

# **Modelos heterocedásticos com erros nas variáveis:**

*modelando a emissão de raios-X contra a massa de buracos negros*

Alexandre Galvão Patriota

IME - USP

# Roteiro

## 1 Áreas de aplicação do modelo

- Astrofísica

## 2 Modelo com erros nas variáveis

- Objetivos Principais
- Estimação via escore corrigido

## 3 Simulações

## 4 Aplicações

- Observatório Chandra

## 5 Considerações finais

## 6 Referências

# Emissão de raios-X versus proporção de Eddington

Os **raios-X** são radiações altamente energéticas que são emitidas pelo disco de acresção de buracos negros supermassivos. Não podem ser observadas, contudo telecópios espaciais podem captá-las (e.g., Hubble e Chandra).

A **proporção de Eddington de quasares** é uma função da massa do buraco negro. Que por sua vez é estimada através da atividade do núcleo galáctico, também conhecido por quasar (quase estrela).

As observações são estimativas obtidas através de tratamento de dados. Cada observação possui uma medida de variabilidade. O interesse é relacionar a verdadeira **emissão de raios-X** com a verdadeira **proporção de Eddington** que não são observados.

OBS: As variáveis são transformadas aplicando o logaritmo na base 10.

# Emissão de raios-X versus proporção de Eddington

Os **raios-X** são radiações altamente energéticas que são emitidas pelo disco de acresção de buracos negros supermassivos. Não podem ser observadas, contudo telecópios espaciais podem captá-las (e.g., Hubble e Chandra).

A **proporção de Eddington de quasares** é uma função da massa do buraco negro. Que por sua vez é estimada através da atividade do núcleo galáctico, também conhecido por quasar (quase estrela).

As observações são estimativas obtidas através de tratamento de dados. Cada observação possui uma medida de variabilidade. O interesse é relacionar a verdadeira **emissão de raios-X** com a verdadeira **proporção de Eddington** que não são observados.

OBS: As variáveis são transformadas aplicando o logaritmo na base 10.

# Emissão de raios-X versus proporção de Eddington


Os **raios-X** são radiações altamente energéticas que são emitidas pelo disco de acresção de buracos negros supermassivos. Não podem ser observadas, contudo telecópios espaciais podem captá-las (e.g., Hubble e Chandra).

A **proporção de Eddington de quasares** é uma função da massa do buraco negro. Que por sua vez é estimada através da atividade do núcleo galáctico, também conhecido por quasar (quase estrela).

As observações são estimativas obtidas através de tratamento de dados. Cada observação possui uma medida de variabilidade. O interesse é relacionar a verdadeira **emissão de raios-X** com a verdadeira **proporção de Eddington** que não são observados.

OBS: As variáveis são transformadas aplicando o logaritmo na base 10.

# Buraco Negro emitindo quasares





# Buraco Negro emitindo quasares



# Dados do Observatório de Chandra

O Observatório *Chandra* é o carro-chefe da NASA na missão para detectar raios-X. O tamanho da amostra é de 153 objetos.



# Modelo com erros nas variáveis

$$\begin{aligned} Y_i &= y_i + e_i \\ X_i &= x_i + u_i \end{aligned} \tag{1}$$

onde  $Y_i$  e  $X_i$  são as variáveis observadas,  $y_i$  e  $x_i$  são as variáveis não observadas, e por fim  $e_i$  e  $u_i$  são os erros do modelo com dist. Normal de média zero e **variâncias conhecidas**  $\lambda_i$  e  $\kappa_i$ , respectivamente.

As variáveis não observadas  $y_i$  e  $x_i$  podem ser relacionadas da seguinte forma [Patriota and Bolfarine(2008)].

$$y_i = \beta_0 + \beta_1 x_i + \dots + \beta_p x_i^p + q_i \quad \text{para } i = 1, 2, \dots, n$$

onde  $n$  é o tamanho amostral,  $q_i$  é o erro da equação com distribuição normal de média zero e variância  $\sigma^2$  (desconhecida). O modelo linear é discutido em [Patriota et al(2009)]

# Modelo com erros nas variáveis

$$\begin{aligned} Y_i &= y_i + e_i \\ X_i &= x_i + u_i \end{aligned} \tag{1}$$

onde  $Y_i$  e  $X_i$  são as variáveis observadas,  $y_i$  e  $x_i$  são as variáveis não observadas, e por fim  $e_i$  e  $u_i$  são os erros do modelo com dist. Normal de média zero e **variâncias conhecidas**  $\lambda_i$  e  $\kappa_i$ , respectivamente.

As variáveis não observadas  $y_i$  e  $x_i$  podem ser relacionadas da seguinte forma [Patriota and Bolfarine(2008)].

$$y_i = \beta_0 + \beta_1 x_i + \dots + \beta_p x_i^p + q_i \quad \text{para } i = 1, 2, \dots, n$$

onde  $n$  é o tamanho amostral,  $q_i$  é o erro da equação com distribuição normal de média zero e variância  $\sigma^2$  (desconhecida). O modelo linear é siductio em [Patriota et al(2009)]

# Objetivos principais

- 1 Estimar os parâmetros  $\beta_0, \beta_1, \dots, \beta_p$  e  $\sigma^2$  consistentemente.
- 2 Testar se  $\mathbf{G}\beta = \mathbf{d}$ , onde  $\beta = (\beta_0, \beta_1, \dots, \beta_p)^\top$ ,  $\mathbf{G}$  é uma matriz de dimensões  $q \times (p + 1)$  e  $\mathbf{d}$  um vetor de dimensão  $q$ .
- 3 Regiões de confiança para  $\mathbf{G}\beta$

Por exemplo, para testar se  $(\beta_0, \beta_3) = (0, 0)$ , temos que

$$\mathbf{G} = \begin{bmatrix} 1 & 0 & 0 & 0 & \dots & 0 \\ 0 & 0 & 1 & 0 & \dots & 0 \end{bmatrix} \quad \text{e} \quad \mathbf{d} = (0, 0)^\top$$

# Objetivos principais

- 1 Estimar os parâmetros  $\beta_0, \beta_1, \dots, \beta_p$  e  $\sigma^2$  consistentemente.
- 2 Testar se  $\mathbf{G}\beta = \mathbf{d}$ , onde  $\beta = (\beta_0, \beta_1, \dots, \beta_p)^\top$ ,  $\mathbf{G}$  é uma matriz de dimensões  $q \times (p + 1)$  e  $\mathbf{d}$  um vetor de dimensão  $q$ .
- 3 Regiões de confiança para  $\mathbf{G}\beta$

Por exemplo, para testar se  $(\beta_0, \beta_3) = (0, 0)$ , temos que

$$\mathbf{G} = \begin{bmatrix} 1 & 0 & 0 & 0 & \dots & 0 \\ 0 & 0 & 1 & 0 & \dots & 0 \end{bmatrix} \quad \text{e} \quad \mathbf{d} = (0, 0)^\top$$

# Objetivos principais

- 1 Estimar os parâmetros  $\beta_0, \beta_1, \dots, \beta_p$  e  $\sigma^2$  consistentemente.
- 2 Testar se  $\mathbf{G}\beta = \mathbf{d}$ , onde  $\beta = (\beta_0, \beta_1, \dots, \beta_p)^\top$ ,  $\mathbf{G}$  é uma matriz de dimensões  $q \times (p + 1)$  e  $\mathbf{d}$  um vetor de dimensão  $q$ .
- 3 Regiões de confiança para  $\mathbf{G}\beta$

Por exemplo, para testar se  $(\beta_0, \beta_3) = (0, 0)$ , temos que

$$\mathbf{G} = \begin{bmatrix} 1 & 0 & 0 & 0 & \dots & 0 \\ 0 & 0 & 1 & 0 & \dots & 0 \end{bmatrix} \quad \text{e} \quad \mathbf{d} = (0, 0)^\top$$

# Objetivos principais

- 1 Estimar os parâmetros  $\beta_0, \beta_1, \dots, \beta_p$  e  $\sigma^2$  consistentemente.
- 2 Testar se  $\mathbf{G}\beta = \mathbf{d}$ , onde  $\beta = (\beta_0, \beta_1, \dots, \beta_p)^\top$ ,  $\mathbf{G}$  é uma matriz de dimensões  $q \times (p + 1)$  e  $\mathbf{d}$  um vetor de dimensão  $q$ .
- 3 Regiões de confiança para  $\mathbf{G}\beta$

Por exemplo, para testar se  $(\beta_0, \beta_3) = (0, 0)$ , temos que

$$\mathbf{G} = \begin{bmatrix} 1 & 0 & 0 & 0 & \dots & 0 \\ 0 & 0 & 1 & 0 & \dots & 0 \end{bmatrix} \quad \text{e} \quad \mathbf{d} = (0, 0)^\top$$

## Estimação via escore corrigido

A abordagem do escore corrigido foi proposta por Nakamura em 1990. A idéia principal é a seguinte:

- (1) Encontre a log-verossimilhança,  $\ell$ , considerando que  $x_i$  é observado diretamente sem erro de medição.

$$(Y_i = \underbrace{\beta_0 + \beta_1 x_i + \dots + \beta_p x_i^p}_{y_i} + q_i + e_i)$$

- (2) Encontre uma pseudo log-verossimilhança,  $\ell^*$ , que seja função apenas das variáveis observadas  $Y_i$  e  $X_i$  de tal forma que

$$E(\ell^*(\mathbf{Y}, \mathbf{X}) | \mathbf{Y}, \mathbf{x}) = \ell(\mathbf{Y}, \mathbf{x})$$

Nakamura mostrou que, sob certas condições de regularidade, os estimadores obtidos da função  $\ell^*$  são consistentes e têm distribuição normal assintótica com uma matriz sanduíche de covariâncias assintótica.

# Simulações de Monte Carlo

- $X_i|x_i \sim \mathcal{N}(x_i, \kappa_i)$  onde  $\sqrt{\kappa_i} \sim U(0.1, 0.2)$ ,
- $Y_i|x_i \sim \mathcal{N}(y_i, \lambda_i)$  onde  $\sqrt{\lambda_i} \sim U(0.1, 0.4)$ .
- $x_i \sim \mathcal{N}(-2, 0.13)$ . A variância do erro na equação é  $\sigma^2 = 0.1$

Dois tipos de relações foram estudadas, a saber: linear e cúbica. Para a relação linear, nós considerados  $(\beta_0, \beta_1)$  em uma vizinhança de  $(0, 1)$ . Para a relação cúbica, foi considerado  $\beta_0 = \beta_2 = 0$  e  $(\beta_1, \beta_3)$  em uma vizinhança de  $(0.1, 0)$ .

Para cada simulação (em um total de 10 000) estimamos os parâmetros, a matriz de covariâncias e testamos se  $(\beta_0, \beta_1) = (0, 1)$  para o caso linear e  $(\beta_1, \beta_3) = (0.1, 0)$ . Como resultado obtemos o tamanho e poder do teste empíricos.

Simulação para  $n = 40$ ,  $n = 80$  e  $n = 160$ 

		Linear			Cúbica		
$\beta_0$		$\beta_1$		$\beta_3$	$\beta_1$		
$n = 40$	0.9	1	1.1		-0.1	0.1	0.3
-0.1	0.3732	0.3529	0.9923	-0.5	0.9713	0.9345	0.9437
0.0	0.8525	<b>0.1255</b>	0.8384	0.0	0.9517	<b>0.2705</b>	0.9702
0.1	0.9933	0.3541	0.3418	0.5	0.9291	0.9633	0.9761
$n = 80$	0.9	1	1.1		-0.1	0.1	0.3
-0.1	0.5447	0.5545	0.9999	-0.5	0.8828	0.7725	0.9867
0.0	0.9898	<b>0.0641</b>	0.9873	0.0	0.8268	<b>0.1168</b>	0.9955
0.1	0.9999	0.5432	0.5160	0.5	0.7801	0.8824	0.9988
$n = 160$	0.9	1	1.1		-0.1	0.1	0.3
-0.1	0.8692	0.8538	1.0000	-0.5	0.7042	0.6325	0.8718
0.0	1.0000	<b>0.0569</b>	1.0000	0.0	0.6590	<b>0.0598</b>	0.9156
0.1	1.0000	0.8483	0.8572	0.5	0.6340	0.7054	0.9556

# Emissão de Raios-X versus proporção de Eddington


Consideramos um modelo cúbico e quártico:

$$y_i|x_i \sim \mathcal{N}(\beta_1 x_i + \beta_3 x_i^3, \sigma^2), \quad y_i|x_i \sim \mathcal{N}(\beta_2 x_i + \beta_3 x_i^3 + \beta_4 x_i^4, \sigma^2)$$

As estimativas são dadas por:

	Linear (MV)	Cúbica	Quártica
$\beta_0$	2.4618 (0.6765)	-	-
$\beta_1$	0.3102 (0.4987)	-2.1202 (0.3944)	-
$\beta_2$	-	-	3.3880 (0.5710)
$\beta_3$	-	0.3415 (0.2156)	2.2296 (0.7024)
$\beta_4$	-	-	0.3889 (0.2248)
$\sigma^2$	0.1279	0.1156 (0.0293)	0.1453 (0.0381)

# Emissão de Raios-X versus proporção de Eddington



# Considerações finais

Não foi possível estimar os modelos linear e quadrático neste conjunto de dados, pois não houve convergência para estes casos.

De acordo com os resultados das simulações, percebemos que a não convergência pode ocorrer quando:

- Um modelo polinomial de ordem  $p$  é verdadeiro e um modelo de ordem  $q < p$  é estimado,
- Os erros de medida da variável  $X$  são muito grandes. Fato que ocorre nos dados da astrofísica.

O modelo proposto pode ser aplicado a problemas de regressão com erros em ambas as variáveis cuja relação não é linear.

-  Akritas MG, Bershady MA. (1996). Linear regression for astronomical data with measurement errors and intrinsic scatter. *The Astrophysical Journal*. **470**:706–714.
-  Gimenez P and Bolfarine H. (1997). Corrected score functions in classical error-in-variables and incidental parameter models. *Australian Journal of Statistics* **39**(3): 325–344.
-  Kelly BC, Bechtold J, Trump JR, Vertergaard M. (2008). Observational constraints on the dependence of ratio-quiet quasar X-ray emission on black hole mass and accretion disk. (To appear) *The Astrophysical Journal*.
-  Kulathinal SB, Kuulasmaa K, Gasbarra D. (2002). Estimation of an errors-in-variables regression model when the variances of the measurement error vary between the observations. *Statistics in Medicine*. **21**:1089–1101.

-  Nakamura T. (1990). Corrected score functions for errors-in-variables models: methodology and applications to generalized linear models. *Biometrika* **77**:127–137.
-  Patriota, AG, Bolfarine, H. (2008). A heteroscedastic polynomial regression with measurement error in both axes. *Sankhya Series B*, **70**: 267-282.
-  Patriota, AG, Bolfarine, H, de Castro, M. (2009). A heteroscedastic structural errors-in-variables model with equation error. *Statistical Methodology*, **6**: 408-423.
-  Zavala AAZ, Bolfarine H and de Castro M. (2007). Consistent estimation and testing in heteroscedastic polynomial errors-in-variables models. *AISM* **59**:515–530.