

Introdução à Teoria Assintótica para modelos para análise de dados longitudinais

Prof. Caio Azevedo

Introdução

- Convergência em distribuição (estimadores/estatísticas do teste), convergência em probabilidade/quase certa (estimadores).
- Existem algumas formas de deduzir resultados assintóticos (slide seguinte):

Introdução

- Resultados específicos para modelos de regressão (geralmente flexibilizando as suposições usuais, normalidade, heterocedasticidade, dependência) relativos à determinados métodos de estimação: mínimos quadrados, máxima verossimilhança, máxima verossimilhança marginal.
- Estudando o comportamento de classes específicas de estimadores:mínimos quadrados, máxima verossimilhança, máxima verossimilhança marginal, verificando se as condições que garantem as propriedades para tais estimadores, valem para os modelos em estudo.

Comentários

- Convergência em distribuição - Teorema central do limite.
Essencialmente três tipos:
 - Variáveis aleatórias IID.
 - Variáveis aleatórias independentes mas não identicamente distribuídas (o caso).
 - Variáveis que apresentam dependência do tipo martingal.
- Convergência em probabilidade - Desigualdades (Chebyshev)

Modelo normal linear multivariado (marginal)

$$\mathbf{Y}_{j(k_j \times 1)} = \mathbf{X}_{j(k_j \times p)} \boldsymbol{\beta}_{(p \times 1)} + \boldsymbol{\xi}_{j(k_j \times 1)}, j = 1, \dots, n \quad (1)$$

(indivíduo)

- $\mathbf{Y}_j = (Y_{1j}, \dots, Y_{kj})'$, k_j : número de condições de avaliação em que o indivíduo j é avaliado.
- \mathbf{X}_j : matriz de planejamento associada aos efeitos fixos (parâmetros de regressão) para o indivíduo j (não-aleatória e conhecida).
- $\boldsymbol{\beta}$: vetor de efeitos fixos ou parâmetros de regressão (não-aleatório e desconhecido).
- $\boldsymbol{\xi}_j$: vetor de erros associado ao indivíduo j , $\boldsymbol{\xi}_j \stackrel{ind.}{\sim} N_{k_j}(\mathbf{0}, \boldsymbol{\Sigma}_j)$.

Modelo Multivariado Marginal (MMM)

- Essencialmente correspondem à extensões dos modelos de regressão lineares normais homocedásticos (MRLNH) (veja http://www.ime.unicamp.br/~cnaber/Material_REG_POS_2S_2014.htm), no sentido de considerarem heterocedasticidade e dependência entre as observações.
- Assim, os resultados assintóticos desenvolvidos para o MRLNH, com o relaxamento das suposições de homocedasticidade e dependência, podem ser utilizados para demonstrar as propriedades assintóticas dos estimadores de máxima verossimilhança dos MMM.

Modelo Multivariado Marginal (MMM)

- Além disso note que, usualmente, considera-se a parametrização adotada pela função gls do pacote R, veja http://www.ime.unicamp.br/~cnaber/aula_Mod_Mult_Marg_ADL_2S_2018.pdf. Assim, a dedução dos resultados assintóticos torna-se menos complexa.

Ausência de normalidade

- Considere o modelo de regressão linear geral:

$$\mathbf{Y}_n = \mathbf{X}_n \boldsymbol{\beta} + \boldsymbol{\xi}_n$$

- Suponha que $\mathcal{E}(\boldsymbol{\xi}_n) = \mathbf{0}_n$ e $Cov(\boldsymbol{\xi}_n) = \sigma^2 \mathbf{I}_n$.
- Suposições adicionais
 - 1 $\max_{1 \leq k \leq n} \mathbf{x}'_{n_k} (\mathbf{X}'_n \mathbf{X}_n)^{-1} \mathbf{x}_{n_k} \rightarrow 0$, quando $n \rightarrow \infty$.
 - 2 $\lim_{n \rightarrow \infty} n^{-1} (\mathbf{X}'_n \mathbf{X}_n) = \mathbf{V}$.
- Pelo Teorema Central do Limte (TCL) de Linderberg-Feller (se $n \rightarrow \infty$), então

$$\sqrt{n}(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta}) \xrightarrow{D} N_p(\mathbf{0}, \sigma^2 \mathbf{V}^{-1})$$

Comentário

- Para n suficientemente grande

$$\widehat{\beta} \approx N_p(\beta, \sigma^2(\mathbf{X}_n \mathbf{X}_n)^{-1})$$

- Em relação à primeira suposição adicional, considere que

$$\mathbf{X}_n = \begin{pmatrix} \mathbf{x}'_{n_1} \\ \mathbf{x}'_{n_2} \\ \vdots \\ \mathbf{x}'_{n_n} \end{pmatrix}; \quad \mathbf{X}_n = \begin{pmatrix} \mathbf{1}_{n_1} & \mathbf{0} \\ \mathbf{0} & \mathbf{1}_{n_2} \end{pmatrix}; \quad n^{-1} \mathbf{X}'_n \mathbf{X}_n = \begin{pmatrix} n_1/n & 0 \\ 0 & n_2/n \end{pmatrix}$$

- Assim

$$\mathbf{x}'_{n_1} (\mathbf{X}'_n \mathbf{X}_n)^{-1} \mathbf{x}_{n_1} = n_1^{-1}; \quad \mathbf{x}'_{n_2} (\mathbf{X}'_n \mathbf{X}_n)^{-1} \mathbf{x}_{n_2} = n_2^{-1}$$

Ausência de homocedasticidade e presença de correlação

- Suponha a mesma estrutura anterior mas $Cov(\xi) = \sigma^2 \Sigma$, Σ conhecida.
- Defina

$$Z = W\beta + \delta \quad (2)$$

em que

$$\Sigma = \Sigma^{1/2} \Sigma^{1/2} \text{ (decomposição de Cholesky)}$$

$$Z = \Sigma^{-1/2} Y$$

$$W = \Sigma^{-1/2} X$$

$$\delta = \Sigma^{-1/2} \xi$$

Cont.

- Assim, $\mathcal{E}(\delta) = \boldsymbol{\Sigma}^{-1/2}\mathcal{E}(\xi) = \mathbf{0}$ e $Cov(\delta) = \sigma^2\boldsymbol{\Sigma}^{-1/2}\boldsymbol{\Sigma}\boldsymbol{\Sigma}^{-1/2} = \sigma^2\mathbf{I}$.
- Logo, o estimador de MQO de β , baseado no modelo (2), é dado por:

$$\hat{\beta} = (\mathbf{W}'\mathbf{W})^{-1}\mathbf{W}'\mathbf{Z} = (\mathbf{X}'\boldsymbol{\Sigma}^{-1}\mathbf{X})^{-1}\mathbf{X}'\boldsymbol{\Sigma}^{-1}\mathbf{Y}$$

- Se $\xi \sim N_n(\mathbf{0}, \sigma^2\boldsymbol{\Sigma})$, então

$$\hat{\beta} \sim N_p(\beta, \sigma^2(\mathbf{X}'\boldsymbol{\Sigma}^{-1}\mathbf{X})^{-1})$$

Cont.

- Se a suposição de normalidade for desconsiderada mas as suposições relativas ao TCL anterior se verificarem, então

$$\hat{\beta} \approx N_p(\beta, \sigma^2(\mathbf{X}'\boldsymbol{\Sigma}^{-1}\mathbf{X})^{-1})$$

- Quando $\boldsymbol{\Sigma}$ é diagonal mas ($\neq \mathbf{I}$), dizemos que $\hat{\beta}$ é o estimador de mínimos quadrados ponderados (MQP) de β (baseado no modelo original).
- Quando $\boldsymbol{\Sigma}$ não é diagonal, dizemos que $\hat{\beta}$ é o estimador de mínimos quadrados generalizados (MQG) de β (baseado no modelo original).

Σ desconhecido

- Considere novamente o modelo original, $\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\xi}$, com $\mathcal{E}(\boldsymbol{\xi}) = \mathbf{0}$ e $Cov(\boldsymbol{\xi}) = \boldsymbol{\Sigma}$.
- Uma alternativa consiste em considerar o estimador de dois estágio de Aitken, ou seja

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}'\hat{\boldsymbol{\Sigma}}^{-1}\mathbf{X})^{-1}\mathbf{X}'\hat{\boldsymbol{\Sigma}}^{-1}\mathbf{Y}$$

em que $\hat{\boldsymbol{\Sigma}}$ é um estimador consistente de $\boldsymbol{\Sigma}$, ($\hat{\boldsymbol{\Sigma}} \xrightarrow{P} \boldsymbol{\Sigma}$).

Cont.

- Assim, temos que (se válidas as condições do TCL apresentado anteriormente), que:

$$\sqrt{n}(\hat{\beta} - \beta) \xrightarrow{D} N_p(\mathbf{0}, \mathbf{V}^{-1})$$

em que $\mathbf{V} = \lim_{n \rightarrow \infty} n^{-1}(\mathbf{X}'_n \boldsymbol{\Sigma}_n^{-1} \mathbf{X}_n)$

- Em geral, toma-se $\hat{\mathbf{V}} = \mathbf{X}' \hat{\boldsymbol{\Sigma}}^{-1} \mathbf{X}$.

Modelo normal linear misto

$$\mathbf{Y}_{j(k_j \times 1)} = \mathbf{X}_{j(k_j \times p)} \boldsymbol{\beta}_{(p \times 1)} + \mathbf{Z}_{j(k_j \times q)} \mathbf{b}_{j(q \times 1)} + \boldsymbol{\xi}_{j(k_j \times 1)}, j = 1, \dots, n$$

(indivíduo)

- $\mathbf{Y}_j = (Y_{j1}, \dots, Y_{jk_j})'$, k_j : número de condições de avaliação em que o indivíduo j é avaliado.
- \mathbf{X}_j : matriz de planejamento associada aos efeitos fixos para o indivíduo j (não-aleatória e conhecida).
- \mathbf{Z}_j : matriz de planejamento associada aos efeitos aleatórios para o indivíduo j (não-aleatória e conhecida).
- $\boldsymbol{\beta}$: vetor de efeitos fixos (não-aleatório e desconhecido).
- \mathbf{b}_j : vetor de efeitos aleatórios associado ao indivíduo j (aleatório e desconhecido), $\mathbf{b}_j \stackrel{ind.}{\sim} N(\mathbf{0}, \Psi)$.
- $\boldsymbol{\xi}_j$: vetor de erros associado ao indivíduo j , $\boldsymbol{\xi}_j \stackrel{ind.}{\sim} N(\mathbf{0}, \Sigma_j)$, $\mathbf{b}_j \perp \boldsymbol{\xi}_j, \forall i$.

Algumas propriedades do modelo

- $\mathcal{E}(\mathbf{Y}_j | \mathbf{b}_j) = \mathbf{X}_j\boldsymbol{\beta} + \mathbf{Z}_j\mathbf{b}_j.$
- $\mathcal{E}(\mathbf{Y}_j) = \mathbf{X}_j\boldsymbol{\beta}.$
- $Cov(\mathbf{Y}_j | \mathbf{b}_j) = \boldsymbol{\Sigma}_j.$
- $Cov(\mathbf{Y}_j) = \mathbf{V}_j = \mathbf{Z}_j\boldsymbol{\Psi}\mathbf{Z}'_j + \boldsymbol{\Sigma}_j.$
- $\mathbf{Y}_j | \mathbf{b}_j \sim N_{k_j}(\mathbf{X}_j\boldsymbol{\beta} + \mathbf{Z}_j\mathbf{b}_j, \boldsymbol{\Sigma}_j).$ Além disso, como

$$\mathbf{Y}_j | \mathbf{b}_j \sim N_{k_j}(\mathbf{X}_j\boldsymbol{\beta} + \mathbf{Z}_j\mathbf{b}_j, \boldsymbol{\Sigma}_j)$$

$$\mathbf{b}_j \sim N_q(\mathbf{0}, \boldsymbol{\Psi})$$

portanto

$$\mathbf{Y}_j \sim N_{k_j}(\mathbf{X}_j\boldsymbol{\beta}, \mathbf{Z}_j\boldsymbol{\Psi}\mathbf{Z}'_j + \boldsymbol{\Sigma}_j) \quad (3)$$

Propriedades assintóticas

- Note que a representação (3) parece com os MMM, com duas matrizes de covariâncias.
- Assim, os resultados discutidos anteriormente, para os MMM, podem ser adaptados para este caso.
- Note também que, usualmente, utiliza-se a parametrização considerada pela função lme do pacote R (http://www.ime.unicamp.br/~cnaber/aula_Mod_Lin_Misto_ADL_2S_2018.pdf), que corresponde à uma representação mais simples do modelo.
- Consequentemente, os resultados assintóticos são dedutíveis de forma mais simples.

Estimadores de máxima verossimilhança/máxima verossimilhança marginal

- Livros sobre teoria assintótica (geral) apresentam condições para convergência em distribuição (normalidade multivariada) para estimadores de máxima verossimilhança para variáveis IID.
- A idéia para se demonstrar os resultados, para o caso de modelos de regressão (MMM, MLM) consiste em visualizar as funções (vetor) escore como variáveis (vetores) aleatórios IID com vetor de médias zero e matriz de covariâncias igual a inversa da Informação de Fisher, com condições adicionais.

Estimadores de máxima verossimilhança/máxima verossimilhança marginal

- Pode-se usar raciocínio análogo, no caso de modelos lineares mistos, em que os vetores escore são vetores aleatórios independentes mas não identicamente distribuídas (INID), de média zero e matriz de covariâncias igual à inversa da Informação de Fisher, com condições adicionais.
- Neste caso, deve-se verificar condições mais específicas (para variáveis INID) como as de Liapunov e Lindenbergs-Feller.

Referências

- Demonstrações acerca de resultados assintóticos para modelos de regressão e estimadores de máxima verossimilhança (Sen and Singer (2019), Sen et al (2009)).
- Demonstrações acerca de estimadores, estatísticas do teste para modelos lineares mistos, problemas em aberto (Demidenko (2004), Demidenko (2013), Jiang (2017)).
- Outras referências sobre Teoria Assintótica para modelos mistos Singer et al 2018 (<https://www.ime.usp.br/~jmsinger/MAE0610/Singer&Nobre&Rocha2018jun.pdf>).

Referências

- Demidenko, E. (2004). Mixed models: theory and applications, Hoboken, NJ: Wiley-Interscience.
- Demidenko, E. (2013). Mixed Models: Theory and Applications with R, Wiley-Series.
- Jiang, J. (2017). Asymptotic Analysis of Mixed Effects Models: Theory, Applications, and Open Problems, Chapman and Hall/CRC.
- Sen, P. K., Singer, J. M. (2019). Large Sample Methods in Statistics (1994): An Introduction with Applications, CRC Press Revivals.
- Sen, P. K., Singer, J. M., Lima, A. C. P. (2009). From Finite Sample to Asymptotic Methods in Statistics, Cambridge University Press.