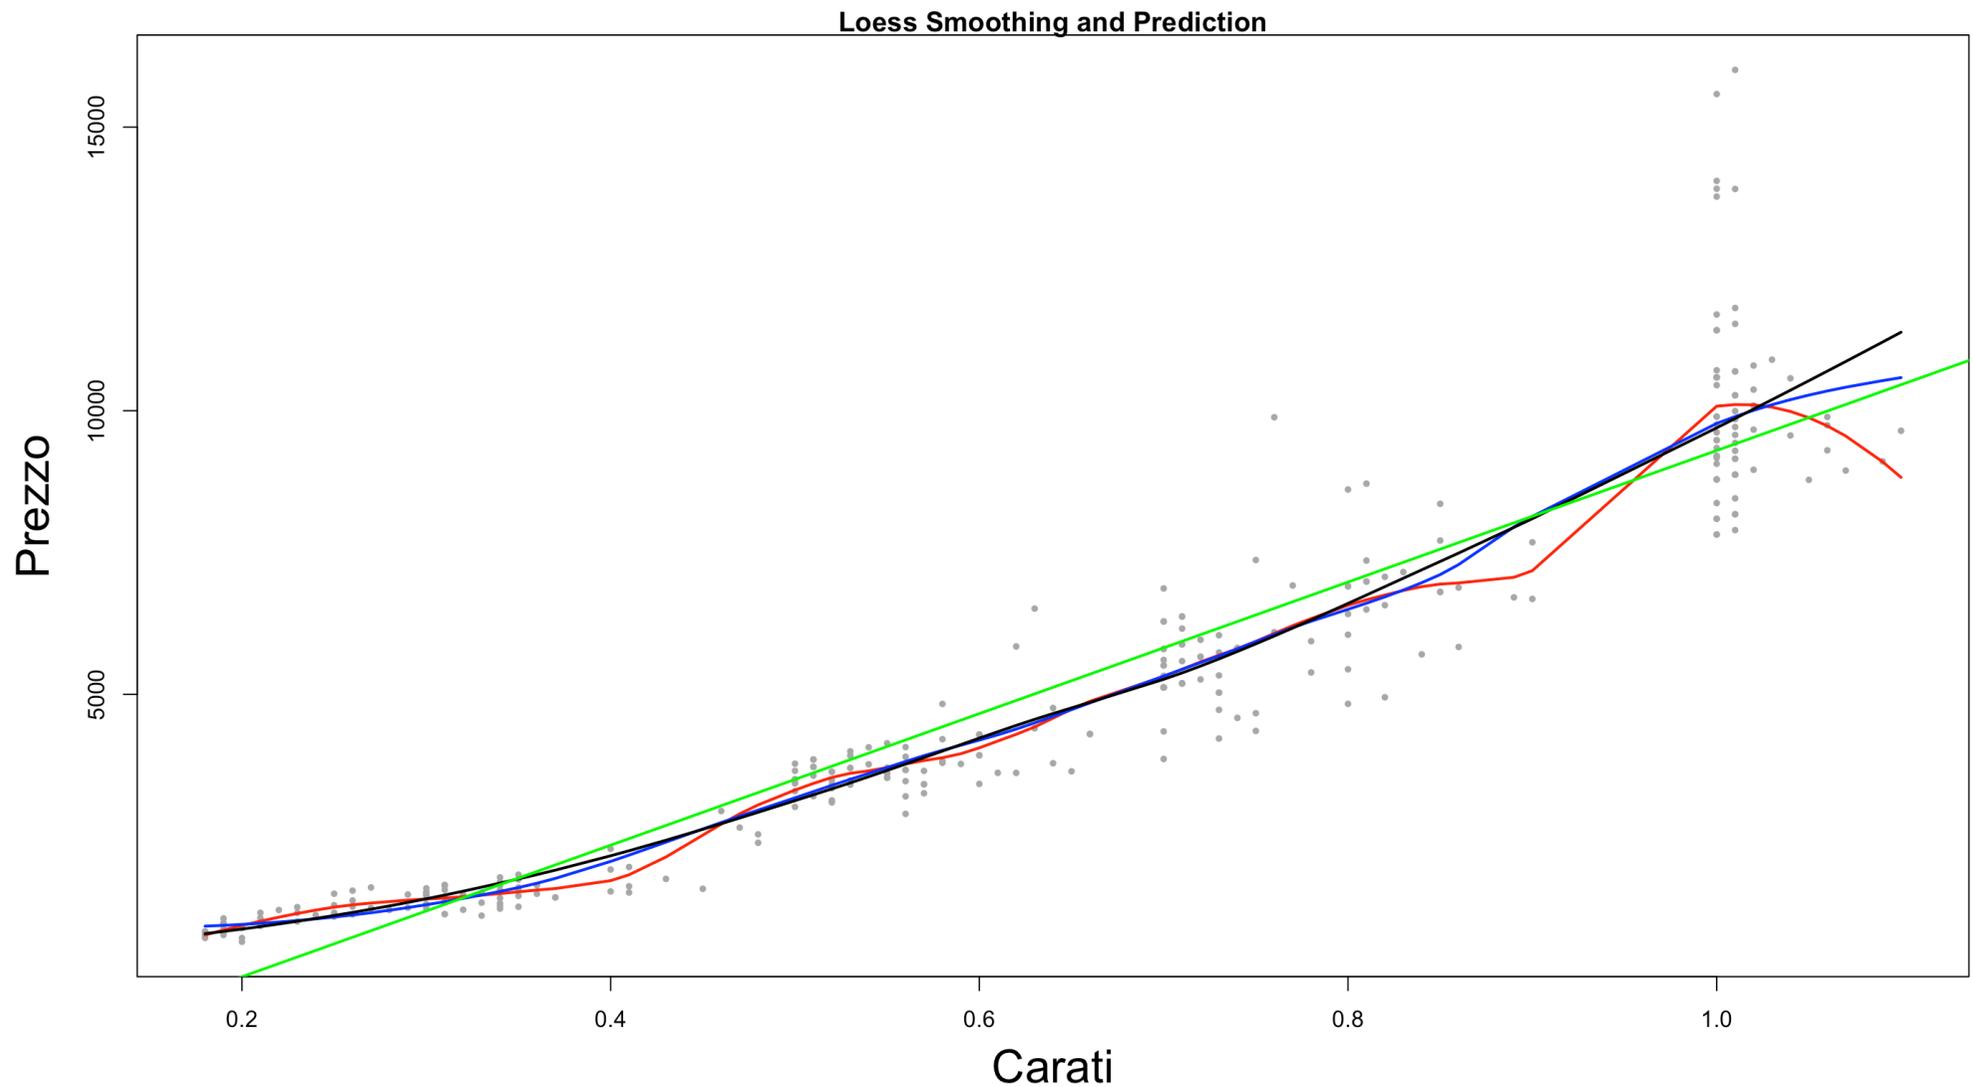


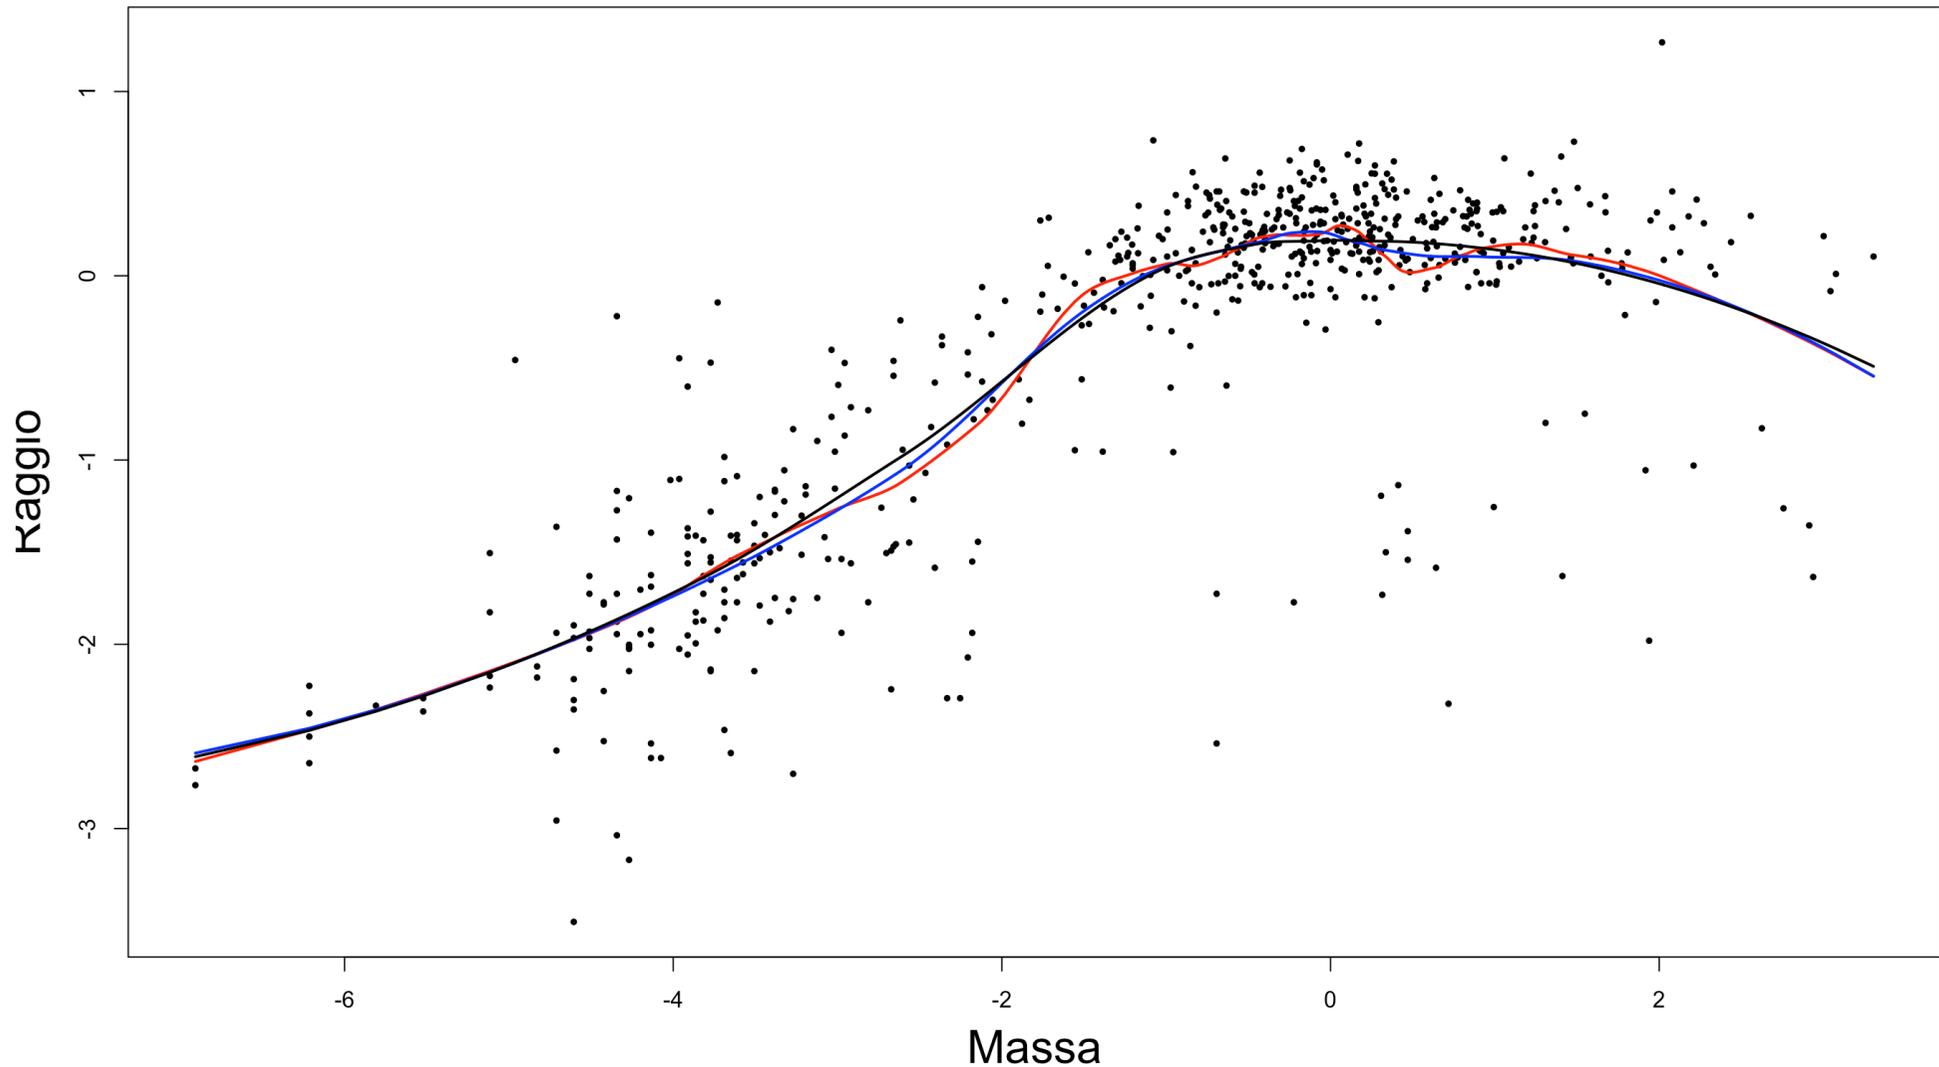
# Esempio: prezzo dei diamanti



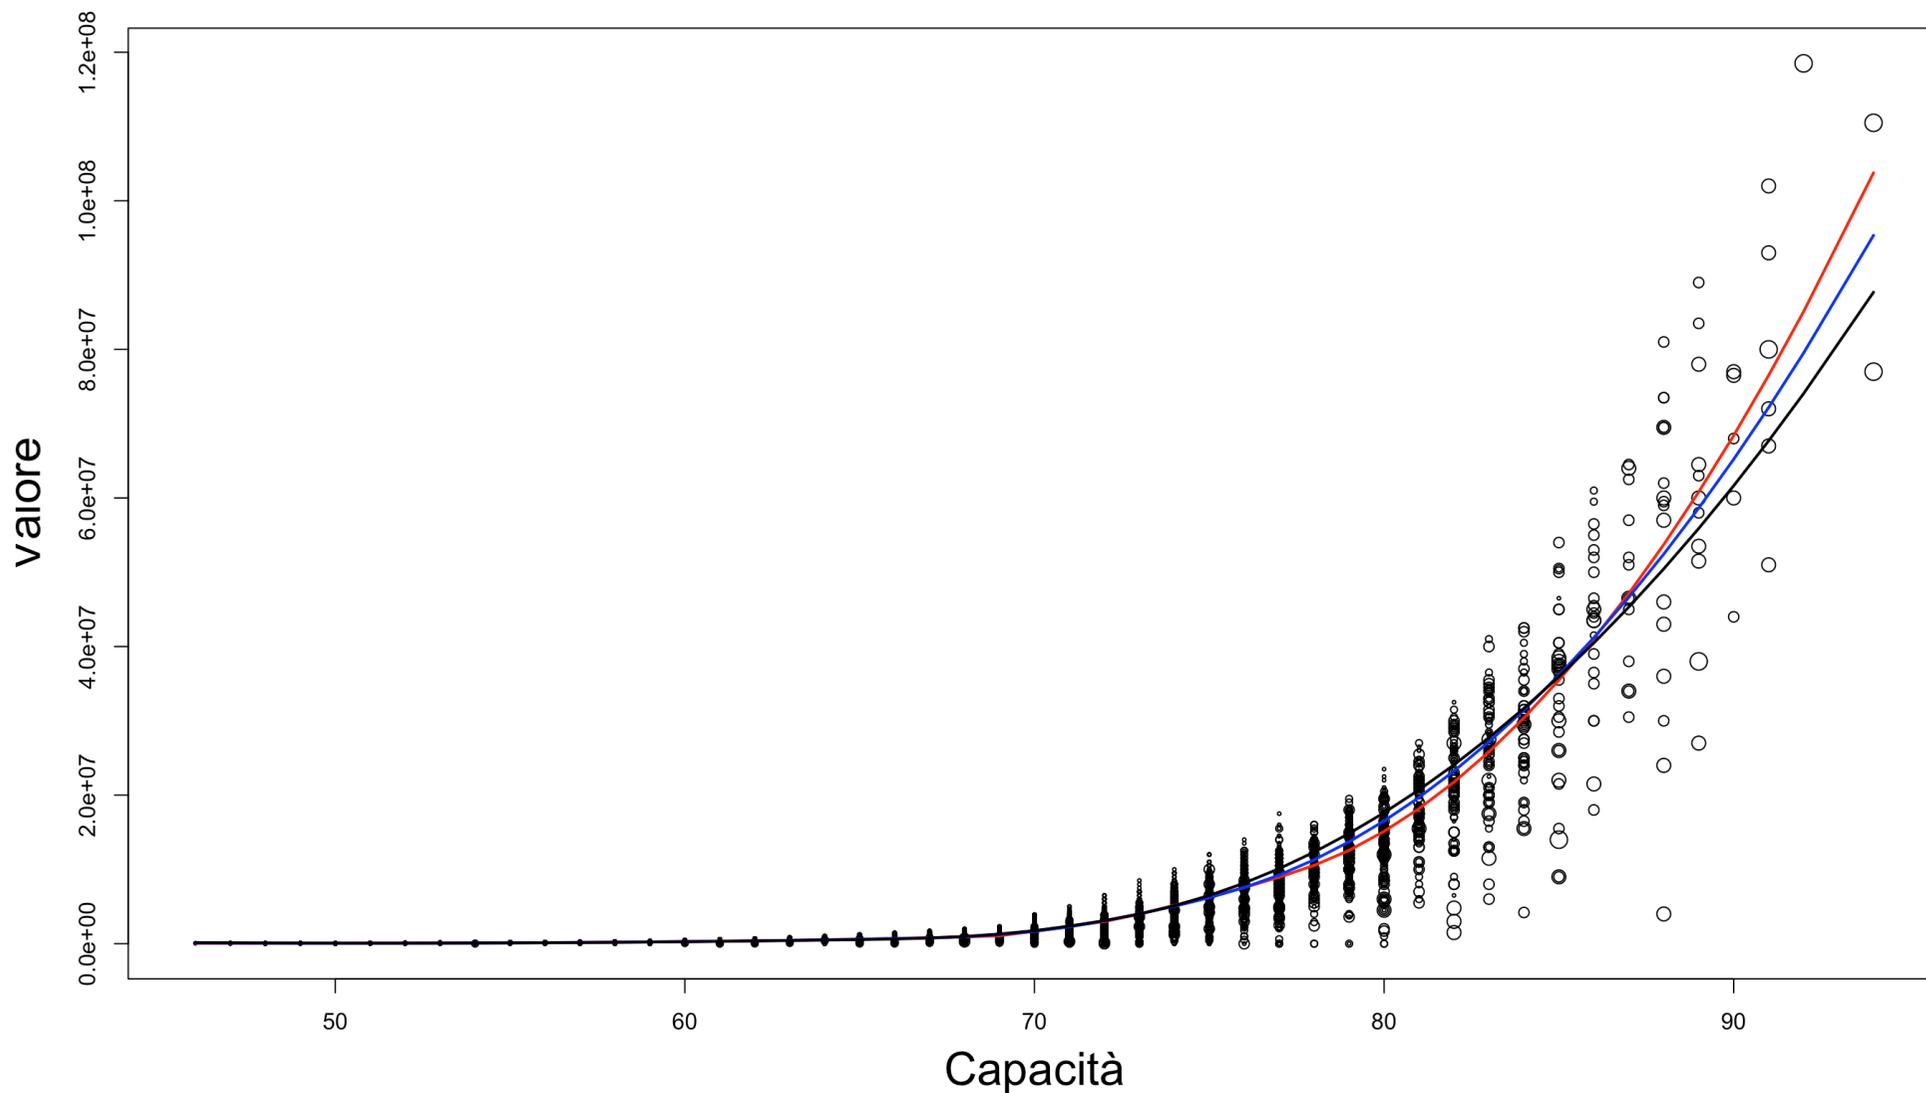
# Esempio: prezzo dei diamanti

```
Diamond <- Diamond[order(Diamond$carat),]
loess25 <- loess(price ~ carat, data=Diamond, span=0.25)
loess50 <- loess(price ~ carat, data=Diamond, span=0.50)
loess75 <- loess(price ~ carat, data=Diamond, span=0.75)
smoothed25 <- predict(loess25)
smoothed50 <- predict(loess50)
smoothed75 <- predict(loess75)
plot(Diamond$carat, Diamond$price, main="Loess Smoothing and Prediction",
     xlab="Carati",
     ylab="Prezzo",xlim=caratlims,cex=.5,pch=19,col="darkgrey",cex.lab=2)
lines(smoothed25, x=Diamond$carat, col="red",lwd=2)
lines(smoothed50, x=Diamond$carat, col="blue",lwd=2)
lines(smoothed75, x=Diamond$carat, col="black",lwd=2)
abline(lreg,lwd=2,col="green")
```

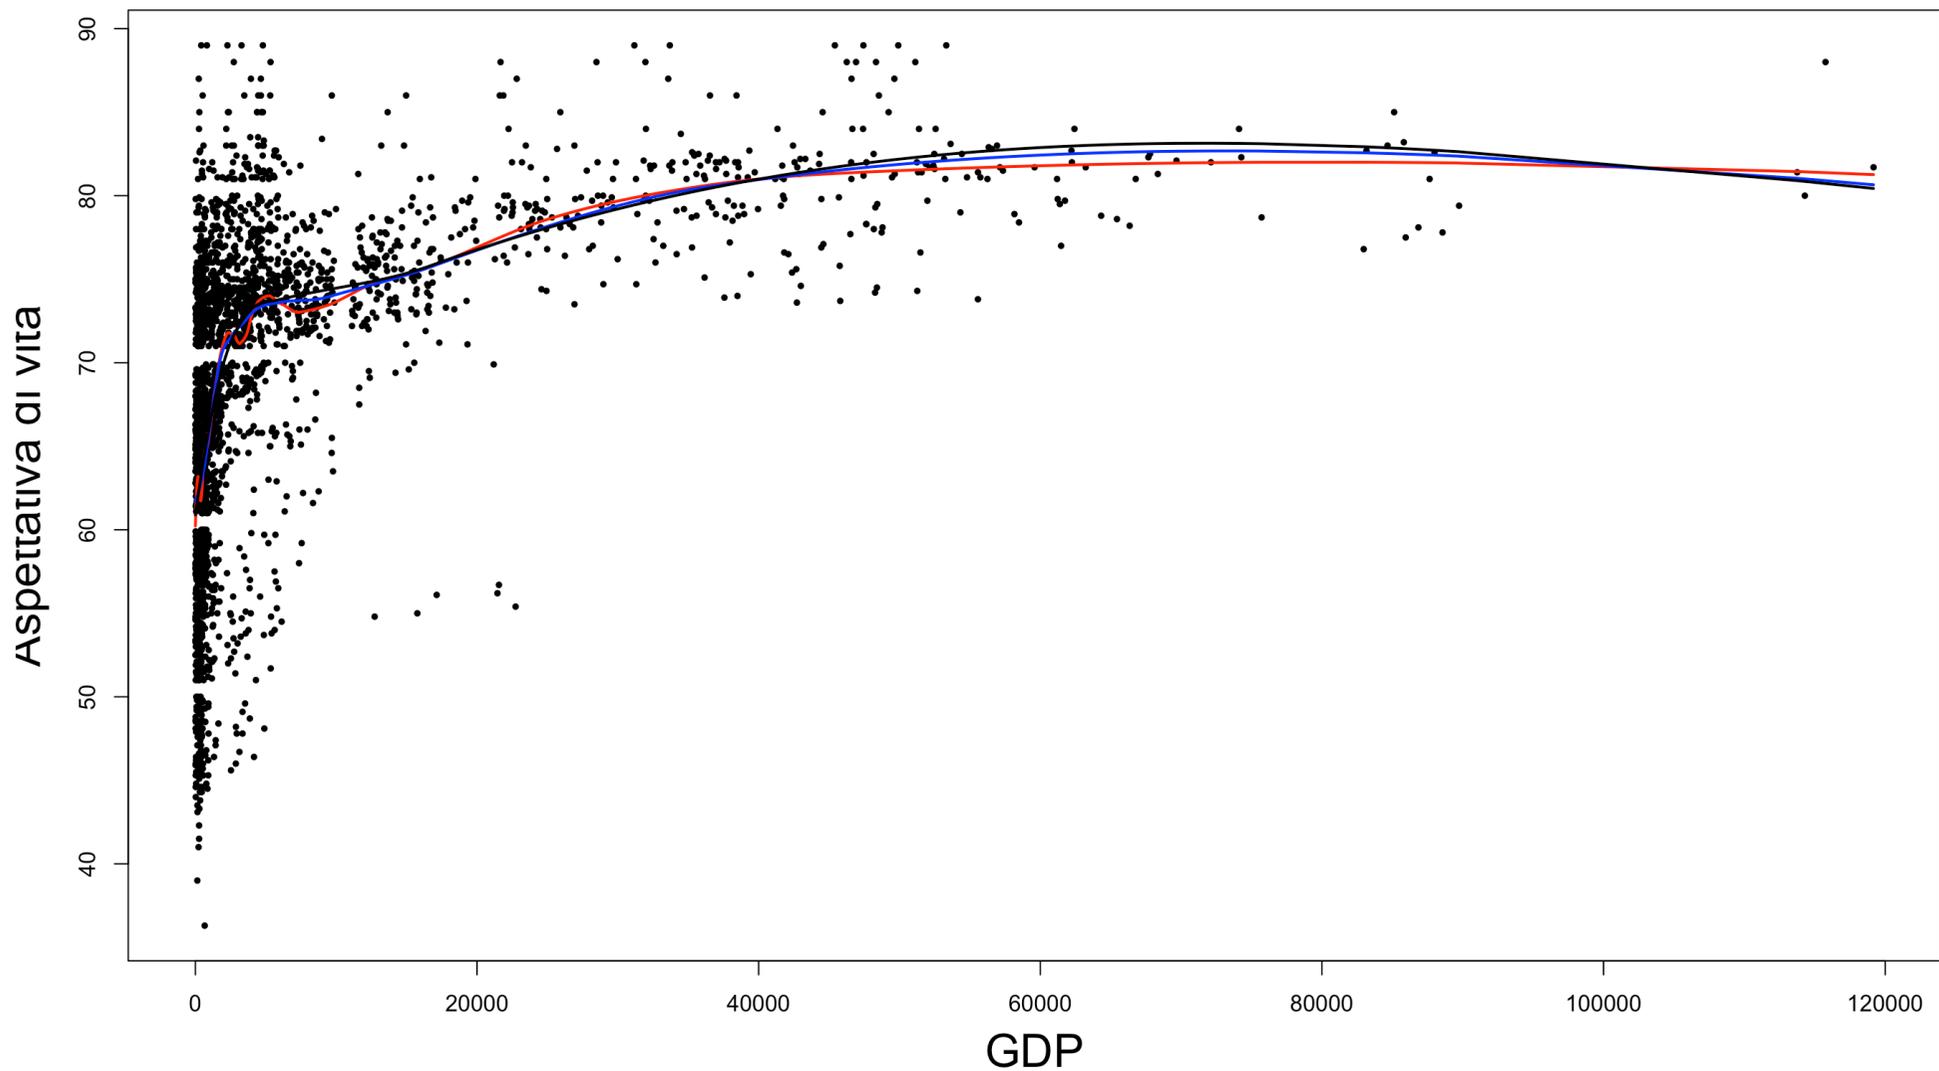
# Esempio: Massa e Raggio degli esopianeti



# Esempio: valore dei calciatori



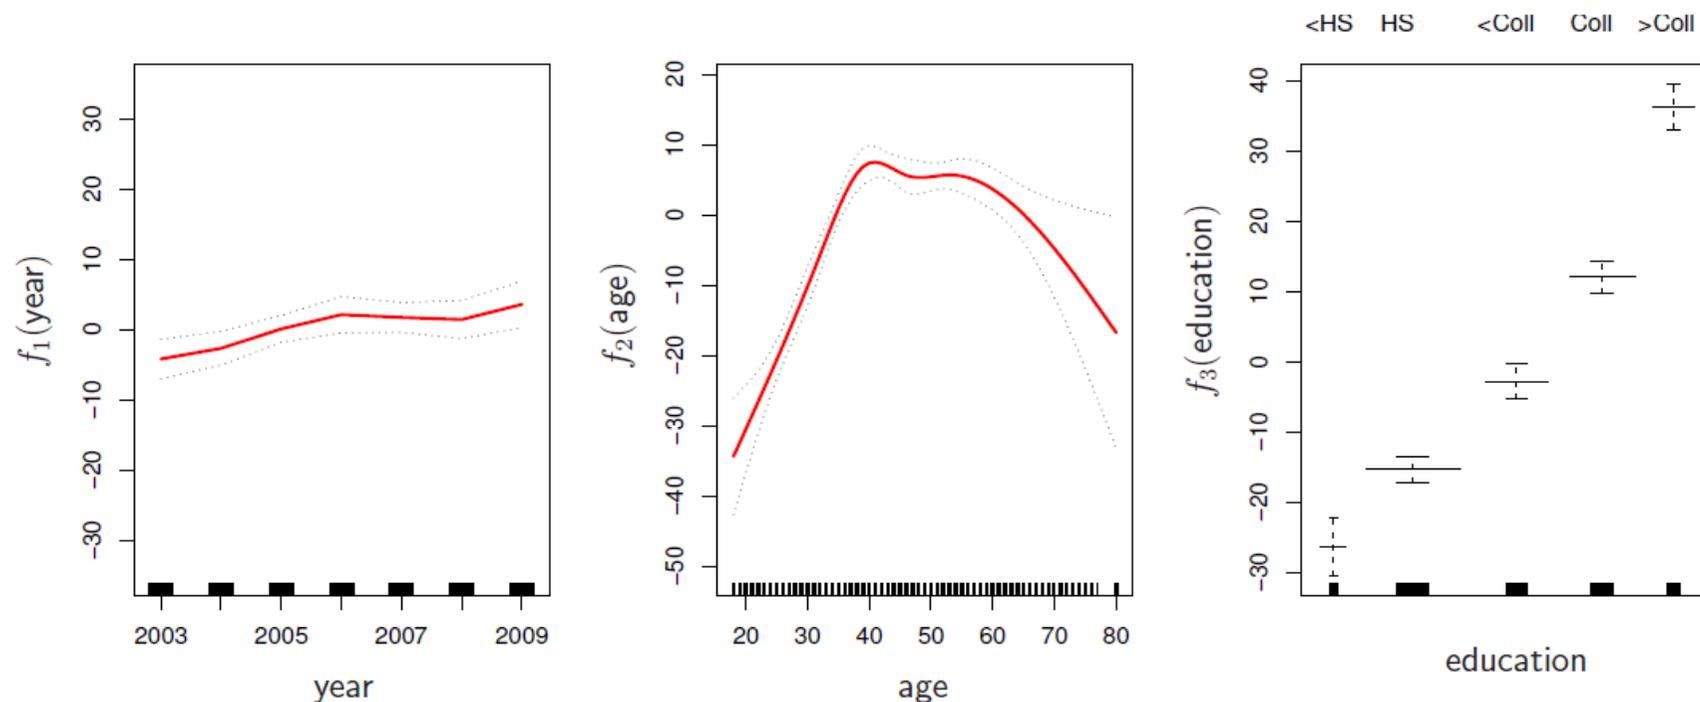
# Esempio: curva di Preston



# Modelli additivi generalizzati (GAM)

Questo tipo di modelli permette di gestire la non linearità nelle variabili, ma conserva la struttura additiva dei modelli lineari. Infatti, la forma funzionale del modello sarà:

$$y_i = \beta_0 + f_1(x_{i1}) + f_2(x_{i2}) + \dots + f_p(x_{ip}) + \epsilon_i$$



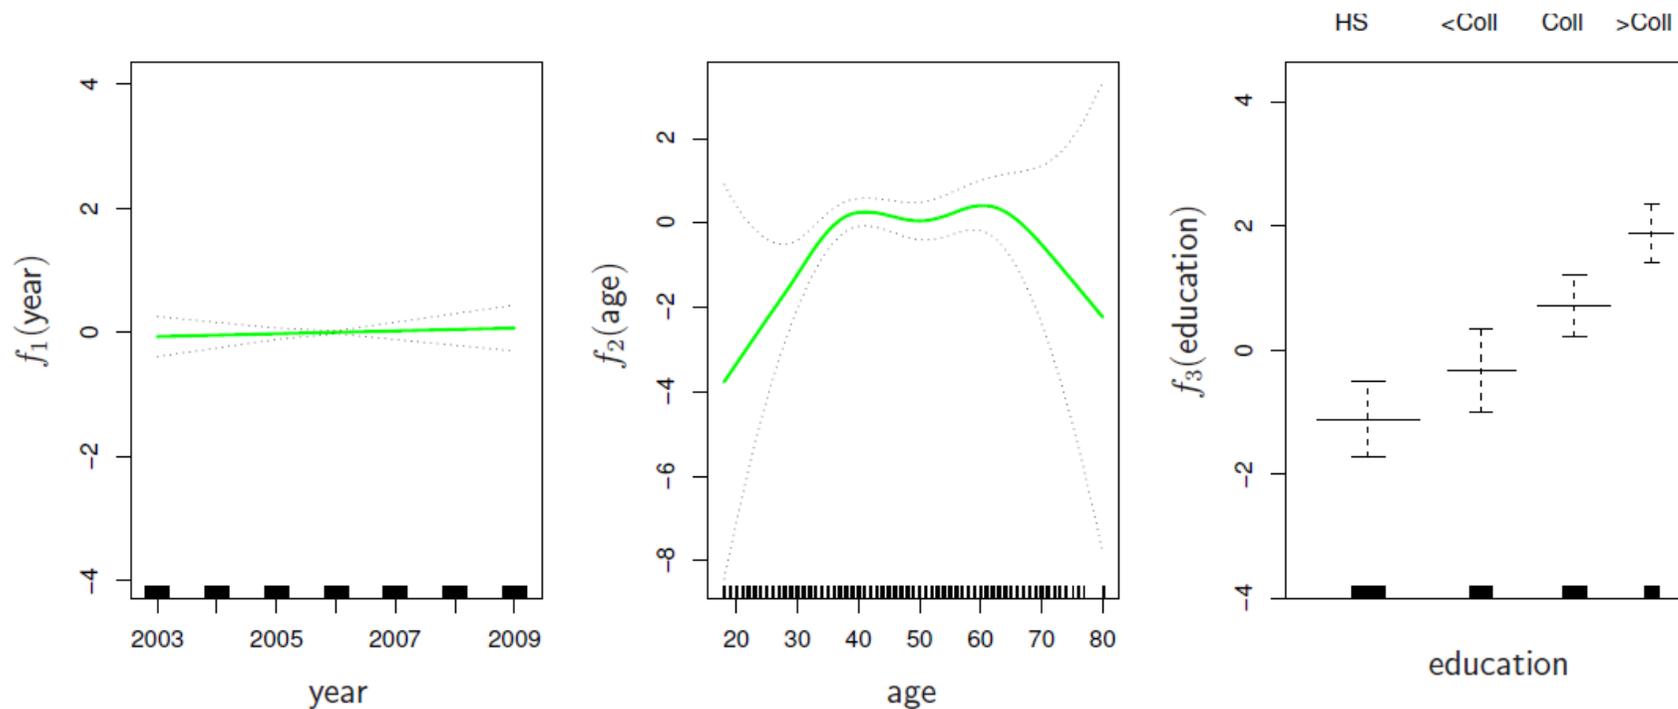
# Caratteristiche del GAM

- Dove ogni termine del modello è una funzione della variabile predittiva di riferimento;
- Si possono utilizzare, per questo tipo di modello anche gli splines:
  - `lm(wage~ns(year,df = 5) + ns(age,df = 5) + education);`
- Ciò che più interessa sono le forme funzionali, e non i coefficienti. Il plot precedente è stato creato con la funzione `plot.gam`;
- Dal grafico si nota che è possibile utilizzare sia termini lineari, che termini non lineari. Per comparare i modelli si utilizza la funzione `anova()`;
- È possibile utilizzare anche «smoothing splines» oppure regressioni locali:
  - `gam(wage~s(year,df = 5) + lo(age,span = .5) + education)`
- I GAMs hanno forma additiva, sebbene interazioni di piccolo ordine possono essere inclusi in maniera naturale, utilizzando forme del tipo:
  - `ns(age,df = 5): ns(year, df = 5).`

# GAMs per classificazione

$$\log\left(\frac{\rho(x)}{1-\rho(x)}\right) = \beta_0 + f_1(X_1) + f_2(X_2) + \dots + f_p(X_p)$$

`gam(I(wage > 250) ~ year + s(age, df = 5) + education, family = binomial)`



# Esempio: consumo di gelati

```
gamlm <- lm(cons~ns(income,3)+ns(price,3)+ns(temp,3),data=Icecream)
library(gam)
gamice <- gam(cons~ns(income,3)+ns(price,3)+ns(temp,3),data=Icecream)
par(mfrow=c(1,3))
plot(gamice, se=TRUE,col="blue")
summary(gamice)
```

Null Deviance: 0.1255 on 29 degrees of freedom

Residual Deviance: 0.0247 on 20 degrees of freedom

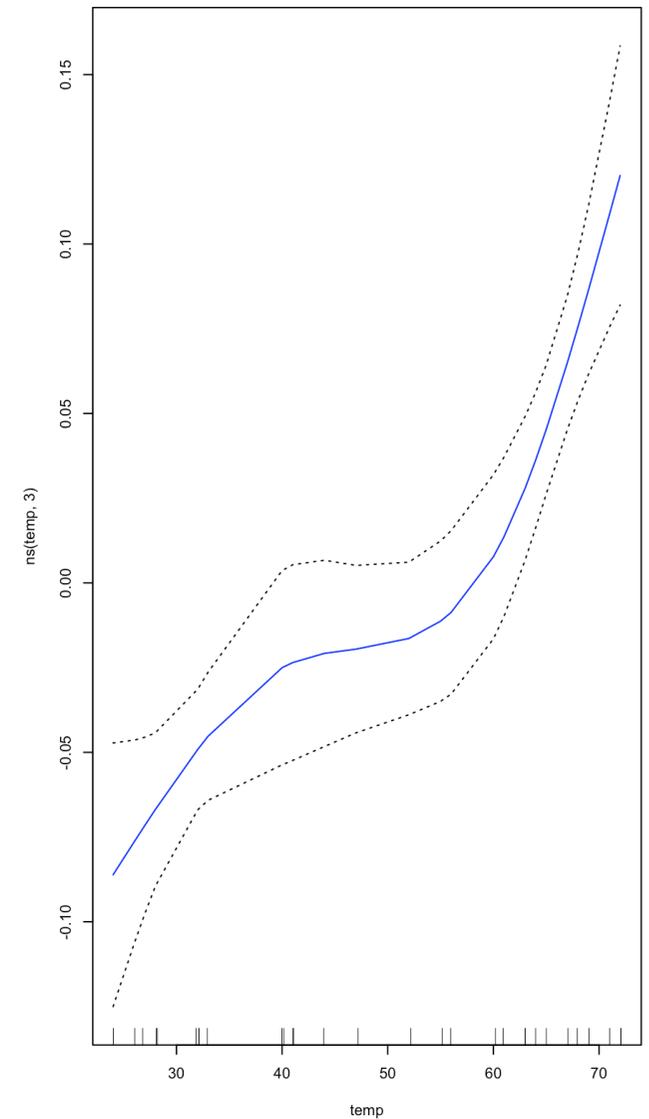
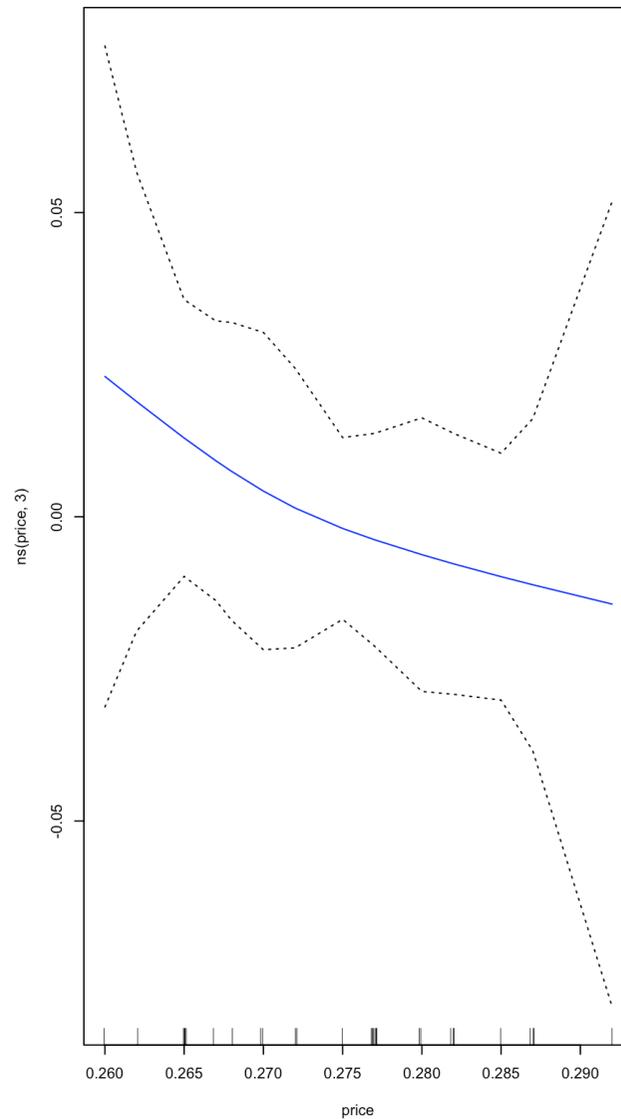
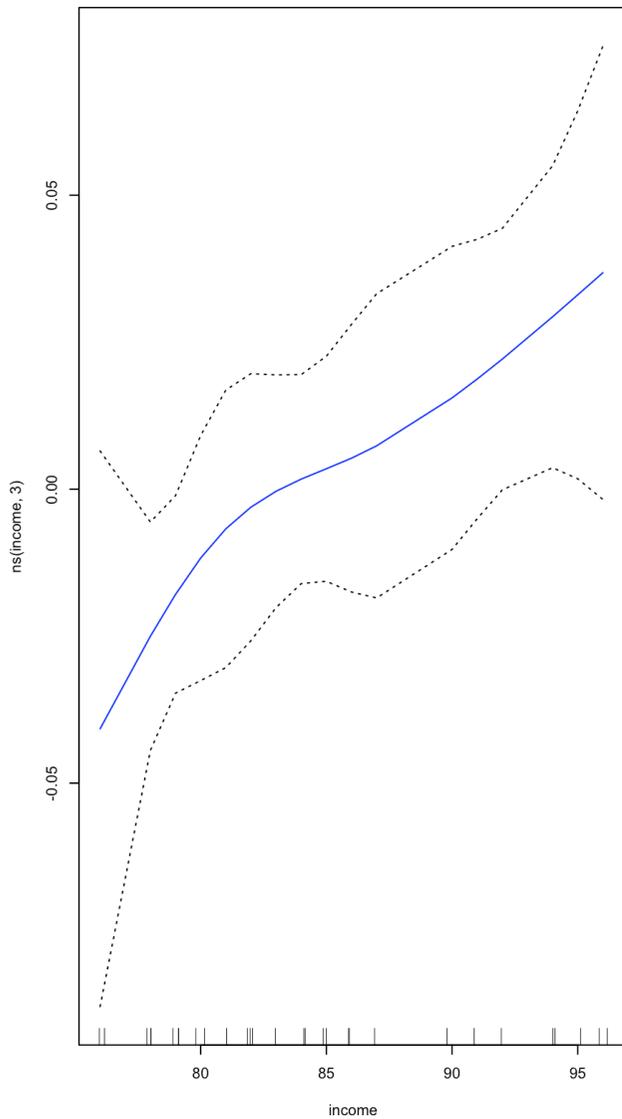
AIC: -105.9169

Number of Local Scoring Iterations: 2

Anova for Parametric Effects

	Df	Sum Sq	Mean Sq	F value	Pr(>F)	
ns(income, 3)	3	0.000396	0.0001319	0.1067	0.955170	
ns(price, 3)	3	0.022089	0.0073631	5.9598	0.004489	**
ns(temp, 3)	3	0.078329	0.0261098	21.1336	2.058e-06	***
Residuals	20	0.024709	0.0012355			

# Esempio: consumo di gelati



# Esempio: valore dei calciatori

```
gamlm <- lm(Valore~ns(Overall,3)+ns(Age,3)+ns(Clausola,3)+International.Reputation,data=fifa)
gamfifa <- gam(Valore~ns(Overall,3)+ns(Age,3)+ns(Clausola,3)+International.Reputation,data=fifa)
par(mfrow=c(1,4))
plot(gamfifa, se=TRUE,col="blue")
summary(gamfifa)
```

	Estimate	Std. Error	t value	Pr(> t )	
(Intercept)	-338063	37924	-8.914	< 2e-16	***
ns(Overall, 3)1	659227	68652	9.602	< 2e-16	***
ns(Overall, 3)2	6527416	176866	36.906	< 2e-16	***
ns(Overall, 3)3	9934548	201578	49.284	< 2e-16	***
ns(Age, 3)1	95676	29236	3.273	0.00107	**
ns(Age, 3)2	-871467	87457	-9.965	< 2e-16	***
ns(Age, 3)3	-1766183	88233	-20.017	< 2e-16	***
ns(Clausola, 3)1	30488539	177926	171.355	< 2e-16	***
ns(Clausola, 3)2	69520402	182492	380.950	< 2e-16	***
ns(Clausola, 3)3	108274117	228714	473.404	< 2e-16	***
International.Reputation	98329	16991	5.787	7.29e-09	***

Multiple R-squared: 0.9911, Adjusted R-squared: 0.9911

Null Deviance: 5.446193e+17 on 16642 degrees of freedom

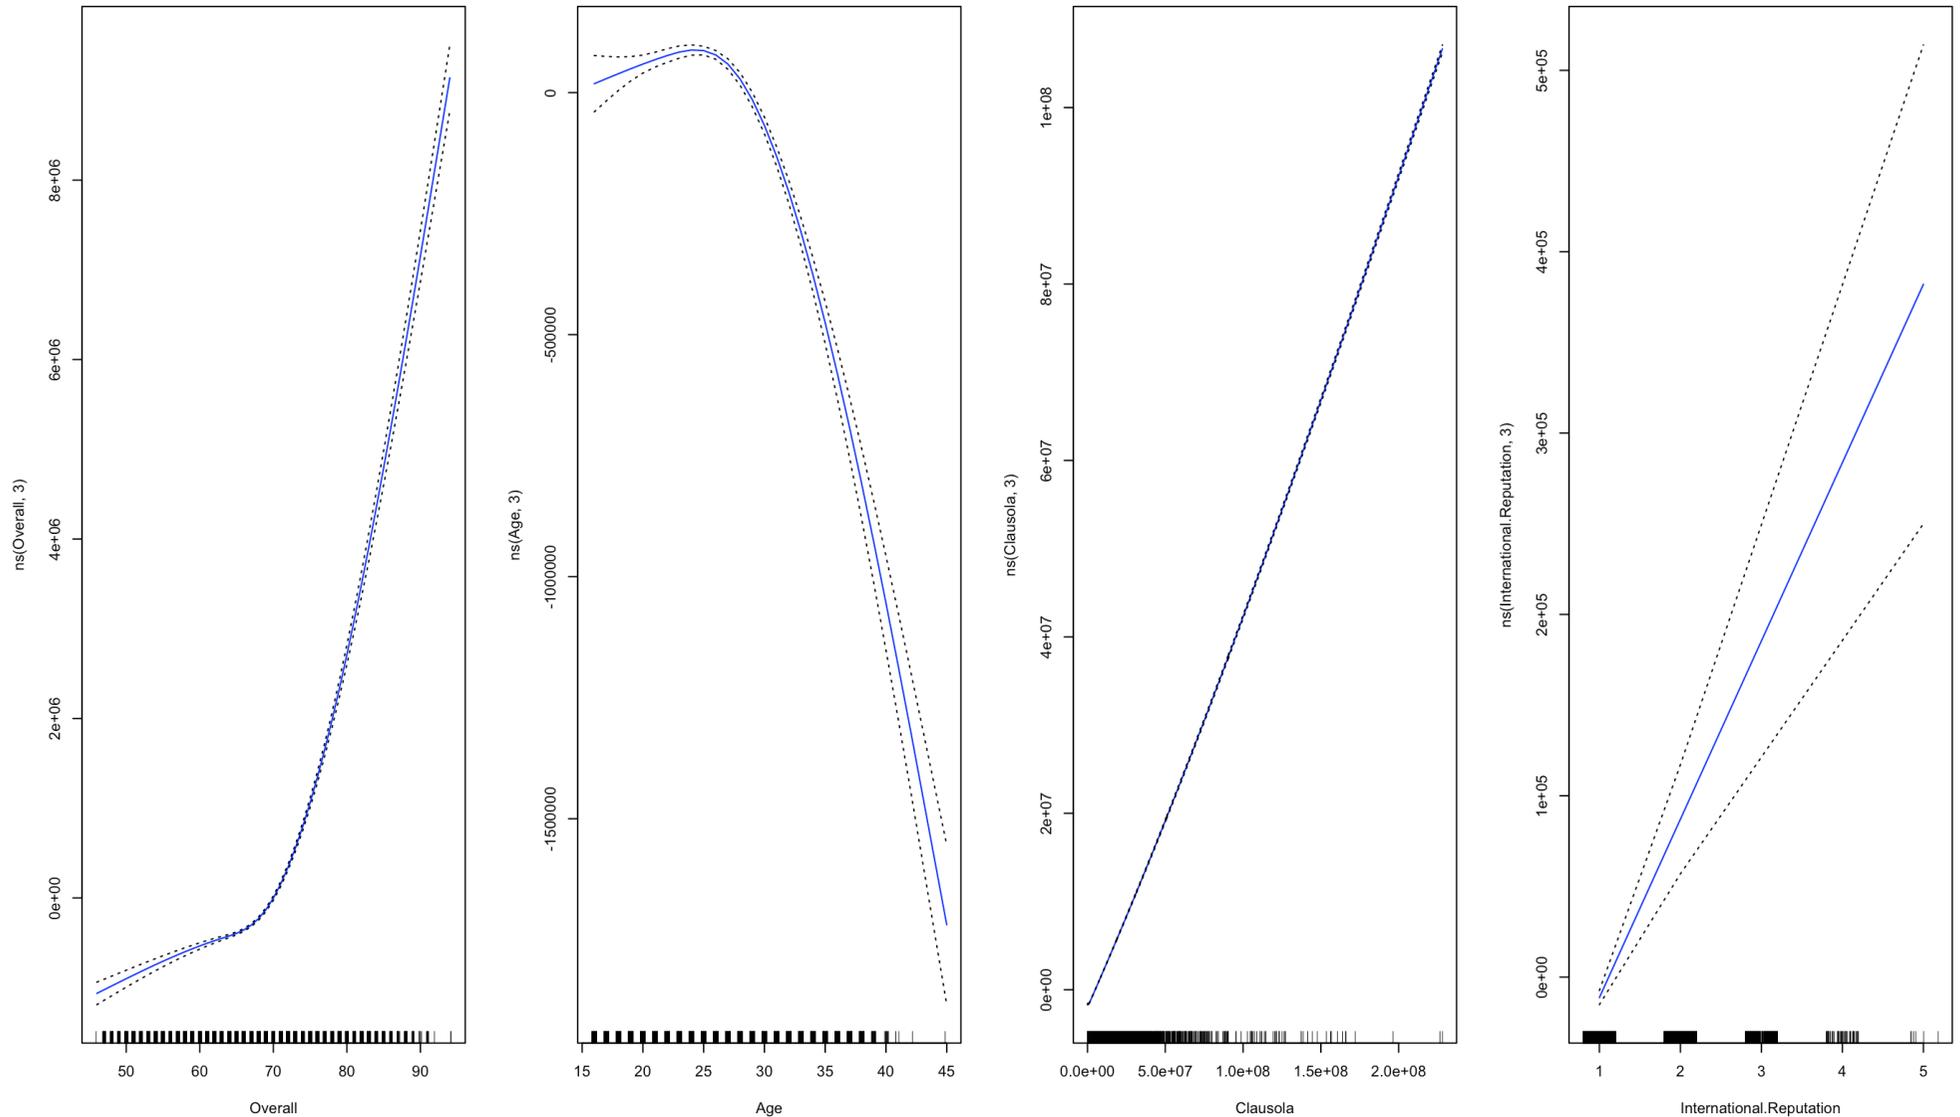
Residual Deviance: 4.842421e+15 on 16632 degrees of freedom

AIC: 486570.8 - 1564 observations deleted due to missingness

Number of Local Scoring Iterations: 2

Anova for Param. Effects	Df	Sum Sq	Mean Sq	F value	Pr(>F)	
ns(Overall, 3)	3	4.6323e+17	1.5441e+17	530342.957	< 2.2e-16	***
ns(Age, 3)	3	7.4879e+15	2.4960e+15	8572.718	< 2.2e-16	***
ns(Clausola, 3)	3	6.9050e+16	2.3017e+16	79053.946	< 2.2e-16	***
International.Reputation	1	9.7509e+12	9.7509e+12	33.491	7.289e-09	***
Residuals	16632	4.8424e+15	2.9115e+11			

# Esempio: valore dei calciatori



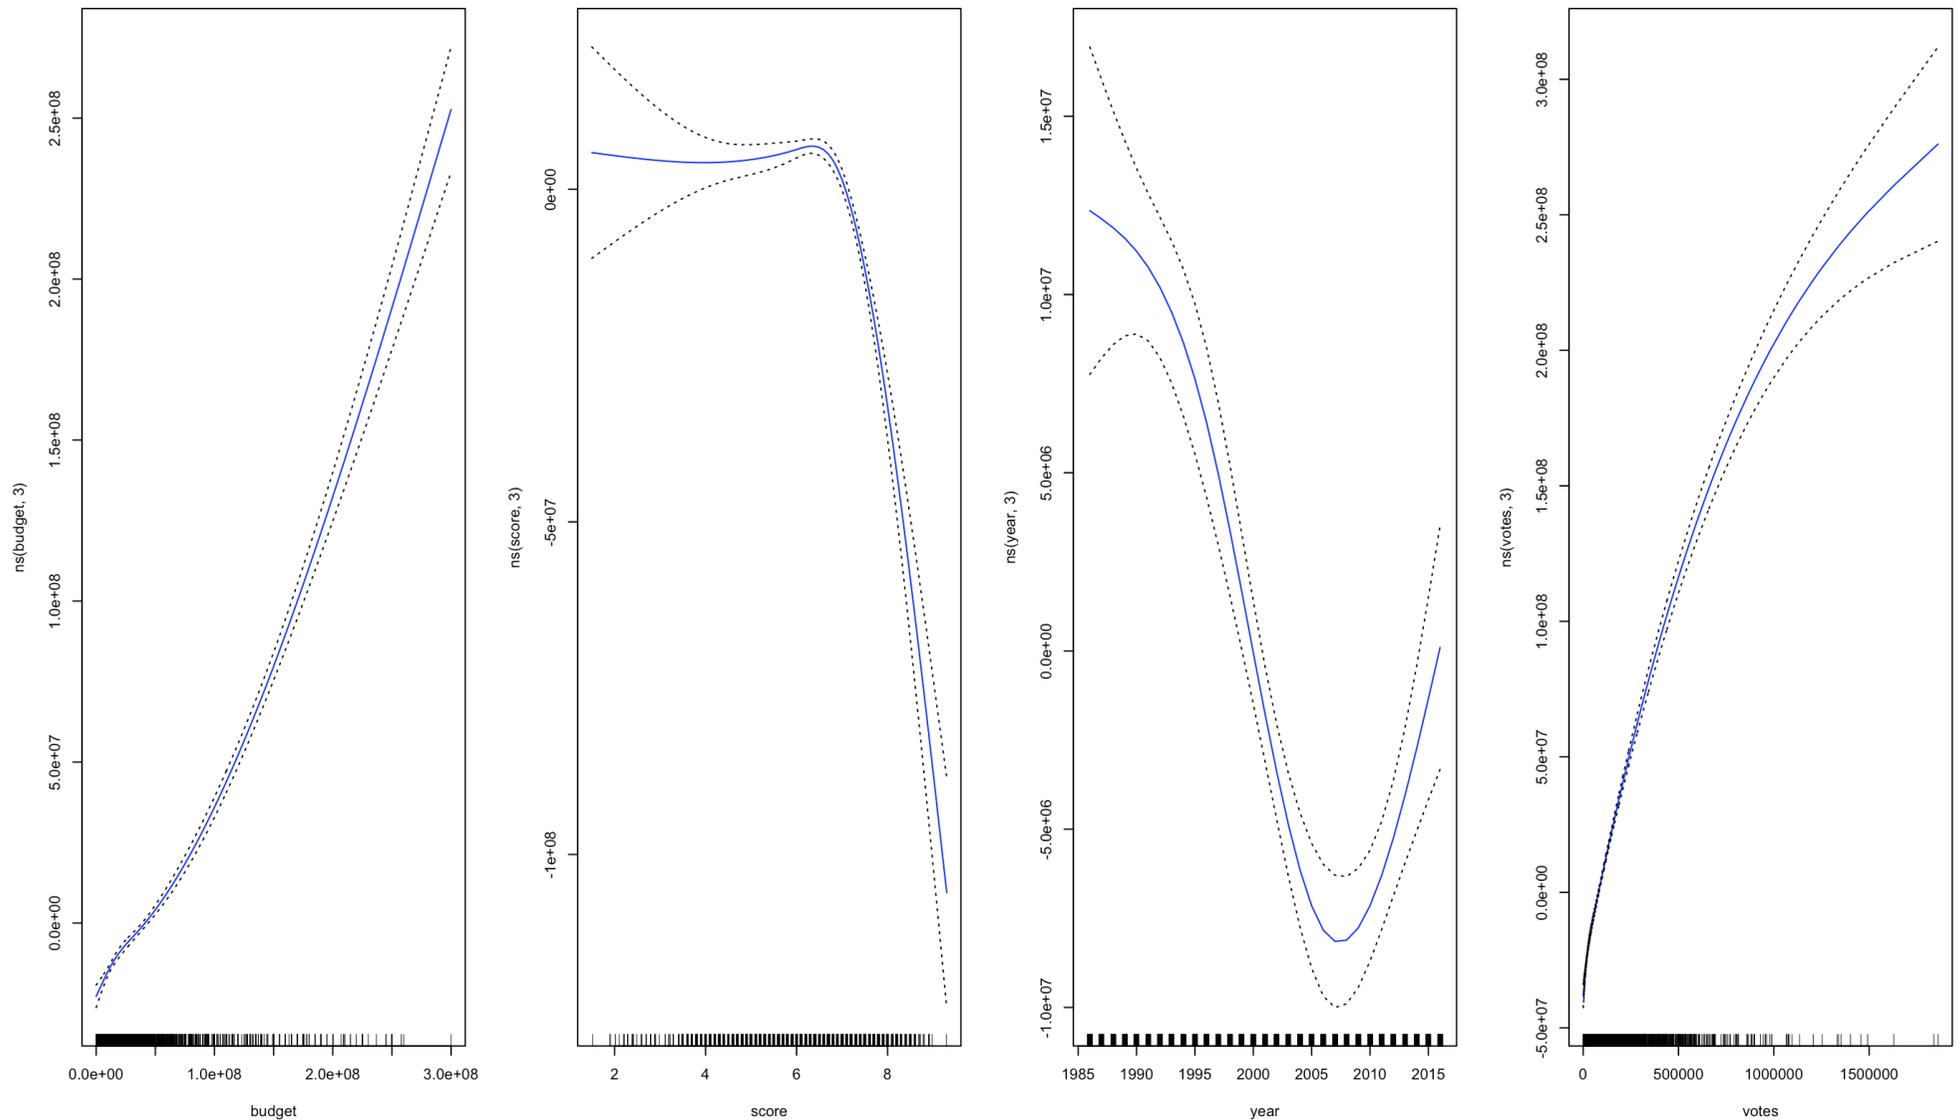
# Esempio: incassi al box-office dei film

```
setwd("~/Documents/prova r pkg/lucidi del corso/movies")
revfilm <- read.csv("movies.csv")
revfilm$budget[revfilm$budget == 0] <- NA
regfilm <- lm(gross ~ ns(budget,3) + ns(score,3) + ns(year,3) + ns(votes,3),data=revfilm)
library(gam)
gamfifa <- gam(gross ~ ns(budget,3) + ns(score,3) + ns(year,3) + ns(votes,3),data=revfilm)
par(mfrow=c(1,4))
plot(gamfifa, se=TRUE,col="blue")
summary(gamfifa)
```

	Estimate	Std. Error	t value	Pr(> t )	AIC: 175504.8					
(Intercept)	-16184841	10614303	-1.525	0.127374	2182 observations deleted due to missingness					
ns(budget, 5)1	11230904	2922775	3.843	0.000123	***Number of Local Scoring Iterations: 2					
ns(budget, 5)2	19233241	3379281	5.692	1.34e-08	***Anova for Parametric Effects					
ns(budget, 5)3	54903118	5510808	9.963	< 2e-16	***	Df	Sum Sq	Mean Sq	F value	Pr(>F)
ns(budget, 5)4	173321272	7772042	22.301	< 2e-16	***ns(budget, 3)	3	9.5392e+18	3.1797e+18	2005.830	< 2.2e-16 ***
ns(budget, 5)5	269418666	11031485	24.423	< 2e-16	***ns(score, 3)	3	9.3944e+17	3.1315e+17	197.538	< 2.2e-16 ***
ns(score, 5)1	14321855	9079660	1.577	0.114782	ns(year, 3)	3	3.0499e+16	1.0166e+16	6.413	0.0002484 ***
ns(score, 5)2	2955757	10052106	0.294	0.768738	ns(votes, 3)	3	2.5380e+18	8.4600e+17	533.669	< 2.2e-16 ***
ns(score, 5)3	22205538	6420680	3.458	0.000548	***Residuals	4625	7.3318e+18	1.5853e+15		
ns(score, 5)4	-85299874	22168973	-3.848	0.000121	***					
ns(score, 5)5	-210184554	15607370	-13.467	< 2e-16	***					
ns(year, 5)1	-16111672	3548985	-4.540	5.77e-06	***					
ns(year, 5)2	-7248466	4280047	-1.694	0.090419	.					
ns(year, 5)3	-34660289	3293845	-10.523	< 2e-16	***					
ns(year, 5)4	-10507927	7003874	-1.500	0.133605						
ns(year, 5)5	-7595549	2690119	-2.823	0.004771	**					
ns(votes, 5)1	24254552	3923245	6.182	6.86e-10	***					
ns(votes, 5)2	34521291	4349362	7.937	2.58e-15	***					
ns(votes, 5)3	239802807	7673023	31.253	< 2e-16	***					
ns(votes, 5)4	346987922	13980108	24.820	< 2e-16	***					
ns(votes, 5)5	410386151	21843117	18.788	< 2e-16	***					

Multiple R-squared: 0.6482, Adjusted R-squared: 0.6467

# Esempio: incassi al box-office dei film



# Introduzione alla robustezza

La statistica parametrica, sia essa frequentista o bayesiana, ha come obiettivo primario quello di trovare procedure che, sotto un dato modello stocastico, siano ottime secondo qualche criterio. Tuttavia nulla viene detto sul comportamento di queste ultime, quando il modello ipotizzato è solo approssimativamente valido. L'obiettivo della statistica robusta è quello di predisporre strumenti per valutare la bontà delle procedure statistiche in intorni di modelli stocastici, e quindi di trovare procedure che mantengano buone proprietà anche quando il modello ipotizzato è solo un'approssimazione del "vero" modello. Vista in quest'ottica la statistica robusta può essere definita come la statistica dei modelli parametrici approssimati.

# Introduzione alla robustezza

La necessità di una statistica robusta è brillantemente mostrata da Tukey nel suo studio sulla distribuzione normale contaminata. Confrontando, infatti, stimatori di posizione e di scala applicati a campioni provenienti da una popolazione normale  $N(0,1)$  e dalle popolazioni contaminate

- $(1 - \eta)N(0, 1) + \eta N(0, 9)$  Modello simmetrico (1)
- $(1 - \eta)N(0, 1) + \eta N(2, 9)$  Modello asimmetrico (2)

con  $\eta \in (0, 1)$ , si giunge ai sorprendenti risultati. Se per la stima della media di una normale l'utilizzo della mediana campionaria in luogo della media campionaria porta ad una perdita d'efficienza del 36% è sufficiente il 10% di contaminazione nel modello (1) ed il 6% nel modello (2) per rendere le due stime ugualmente efficienti.

# Introduzione alla robustezza

$\eta$	0.0000	0.0018	0.0282	0.1006
Var(media)	1.0000	1.0140	1.2252	1.8047
Var(media)	1.5708	1.5745	1.6315	<i>1.8047</i>
C.V.(deviazione standard)	0.7071	0.7627	1.1725	1.3540
C.V.(media scarti assoluti)	0.7555	<i>0.7627</i>	0.8514	0.9822
C.V.(mediana scarti assoluti)	1.1664	1.1668	<i>1.1725</i>	1.1899

Tabella 1: Modello simmetrico:  $(1 - \eta)N(0, 1) + \eta N(0, 9)$

$\eta$	0.0000	0.0008	0.0115	0.0617
Var(media)	1.0000	1.0097	1.1377	1.7254
Var(media)	1.5708	1.5727	1.5977	<i>1.7254</i>
C.V.(deviazione standard)	0.7071	0.7611	1.1694	1.5176
C.V.(media scarti assoluti)	0.7555	<i>0.7611</i>	0.8263	0.9973
C.V.(mediana scarti assoluti)	1.1664	1.1666	<i>1.1694</i>	1.1838

Tabella 2: Modello asimmetrico:  $(1 - \eta)N(0, 1) + \eta N(2, 9)$

# Introduzione alla robustezza

Per quanto riguarda la stima del parametro di scala si nota che è sufficiente lo 0.2% di contaminazione nel modello (1) e lo 0.1% nel modello (2) per rendere la media degli scarti assoluti dalla media più efficiente della deviazione standard campionaria (normalmente più efficiente del 12%).

Tukey commenta così i suoi risultati:

“Una tacita speranza nell'ignorare le deviazioni dai modelli ideali era che non avrebbero avuto importanza; che le procedure statistiche che erano ottimali secondo il modello rigoroso sarebbero ancora approssimativamente ottimali sotto il modello approssimativo. Sfortunatamente, si è scoperto che questa speranza era spesso drasticamente sbagliata; anche le lievi deviazioni hanno spesso effetti molto più grandi di quanto non fossero stati anticipati dalla maggior parte degli statistici.”

# Outlier, leverage, influence

Un outlier è un punto che non è ben stimato dal modello. Se il residuo associato al punto  $i$  è “grande”, allora possiamo considerare il punto  $i$  come un potenziale outlier. L' $i$ -esimo residuo dovrebbe seguire una distribuzione  $t$  di Student con  $(n-p-1)$  gradi di libertà.

Nel package `car` troviamo il comando `outlierTest()` che consente di effettuare il test per individuare i valori outlier fornendo il Bonferroni  $p$ -value per il valore outlier più estremo.

Gli elementi  $h_{ii}$  sulla diagonale principale della matrice  $H$  (hat) si chiamano leverages (punti di leva).

Poiché  $\text{var}(\text{pred}(y_i)) = h_i \sigma^2$   $h_i$  è la precisione con cui il valore è stimato relativamente a  $\sigma^2$ . Quindi, valori piccoli di  $h_i$  indicano che lo stimatore di  $y_i$  è basato sul contributo di molte osservazioni. Invece, valori grandi di  $h_i$  ossia molto vicini a 1, implicano che  $\text{var}(y_i - \text{pred}(y_i)) = (1 - h_i) \sigma^2 \approx 0$  e che  $\text{pred}(y_i)$  tende a essere vicino a  $y_i$  e che  $\text{pred}(y_i)$  è determinato in modo predominante dalla singola osservazione  $y_i$  che quindi ha un effetto di leva importante.

# Outlier, leverage, influence

Un punto con “alto” leverage ha un residuo con varianza “piccola” (cioè la retta deve passare “vicino” a questo punto). Un punto con “alto” leverage è un punto “distante”. Hoaglin e Wesh suggeriscono di segnalare come punti con un elevato effetto di leva quei punti per cui  $h_i > 2p/n$ . Per calcolare i punti di leverage in R possiamo usare i comandi `hat()` e `hatvalues()`.

Un punto influente (influence) è un punto che, se rimosso, produce un notevole cambiamento nella stima del modello. Un punto influente non necessariamente è un outlier e può o non può avere un leverage elevato, ma, in generale ha almeno una di queste due caratteristiche.

Misure di influence sono date dai residui jackknife, dai cambiamenti nelle stime dei coefficienti di regressione e della varianza residua che si ottengono escludendo un punto dal stima e dalla distanza di Cook.

Per la distanza di Cook possiamo usare i comandi `cooks.distance()` ed `influence.measures()` nel package `stats`.

# Regressione robusta

Quando nella regressione gli errori non sono distribuiti normalmente oppure si hanno molti valori outliers le stime OLS non sono buone e si deve ricorrere alla regressione robusta<sup>36</sup>. Il metodo più usato per questo tipo di regressione è quello della M-estimation introdotto da Huber. Tali stimatori possono essere considerati una generalizzazione delle stime di massima verosimiglianza. Abbiamo il modello lineare generale (con  $k$  regressori) riferito all' $i$ -esima di  $n$  osservazioni ed espresso in notazione vettoriale:

$$y_i = X_i^T \beta + \varepsilon_i \quad \text{e stimato da:} \quad y_i = X_i^T \hat{\beta} + e_i$$

Il generico *M-estimator* è ottenuto minimizzando la funzione obiettivo:

$$\rho(e_i) = \sum_{i=1}^n \rho(y_i - X_i^T \hat{\beta})$$

dove la funzione  $\rho$  fornisce il contributo di ogni singolo residuo alla funzione obiettivo. La funzione  $\rho$  deve godere delle seguenti proprietà:

# Regressione robusta

- 1)  $\rho(e) \geq 0$
- 2)  $\rho(0) = 0$
- 3)  $\rho(e) = \rho(-e)$
- 4)  $\rho(e_i) \geq \rho(e_j)$  se  $|e_i| > |e_j|$

Ci sono diverse funzioni obiettivo che possono essere utilizzate e che soddisfano questi requisiti: se  $\rho(e) = e^2$  abbiamo le stime dei minimi quadrati ordinari (OLS), se  $\rho(e) = |e|$  abbiamo le stime LAD (Least absolute deviation regression), altre funzioni sono quella di Huber e la biquadratica:

<i>Method</i>	<i>Objective Function</i>	<i>Weight Function</i>
Least-Squares	$\rho_{LS}(e) = e^2$	$w_{LS}(e) = 1$
Huber	$\rho_H(e) = \begin{cases} \frac{1}{2}e^2 & \text{for }  e  \leq k \\ k e  - \frac{1}{2}k^2 & \text{for }  e  > k \end{cases}$	$w_H(e) = \begin{cases} 1 & \text{for }  e  \leq k \\ k/ e  & \text{for }  e  > k \end{cases}$
Bisquare	$\rho_B(e) = \begin{cases} \frac{k^2}{6} \left\{ 1 - \left[ 1 - \left( \frac{e}{k} \right)^2 \right]^3 \right\} & \text{for }  e  \leq k \\ k^2/6 & \text{for }  e  > k \end{cases}$	$w_B(e) = \begin{cases} \left[ 1 - \left( \frac{e}{k} \right)^2 \right]^2 & \text{for }  e  \leq k \\ 0 & \text{for }  e  > k \end{cases}$

# Regressione robusta

Se poniamo  $\psi = \rho'$  (la derivata prima) e differenziamo la funzione obiettivo rispetto ai coefficienti  $\hat{\beta}$ , poniamo uguali a zero le derivate parziali, otteniamo un sistema di  $k+1$  equazioni di stima per i coefficienti:

$$\sum_{i=1}^n \psi\left(y_i - X_i^T \hat{\beta}\right) X_i^T = 0$$

Se definiamo la funzione peso  $w(e) = \psi(e)/e$  e poniamo  $w_i = w(e_i)$  le equazioni possono essere riscritte in questi termini:

$$\sum_{i=1}^n w_i \left(y_i - X_i^T \hat{\beta}\right) X_i^T = 0$$

La soluzione di tale sistema è un problema di minimi quadrati ponderati e si ottiene attraverso una procedura iterativa (IRLS=iteratively reweigheted least squares).

Un'altra tecnica di regressione robusta è quella della regressione LTS (least trimmed squares).

# Regressione robusta

Un'altra tecnica di regressione robusta è quella della regressione LTS (least trimmed squares) .

In questo caso i quadrati dei residui vengono ordinati in ordine crescente:

$$(e^2)_{(1)}, (e^2)_{(2)}, \dots, (e^2)_{(n)}$$

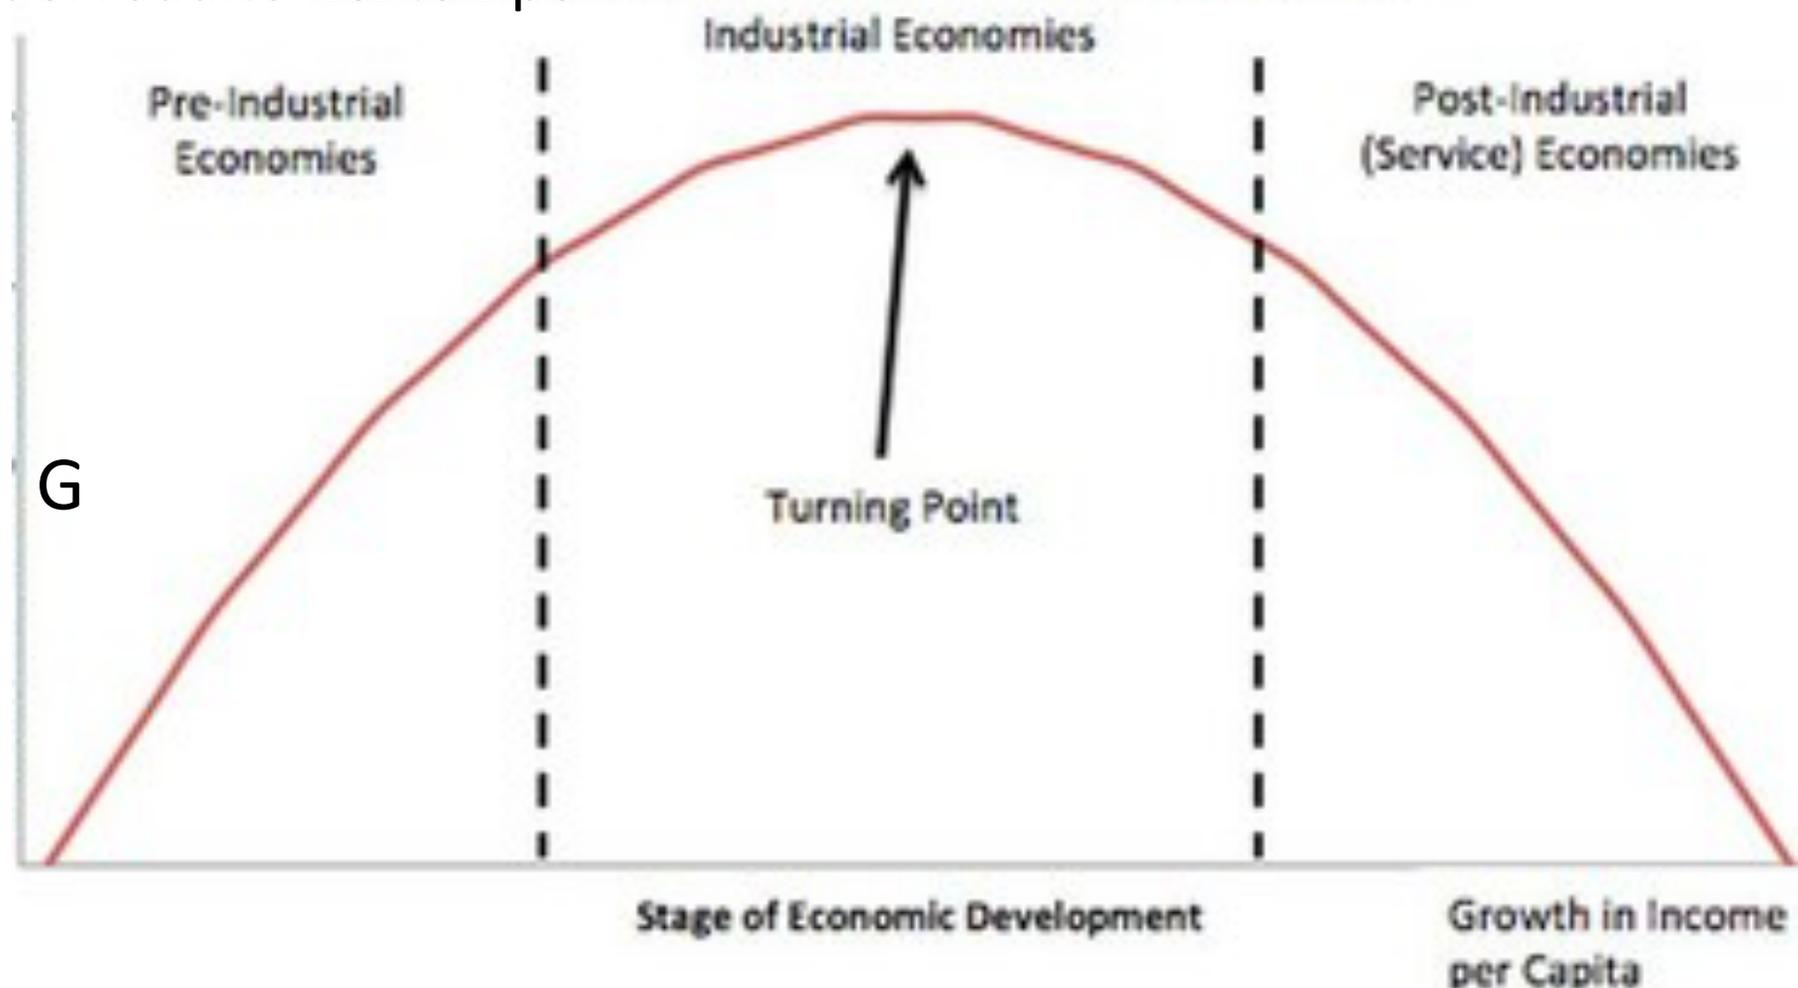
le stime LTS dei coefficienti di regressione  $\hat{\beta}$  sono ottenute minimizzando la somma dei piccoli  $m$  valori dei quadrati dei residui:

$$LTS(\beta) = \min \left\{ \sum_{i=1}^m (e^2)_{(i)} \right\}$$

dove  $m = \lfloor n / 2 \rfloor + \lfloor (k + 2) / 2 \rfloor$  e  $\lfloor \cdot \rfloor$  indica l'approssimazione all'intero più piccolo.

# Esempio: curva di Kuznets

La curva di Kuznets descrive l'andamento della diseguaglianza in rapporto al tasso di sviluppo, mostrando l'evoluzione della distribuzione del reddito nel tempo.



# Esempio: curva di Kuznets

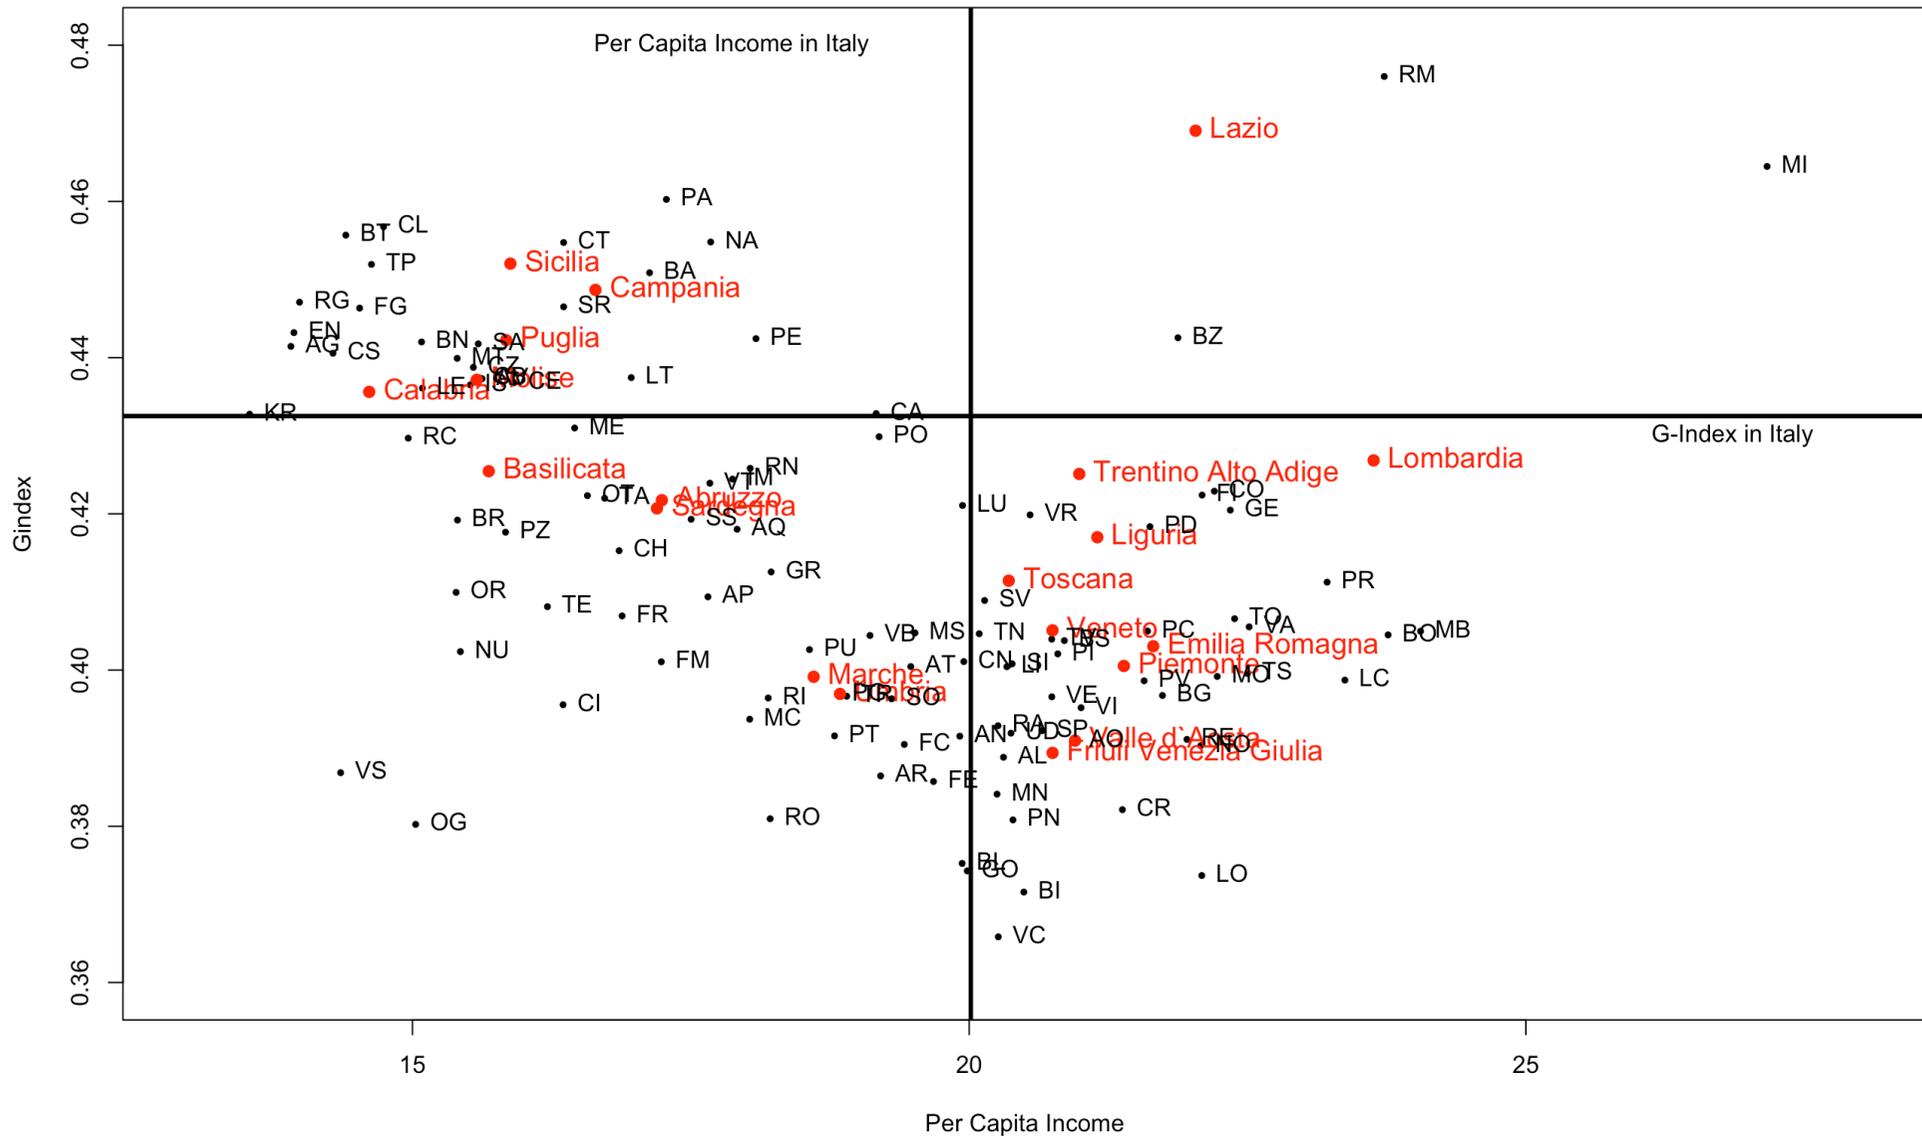
Sull'asse delle ascisse troviamo il Prodotto nazionale lordo pro-capite, mentre su quello delle ordinate il coefficiente di Gini. La forma della curva assomiglia ad una U rovesciata e sta appunto ad indicare che la distribuzione del reddito tende a peggiorare nella prima fase dello sviluppo (massimo incurvamento), migliorando invece in maniera costante con la transizione a un'economia di tipo industriale. Questo avviene in quanto in una prima fase la fascia di popolazione più ricca investe il proprio capitale, incrementando ulteriormente la propria ricchezza; in un secondo momento però viene colpita maggiormente dalla tassazione, con conseguente effetto redistributivo.

Ne esistono anche varianti ambientali.

Proviamo a vedere la cosa nello spazio (cross section) invece che nel tempo (time series), utilizzando i dati resi noti dall'agenzia delle entrate per tutti gli e per tutti i comuni italiani.

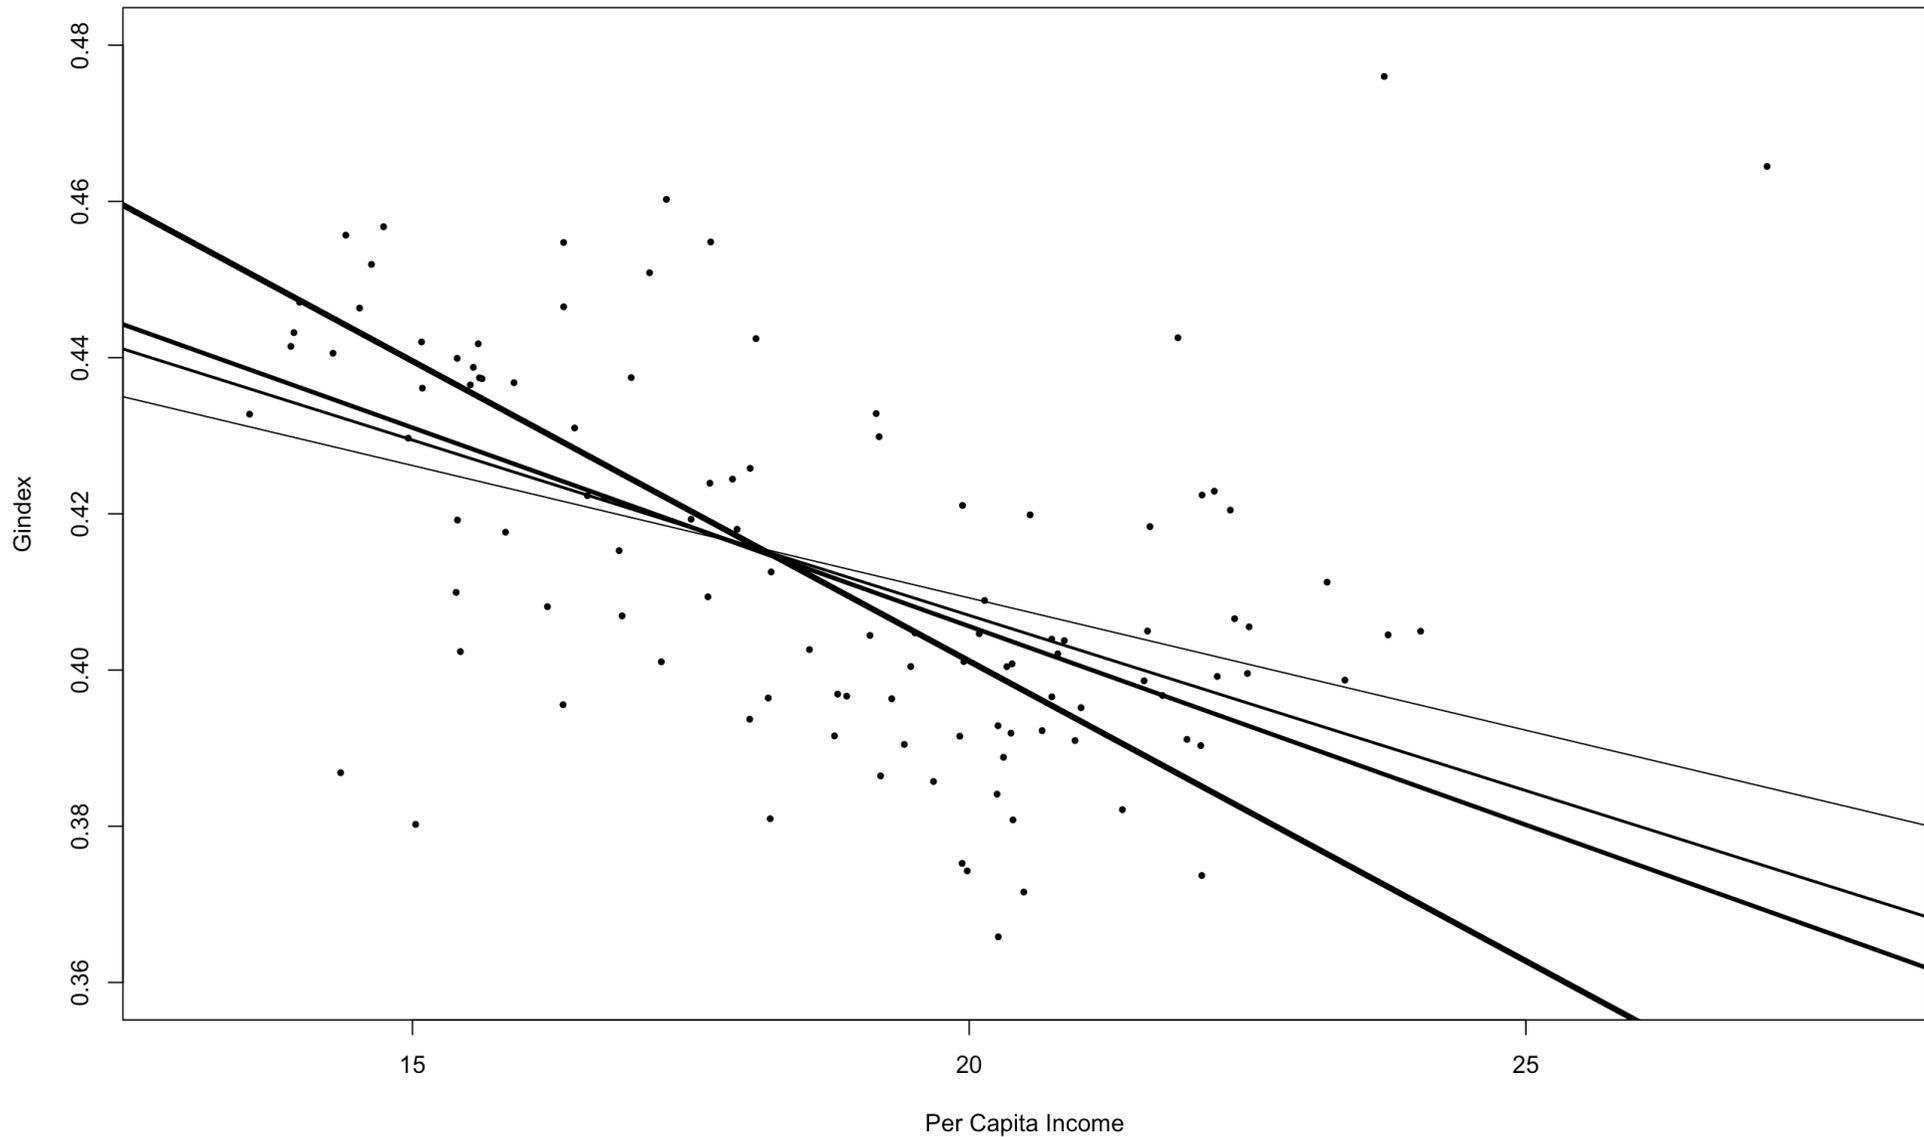
# Esempio: curva di Kuznets

Provincial and Regional Per Capita Income and G-Index



# Esempio: curva di Kuznets

Provincial and Regional Per Capita Income and G-Index



# Esempio: curva di Kuznets

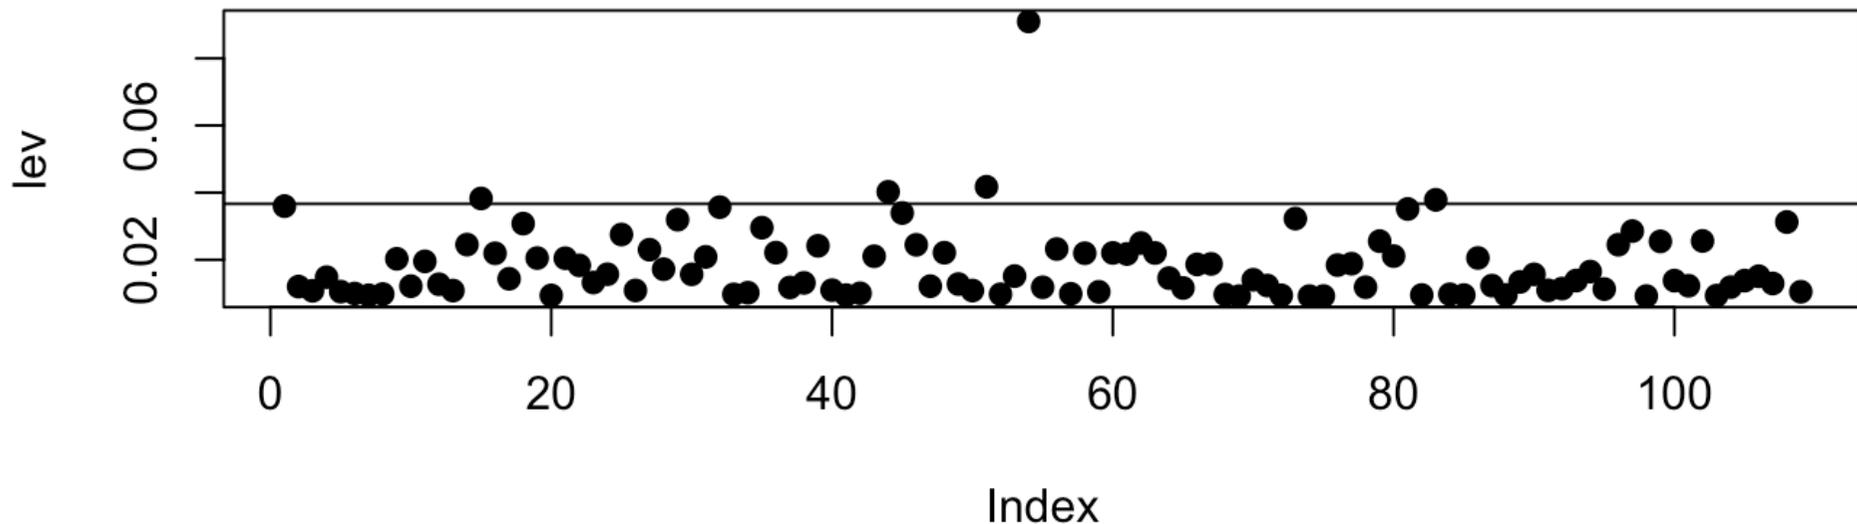
```
load("/Users/utente/Documents/prova r pkg/lucidi del corso/Kuznets.RData")
plot(provku$rmed,provku$gindex,cex=0.5,pch=19,xlim=c(13,28),ylim=c(0.36,0.48),xlab=
"Per Capita Income",ylab="Gindex",main="Provincial and Regional Per Capita Income
and G-Index") points(regku$rmed,regku$gindex,cex=1,pch=19,col=2)
text(regku$rmed,regku$gindex,regku$cod,pos = 4,cex=1.2,col=2)
text(provku$rmed,provku$gindex,provku$cod,pos = 4)
abline(v=itku$rmed,lw=3);abline(h=itku$gindex,lw=3)
text(16.5,0.48,"Per Capita Income in Italy",pos=4)
text(26,0.43,"G-Index in Italy",pos=4)
library(MASS);plot(provku$rmed,provku$gindex,cex=0.5,pch=19,xlim=c(13,28),ylim=c(0.
36,0.48),xlab="Per Capita Income",ylab="Gindex",main="Provincial and Regional Per
Capita Income and G-Index")
reglm <-lm(gindex~rmed, data=provku)
regrml1 <-rlm(gindex~rmed, data=provku, psi=psi.huber)
regrml2 <-rlm(gindex~rmed, data=provku, psi=psi.bisquare)
reglts <-lqs(gindex~rmed, data=provku, method="lts")
abline(reglm);abline(regrml1,lwd=2);abline(regrml2,lwd=3);abline(reglts,lwd=4)
confronto<-data.frame(coef(reglm),coef(regrml1),coef(regrml2),coef(reglts))
options(digits=3); Confronto
      coef.reglm. coef.regrml1. coef.regrml2. coef.reglts.
(Intercept)    0.47703      0.49677      0.50731      0.55481
rmed           -0.00339     -0.00449     -0.00509     -0.00768
library(car)
outlierTest(reglm)
      rstudent      p-value Bonferonni p
Milano 4.07      8.93e-05      0.00973
Roma   3.94      1.49e-04      0.01622
```

# Esempio: curva di Kuznets

```
library(car)
outlierTest(reglm)
  rstudent      p-value Bonferonni p
Milano 4.07      8.93e-05  0.00973
Roma    3.94      1.49e-04  0.01622
```

```
lev<-hat(model.matrix(reglm))
lev<-hatvalues(reglm)
n<-length(lev)
p<-sum(lev)
plot(lev, main="Punti di leva",cex=1,pch=19)
abline(h=2*p/n)
```

## Punti di leva



# Regressione Quantilica

## Motivazione

*Quello che fa la curva di regressione è un grande riassunto per le medie delle distribuzioni corrispondenti all'insieme delle  $x$ . Potremmo andare oltre e calcolare diverse curve di regressione corrispondenti ai vari punti percentuali delle distribuzioni e ottenere così un'immagine più completa dell'insieme dei dati. Di solito questo non viene fatto, e così la regressione dà spesso un'immagine piuttosto incompleta. Proprio come la media fornisce un'immagine incompleta di una singola distribuzione, così la curva di regressione fornisce un'immagine corrispondente incompleta per un insieme di distribuzioni.*

Mosteller and Tukey (1977)

# Regressione Quantilica

Data una variabile aleatoria  $X$ , con funzione di distribuzione  $F$ , definiamo il  $\tau$ -esimo quantile di  $X$  come:

$$Q_{X(\tau)} = F^{-1}_X(\tau) = \inf\{x \mid F(x) \geq \tau\}.$$

dal punto di vista delle densità, il  $\tau$ -esimo quantile divide l'area sotto la densità in due parti: una con area  $\tau$  al di sotto del  $\tau$ -esimo quantile e l'altra con area  $1 - \tau$  sopra di esso.

I quantili risolvono un semplice problema di ottimizzazione:

$$\alpha^*(\tau) = \operatorname{argmin}_{\alpha} E \rho_{\tau}(Y - \alpha)$$

Così come la media risolve:

$$\mu = \operatorname{argmin}_m E(Y - m)^2$$

# Regressione Quantilica

Se  $\varepsilon_i$  è l'errore di previsione del modello, OLS minimizza la somma dei quadrati degli errori. La regressione mediana, minimizza la somma dei loro valori assoluti. La regressione quantilica minimizza una somma che dà penalità asimmetriche  $(1 - q)|e_i|$  per errori positivi e  $q|e_i|$  per errori negativi. Sebbene il suo calcolo richieda metodi di programmazione lineare, lo stimatore di regressione quantilica è asintoticamente distribuito normalmente.

La regressione mediana è più robusta rispetto alla regressione rispetto ai minimi quadrati ed è semiparametrica in quanto evita ipotesi sulla distribuzione Gaussiana dell'errore.

# Regressione Quantilica

La regressione quantilica può essere in alcune circostanze una valida alternativa alla regressione ordinaria quando non sono verificati tutti i requisiti di base per applicare gli OLS o la ML, in particolare quando si hanno degli outlier (la regressione quantilica è una tecnica robusta) e le stime dei coefficienti di regressione risultano più efficienti quando gli errori non sono distribuiti normalmente.

Definiamo come  $f(y_i | x_i)$  e  $F(y_i | x_i)$ , rispettivamente, la funzione di densità di probabilità (pdf) e la funzione di distribuzione cumulativa (cdf) della variabile dipendente  $y_i$  condizionata alle esplicative (ausiliarie, covariate) osservate  $x_i$ . Supponiamo che per ogni unità  $i$  e per ogni  $\tau \in (0, 1)$ , esista un vettore  $K$ -dimensionale  $\beta(\tau)$  tale che:

$$Q_{y_i}(\tau | \mathbf{x}_i) = \mathbf{x}_i^T \beta(\tau)$$

# Regressione Quantilica

dove  $Q_{y_i}(\tau | \mathbf{x}_i) \equiv \inf\{y_i: F(y_i | \mathbf{x}_i) \geq \tau\}$  è il  $\tau$ -esimo quantile condizionato di  $y_i$ .

Una stima  $\hat{\beta}_{QR}(\tau)$  del vettore  $\beta$  seguendo l'approccio suggerito da Koenker e Bassett, si ottiene minimizzando con metodi di programmazione lineare (cioè l'algoritmo del simplesso), la funzione obiettivo:

$$L_n(\beta(\tau)) = n^{-1} \sum_{i=1}^n w_i \left[ (\tau - \pi_{i\tau}) (y_i - \mathbf{x}_i^T \beta(\tau)) \right]$$

con  $\pi_{i\tau} = I(y_i \leq \mathbf{x}_i^T \beta(\tau))$ , dove  $I(\cdot)$  è la funzione di indicatore e  $w_i$  è il peso dell'unità  $i$ . Questo peso può essere utilizzato per tenere conto del disegno di campionamento dell'indagine, anche se di solito è considerato costante, assumendo implicitamente che il disegno di campionamento non sia informativo per l'inferenza su  $\beta$ .

# Regressione Quantilica

Il vettore di coefficienti  $\hat{\beta}_{QR}(\tau)$  si ottiene quindi minimizzando una funzione:

$$L_n(\beta(\tau)) = \sum_{i: y_i \geq \mathbf{x}_i^T \beta} q |y_i - \mathbf{x}_i^T \beta(\tau)| + \sum_{i: y_i < \mathbf{x}_i^T \beta} (1 - q) |y_i - \mathbf{x}_i^T \beta(\tau)|$$

Questa funzione non è differenziabile ed è minimizzata tramite il metodo del semplice, che garantisce una soluzione in un numero finito di iterazioni. Sebbene sia dimostrato che lo stimatore è asintoticamente normale con matrice di var e cov nota analiticamente, la sua espressione è difficile da stimare. Quindi degli errori standard Bootstrap vengono spesso utilizzati al posto degli errori standard analitici.

# Regressione Quantilica

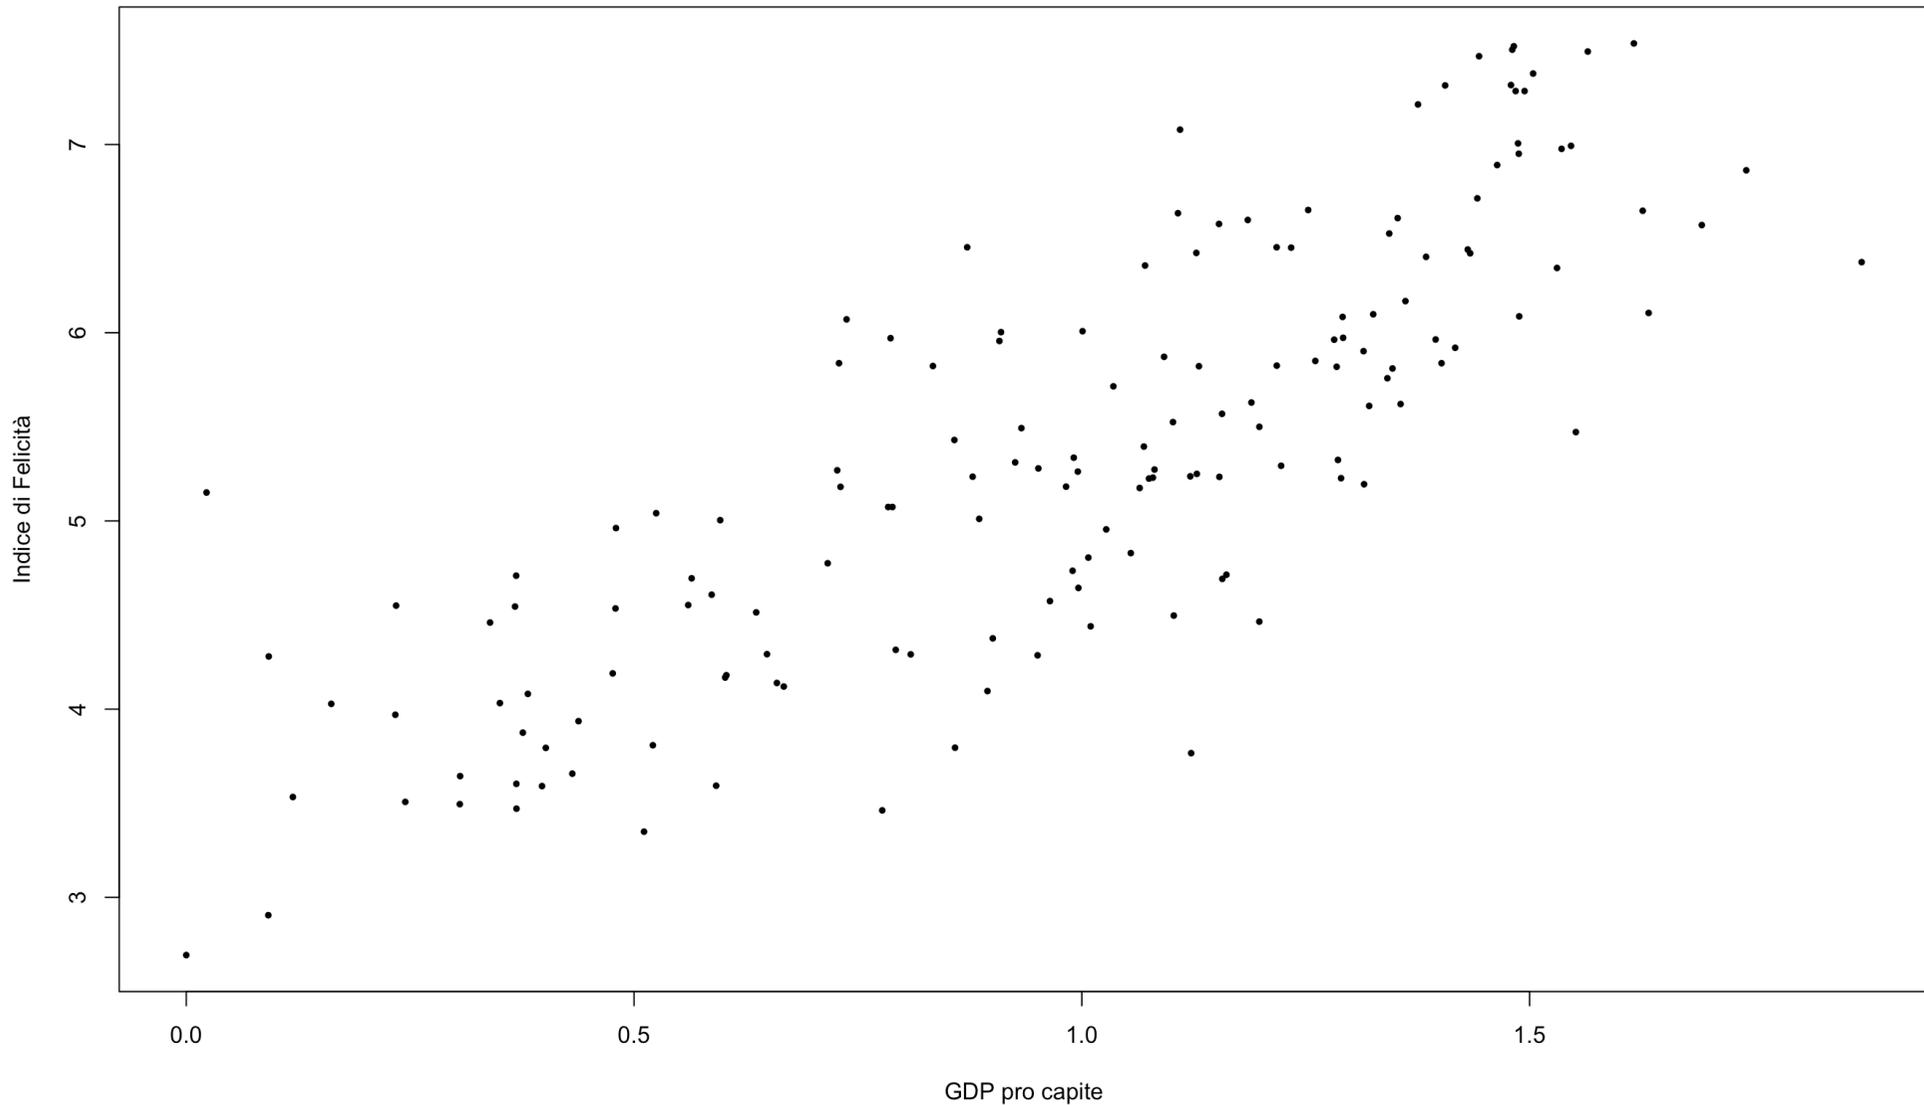
Si ottiene quindi un vettore di stime che, secondo i teoremi asintotici riportati da Koenker, hanno una distribuzione normale asintoticamente multivariata, con vettore medio e matrice di covarianza la cui stima presume che gli errori siano iid (Koenker e Bassett, 1978).

Alcuni vantaggi della regressione quantilica (QR): mentre l'OLS può essere inefficiente se gli errori sono lontani dall'ipotesi di gaussianità, QR è più robusta rispetto agli errori non normali e ai valori anomali. Il QR fornisce anche una descrizione più ricca di informazioni, permettendoci di considerare l'impatto di una covariata sull'intera distribuzione di  $y$ , non solo sulla sua media condizionata.

Inoltre, QR è invariante alle trasformazioni monotone, come  $\log(\cdot)$ , quindi i quantili di  $h(y)$ , una trasformata monotona di  $y$ , sono  $h(Q_q(y))$ , e la trasformazione inversa può essere usata per tradurre il risale a  $y$ .

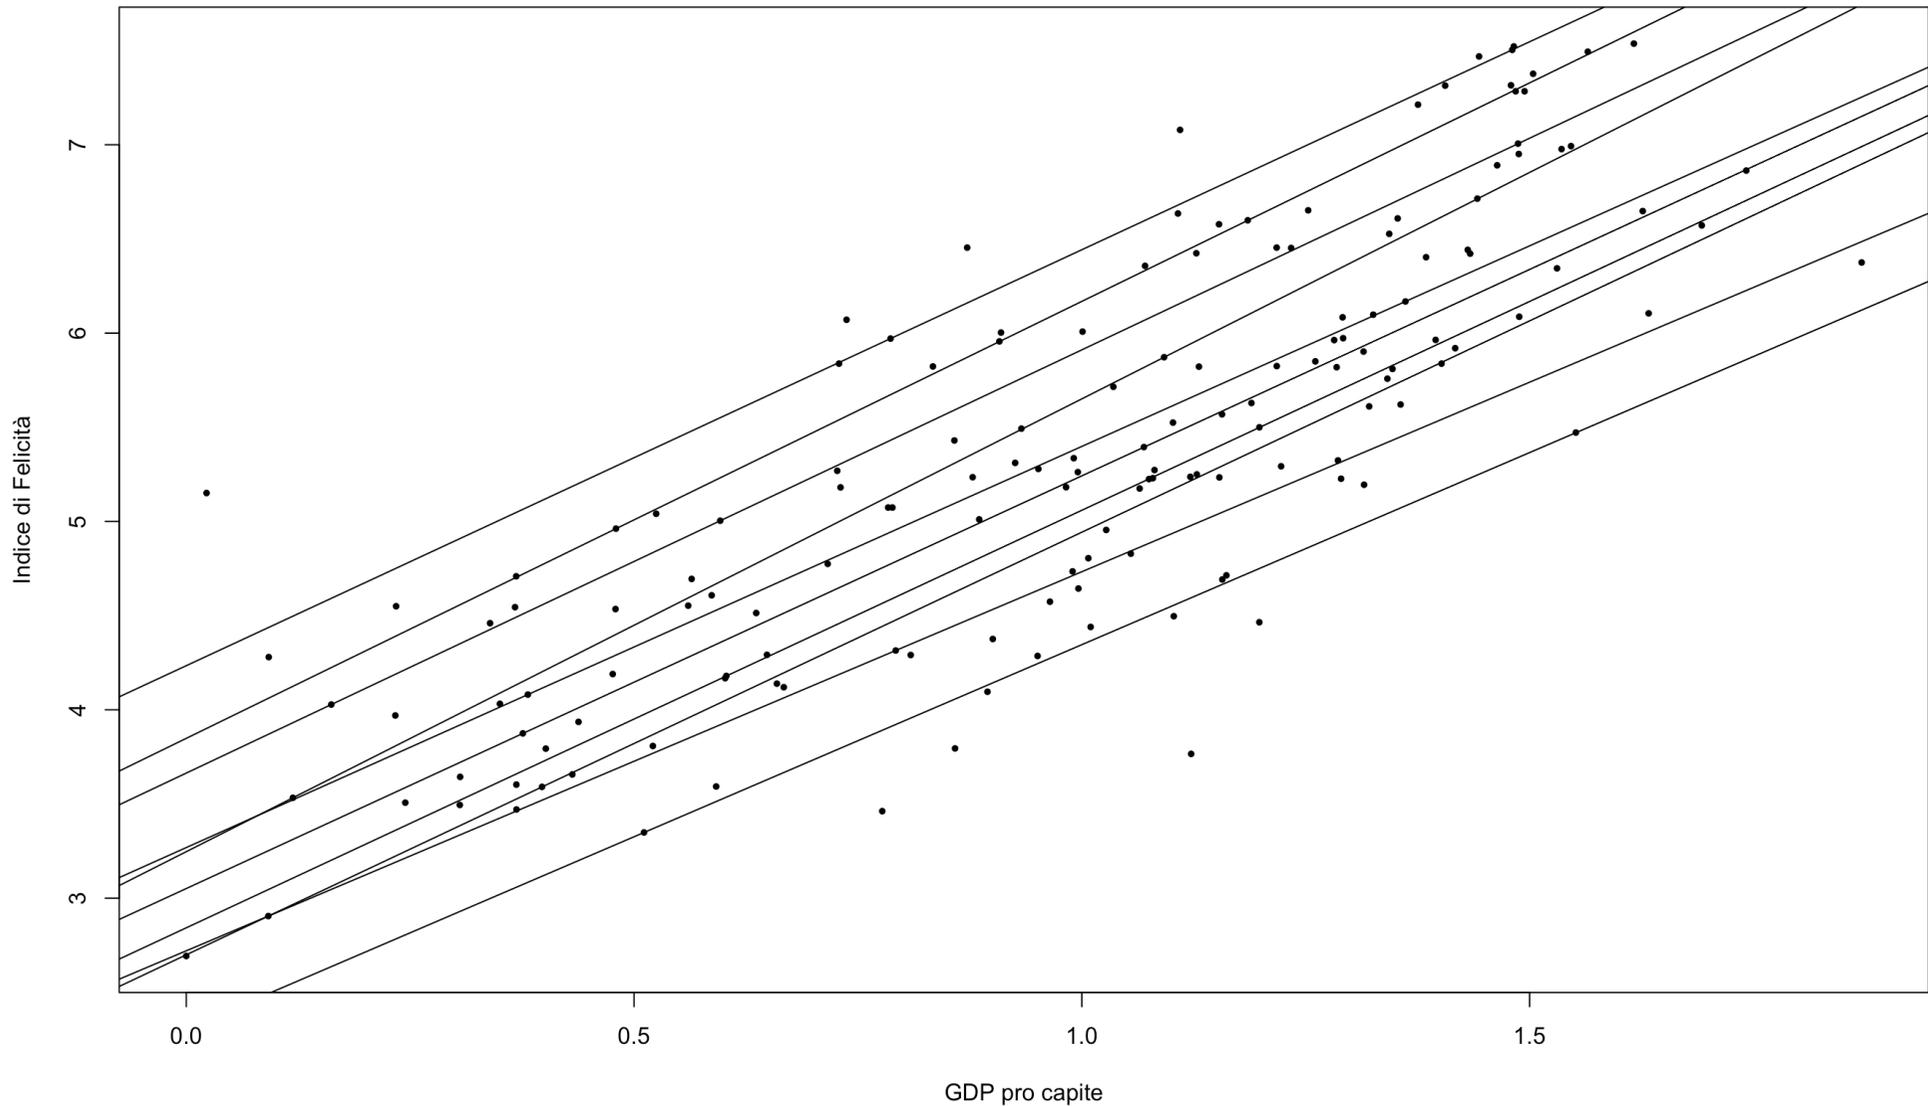
# Esempio: “I soldi fanno la felicità?”

Felicità e Reddito



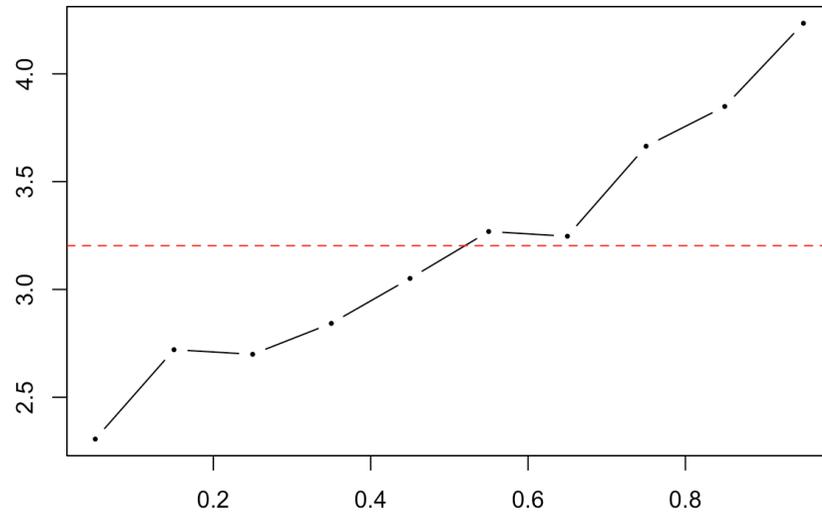
# Esempio: “I soldi fanno la felicità?”

Felicità e Reddito

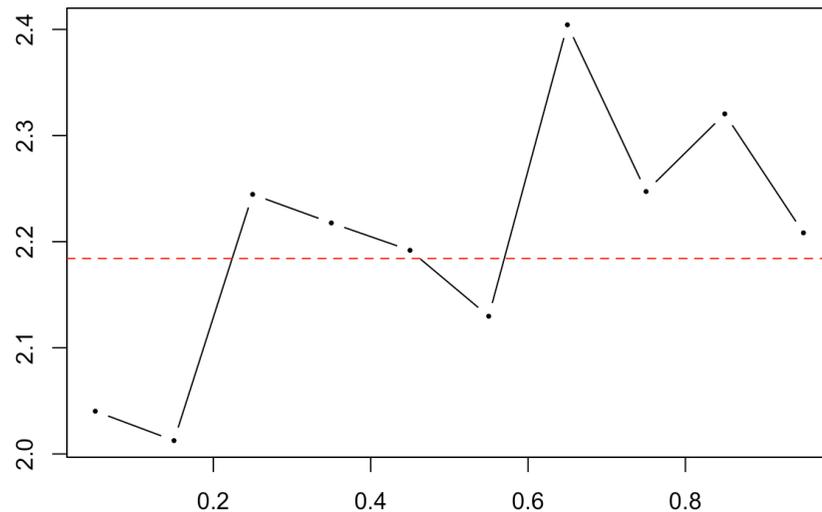


# Esempio: “I soldi fanno la felicità?”

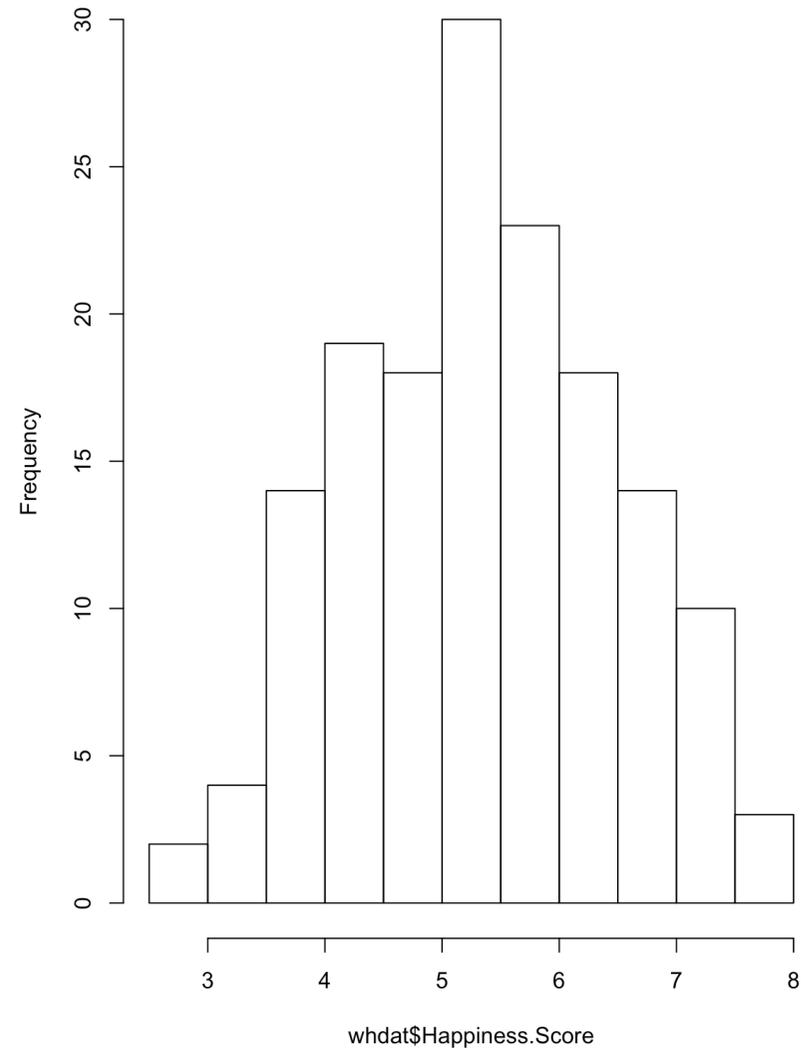
(Intercept)



whdat\$Economy..GDP.per.Capita.

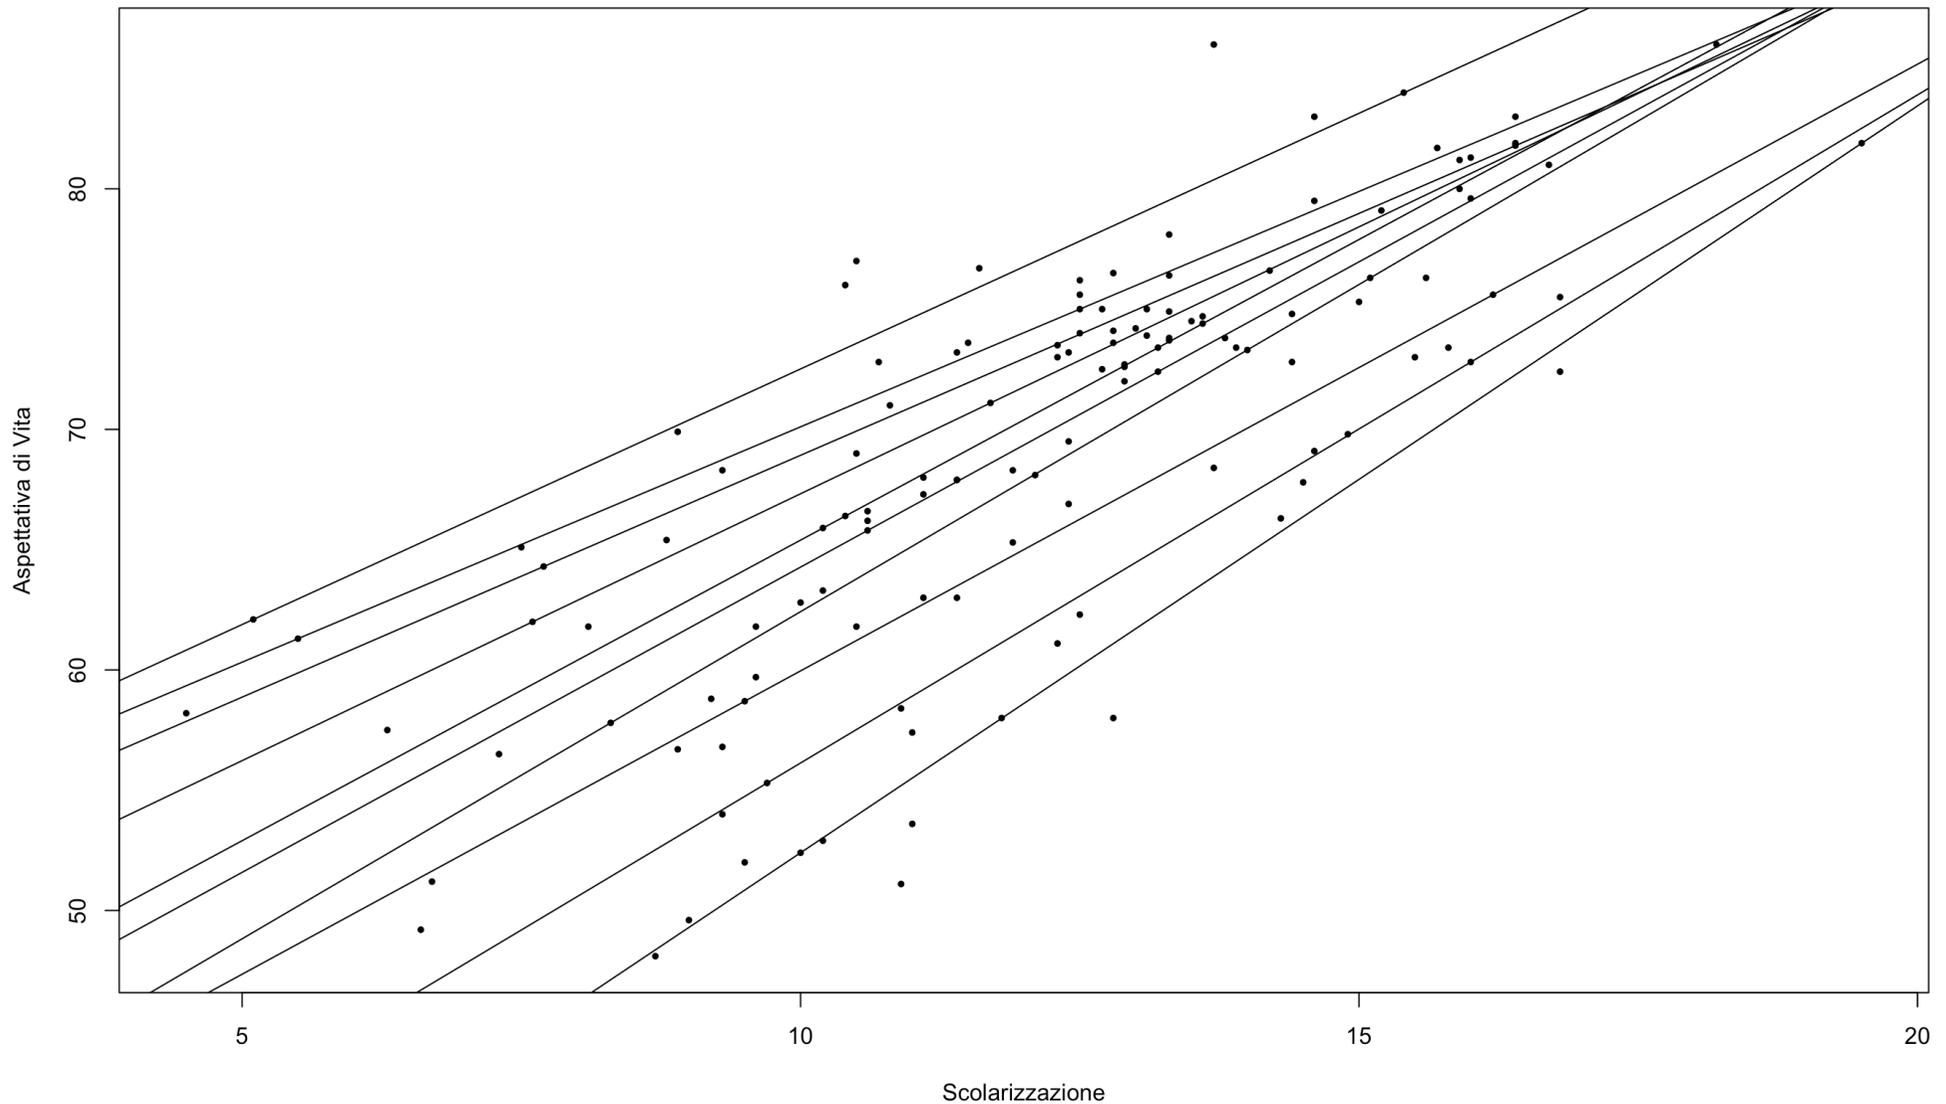


Histogram of whdat\$Happiness.Score



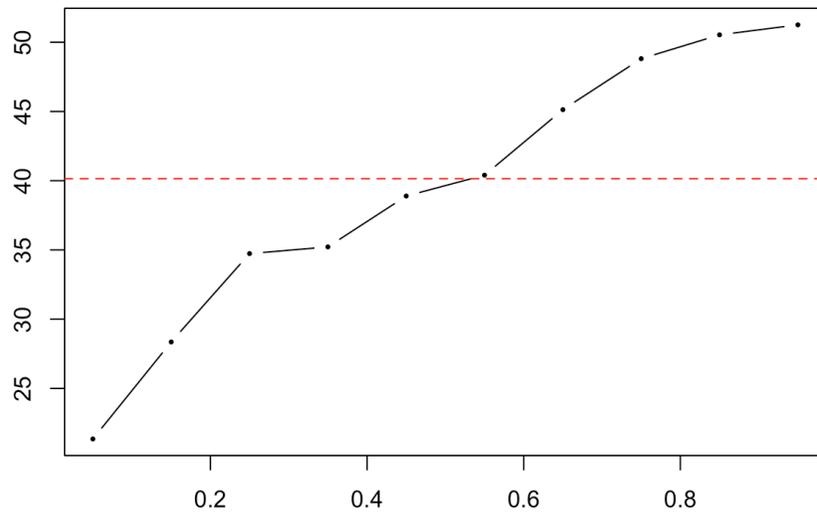
# Esempio: eteroschedasticità

Salute e Scuola

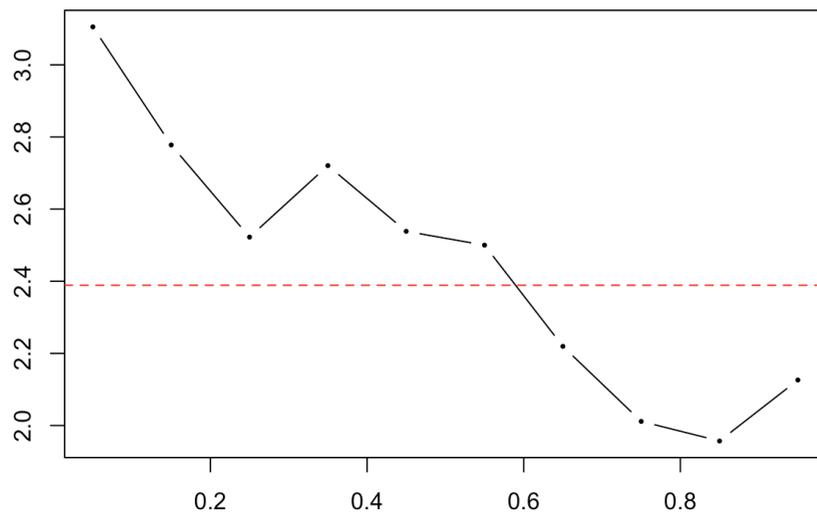


# Esempio: eteroschedasticità

(Intercept)



ledat2010\$Schooling



Histogram of ledat2010\$Life.expectancy

