

Análise de Regressão Múltipla – Inferência

$$\diamond y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + u$$

Inferência Estatística Clássica

- Inferência é a área que descreve os procedimentos por meio dos quais usamos as observações para *tirar conclusões* sobre a população ou sobre o processo gerador dos dados

Inferência Estatística Clássica

- O pressuposto é que existe um processo gerador dos dados desconhecido
- Esse processo pode ser descrito por uma distribuição de probabilidade
- Esta distribuição de probabilidade pode ser descrita por um conjunto de parâmetros
- D. Normal – desconhecidos μ e σ^2 .

Inferência Estatística Clássica

- Em geral a inferência estatística pode ser classificada por dois tópicos:
- Inferência Clássica
- Inferência Bayesiana

Inferência Estatística Clássica

- A inferência estatística clássica possui duas premissas:
 1. Os dados amostrais são as únicas informações relevantes.
 2. A construção e avaliação dos diferentes procedimentos para a inferência se baseiam em comportamentos de longo prazo sob circunstâncias essencialmente similares.

Inferência Estatística Bayesiana

- Combinamos informação amostral com informação prévia
- Suponha uma amostra aleatória n de uma população normalmente distribuída com μ e σ^2 desconhecidas
- Queremos fazer inferência sobre o valor de μ

Inferência Estatística Bayesiana

- Em inferência clássica tomamos a média amostral como o estimador de μ -- nesse caso sua variância será σ^2/n
- O inverso dessa variância é conhecido como **precisão amostral** (n/σ^2)
- Em inferência Bayesiana temos informação prévia sobre o valor de μ

Inferência Estatística Bayesiana

- Esse valor prévio de μ é expresso em termos de uma distribuição de probabilidade conhecida como *distribuição a priori*
- Suponha uma distribuição a priori, $N(\mu_0, \sigma_0^2)$ com precisão $1/\sigma^2$
- Combinando com a informação amostral obtemos a *distribuição a posteriori* de μ

Estimando a média

- A média estimada é uma ponderação com a média amostral e a média *a priori*

$$\mu_{\text{Bayesiana}} = \frac{w_1 \bar{y} + w_2 \mu_0}{w_1 + w_2}$$

$$w_1 = n / \sigma^2$$

$$w_2 = 1 / \sigma_0^2$$

Média Bayesiana

- Exemplo:
 - Média amostral = 20 e $\sigma^2 = 4$
 - Média a priori = 10 e $\sigma_0^2 = 2$
- Então teremos:
 - Média a posteriori =

$$\frac{\frac{1}{4}(20) + \frac{1}{2}(10)}{\frac{1}{4} + \frac{1}{2}} = \frac{10}{3/4} = 13.33$$

Inferência Estatística Clássica

- Estimativa pontual
- Estimativa intervalar
- Teste de hipótese

Estimativa Pontual

- Suponha que a distribuição de probabilidade envolva um parâmetro θ e que tenhamos uma amostra n de (y_1, \dots, y_n) dessa distribuição
- Faça $g(y_1, \dots, y_n)$ o estimador de θ
 - Estimador: $g(y_1, \dots, y_n)$
 - Estimativa: θ

Estimativa Pontual

- Interpretação: o estimador é uma V.A. e a estimativa um valor dessa V.A.
- Por exemplo, se usamos a média amostral, $\bar{4}$, para estimar o valor de θ , então essa é a estimativa de θ

Teste de Hipótese

- Em teste de hipótese sugerimos uma hipótese sobre o valor estimado de θ
- Por exemplo, $\theta = 4$, e examinamos o grau de evidência na amostra em favor da hipótese, pensando se aceitamos ou rejeitamos esta hipótese

Inferência em Regressão


Hipóteses do Modelo Linear Clássico (MLC)

- Até agora, sabemos que dadas as hipóteses Gauss-Markov, o estimador OLS é BLUE
- Para usar testes de hipóteses, precisamos adicionar outra hipótese
- Assuma que u é independente de x_1, x_2, \dots, x_k e u é normalmente distribuída com média zero e variância σ^2 : $u \sim N(0, \sigma^2)$

Hipóteses MLC

- Sob MLC, OLS não é apenas BLUE, mas é o estimador não-viesado da menor variância
- Podemos resumir as hipóteses da população do MLC como segue
- $y|\mathbf{x} \sim N(\beta_0 + \beta_1x_1 + \dots + \beta_kx_k, \sigma^2)$
- Por enquanto assumimos apenas normalidade
- Grandes amostras nos permitem excluir essa hipótese de normalidade

A distribuição normal homocedastica com uma única variável explicativa



Distribuições de Amostragem Normais

Sob as hipóteses MLC, condicional sobre os valores amostrais das variáveis independentes

$$\hat{\beta}_j \sim \text{Normal} \left[\beta_j, \text{Var}(\hat{\beta}_j) \right], \text{ então}$$

$$\frac{(\hat{\beta}_j - \beta_j)}{SD(\hat{\beta}_j)} \sim N(0,1)$$

$\hat{\beta}_j$ é distribuída normalmente porque é uma combinação linear dos erros

O Teste t

Sob as hipóteses do MLC

$$\frac{(\hat{\beta}_j - \beta_j)}{SE(\hat{\beta}_j)} \sim t_{n-k-1}$$

Esta é uma distribuição t

porque temos que estimar σ^2 por $\hat{\sigma}^2$

Note que os graus de liberdade são: $n - k - 1$

O Teste t

- Conhecendo a distribuição amostral para o estimador padronizado nos permite conduzir testes de hipóteses
- Comece com uma hipótese nula
- Por exemplo, $H_0: \beta_j = 0$
- Se aceitarmos a hipótese nula, então aceitamos que x_j não possui efeito sobre y , controlando para os outros x 's

O Teste t

Para realizar o teste primeiro precisamos formar

a estatística t para $\hat{\beta}_j$: $t_{\hat{\beta}_j} \equiv \frac{\hat{\beta}_j}{SE(\hat{\beta}_j)}$

Nós iremos usar a estatística t em conjunto com uma regra de rejeição para determinar quando aceitar a hipótese nula, H_0

Teste t : Alternativas

- Além da hipótese nula, H_0 , precisamos de uma hipótese alternativa, H_1 , e um nível de significância
- H_1 pode ser uni-caudal ou bi-caudal
- $H_1: \beta_j > 0$ ou $H_1: \beta_j < 0$ são uni-caudais
- $H_1: \beta_j \neq 0$ é uma alternativa bi-caudal
- Se desejamos ter apenas 5% de probabilidade de rejeitar H_0 se ele é realmente verdade, então dizemos que o nível de significância é de 5%

Alternativa Uni-caudal


- Tendo selecionado um nível de significância, α , procuramos o percentil $(1 - \alpha)$ em uma distribuição t com $n - k - 1$ graus de liberdade e df – chamamos isto de valor crítico
- Nós podemos rejeitar a hipótese nula se a estatística t é maior do que o valor crítico
- Se a estatística t é menor do que o valor crítico então falhamos em rejeitar a hipótese nula

Alternativa Uni-caudal

$$y_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_k x_{ik} + u_i$$

$$H_0: \beta_j = 0$$

$$H_1: \beta_j > 0$$



Uni-caudal vs bi-caudal


- Como a distribuição t é simétrica, testando $H_1: \beta_j < 0$ é direto. O valor crítico é apenas o valor negativo anterior
- Nós podemos rejeitar a nula se a estatística $t < -c$, e se a estatística $t > c$ então falhamos em rejeitar a hipótese nula
- Para um teste bi-caudal, nós determinamos o valor crítico baseado em $\alpha/2$ e rejeitamos $H_1: \beta_j \neq 0$ se o valor absoluto da estatística $t > c$

Alternativas Bi-caudais

$$y_i = \beta_0 + \beta_1 X_{i1} + \dots + \beta_k X_{ik} + u_i$$

$$H_0: \beta_j = 0$$

$$H_1: \beta_j \neq 0$$



Sumário para $H_0: \beta_j = 0$

- A não ser que seja explicitado, assumimos que a alternativa seja bi-caudal
- Se nós rejeitarmos a nula, tipicamente dizemos “ x_j é estatisticamente significativa ao nível de α %”
- Se nós falhamos em rejeitar a hipótese nula, dizemos tipicamente que “ x_j é estatisticamente insignificante ao nível de α %”

Testando outras hipóteses

- Uma forma mais geral de testar a estatística t reconhece que desejamos testar algo como $H_0: \beta_j = a_j$
- Nesse caso, a estatística t apropriada é

$$t = \frac{(\hat{\beta}_j - a_j)}{SE(\hat{\beta}_j)}, \text{ onde}$$

$a_j = 0$ para o teste padrão

Intervalos de Confiança

- Outra forma de usar testes estatísticos é construir um intervalo de confiança usando o mesmo valor crítico como foi usado para o teste bi-caudal
- Um intervalo de confiança de $(1 - \alpha) \%$ é definido como:

$$\hat{\beta}_j \pm c \bullet SE(\hat{\beta}_j), \text{ tal que } c \text{ é o percentual } \left(1 - \frac{\alpha}{2}\right)$$

em uma distribuição t_{n-k-1}

Computando valores- p para testes t

- Uma alternativa à versão clássica do teste é perguntar: “qual é o menor nível de significância ao qual a hipótese nula seria rejeitada?”
- Então, calcule a estatística t , e então procure qual o percentil é apropriado à distribuição t – este é o valor- p
- O valor- p é a probabilidade da estatística t aceitar a hipótese nula

Testes no computador

- A maioria dos programas computa o valor-p, assumindo um teste bi-caudal
- Se você realmente deseja uma alternativa unicaudal, então deve dividir o valor-p por 2
- Stata fornece a estatística t , p -value, e intervalo de confiança de confidence 95% para $H_0: \beta_j = 0$, nas colunas “ t ”, “ $P > |t|$ ” e “[95% Conf. Interval]”

Preços Hedônicos

- Modelo de preços em termos de suas características
- Decomposição do preço na disposição a pagar por cada característica
- Mercado imobiliário residencial
 - Atributos do imóvel
 - Atributos da vizinhança (peer effect)
 - Distância do trabalho

Testando uma combinação linear

- Suponha que ao invés de testar se β_1 é igual a uma constante, você deseja testar se ele é igual a outro parâmetro, isto é $H_0 : \beta_1 = \beta_2$
- Use o mesmo procedimento para formar uma estatística t

$$t = \frac{\hat{\beta}_1 - \hat{\beta}_2}{SE(\hat{\beta}_1 - \hat{\beta}_2)}$$

Testando uma combinação linear

Uma vez que

$$SE(\hat{\beta}_1 - \hat{\beta}_2) = \sqrt{\text{Var}(\hat{\beta}_1 - \hat{\beta}_2)}, \text{ então}$$

$$\text{Var}(\hat{\beta}_1 - \hat{\beta}_2) = \text{Var}(\hat{\beta}_1) + \text{Var}(\hat{\beta}_2) - 2\text{Cov}(\hat{\beta}_1, \hat{\beta}_2)$$

$$SE(\hat{\beta}_1 - \hat{\beta}_2) = \left\{ \left[SE(\hat{\beta}_1) \right]^2 + \left[SE(\hat{\beta}_2) \right]^2 - 2s_{12} \right\}^{1/2}$$

onde s_{12} é uma estimativa da $\text{Cov}(\hat{\beta}_1, \hat{\beta}_2)$

Testando uma combinação linear

- Então, para usar a fórmula precisamos de s_{12} , o que não está na tela dos programas
- Mas vários programas possuem uma opção para fazer isto
- No Stata, após o comando de regressão **reg y x1 x2 ... xk** você deve escrever **test x1 = x2** para ter um p-valor para este teste
- Genericamente falando, você sempre pode re-escrever o problema para o teste que deseja fazer

Exemplo:

- Suponha que você esteja interessado no efeito de gastos de uma campanha de gastos sobre votos
- Modelo é $voteA = \beta_0 + \beta_1 \log(expendA) + \beta_2 \log(expendB) + \beta_3 prtyst rA + u$
- $H_0: \beta_1 = -\beta_2$, or $H_0: \theta_1 = \beta_1 + \beta_2 = 0$
- $\beta_1 = \theta_1 - \beta_2$, então subst. e re-arrange \Rightarrow
 $voteA = \beta_0 + \theta_1 \log(expendA) + \beta_2 \log(expendB - expendA) + \beta_3 prtyst rA + u$

Exemplo:

- Este é o mesmo modelo original, mas agora temos o desvio padrão para $\beta_1 + \beta_2 = \theta_1$ diretamente a partir da regressão básica
- Qualquer combinação linear de parâmetros poderia ser testado de uma forma similar
- Outros exemplos de hipóteses sobre combinação linear de parâmetros:
 - $\beta_1 = 1 + \beta_2$; $\beta_1 = 5\beta_2$; $\beta_1 = -1/2\beta_2$; etc

Múltiplas Restrições Lineares

- Tudo que fizemos até o momento envolvia testar uma única restrição linear, (e.g. $\beta_1 = 0$ ou $\beta_1 = \beta_2$)
- Entretanto, podemos desejar testar conjuntamente testes de hipóteses múltiplas sobre nossos parâmetros
- Um exemplo típico de teste são as “restrições de exclusão” – desejamos saber se um grupo de parâmetros é igual a zero

Testando Restrições de Exclusão

- Agora a hipótese nula poderia ser algo como $H_0: \beta_{k-q+1} = 0, \dots, \beta_k = 0$
- A alternativa é apenas $H_1: H_0$ não é verdadeira
- Não podemos apenas checar cada estatística t separadamente, porque nós desejamos saber se os q parâmetros são conjuntamente significantes a um dado nível – é possível que individualmente nenhum termo seja significativo

Restrições de Exclusão

- Para testar precisamos estimar o **modelo restrito** sem a inclusão de x_{k-q+1}, \dots, x_k , bem como o **modelo não-restrito** com todos os x 's incluídos
- Intuitivamente, nós desejamos saber se a mudança em SSR é grande o suficiente para garantir a inclusão de x_{k-q+1}, \dots, x_k

$$F \equiv \frac{(SSR_r - SSR_{ur})/q}{SSR_{ur}/(n - k - 1)}, \text{ tal que}$$

r é restrito e ur é o não restrito

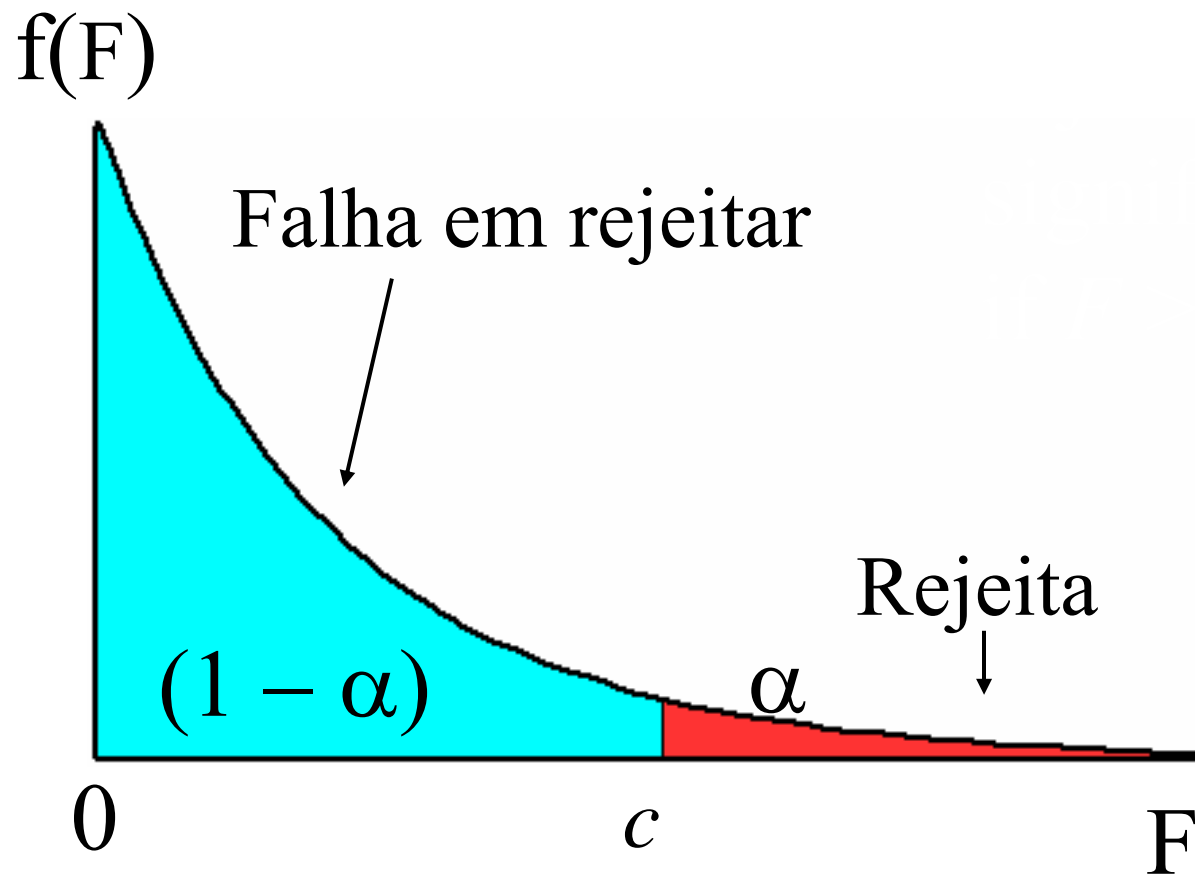
A Estatística F

- A estatística F é sempre positiva, uma vez que a SSR de um modelo restrito não pode ser menor do que a SSR do modelo não-restrito
- Essencialmente, a estatística F está medindo o aumento relativo na SSR quando movendo do modelo não restrito para o modelo restrito
- $q = \#$ de restrições, ou $df_r - df_{ur}$
- $n - k - 1 = df_{ur}$

A Estatística F

- Para decidir se o incremento na SSR é grande o suficiente para rejeitar as exclusões quando mudamos para um modelo restrito, precisamos conhecer um pouco da distribuição amostral da nossa estatística F
- Não surpreendentemente, $F \sim F_{q, n-k-1}$, tal que q é referida como o numerador dos graus de liberdade e $n - k - 1$ como o denominador dos graus de liberdade

A Estatística F



O R^2 forma a Estatística F

- Como as SSR podem ser grandes e estranhas, uma fórmula alternativa pode ser útil
- Nós usamos o fato que $SSR = SST(1 - R^2)$ para qualquer regressão, então podemos substituir para SSR_u e SSR_{ur}

$$F \equiv \frac{\left(R_{ur}^2 - R_r^2 \right) / q}{\left(1 - R_{ur}^2 \right) / \left(n - k - 1 \right)}$$

Significância Total

- Um caso especial de exclusão de restrições é testar $H_0: \beta_1 = \beta_2 = \dots = \beta_k = 0$
- Dado que o R^2 de um modelo com apenas um intercepto será zero, a estatística F é simplesmente

$$F = \frac{R^2 / k}{(1 - R^2) / (n - k - 1)}$$

Restrições Lineares Gerais

- A forma básica da estatística F irá funcionar para qualquer conjunto de restrições lineares
- Primeiro estime o modelo não-restrito e depois o restrito
- Em cada caso, guarde os valores da SSR
- Impor restrições pode ser difícil – isso pode requerer que as variáveis tenham que ser redefinidas novamente

Exemplo:

- Vamos usar o mesmo modelo de votos
- O modelo é $voteA = \beta_0 + \beta_1 \log(expendA) + \beta_2 \log(expendB) + \beta_3 prtyst rA + u$
- agora a hipótese nula $H_0: \beta_1 = 1, \beta_3 = 0$
- Substituindo as restrições: $voteA = \beta_0 + \log(expendA) + \beta_2 \log(expendB) + u$, então
- Use $voteA - \log(expendA) = \beta_0 + \beta_2 \log(expendB) + u$ como o modelo restrito

Sumário Estatística F

- Apenas como a estatística t , valores-p podem ser calculados procurando pelo percentil apropriado na distribuição F
- Stata realiza isso pelos comandos: **display fprob(q , $n - k - 1$, F)**, onde os valores apropriados de F , q , e $n - k - 1$ devem ser usados
- Se apenas uma exclusão está sendo testada, então $F = t^2$, e os valores p serão os mesmos