

Regresiones por cuantiles

Gabriel V. Montes-Rojas

Valor esperado y promedio

- Sea y una variable aleatoria con $E(y) = \mu_y$, $Var(y) = \sigma^2 < \infty$, con función de distribución F_y , y una muestra aleatoria $\{y_i\}_{i=1}^N$.
- La esperanza es la solución a la minimización del valor esperado de las desviaciones al cuadrado, o sea $E(y) = \arg \min_c E(y - c)^2$. (¿Por qué?)
- Entonces usando el principio de analogía

$$\hat{\mu}_y \equiv \frac{1}{N} \sum_{i=1}^N y_i = \arg \min_c \sum_{i=1}^N (y_i - c)^2$$

Mediana

- La mediana es un **estadístico de orden** (order statistic) que informa el número η_y donde (al menos) 50% de las observaciones están por encima y 50% (como mucho) por debajo del mismo. En términos formales η_y es cualquier número que satisface $P[y \leq \eta_y] \geq 1/2$ y $P[y \geq \eta_y] \leq 1/2$. En general,

$$\eta_y = \inf \{ \xi : F_y(\xi) \geq 0.5 \}$$
- Si F_y es estrictamente creciente, la densidad f_y es positiva y continua, entonces $\eta_y = F_y^{-1}(1/2)$.
- La mediana es también la solución a la minimización del valor absoluto de las desviaciones, o sea $\eta_y = \arg \min_c E|y - c|$.
 Prueba: $E|y - c| = E(1[y > c](y - c) - 1[y < c](y - c))$. Tomando derivadas *direccionales*,
 $\partial E|y - c|/\partial c = -E(1[y > c]) + E(1[y < c]) = -P[y > c] + P[y < c]$. Entonces c tiene que ser la mediana.
- Notemos que en este caso la condición de primer orden es $-E(\text{sgn}(y - c)) = 0$ donde $\text{sgn}(\cdot)$ es la función signo $\text{sgn}(u) = 1 - 2 \cdot 1[u < 0]$.
- Usando el principio de analogía, la mediana se puede estimar como

$$\hat{\eta}_y = \arg \min_c \sum_{i=1}^N |y_i - c|$$

Estadístico de orden

Definamos $Q_\tau(y) = \inf\{\xi : F_y(\xi) \geq \tau\}$ como el cuantil/percentil $\tau \in [0, 1]$ de y donde F_y es la función de distribución de y . Si F es continua, entonces $Q_\tau(y) = F_y^{-1}(\tau)$.

Por ejemplo,

- ... si queremos separar la población en (10-90), entonces necesitamos el cuantil 10 (primer decil), $\tau = .1 \rightarrow Q_{.1}(y)$.
- ... si queremos separar la población en (25-75), entonces necesitamos el cuantil 25 (primer cuartil), $\tau = .25 \rightarrow Q_{.25}(y)$.
- ... si queremos separar la población en (50-50), entonces necesitamos el cuantil 50 (mediana), $\tau = .5 \rightarrow Q_{.5}(y)$.
- ... si queremos separar la población en (75-25), entonces necesitamos el cuantil 75 (tercer cuartil), $\tau = .75 \rightarrow Q_{.75}(y)$.
- ... si queremos separar la población en (90-10), entonces necesitamos el cuantil 90 (noveno decil), $\tau = .9 \rightarrow Q_{.9}(y)$.

MCO

- Consideremos ahora el modelo lineal estructural $y = \mathbf{x}\beta + u$ con $E(u|\mathbf{x}) = 0$, $Var(u|\mathbf{x}) = \sigma^2 < \infty$, con función de distribución F_u , y una muestra aleatoria $\{y_i, \mathbf{x}_i\}_{i=1}^N$. Ahora tenemos K variables explicativas \mathbf{x} .
- Una generalización del problema univariado es el análisis condicional.
- La esperanza condicional es la solución al problema de minimización del valor esperado de las desviaciones al cuadrado, o sea $E(y|\mathbf{x}) = \arg \min_{m(\mathbf{x})} E((y - m(\mathbf{x}))^2)$.
- Para este caso, si asumimos $E(y|\mathbf{x}) = \mathbf{x}\beta$, entonces

$$\beta = \frac{\partial E(y|\mathbf{x})}{\partial \mathbf{x}},$$

esto es, los coeficientes de la regresión son el efecto marginal de un cambio en \mathbf{x} sobre la esperanza condicional de y .

- Usando el principio de analogía,

$$\hat{\beta} = \arg \min_{\mathbf{b}} \sum_{i=1}^N (y_i - \mathbf{x}_i \mathbf{b})^2$$

Éste es el bien conocido estimador MCO.

Regresión en la mediana

- La mediana condicional es la solución a la minimización del valor esperado de los valores absolutos de las desviaciones, o sea

$$Q_{.5}(y|\mathbf{x}) = \arg \min_{q(\mathbf{x})} E(|y - q(\mathbf{x})|).$$
- Si asumimos $q(\mathbf{x}) = \mathbf{x}\beta(.5)$ tenemos el modelo lineal de mediana condicional.
- También podemos escribir el modelo como

$$y_i = \mathbf{x}_i\beta(.5) + u_i$$

donde $Q_{.5}(y|\mathbf{x}) = \mathbf{x}\beta(.5)$ o $Q_{.5}(u|\mathbf{x}) = 0$.

- Entonces

$$\beta(.5) = \frac{\partial Q_{.5}(y|\mathbf{x})}{\partial \mathbf{x}},$$

esto es, los coeficientes de la regresión en la mediana son el efecto marginal de un cambio en \mathbf{x} sobre la mediana condicional de y .

- Usando el principio de analogía,

$$\hat{\beta}(.5) = \arg \min_{\mathbf{b}} \sum_{i=1}^N |y_i - \mathbf{x}_i\mathbf{b}|$$

Este es el estimador de regresión en la mediana, **least absolute deviation (LAD)** estimator.

Regresiones por cuantiles

- En forma general, para cualquier cuantil $\tau \in (0, 1)$ de interés, el cuantil condicional es la solución a $Q_\tau(y|\mathbf{x}) = \arg \min_{q(\mathbf{x})} \rho_\tau(y - q(\mathbf{x}))$, donde $\rho_\tau(u) = u \cdot (\tau - 1[u < 0])$.
 La función $\rho_\tau(\cdot)$ (check function) es asimétrica tal que

$$\rho_\tau(u) = \begin{cases} \tau u & \text{si } u \geq 0 \\ (\tau - 1)u & \text{si } u < 0 \end{cases}$$

- Si asumimos $Q_\tau(y|\mathbf{x}) = \mathbf{x}\boldsymbol{\beta}(\tau)$ tenemos el modelo lineal del cuantil condicional τ .
- También podemos escribir el modelo para cada cuantil τ como

$$y_i = \mathbf{x}_i\boldsymbol{\beta}(\tau) + u_i,$$


donde $u_i \equiv y_i - \mathbf{x}_i\boldsymbol{\beta}(\tau)$ y $Q_\tau(u|\mathbf{x}) = 0$.

- Tenemos que

$$\boldsymbol{\beta}(\tau) = \frac{\partial Q_\tau(y|\mathbf{x})}{\partial \mathbf{x}},$$

esto es, el coeficiente de la regresión del cuantil τ es el efecto marginal de un cambio en \mathbf{x} en el cuantil condicional τ de y .

Check function



Regresiones por cuantiles

- Usando el principio de analogía, para $\tau \in (0, 1)$,

$$\hat{\beta}(\tau) = \arg \min_{\mathbf{b}} \sum_{i=1}^N \rho_{\tau}(y_i - \mathbf{x}_i \mathbf{b})$$

Este es el estimador de regresión por cuantiles, **quantile regression** (QR) de Koenker and Basset (1978, Econometrica).

- Si $\tau = 0.5$ tenemos regresión en la mediana.
- La condición de primer orden es

$$\frac{1}{N} \sum_{i=1}^N \mathbf{x}'_i (\tau - 1(y_i < \mathbf{x}_i \mathbf{b})) = \sum_{i=1}^N \mathbf{s}(\tau, \mathbf{b}; y_i, \mathbf{x}_i) = \mathbf{0}_K$$

donde $\mathbf{s}(\tau, \mathbf{b}; y, \mathbf{x}) = (\tau - 1(y < \mathbf{x} \mathbf{b})) \mathbf{x}$ es la función score. Notar que ρ_{τ} no es diferenciable pero tiene derivada unidireccional.

- Comparar con la CPO de MCO: $\frac{1}{N} \sum_{i=1}^N \mathbf{x}'_i (y_i - \mathbf{x}_i \mathbf{b})$ donde el error $\hat{u}_i = y_i - \mathbf{x}_i \mathbf{b}$ es reemplazado por $(\tau - 1(y_i < \mathbf{x}_i \mathbf{b}))$.
- Otra diferencia con MCO es que en QR no hay un cero exacto en las CPO, pero $N^{-1/2} \sum_{i=1}^N \mathbf{s}_i(\hat{\beta}) = o_p(1)$.

Modelos de locación-escala

El siguiente modelo se denomina de locación-escala (location-scale)

$$y = \beta_0 + \beta_1 x + (1 + \gamma x)\epsilon \text{ con } \epsilon \sim F_\epsilon, \epsilon \perp x.$$

En este modelo, los cuantiles condicionales son

$Q_\tau(y|x) = (\beta_0 + Q_\tau(\epsilon)) + (\beta_1 + \gamma Q_\tau(\epsilon))x = \beta_0(\tau) + \beta_1(\tau)x$, es decir, dependen de los cuantiles del error. Entonces,

$$\frac{\partial Q_\tau(y|x)}{\partial x} = \beta_1(\tau) = \beta_1 + \gamma Q_\tau(\epsilon),$$

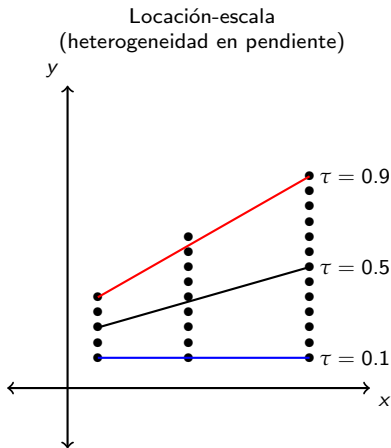
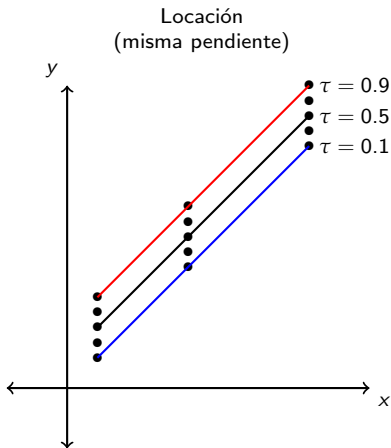
donde $Q_\tau(\epsilon)$ es el cuantil τ de ϵ .

Sin embargo, para la media condicional, $E(y|x) = \beta_0 + \beta_1 x$,

$$\frac{\partial E(y|x)}{\partial x} = \beta_1 \text{ (constante)}$$

En este modelo se puede ver que para tener heterogeneidad en los cuantiles se requiere heterocedasticidad, $\gamma \neq 0$.

Modelo de locación y locación-escala



Máxima verosimilitud

Bera, A., Galvao, A. Montes-Rojas, G. & Park, S-Y. (2016). "Asymmetric Laplace regression: Maximum likelihood, maximum entropy and quantile regression," Journal of Econometric Methods, 5(1), 79-101.

- MCO se basa en la densidad condicional normal:

$$f(y; \mu, \sigma) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(y - \mu)^2}{\sigma^2}\right)$$

- El modelo QR se basa en la densidad de Laplace asimétrica:

$$f(y; \mu, \tau, \sigma) = \frac{\tau(1 - \tau)}{\sigma} \exp\left(-\frac{\rho_{\tau}(y - \mu)}{\sigma}\right)$$

para dados (τ, σ) . La distribución de Laplace simétrica (doble exponencial) es un caso particular para $\tau=1/2$.

Teoría asintótica

- Los modelos QR son diferentes de los estimadores M porque la función objetivo $\rho_\tau(\cdot)$ no es dos veces diferenciable.

- Escribamos la función objetivo como un estimador M:

$$\hat{\beta}(\tau) = \arg \min_{\mathbf{b}} \sum_{i=1}^N \rho(y_i - \mathbf{x}_i \mathbf{b}) \text{ donde}$$

$$\rho_\tau(y_i - \mathbf{x}_i \beta) = q(\mathbf{w}_i, \beta) = \tau 1[y_i - \mathbf{x}_i \beta \geq 0](y_i - \mathbf{x}_i \beta) - (1 - \tau) 1[y_i - \mathbf{x}_i \beta < 0](y_i - \mathbf{x}_i \beta).$$

- El score es

$$\mathbf{s}_i(\beta) = -\mathbf{x}_i' \{ \tau 1[y_i - \mathbf{x}_i \beta \geq 0] - (1 - \tau) 1[y_i - \mathbf{x}_i \beta < 0] \}.$$

- Asumamos que existe un solo valor $\beta_0 = \beta_0(\tau)$
- Notar que si $u_i \equiv y_i - \mathbf{x}_i \beta_0$ tiene una distribución que es continua en cero,

$$E[\mathbf{s}_i(\beta_0) | \mathbf{x}_i] = \mathbf{0} \text{ porque}$$

$$E(1[y_i - \mathbf{x}_i \beta_0 \geq 0] | \mathbf{x}_i) = P(1[y_i - \mathbf{x}_i \beta_0 \geq 0] | \mathbf{x}_i) = (1 - \tau) \text{ y}$$

$$E(1[y_i - \mathbf{x}_i \beta_0 < 0] | \mathbf{x}_i) = P(1[y_i - \mathbf{x}_i \beta_0 < 0] | \mathbf{x}_i) = \tau.$$

Teoría asintótica

- Asumiendo que $F_u(\cdot|\mathbf{x})$ es continuamente diferenciable en 0 con densidad $f_u(\cdot|\mathbf{x}) > 0$,

$$\begin{aligned}
 E[\mathbf{s}_i(\boldsymbol{\beta}_0)|\mathbf{x}_i] &= -\mathbf{x}'_i\{\tau P[y_i - \mathbf{x}_i\boldsymbol{\beta} \geq 0|\mathbf{x}_i] - (1 - \tau)P[y_i - \mathbf{x}_i\boldsymbol{\beta} < 0|\mathbf{x}_i]\} \\
 &= -\mathbf{x}'_i\{\tau P[u_i \geq \mathbf{x}_i(\boldsymbol{\beta} - \boldsymbol{\beta}_0)|\mathbf{x}_i] - (1 - \tau)P[u_i < \mathbf{x}_i(\boldsymbol{\beta} - \boldsymbol{\beta}_0)|\mathbf{x}_i]\} \\
 &= -\mathbf{x}'_i\{\tau(1 - F_u[\mathbf{x}_i(\boldsymbol{\beta} - \boldsymbol{\beta}_0)|\mathbf{x}_i]) - (1 - \tau)F_u[\mathbf{x}_i(\boldsymbol{\beta} - \boldsymbol{\beta}_0)|\mathbf{x}_i]\} \\
 &= -\mathbf{x}'_i[\tau - F_u(\mathbf{x}_i(\boldsymbol{\beta} - \boldsymbol{\beta}_0)|\mathbf{x}_i)]
 \end{aligned}$$

Notar que esto da una condición de identificación: si y sólo si $\boldsymbol{\beta} = \boldsymbol{\beta}_0$ entonces $F_u(0|\mathbf{x}_i) = F_u(y_i - \mathbf{x}_i\boldsymbol{\beta}_0|\mathbf{x}_i) = F_y(Q_\tau(y|\mathbf{x}_i)|\mathbf{x}_i) = \tau$.

Teoría asintótica

- La teoría asintótica clásica requiere $E[\nabla_{\beta} \mathbf{s}(\beta_0) | \mathbf{x}]$ para calcular la varianza. Sin embargo $\mathbf{s}(\beta_0)$ no es diferenciable.
- Se puede probar que se puede reemplazar con

$$\nabla_{\beta} E[\mathbf{s}(\beta_0) | \mathbf{x}] = f_u(0 | \mathbf{x}) \mathbf{x}' \mathbf{x}$$

tal que

$$\mathbf{A}_0 = E[f_u(0 | \mathbf{x}) \mathbf{x}' \mathbf{x}],$$

donde $u = y - \mathbf{x}\beta(\tau)$.

- También,

$$\mathbf{B}_0 \equiv E[\mathbf{s}(\beta_0) \mathbf{s}(\beta_0)'] = \tau(1 - \tau) E[\mathbf{x}' \mathbf{x}].$$

- Entonces,

$$\sqrt{N}(\hat{\beta} - \beta_0) \xrightarrow{d} N(\mathbf{0}, \mathbf{A}_0^{-1} \mathbf{B}_0 \mathbf{A}_0^{-1}).$$

- Si asumimos que u es independiente de \mathbf{x} , entonces la varianza asintótica se simplifica a $\frac{\tau(1-\tau)}{(f_u(F_u^{-1}(\tau)))^2} [E(\mathbf{x}' \mathbf{x})]^{-1}$.

Teoría asintótica

Estimación de la varianza

Uno de los temas centrales en QR es la estimación de la varianza. En particular de $\mathbf{A}_0 = E[f_u(0|\mathbf{x})\mathbf{x}'\mathbf{x}]$, donde la complicación es que está la densidad (no observada) de u . Existen tres grandes métodos no-paramétricos para estimarla.

Estimador basado en la sparsity function.

Sea $Q_\tau(Y) = F_Y^{-1}(\tau)$ el cuantil τ de Y , entonces se puede demostrar que

$\frac{\partial Q_\tau(Y)}{\partial \tau} = \frac{1}{f(Q_\tau(Y))}$. Usando este resultado Hendricks, W., Koenker, R. (1992).

Hierarchical spline models for conditional quantiles and the demand for electricity. Journal of the American Statistical Association, 87, 5868, proponen

$$\hat{f}_{u_\tau}(0|\mathbf{x}) = \frac{2h}{\widehat{Q_{\tau+h}(y|\mathbf{x})} - \widehat{Q_{\tau-h}(y|\mathbf{x})}},$$

donde el estimador es consistente si $h \rightarrow 0$ y $Nh \rightarrow \infty$, y $\widehat{Q_\tau(y|\mathbf{x})} = \mathbf{x}\hat{\beta}(\tau)$.

Entonces, se propone

$$\hat{\mathbf{A}}_0 = \frac{1}{N} \sum_{i=1}^N \hat{f}_{u_\tau}(0|\mathbf{x}_i)\mathbf{x}'_i\mathbf{x}_i.$$

Teoría asintótica

Estimación de la varianza

Estimador no-paramétrico usando kernels.

Powell, J. L. (1991). Estimation of monotonic regression models under quantile restrictions. In W. Barnett, J. Powell, G. Tauchen (Eds.), Nonparametric and semiparametric models in econometrics. Cambridge: Cambridge University Press.
 En este caso:

$$\hat{\mathbf{A}}_0 = \frac{1}{Nh} \sum_{i=1}^N K_h(y_i - \mathbf{x}_i \hat{\boldsymbol{\beta}}(\tau)) \mathbf{x}_i' \mathbf{x}_i.$$


donde el estimador es consistente si $h \rightarrow 0$.

Estimador no-paramétrico usando bootstrap.

Ambos estimadores pueden tener diferencias entre sí. Se propone entonces un estimador de bootstrap. Si tenemos $b = 1, 2, \dots, B$ muestras aleatorias de la muestra original $\{y_i, \mathbf{x}_i\}_{i=1}^N$, podemos simular la distribución de $\hat{\boldsymbol{\beta}}(\tau)$ a partir de $\{\hat{\boldsymbol{\beta}}(\tau)^b\}_{b=1}^B$. En particular, podemos calcularle la matriz de varianzas y covarianzas.

Quantile crossing

Otro tema con QR es que los cuantiles estimados no deben cruzarse, es decir $\hat{Q}_{\tau_1}(y|x) \leq \hat{Q}_{\tau_2}(y|x)$ si $\tau_1 < \tau_2$. Esto da lugar a no linealidades en la forma funcional. Existe un método “rearranging” para garantizar que los cuantiles no se crucen. También se puede demostrar que $\hat{Q}_{\tau_1}(y|\bar{x}) \leq \hat{Q}_{\tau_2}(y|\bar{x})$ si $\tau_1 < \tau_2$, en la media de x .



QR como un estimador robusto

- Consideremos el modelo unidimensional con *cdf* F . Consideremos la perturbación en la muestra con probabilidad ϵ en el valor y , y la nueva *cdf*: $F_\epsilon = \epsilon\delta_y + (1 - \epsilon)F$.

- La función de influencia (influence function) para un estadístico $\hat{\beta}(F)$ es

$$IF_{\hat{\beta}}(y, F) = \lim_{\epsilon \rightarrow 0} \frac{\hat{\beta}(F) - \hat{\beta}(F_\epsilon)}{\epsilon}$$

- Para la media,

$$\hat{\mu}(F_\epsilon) = \int y dF_\epsilon = \epsilon y + (1 - \epsilon)\hat{\mu}(F)$$

$$IF_{\hat{\mu}}(y, F) = y - \hat{\mu}(F)$$

QR como un estimador robusto

- Para la estimación de un cuantil,

$$\hat{\eta}_\tau(F_\epsilon) = F_\epsilon^{-1}(\tau)$$

$$IF_{\hat{\eta}_\tau}(y, F) = \frac{\text{sgn}(y - F^{-1}(\tau))}{f(F^{-1}(\tau))}$$

- Hay una diferencia importante entre las dos funciones de influencia. Para la media una observación extraña (outlier) altera a estimación mucho, mientras que para el cuantil la influencia es $1/f(F^{-1}(\tau))$ que se llama la *sparsity* a un cuantil particular.
- Por ejemplo, consideremos las dos muestras $\{0, 1, 2\}$ y $\{0, 1, 100000000\}$.

QR como un estimador robusto

- Para MCO,

$$IF_{\hat{\beta}}((y, \mathbf{x}), F) = (\mathbf{x}'\mathbf{x})^{-1}\mathbf{x}(y - \mathbf{x}\hat{\beta}_F)$$

- Para QR,

$$IF_{\hat{\beta}(\tau)}((y, \mathbf{x}), F) = Q^{-1} \mathbf{x} \operatorname{sgn}(y - \mathbf{x}\hat{\beta}(\tau))$$

donde $Q = \int \mathbf{x}'\mathbf{x}f(\mathbf{x}\hat{\beta}_F)dG(x)$ y $G(\cdot)$ es la *cdf* de \mathbf{x} .


Efecto de la capacitación sobre los salarios

- Consideremos el estudio que se plantea en el trabajo práctico, el efecto de la capacitación sobre los salarios

$$y = d\alpha + \mathbf{x}\beta + u$$

- y : wages
- d : training treatment indicator (dummy variable: 1 if received training)
- \mathbf{x} : other covariates (age, education, marital status, race, etc.)
- u : unobservables (ability, predisposition to work)
- Evaluar este programa corresponde a ver si $\alpha > 0$.
- Sin embargo, puede haber gran heterogeneidad en los efectos de la capacitación en la población.
- En particular, nos interesa comparar el average treatment effect (ATE) con quantile treatment effects (QTE).

QR vs. MCO



QR en STATA

- MCO: `reg y x1 x2`
- Regresión en la mediana: `qreg y x1 x2, q(.5)`
- QR, $\tau = .1$: `qreg y x1 x2, q(.1)`
- QR, $\tau = .9$: `qreg y x1 x2, q(.9)`
- Si queremos hacer un gráfico del proceso de cuantiles $(\tau, \beta(\tau))$, $\tau \in (0, 1)$, consideremos el siguiente ejemplo:

```
gen beta1s=.
gen beta1ols=.
reg y x1 x2
replace beta1ols=_b[x1]
gen tau=.
forvalues tau = 1(1)99 {
  qreg y x1 x2, q('tau')
  replace beta1s=_b[x1] in 'tau'
  replace tau='tau' in 'tau'
}
line beta1s beta1ols tau
```

- Ver el comando `grqreg`.

QR en STATA

- Uno de los problemas con QR es que requiere la estimación de la función de densidad.
- Ver la descripción en <https://www.stata.com/manuals13/rqreg.pdf>
- Métodos de bootstrap: `bsqreg` y `x1 x2`
- QR para varios cuantiles simultáneos: `sqreg` y `x1 x2, q(10 25 50 75 90)`
- QR para estimadores inter-cuantiles: `iqreg` y `x1 x2, q(10 90)`

Referencias

Estas notas están basadas en

- *Capítulo 12 de Wooldridge.*
- *Frölich, M., and B. Melly. 2010. Estimation of quantile treatment effects with Stata. Stata Journal 10: 423-457.*
- *Koenker, R. (2005), Quantile Regression. Cambridge: Cambridge University Press.*
- *Koenker, R. and Hallock, K. (2001) "Quantile regression," Journal of Economic Perspectives 15(4), 143–156.*