

Modelos Bayesianos

Ernesto F. L. Amaral
Magna M. Inácio

09 de dezembro de 2010
Tópicos Especiais em Teoria e Análise Política:
Problema de Desenho e Análise Empírica (DCP 859B4)

Objetivos

- Apresentar conceitos básicos de estatística Bayesiana.
- Explicar diferenças entre abordagens tradicionais e Bayesianas para análise de dados.

Uma Breve História

- Estatística Bayesiana é assim chamada por ter sido elaborada por Thomas Bayes (1763).
- Laplace (1812) aplicou esta abordagem a problemas práticos.
- A abordagem frequentista foi desenvolvida entre 1850 e 1950 por Fisher, Pearson, Neyman e outros, tornando-se o método dominante.
- Métodos Bayesianos estão sendo mais utilizados, devido às suas vantagens e desenvolvimento de computadores.
- Há diferenças nos conceitos e métodos das abordagens frequentistas e Bayesianas.

Comparação de Termos Frequentistas e Bayesianos

Frequentista

Bayesiano

Estimação

Estimativas pontuais
Intervalos de confiança

Distribuições
a priori e posteriores

Inferência

Intervalos de confiança
Testes de significância

Distribuições
a priori e posteriores

Análise Bayesiana \neq Análise Frequentista

- Na **perspectiva Bayesiana**, a probabilidade representa uma abordagem subjetiva do desconhecido.
 - Qualquer quantidade para a qual o valor verdadeiro é incerto, incluindo os parâmetros do modelo, pode se representada com distribuições de probabilidade.
- Na **perspectiva clássica**, não é aceitável colocar distribuições de probabilidade nos parâmetros, porque estes são considerados como quantidades fixas.
 - Somente dados são aleatórios, então distribuições de probabilidade somente podem representar os dados.

Problemas com Estatística Tradicional

(segundo Bayesianos)

- Produz respostas em termos que são difíceis de interpretar e que são mal compreendidos.
- Produz respostas em termos que não são usualmente de grande interesse:

$\Pr(\text{dados}|H)$, ao invés de $\Pr(H|\text{dados})$

- Falta de métodos claros para incluir dados (conhecimentos) existentes e para lidar com incerteza.

Responda Verdadeiro ou Falso

7

- (p é o valor da probabilidade de teste de significância para H_0)
- $p=0,01$: há 1 em 100 chances que H_0 seja verdadeira.
 - $p<0,001$ significa que H_0 é falsa.
 - H_0 tem maior probabilidade de ser verdadeira se $p>0,9$ do que se $p<0,1$.
 - Se 2 amostras A e B não são diferentes significativamente (H_0 não é rejeitada), A e B são assumidas como iguais.
 - Se $p<0,05$ (significante) para um conjunto de dados e $p < 0,001$ (muito significativo) em outro conjunto, o segundo conjunto de dados indica que H_0 é falsa mais fortemente.
 - Se H_0 não for rejeitada e a magnitude do coeficiente for alta, é mais provável que H_0 seja verdadeira do que se H_0 não for rejeitada e a magnitude do coeficiente for baixa.
 - Se o intervalo de confiança de 95% de uma estimativa Y vai de A a B, isso significa que o valor verdadeiro de Y está situado entre A e B com probabilidade 0,95.


Dois Conceitos Bayesianos Fundamentais

- Coisas que são desconhecidas são representadas por distribuições de probabilidade.

- Coisas que são conhecidas (dados) são usadas para aperfeiçoar nosso conhecimento acerca do problema, a partir do Teorema de Bayes.

O Desconhecido

– Coisas que são desconhecidas são representadas por distribuições de probabilidade.



– A probabilidade da distribuição pode ser contínua (uniforme, normal...) ou discreta (binomial, Poisson).

O Conhecido

- Regra da multiplicação:

$$\Pr(x, y) = \Pr(x) \Pr(y | x) = \Pr(y) \Pr(x | y)$$

- Teorema de Bayes:

$$\Pr(y | x) = \frac{\Pr(x | y) \Pr(y)}{\Pr(x)}$$

- Seja y =hipótese sobre o desconhecido e x =dados:

$$p(\mathbf{H} | \text{dados}) = \frac{p(\text{dados} | \mathbf{H}) p(\mathbf{H})}{p(\text{dados})}$$

- Distribuição posterior é proporcional a:

Posterior  Verossimilhança (Likelihood) X Priori

Paradigma para Inferência Bayesiana

Posterior \propto Verossimilhança X Priori

– Ou seja:

novo estado do conhecimento \propto

informação dos dados novos

X estado atual do conhecimento

– Os dados novos atualizam o estado atual do conhecimento, com base no Teorema de Bayes.


– O resultado é um novo estado do conhecimento, representado pela distribuição posterior.

Objetivos da Estatística Bayesiana

- Representar o desconhecimento a priori sobre os parâmetros do modelo com uma distribuição de probabilidade (**distribuição a priori**).
- Atualizar esse desconhecimento a priori com dados atuais (*likelihood*).
- Produzir uma distribuição de probabilidade para o parâmetro que contenha menos desconhecimento (**distribuição posterior**).


Distribuição a Priori

- Função a priori $\Pr(H)$ fornece a probabilidade dos diferentes valores possíveis da quantidade de interesse **antes** dos dados serem considerados.
- Representa o estado do conhecimento anterior aos dados.
- A distribuição a priori pode ser ampla, plana, uniforme se possuímos poucos dados (priori não informativa), ou pode se concentrada com um ápice se possuímos mais informação (priori informativa).



Verossimilhança (*Likelihood*)

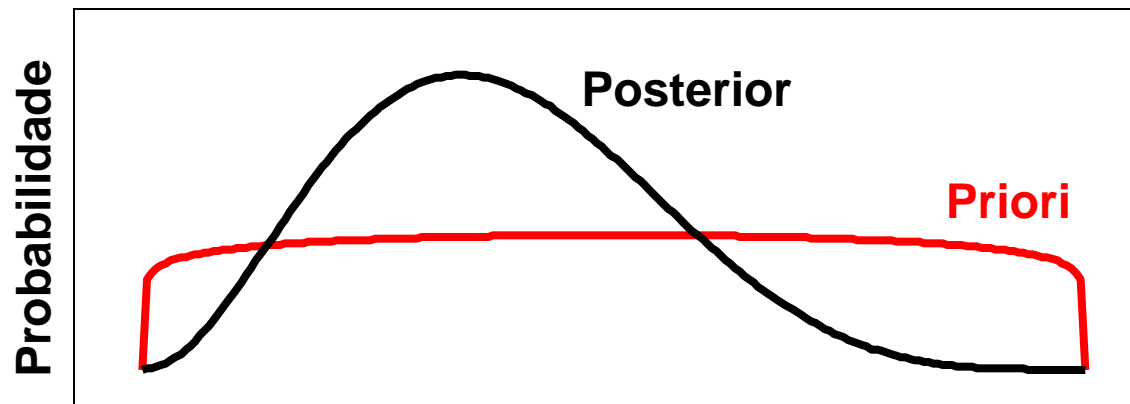
- Função de verossimilhança $\Pr(\text{dados}|H)$ fornece a probabilidade de obter o dado, considerando diferentes valores possíveis da quantidade desconhecida de interesse (hipótese H).
- Verossimilhança: (1) é calculada usando um modelo estatístico que representa o processo que produziu os dados; e (2) conecta os parâmetros do modelo aos dados.
- Também são utilizadas em análises frequentistas.



**Quantidade desconhecida de interesse
(Quantidade de votos, tamanho da
população, parâmetro do modelo)**

Distribuição Posterior

- Função posterior $\Pr(H|\text{dados})$ fornece a probabilidade dos diferentes valores possíveis da quantidade de interesse **depois** de considerar os dados, representando o estado do conhecimento posterior aos dados.
- Posterior é combinação da priori (o que sabemos antes) com a verossimilhança (o que os dados nos disseram).
- Diferença entre priori e posterior indica o quanto aprendemos com os dados.



Quantidade desconhecida de interesse
(Quantidade de votos, tamanho da
população, parâmetro do modelo)

Exemplo: Tabela de Contingência


	Grupo 1	Grupo 2
Tipo A	1	4
Tipo B (não A)	8	6

- Questão principal:
 - A fração do tipo A é diferente entre os dois grupos?
- Pressupostos:
 - Amostras são aleatórias e independentes.
 - A e B são únicos tipos possíveis.

Análise Frequentista

	Grupo 1	Grupo 2
Tipo A	1	4
Tipo B (não A)	8	6

- Teste de Pearson: $p=0,36$.
- Teste de Fisher: $p=0,30$.
- Conclusão: hipótese nula de que a fração do tipo A é igual nos dois grupos não é rejeitada.



Análise Bayesiana

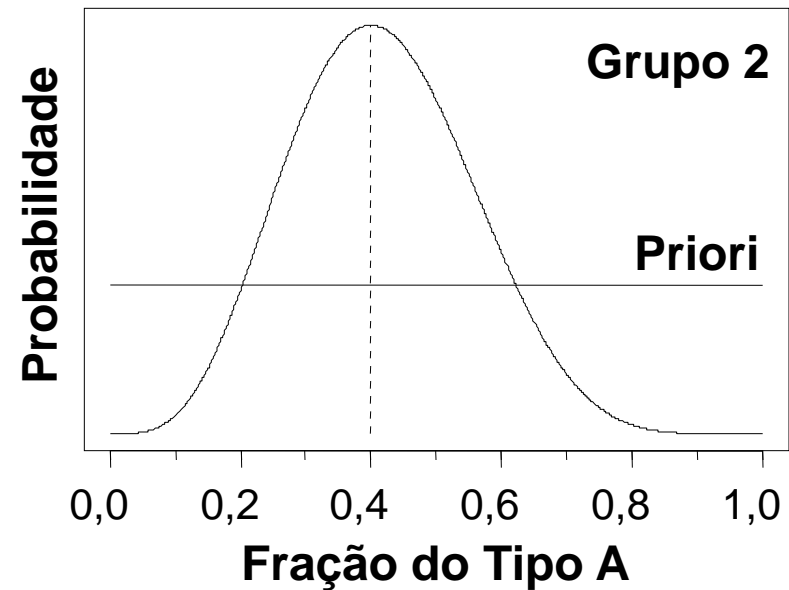
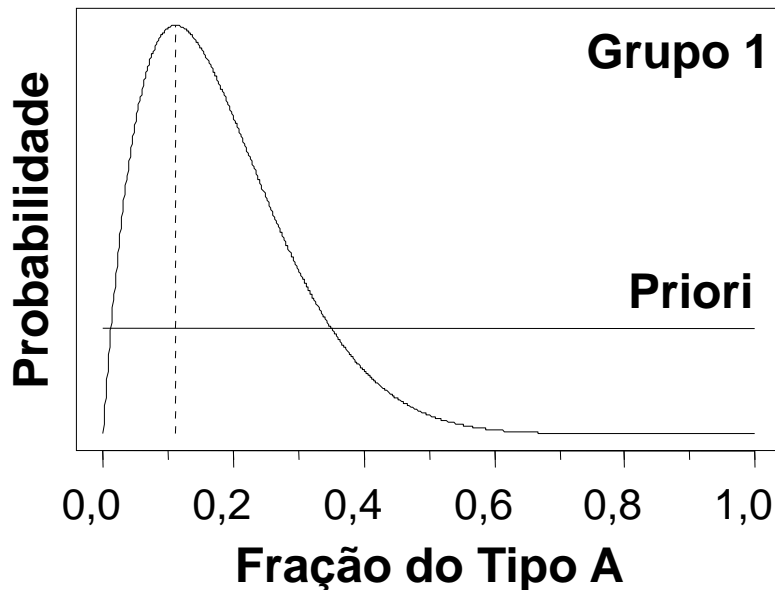
	Grupo 1	Grupo 2
Tipo A	1	4
Tipo B (não A)	8	6

– Distribuição a priori uniforme:
 $\Pr(x) \sim U(0,1)$

– Verossimilhança binomial:

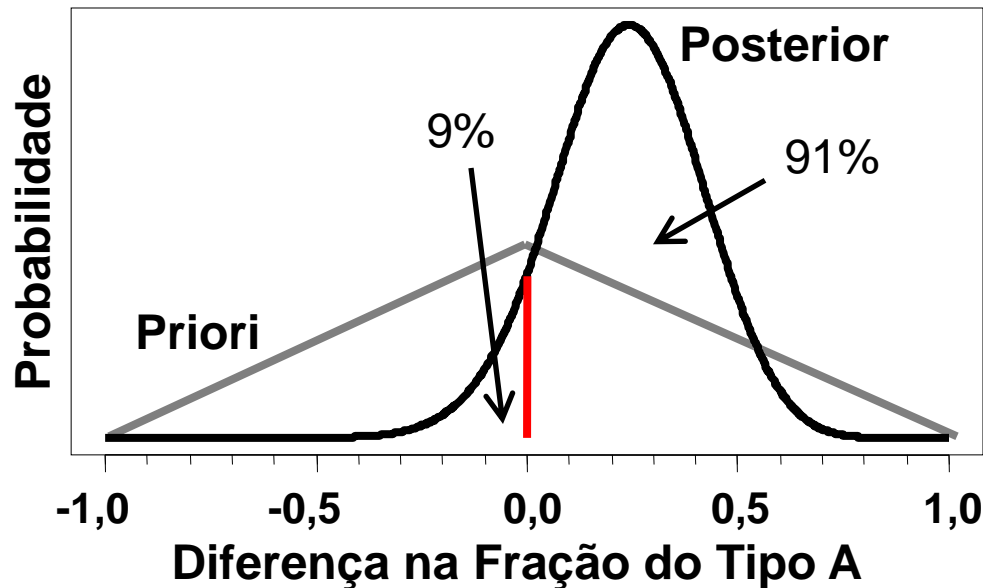
$$\Pr(x | n_A, n_B) \propto x^{n_A} (1-x)^{n_B}$$

onde x é a fração do tipo A.



Análise Bayesiana: Mais Clara e Direta

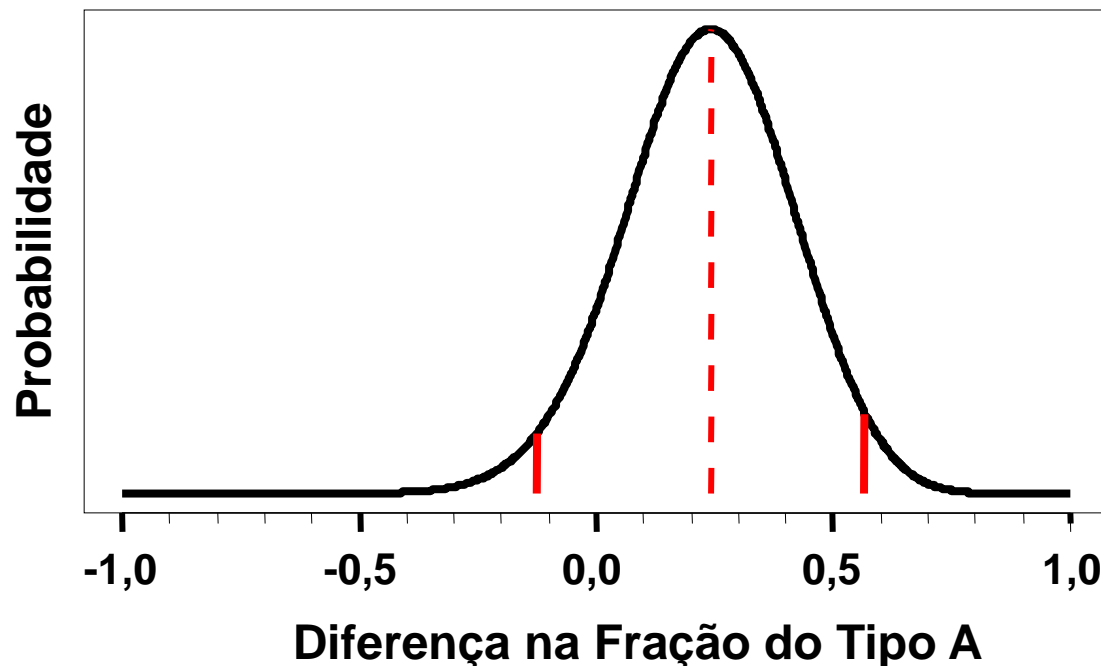
- Como estamos interessados na **diferença** da fração do tipo A entre o grupo 1 e o grupo 2, calculamos a distribuição posterior sobre a diferença.
- Embora as distribuições a priori são uniformes na fração do tipo A para cada grupo, a distribuição a priori na diferença entre grupos não é uniforme.



- A probabilidade que a fração do tipo A seja maior no grupo 2 é de 0,91 (acima de zero).
- É 10 vezes mais provável (91% / 9%) que a fração do tipo A seja maior no grupo 2 do que seja menor.

Análise Bayesiana: Distribuição Posterior ²⁰

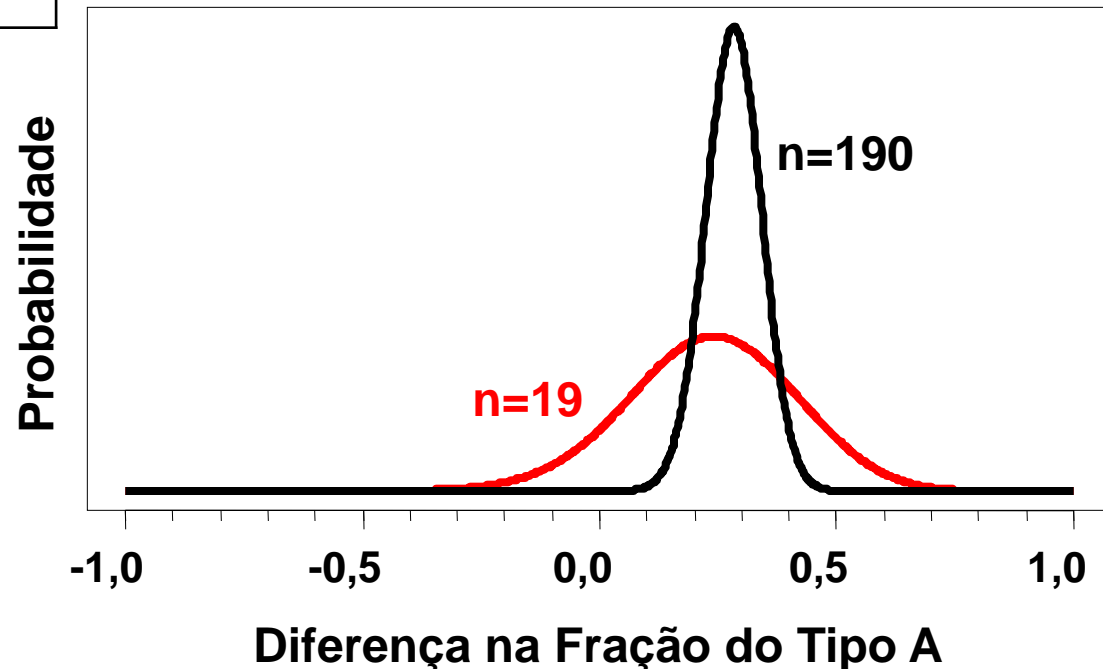
- A distribuição posterior da diferença na fração do tipo A entre grupo 2 e grupo 1 é o novo estado do conhecimento.
- Média = 0,241.
- Mediana = 0,235.
- Moda = 0,241.
- Intervalo de confiança de 95%: -0,13 a 0,57.



Análise Bayesiana com Amostra Maior

- Suponha que tenhamos dados adicionais, de modo que o tamanho da amostra seja muito maior.
- A distribuição posterior da diferença será mais concentrada.

	Grupo 1	Grupo 2
Tipo A	10	40
Tipo B (não A)	80	60



Problemas com Estatística Bayesiana

(segundo não-Bayesianos)

- Distribuições a priori introduzem julgamento subjetivo na análise de dados.
- Distribuições a priori afetam os resultados, de modo que diferentes pesquisadores podem chegar em respostas distintas com mesmos dados.
- É muito complicado, já que não existem programas computacionais simples como nosso amigo Stata.

Contra Argumentação: Interpretação

- As **estimativas de intervalo Bayesianos** possuem interpretação clara e direta:
 - Simplesmente dizemos que um parâmetro se encontra em um intervalo com determinada probabilidade.
- Os **intervalos de confiança clássicos** indicam a probabilidade de obter uma estimativa de intervalo que contem o parâmetro de interesse, sob a hipótese de realização de várias amostras.

Contra Argumentação: Hipóteses

- A **abordagem Bayesiana** pode naturalmente incorporar resultados de pesquisas anteriores na distribuição a priori.
 - O processo de construção de hipóteses é formalizado com sua incorporação como parte do modelo.
- A **abordagem clássica** não possui meios para usar resultados prévios nas análises atuais, além de especificar hipóteses.

Contra Argumentação: Estatísticas

- Na **abordagem Bayesiana**, são estimadas estatísticas dos parâmetros mais detalhadas, tais como média, mediana, moda e intervalo interquartil.
- Na **abordagem clássica**, simplesmente obtemos a estimativa do parâmetro e do erro padrão.

Contra Argumentação: Subjetividade

- A **abordagem Bayesiana** é acusada de ser subjetiva por incorporar distribuições a priori.
- Porém, **toda estatística é subjetiva:**
 - Em um trabalho com estatística frequentista, por exemplo, podemos escolher uma distribuição normal e aplicar um modelo MQO, ou podemos escolher uma distribuição binomial e aplicar um modelo logístico.
 - O nível de significância (α) é definido subjetivamente.
- Por fim, a influência de distribuições a priori pode ser avaliada após estimação da distribuição posterior.