que, mesmo quando a variância era desconhecida, as médias amostrais se distribuíam de uma maneira específica.

Publicou seus achados usando o pseudônimo de “Student”, regra da Guinness.

Essa distribuição ficou conhecida como t de Student.

Distribuição t de Student



$$f(t) = \frac{\Gamma(\frac{\nu+1}{2})}{\sqrt{\nu\pi}\Gamma(\frac{\nu}{2})} \left(1 + \frac{t^2}{\nu}\right)^{-\frac{\nu+1}{2}},$$

Parece uma normal né?

É como se a distribuição t de Student fosse quase uma normal, mas ajustando um pouco a curva, pra compensar a incerteza que temos sobre σ .


Quanto maior o tamanho da amostra, mais informação temos, e melhoramos nossa estimativa de σ .

Então quando n é muito grande, a distribuição t de Student fica quase igual uma normal.

Usando o mesmo raciocínio

Usando a normal (TLC)

$$IC(\mu, 95\%) = \bar{x} \pm 1,96 * (\sigma / \sqrt{n})$$




Usando a distribuição t de Student

$$IC(\mu; 95\%) = \bar{x} \pm t_{95\%} * (s / \sqrt{n})$$




Depende do tamanho da amostra



Distribuição t de Student



William Gosset:
Mestre cervejeiro da Guinness
(também era estatístico e químico)






Variáveis qualitativas dicotômicas

Estimativa de proporção

Probabilidade p de um animal sobreviver
à uma dada doença

Como estimar p , a partir de uma
amostra?





Exemplo
População: $p = ?$

Amostra: $\hat{p} = 86\%$

Animal	Desfecho
1	Morreu
2	Sobreviveu
3	Morreu
...	...
100	Sobreviveu

Animal	Desfecho
1	Morreu
2	Sobreviveu
3	Morreu
...	...
100	Sobreviveu



Juntar n experimentos
Bernoulli → Binomial



Cada observação é um
experimento de Bernoulli

Desfecho	Total
Morreu	14
Sobreviveu	86

Distribuição de
Bernoulli:

$$\mu = p$$

$$\sigma^2 = p(1-p)$$

$$\sigma = \sqrt{p(1-p)}$$


Distribuição
Binomial:

$$\mu = np$$

$$\sigma^2 = np(1-p)$$

$$\sigma = \sqrt{np(1-p)}$$

Binomial → Normal *





Usando a normal (TLC)

$$IC(\mu, 95\%) = \bar{x} \pm 1,96 * \frac{\sigma}{\sqrt{n}}$$

Substituindo média e desvio-padrão

$$IC(p; 95\%) = \hat{p} \pm 1,96 * \frac{\sqrt{p(1-p)}}{\sqrt{n}}$$

* Quando $np > 5$ e $n(1 - p) > 5$ (Morettin)



Exemplo
População: $p = ?$

Amostra: $\hat{p} = 86\%$

$$IC(p; 95\%) = \hat{p} \pm 1,96 * \frac{\sqrt{p(1-p)}}{\sqrt{n}}$$

$$IC(p; 95\%) = 78\% ; 92\%$$

Sei a probabilidade exata de sobrevivência?
Não.

Mas sei que ela deve estar nessa faixa de valores.

Obrigado
