



POLÍCIA FEDERAL

RESUMÃO DE ESTATÍSTICA

PROFESSORES ARTHUR LIMA E HUGO LIMA

APRESENTAÇÃO

PROFESSORES ARTHUR LIMA E HUGO LIMA

Futuros Policiais Federais, tudo bem?

Eu (professor Arthur Lima) e o professor Hugo Lima elaboramos este resumo de Fórmulas de Estatística para o concurso da Polícia Federal 2021. Aproveitamos para incluir alguns conceitos muito cobrados que podem ajudar a acertar várias questões nas provas!

Somos Engenheiros pelo Instituto Tecnológico de Aeronáutica (ITA) e fomos aprovados nos concursos da Receita Federal para o cargo de Auditor-Fiscal. Também somos os professores responsáveis pelas disciplinas de Raciocínio Lógico, Matemática, Matemática Financeira e Estatística no Direção Concursos.

Mantenham este resumo sempre acessível para revisarem várias vezes as fórmulas de Estatística até a prova da Polícia Federal, ok?

E, por favor, compartilhem esse material com seus amigos que vão prestar o concurso da Polícia Federal.

Bons estudos! Nos vemos na ANP ainda este ano!



RESUMÃO DE ESTATÍSTICA

PROFESSORES ARTHUR LIMA E HUGO LIMA

MEDIDAS DESCRITIVAS - POSIÇÃO

MÉDIA

Dados em rol (lista):

$$\text{Média}(\bar{X}) = \frac{\text{Soma}}{\text{quantidade}} = \frac{\sum X_i}{n}$$

Tabela de frequências (e média ponderada, usando os pesos no lugar de f_i):

$$\bar{X} = \frac{\sum X_i \times f_i}{\sum f_i}$$

Dados agrupados em intervalos (usar ponto médio – PM):

$$\bar{X} = \frac{\sum PM_i \times f_i}{\sum f_i}$$

- Média é afetada por todos os valores da distribuição
- Se somarmos / subtrairmos ou multiplicarmos / dividirmos todos os termos de uma distribuição pelo mesmo número, a média sofrerá o mesmo efeito

MEDIANA

Passos:

- 1 - colocar dados em ordem crescente;
- 2 - calcular a posição da mediana:

$$\text{Posição} = (n+1)/2$$

- 3 - localizar a mediana (calcular a média entre 2 valores, se necessário).

- Mediana não é afetada pelas mudanças de valores extremos da distribuição

MODA

É o valor com maior número de frequências (repetições).

- Moda não é afetada pelas mudanças de valores extremos da distribuição

SIMETRIA

É o valor com maior número de frequências (repetições).

Simetria da Distribuição	Média, Mediana e Moda
Simétrica	Média = Mediana = Moda
Assimétrica positiva (à direita)	Média > Mediana > Moda
Assimétrica negativa (à esquerda)	Média < Mediana < Moda

RESUMÃO DE ESTATÍSTICA PARA PF

PROFESSORES ARTHUR LIMA E HUGO LIMA


ESPERANÇA OU VALOR ESPERADO "MÉDIA"

$$E(X) = \sum x \cdot p(x)$$

MEDIDAS SEPARATRIZES - QUARTIS

Quartil	Posição
1	$(n+1)/4$
2	$2(n+1)/4$
3	$3(n+1)/4$

DIAGRAMA BOX PLOT



Limite Superior → MENOR valor entre o valor máximo e $Q3 + 1,5 \cdot (Q3 - Q1)$

Limite Inferior → MAIOR valor entre o valor mínimo e $Q1 - 1,5 \cdot (Q3 - Q1)$

Outliers (valores atípicos) → acima do Limite Superior ou abaixo do Limite Inferior



**AULAS GRÁTIS
TODOS OS DIAS**

INSCREVA-SE

TÉCNICAS DE AMOSTRAGEM PROBABILÍSTICAS (CASUAIS)

• **Aleatória Simples:** é preciso ter acesso a todos os elementos da população; todos os elementos precisam ter a mesma chance de serem escolhidos para a amostra; população única; com ou sem reposição.

• **Sistemática:** regra objetiva / lógica / sistema para seleção dos elementos da amostra.

• **Estratificada:** população é dividida em estratos (agrupamentos mais homogêneos entre si) e são selecionados ALGUNS elementos de TODOS os estratos.

• **Por conglomerados:** população é dividida em subgrupos (conglomerados, não necessariamente mais homogêneos entre si), e TODOS os elementos de ALGUNS subgrupos são analisados.

MEDIDAS DESCRITIVAS - DISPERSÃO

VARIÂNCIA

$$\text{Variância} (\sigma^2) = E(X^2) - [E(X)]^2$$

ou

$$\text{Variância} (\sigma^2) = \frac{\sum X^2 - \frac{1}{n} \cdot (\sum X)^2}{n}$$

Tabela de Frequências:

$$\text{Variância} (\sigma^2) = \frac{\sum X^2 \cdot f_i - \frac{1}{n} \cdot (\sum X \cdot f_i)^2}{n}$$

Intervalos de Classes:

$$\text{Variância} (\sigma^2) = \frac{\sum PM_i^2 \cdot f_i - \frac{1}{n} \cdot (\sum PM_i \cdot f_i)^2}{n}$$

Para calcular a variância AMOSTRAL, substitua n por "n-1" no denominador das fórmulas acima

RESUMÃO DE ESTATÍSTICA PARA PF

PROFESSORES ARTHUR LIMA E HUGO LIMA

DESVIO PADRÃO

$$\text{Desvio padrão } (\sigma) = \sqrt{\text{Variância}}$$

- Somas/subtrações não afetam o desvio padrão e nem a variância
- Se multiplicarmos/dividirmos todos os termos da distribuição pelo mesmo número, o desvio padrão é multiplicado/dividido pelo número, e a variância pelo quadrado do número

$$\text{Desvio padrão} < \frac{\text{Amplitude}}{2}$$

COEFICIENTE DE VARIAÇÃO

$$CV = \frac{\text{Desvio Padrão}}{\text{Média}} = \frac{\sigma}{\mu}$$

- Medida de dispersão RELATIVA (boa para comparações entre distribuições)
- Não tem unidade

MEDIDAS DE ASSIMETRIA

$$\text{Coeficiente Percentílico} = \frac{P_{90} + P_{10} - 2 \cdot P_{50}}{P_{90} - P_{10}}$$

$$\text{Coeficiente Quartílico} = \frac{Q_3 + Q_1 - 2 \cdot Md}{Q_3 - Q_1}$$

$$\text{Primeiro coeficiente de Pearson} = \frac{(\text{Média} - \text{Moda})}{\text{Desvio Padrão}}$$

$$\text{Segundo coeficiente de Pearson} = 3 \cdot \frac{(\text{Média} - \text{Mediana})}{\text{Desvio Padrão}}$$

MEDIDAS DE CURTOSE

Medem o grau de achatamento de uma distribuição em relação à distribuição normal.

$$(C = m_4 / s^4)$$

Classificação	Coef. Momento de Curtose
Platicúrtica (mais achatada)	$C < 3$
Mesocúrtica	$C = 3$
Leptocúrtica	$C > 3$

$$K = \frac{Q_3 - Q_1}{2 \cdot (P_{90} - P_{10})}$$

Classificação	Coef. Percentílico de Curtose
Platicúrtica (mais achatada)	$C < 3$
Mesocúrtica	$C = 3$
Leptocúrtica	$C > 3$

- Distribuição normal é mesocúrtica

PROBABILIDADE

DEFINIÇÃO

Probabilidade do evento = número de resultados favoráveis / número total de resultados

Eventos independentes:

$$P(A \cap B) = P(A) \times P(B)$$

Probabilidade da união de eventos:

$$P(A \cup B) = P(A) + P(B) - P(A \cap B)$$

Eventos mutuamente excludentes:

$$P(A \cap B) = 0$$

Eventos complementares:

$$\text{Probabilidade}(E) = 1 - \text{Probabilidade}(E^c)$$

Probabilidade condicional:

$$P(A/B) = P(A \cap B) / P(B)$$

QUER AJUDA EM ESTATÍSTICA?

DIREÇÃO CONCURSOS

OPERACAO 104 POLICIA FEDERAL

ESTATÍSTICA COM ARTHUR LIMA

ASSISTA

PRINCIPAIS DISTRIBUIÇÕES DE PROBABILIDADE DISCRETAS

DISTRIBUIÇÃO	COMO IDENTIFICAR	VALOR ESPERADO (MÉDIA)	VARIÂNCIA
Bernoulli	1 tentativa 2 resultados possíveis	$E(X) = p$	$Var(X) = p.(1-p)$
Binomial	"n" tentativas independentes 2 resultados possíveis Probabilidade de sucesso constante	$E(X) = n.p$	$Var(X) = n.p.(1-p)$
Poisson	Fenômeno que se estende no tempo ou espaço com independência e regularidade conhecida	$E(X) = \lambda$	$Var(X) = \lambda$
Geométrica	Probabilidade de "n" tentativas até o primeiro sucesso	$E(X) = 1/p$	$Var(X) = (1-p)/p^2$

FUNÇÃO DE PROBABILIDADE BINOMIAL

$$P(k, n, p) = C(n, k) \cdot p^k \cdot (1-p)^{n-k}$$

(probabilidade de k sucessos em n tentativas com probabilidade p de sucesso a cada tentativa)

FUNÇÃO DE PROBABILIDADE POISSON

$$f(k, \lambda) = \frac{e^{-\lambda} \cdot \lambda^k}{k!}$$

(probabilidade de k repetições do evento durante o período observado)

FUNÇÃO DE PROBABILIDADE GEOMÉTRICA

$$P(X = n) = p.(1 - p)^{n-1}$$

PRINCIPAIS DISTRIBUIÇÕES DE PROBABILIDADE CONTÍNUAS

DISTRIBUIÇÃO	VALOR ESPERADO (MÉDIA)	VARIÂNCIA
Uniforme	$E(X) = (\text{Máximo} + \text{Mínimo}) / 2$	$Var(X) = (\text{máximo} - \text{mínimo})^2 / 12$
Exponencial	$E(X) = 1/\lambda$	$Var(X) = 1/\lambda^2$
Qui-quadrado	$E(X) = n$	$Var(X) = 2n$

- Nas distribuições contínuas, a probabilidade de qualquer valor exato é ZERO
- Função de distribuição acumulada exponencial: $F(X < x) = 1 - e^{-(\lambda \cdot x)}$
- Qui-quadrado é obtida pela soma dos quadrados de "n" distribuições normais padronizadas independentes.

**ISOLADA DE ESTATÍSTICA
COM CUPOM DE 15%**

ARTHUR15

CLIQUE AQUI

RESUMÃO DE ESTATÍSTICA PARA PF

PROFESSORES ARTHUR LIMA E HUGO LIMA

Distribuição Normal

- Presente em fenômenos da natureza em que a maior parte dos valores está próxima da média, mas há valores mais afastados da média para ambos os lados;

- Se os dados tem distribuição normal, pode-se dizer que cerca de 68% encontram-se entre $\mu - \sigma$ e $\mu + \sigma$. Da mesma forma, 95% dos dados encontram-se entre $\mu - 2\sigma$ e $\mu + 2\sigma$, e 99,7% entre $\mu - 3\sigma$ e $\mu + 3\sigma$;

- A distribuição normal padrão tem média 0 e desvio padrão 1;

- Para transformar uma distribuição normal qualquer em uma normal padrão, basta usar a transformação: $Z = (X - \mu) / \sigma$;

- A distribuição é simétrica, de modo que

$P(X > a)$ é igual a $P(X < -a)$, e

média = mediana = moda;

- Se X e Y forem independentes e seguirem distribuição normal, então $X + Y$ e $X - Y$ também terão distribuição normal, e:

$$E(X + Y) = E(X) + E(Y)$$

$$Var(X + Y) = Var(X) + Var(Y)$$

PROBABILIDADE

- Parâmetro: característica da população (ex.: idade média populacional);

- Estimativa: valor obtido a partir de uma amostra (ex.: média amostral);

- Estimador: função matemática usada para obter a estimativa (ex.: somar todos os valores e dividir pela quantidade).

DEFINIÇÃO

- Viés: “parcialidade” ou “tendência” do estimador. Um estimador não viesado tem como valor esperado o próprio valor do parâmetro;

- Consistência: um estimador consistente converge para o valor do parâmetro à medida que o número de observações aumenta (e a sua variância tende a zero);

- Eficiência: entre dois estimadores, o mais eficiente é o que possui MENOR variância;

- Suficiência: o estimador suficiente capta todas as informações sobre o parâmetro a ser estimado.

ESTIMADOR IDEAL

Não-viesado (não tendencioso), consistente, eficiente e suficiente.

ESTIMADORES IMPORTANTES PARA A MÉDIA

- média amostral: é não-viesada e consistente

- mediana amostral: é não-viesada e consistente, mas é menos eficiente que a média amostral

- primeiro item coletado: é não-viesado, mas não é consistente

OUTROS ESTIMADORES IMPORTANTES

- Variância (com “n” no denominador): é viesado. Colocando-se n-1 no denominador, fica não-viesado (variância amostral).

- Desvio padrão (com “n” ou com “n-1” no denominador): é viesado.

#FORÇATAREFA
A MAIOR OPERAÇÃO DE ESTUDOS PARA A POLÍCIA FEDERAL
ACESSAR PLAYLIST

RESUMÃO DE ESTATÍSTICA PARA PF

PROFESSORES ARTHUR LIMA E HUGO LIMA

ESTIMAÇÃO INTERVALAR

TEOREMA CENTRAL DO LIMITE E DISTRIBUIÇÕES AMOSTRAIS

A distribuição amostral da média é NORMAL, com:

$$\text{Média} = \text{média da população } (\mu)$$

$$\text{Desvio padrão} = \frac{\sigma}{\sqrt{n}}$$

ERRO PADRÃO NA ESTIMATIVA

$$E = \frac{\sigma}{\sqrt{n}} \rightarrow \text{erro padrão na estimativa de médias}$$

$$E = \sqrt{\frac{p(1-p)}{n}} \rightarrow \text{erro padrão na estimativa de proporções}$$

INTERVALO DE CONFIANÇA PARA A MÉDIA

$$\text{Média amostral} \pm Z_{\frac{\alpha}{2}} \cdot \frac{\sigma}{\sqrt{n}} \quad \text{ou} \quad \text{Média amostral} \pm t_{\frac{\alpha}{2}} \cdot \frac{s}{\sqrt{n}}$$

- Usar a segunda SOMENTE quando $n < 30$ e o desvio padrão populacional for desconhecido
- Número de graus de liberdade (t de Student) = $n - 1$

$$\text{Amplitude do intervalo} = 2 \cdot Z_{\frac{\alpha}{2}} \cdot \frac{\sigma}{\sqrt{n}}$$

ou

$$\text{Amplitude do intervalo} = 2 \cdot t_{\frac{\alpha}{2}} \cdot \frac{s}{\sqrt{n}}$$

INTERVALO DE CONFIANÇA PARA PROPORÇÕES

$$\text{Proporção amostral } (p) \pm Z_{\frac{\alpha}{2}} \cdot \sqrt{p \cdot \frac{1-p}{n}}$$

$$\text{Amplitude do intervalo} = 2 \cdot Z_{\frac{\alpha}{2}} \cdot \sqrt{p \cdot \frac{1-p}{n}}$$

$$\text{Margem de erro} = Z_{\frac{\alpha}{2}} \cdot \sqrt{p \cdot \frac{1-p}{n}}$$

INTERVALOS DE CONFIANÇA VS. INTERVALOS DE CREDIBILIDADE

intervalos de Confiança	intervalos de Credibilidade
Estatística Frequentista	Estatística Bayesiana
Não dependem da distribuição a priori	Utilizam informações da distribuição a priori (cria intervalo de probabilidade a posterior)

TAMANHO DE AMOSTRAS

$$n = \left(\frac{Z_{\alpha/2} \cdot \sigma}{d} \right)^2 \rightarrow \text{para estimativa de médias}$$

$$n = \left(\frac{Z_{\alpha/2}}{d} \right)^2 \cdot p \cdot q \rightarrow \text{para estimativa de proporções}$$

- As fórmulas acima consideram que a população é infinita (amostragem com reposição)
- Quando p e q forem desconhecidos, usar $p = q = 0,5$

TESTES DE HIPÓTESES

RECEITA DE BOLO – TESTES DE HIPÓTESES PARA MÉDIAS

1 – Formular a hipótese nula (H_0) e a hipótese alternativa (H_1) – mutuamente excludentes

2 – Rascunhar a curva normal, marcando as regiões de aceitação e de rejeição (região crítica) de acordo com o nível de significância α e o tipo de teste (bilateral, se H_1 for do tipo “média diferente de”, ou unilateral, se H_1 for do tipo “maior que” ou “menor que”)

3 – Obter Z_{tabelado} com base no nível de significância e tipo de teste

4 – Obter $Z_{\text{calculado}}$ por meio da expressão:

$$Z_{\text{calculado}} = \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}}$$

5 – Posicionar $Z_{\text{calculado}}$ no gráfico e obter a conclusão do teste – aceitação ou rejeição de H_0

RESUMÃO DE ESTATÍSTICA PARA PF

PROFESSORES ARTHUR LIMA E HUGO LIMA

Usar t de Student se $n < 30$ e o desvio padrão populacional for desconhecido. Neste caso,

$$t_{\text{calculado}} = \frac{\bar{X} - \mu}{\frac{s}{\sqrt{n}}}$$

Número de graus de liberdade = $n - 1$

Se for um teste de hipóteses para proporções, usar

$$Z_{\text{calculado}} = \frac{(p - p_0)}{\sqrt{p_0 \cdot \frac{1 - p_0}{n}}}$$

onde p é a proporção obtida na amostra e p_0 está nas hipóteses do teste.

ERROS EM TESTES DE HIPÓTESES

	H_0 é verdadeira	H_0 é Falsa
H_0 é Aceita	Certo	Erro tipo II (falso negativo, probabilidade β)
H_0 é Rejeitada	Erro tipo I (falso positivo, probabilidade α)	Certo

OUTROS CONCEITOS EM TESTES DE HIPÓTESES

- Poder (Potência) do Teste: probabilidade de rejeitar corretamente a hipótese nula ($1 - \beta$)
- p-valor (nível descritivo, probabilidade de significância): $p\text{-valor} \leq \alpha \rightarrow$ rejeitar H_0

ANÁLISE DE REGRESSÃO

COVARIÂNCIA

$$\text{Cov}(X, Y) = E(X \cdot Y) - E(X) \cdot E(Y)$$

- Positiva: as duas variáveis tendem a crescer / decrescer juntas
- Negativa: quando uma variável cresce, a outra tende a decrescer

$$\text{Var}(X + Y) = \text{Var}(X) + \text{Var}(Y) + 2 \cdot a \cdot b \cdot \text{cov}(X, Y)$$

$$\text{Var}(X - Y) = \text{Var}(X) + \text{Var}(Y) - 2 \cdot a \cdot b \cdot \text{cov}(X, Y)$$

$$\text{Cov}(a \cdot X + b, c \cdot Y + d) = a \cdot c \cdot \text{cov}(X, Y)$$

CORRELAÇÃO

$$\text{Correlação}(X, Y) = (\text{cov}(X, Y)) / (\sigma_X \sigma_Y)$$

- Varia de -1 (correlação fortemente negativa) a +1 (correlação fortemente positiva)
- Se variáveis são INDEPENDENTES, então a correlação é NULA (o contrário não é necessariamente verdade)

$$\text{Correlação}(X, X) = 1$$

$$\text{Correlação}(a \cdot X + b, c \cdot Y + d) = (\text{sinal de } a \cdot c) \times \text{Correlação}(X, Y)$$

REGRESSÃO LINEAR SIMPLES

$$Y_i = \alpha + \beta \cdot X_i + \epsilon_i$$

- α é o coeficiente linear, β é o coeficiente angular, ϵ_i é o erro aleatório
- X é a variável independente, Y é a variável dependente

$$\beta = \frac{n \cdot \sum XY - \sum X \cdot \sum Y}{n \cdot \sum X^2 - (\sum X)^2}$$

ou

$$\beta = \frac{\text{cov}(X, Y)}{\text{Var}(X)}$$

$$\text{Relação entre as médias: } \bar{Y} = \alpha + \beta \cdot \bar{X}$$

QUER AJUDA EM INFORMÁTICA?

DIREÇÃO CONCURSOS

130 QUESTÕES DE INFORMÁTICA - PF + PRF

ASSISTA

COEFICIENTE DE DETERMINAÇÃO R^2

- É o quadrado do coeficiente de correlação
- Mede o ajustamento da regressão ao modelo linear
 - Varia entre 0 e 1 (quanto mais próximo de 1, melhor o ajustamento)
 - Interpretação: é o percentual das variações da variável dependente que são explicadas pela variável independente.

ANÁLISE DE VARIÂNCIA

- usada para comparação de médias entre 3 ou mais grupos;

Hipótese nula (H_0): as médias não possuem diferença significativa

Hipótese alternativa (H_1): pelo menos uma média difere das demais

LEIS DOS GRANDES NÚMEROS

- Afirmam que a média amostral converge para média populacional à medida que aumentamos o tamanho da amostra.

Lei FRACA dos grandes números	Lei FORTE dos grandes números
A convergência ocorre em PROBABILIDADE	A convergência é CERTA / QUASE CERTA
Se o número de elementos da amostra é suficientemente grande, a convergência é PROVÁVEL	A partir de um tamanho de amostra "n" suficientemente grande, a convergência é CERTA / QUASE CERTA

ANÁLISE DE RESÍDUOS

- Trata-se do estudo do comportamento do resíduo (erro aleatório) da regressão linear;
- Características desejáveis do resíduo:
 - média igual a zero;
 - variância constante (homocedasticidade, e NÃO heterocedasticidade);
 - normalidade (resíduos com distribuição normal em torno do zero);
- Diagrama de dispersão de resíduos (gráfico de resíduos): permite verificar a homocedasticidade e a presença de outliers;
- Quando a suposição da homocedasticidade é violada, a distribuição de probabilidade do modelo é afetada, mas não o valor esperado.

RESUMÃO DE ESTATÍSTICA PARA PF

PROFESSORES ARTHUR LIMA E HUGO LIMA

Fontes de variação	Soma de quadrados	Graus de Liberdade	Quadrados médios (soma/gl)	F
Entre grupos (equação)	SQE	Grupos - 1	$QME = SQE / (\text{Grupos} - 1)$	$F = QME / QMR$
Dentro dos grupos (resíduo)	SQR	N - Grupos	$QMR = SQR / (N - \text{Grupos})$	
Total (modelo)	SQT	N - 1	$QMT = SQT / (N - 1)$	

$$SQE + SQR = SQT$$

$$R^2 = SQE / SQT$$

$$\beta = R \cdot \sigma_y / \sigma_x$$

As variâncias são os Quadrados Médios do quadro acima