



**UNIVERSITÀ
DEGLI STUDI
DI TRIESTE**



Dipartimento di scienze economiche,
aziendali, matematiche e statistiche
"Bruno de Finetti"

5. Regressione semiparametrica

Francesco Pauli

DEAMS

Università di Trieste

A.A. 2020/2021

Modelli parametrici, semiparametrici, non parametrici

Si ha un modello parametrico quando la famiglia di distribuzioni all'interno della quale cerchiamo una distribuzione che descriva i dati è indicizzata da un parametro $\theta \in \mathbb{R}^d$, **con d non troppo grande e fisso.**



Muoversi verso i metodi semiparametrici o non parametrici significa

- ridurre le assunzioni
- aumentare il numero di parametri e, in qualche senso, stimarlo (non c'è una separazione netta).

Esempio: stima della distribuzione

Esempio: stima della distribuzione di $X_1, \dots, X_n \sim F()$



Stima parametrica di F : supponiamo

$$F \in \mathcal{F} = \{F_\theta() : \theta \in \mathbb{R}^d\}$$

sia ad esempio $X_i \sim \text{IID}(\mathcal{N}(\mu, \sigma^2))$, stimiamo θ (ad es. SMV) e $F_{\hat{\theta}}$ è la stima di F .



Stima non parametrica di F : si assume F sia una FdR, una stima non parametrica è la **FdR empirica**

$$\hat{F}_n(x) = \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{\{x_i \leq x\}}$$

Esempio: regressione

Esempio: stima della funzione di regressione $E(Y|X = x)$ da un campione $(x_i, Y_i), i = 1, \dots, n$



Sono modelli parametrici

- il modello lineare: $(Y|X = x) \sim \mathcal{N}(\beta_1 + \beta_2 x, \sigma^2)$ indipendenti dove

$$E(Y|X = x) = \beta_1 + \beta_2 x$$

e dove si stima $\theta = (\beta_1, \beta_2)$ ad esempio con la MV.

- anche i GLM, dove

$$g(E(Y|X = x)) = \beta_1 + \beta_2 x$$

con g funzione legame nota.



In un modello non/semi parametrica/o: si assume $E(Y|X = x) = f(x)$ dove f appartiene a una classe di funzioni sufficientemente flessibile (non ci sono parametri di interesse diretto).

Regressione non parametrica

Si assume che le osservazioni siano indipendenti e

$$E(Y|X = x) = f(x); \quad V(Y|X = x) = \sigma^2$$

dove f è una funzione “regolare” (continua con qualche derivata continua).



Due approcci

- tecniche “locali”
 - se avessimo tante osservazioni per ciascun x_0 potremmo stimare $f(x_0)$ come una media campionaria.
 - in generale, avendo un’osservazione per ciascun x potremmo usare le osservazioni vicine.

Regressione non parametrica

Si assume che le osservazioni siano indipendenti e

$$E(Y|X = x) = f(x); \quad V(Y|X = x) = \sigma^2$$

dove f è una funzione “regolare” (continua con qualche derivata continua).



Due approcci

- tecniche “locali”: stima $E(Y|X = x_0)$ usando punti vicini a x_0 .
- tecniche “globali” (spline)
 - definiamo una classe di funzioni $f(x; \theta)$ abbastanza flessibile da poter approssimare qualunque funzione regolare $f(\cdot)$
 - stimiamo f scegliendo il miglior rappresentante in $f(x; \theta)$

Regressione non parametrica

Si assume che le osservazioni siano indipendenti e

$$E(Y|X = x) = f(x); \quad V(Y|X = x) = \sigma^2$$

dove f è una funzione “regolare” (continua con qualche derivata continua).



Due approcci

- tecniche “locali”: stima $E(Y|X = x_0)$ usando punti vicini a x_0 .
- tecniche “globali” (spline): definiamo un modello flessibile per $f(x; \theta)$

Regressione non parametrica

Si assume che le osservazioni siano indipendenti e

$$E(Y|X = x) = f(x); \quad V(Y|X = x) = \sigma^2$$

dove f è una funzione “regolare” (continua con qualche derivata continua).



Due approcci

- tecniche “locali”: stima $E(Y|X = x_0)$ usando punti vicini a x_0 .
- tecniche “globali” (spline): definiamo un modello flessibile per $f(x; \theta)$

Un aspetto cruciale in entrambi i metodi è determinare quanto liscia debba essere \hat{f} che si traduce in


- decidere cosa significa “vicino”
- decidere quanto flessibile dev’essere il modello $f(x; \theta)$

In entrambi i casi, serve un compromesso tra distorsione e varianza.

Indice

- 1 Regressione non parametrica, caso gaussiano
- 2 Regressione col metodo del nucleo
- 3 Spline
- 4 Verosimiglianza (somma dei quadrati) penalizzata
- 5 Stima della varianza
- 6 Altre basi
- 7 Più esplicative

Esempio: dati "lidar"



LIDAR = Light Detection And Ranging

- è una tecnica per individuare composti chimici nell'atmosfera
- x : distanza percorsa prima della riflessione
- y : logaritmo del rapporto tra luce ricevuta tra le due fonti laser

- L'obiettivo è stimare

$$f(x) = E(Y|X = x)$$


- (Esempio ben noto dove le tecniche banali, trasformazioni o regressione polinomiale, funzionano male.)

LIDAR: modello lineare

Assumiamo

$$y = X\beta + \varepsilon$$

dove $X \in \mathcal{M}_{n \times p}$, $\beta \in \mathbb{R}^p$,
 $\varepsilon \sim N(0, \sigma^2 I)$,



Non molto soddisfacente...

Usando la massima verosimiglianza

$$\hat{\beta} = (X^T X)^{-1} X^T y$$

sicché

$$\hat{y} = X\hat{\beta} = X(X^T X)^{-1} X^T y$$

dove $H = X(X^T X)^{-1} X^T$ è la matrice di proiezione da \mathbb{R}^n al sottospazio generato dalle colonne di X , si ricordi che


$$\text{trace} H = p$$

LIDAR: modello lineare

Assumiamo

$$y = X\beta + \varepsilon$$

dove $X \in \mathcal{M}_{n \times p}$, $\beta \in \mathbb{R}^p$,
 $\varepsilon \sim N(0, \sigma^2 I)$,



Non molto soddisfacente...

Si noti che

$$\hat{y} = X\hat{\beta}y = X(X^T X)^{-1}X^T y$$

significa che la stima del valore atteso condizionato è

$$E(\widehat{Y|X=x}) = \hat{f}(x) = \sum_{i=1}^n h_i(x) Y_i$$


dove

$$h(x)^T = x^T (X^T X)^{-1} X^T$$

LIDAR: costante a tratti

Consideriamo una partizione dello spazio della variabile esplicativa, indichiamo gli estremi degli intervalli con

$$-\infty = c_0 < c_1 < \dots < c_{K-1} < c_K = +\infty$$



e stimiamo $E(Y|X = x)$ assumendo sia costante negli intervalli


$$\hat{f}(x) = \frac{\sum_{k=0}^{K-1} \sum_{i=1}^n y_i I_{[c_k, c_{k+1}]}(x_i)}{\sum_{k=0}^{K-1} \sum_{i=1}^n I_{[c_k, c_{k+1}]}(x_i)}$$

Il risultato

- non è liscio (addirittura discontinuo), e
- dipende dalla scelta degli intervalli.

LIDAR: media mobile

Se assumiamo che $f(x)$ sia continua, allora è ragionevole stimare $f(x)$ come la media di valori di Y_i che corrispondono a x_i vicini a x .




In particolare potremmo usare la media di quegli x_i che giacciono in un intorno di x di raggio h

$$\hat{f}(x) = \frac{\sum_{i=1}^n y_i I_h(|x - x_i|)}{\sum_{i=1}^n I_h(|x - x_i|)}$$

LIDAR: media mobile (vicini più vicini)

Se assumiamo che $f(x)$ sia continua, allora è ragionevole stimare $f(x)$ come la media di valori di Y_i che corrispondono a x_i vicini a x .



Alternativamente potremmo usare la media dei k vicini più vicini ad x ,

$$N_k(x) = \{x_i : |x - x_i| \leq d_{(k)}\}$$

dove $d_i = |x - x_i|$ e $d_{(1)} \leq \dots \leq d_{(n)}$ sono le distanze ordinate, allora

$$\hat{f}(x) = \frac{1}{k} \sum_{i=1}^n y_i I_{N_k(x)}(x_i)$$

Errore di stima: distorsione e varianza

La stima

$$\hat{f}(x) = \frac{1}{k} \sum_{i=1}^n y_i I_{N_k(x)}(x_i) = \frac{1}{k} \sum_{y_i \in N_k(x)} y_i$$

dove $N_k(x) = \{x_i : |x - x_i| \leq d_{(k)}\}$ è basata su k osservazioni: **più grande è k ,**

- più osservazioni sono usate e quindi minore è la variabilità:
- d'altra parte, s'impiegano osservazioni più distanti, a seconda della forma di $f()$ in un intorno di x , la media delle osservazioni può differire più o meno marcatamente da $E(Y|X = x) = f(x)$:

Il compromesso tra distorsione e varianza è una caratteristica distintiva dei lisciatori.

Errore di stima: distorsione e varianza

La stima


$$\hat{f}(x) = \frac{1}{k} \sum_{i=1}^n y_i I_{N_k(x)}(x_i) = \frac{1}{k} \sum_{y_i \in N_k(x)} y_i$$

dove $N_k(x) = \{x_i : |x - x_i| \leq d_{(k)}\}$ è basata su k osservazioni: **più grande è k ,**

- più osservazioni sono usate e quindi minore è la variabilità:
 - **più piccola è la varianza**
- d'altra parte, s'impiegano osservazioni più distanti, a seconda della forma di $f()$ in un intorno di x , la media delle osservazioni può differire più o meno marcatamente da $E(Y|X = x) = f(x)$:
 - **più grande è la distorsione**

Il compromesso tra distorsione e varianza è una caratteristica distintiva dei lisciatori.

Distorsione, forma di f e k



Derivazione teorica di distorsione e varianza

Sia $N_k(x) = \{x_i : |x - x_i| \leq d_{(k)}\}$, e lo stimatore

$$\hat{f}(x) = \frac{1}{k} \sum_{i=1}^n y_i I_{N_k(x)}(x_i) = \frac{1}{k} \sum_{y_i \in N_k(x)} y_i$$

La varianza è (assumendo $V(Y_i) = \sigma^2$ per ogni i)

$$V(\hat{f}(x)) = \frac{1}{k} \sum_{y_i \in N_k(x)} V(Y_i) = \frac{\sigma^2}{k}$$

Derivazione teorica di distorsione e varianza

Sia $N_k(x) = \{x_i : |x - x_i| \leq d_{(k)}\}$, e lo stimatore

$$\hat{f}(x) = \frac{1}{k} \sum_{i=1}^n y_i I_{N_k(x)}(x_i) = \frac{1}{k} \sum_{y_i \in N_k(x)} y_i$$

La distorsione è

$$\begin{aligned} E(\hat{f}(x)) - f(x) &= \frac{1}{k} \sum_{N_k(x)} (f(x_i) - f(x)) \\ &\approx \frac{1}{k} \sum_{N_k(x)} \left(f'(x)(x_i - x) + \frac{1}{2} f''(x)(x_i - x)^2 \right) \end{aligned}$$

assumendo le covariate equidistanziate: $x_{i+1} - x_i = \Delta$

$$\approx \frac{2k(k+2)(k+1)}{6k} f''(x) \Delta^2$$

Derivazione teorica di distorsione e varianza

Sia $N_k(x) = \{x_i : |x - x_i| \leq d_{(k)}\}$, e lo stimatore

$$\hat{f}(x) = \frac{1}{k} \sum_{i=1}^n y_i I_{N_k(x)}(x_i) = \frac{1}{k} \sum_{y_i \in N_k(x)} y_i$$

Quindi l'MSE è


$$E((\hat{f}(x) - f(x))^2) \approx \left(\underbrace{\frac{2k(k+2)(k+1)}{6k} f''(x) \Delta^2}_{\text{distorsione}} \right)^2 + \underbrace{\frac{\sigma^2}{k}}_{\text{varianza}}$$

e quindi

- la distorsione cresce con k e con $|f''|$
- la varianza decresce con k

Distorsione e varianza, esempio


Consideriamo un campione, la vera $f(\cdot)$ è in verde,



Distorsione e varianza, esempio

Consideriamo un campione, la vera $f(\cdot)$ è in verde,




- calcoliamo distorsione, varianza e quindi MSE per $\hat{f}_k(0.6)$ in funzione di k , individuiamo un valore ottimale di k .



Distorsione e varianza, esempio

Consideriamo un campione, la vera $f(\cdot)$ è in verde,

- calcoliamo distorsione, varianza e quindi MSE per $\hat{f}_k(0.6)$ in funzione di k , individuiamo un valore ottimale di k .
- facciamo lo stesso per $\hat{f}_k(0.9)$, otteniamo un **diverso** valore ottimale di k .




Da $MSE(x)$ all'errore complessivo

Disponiamo dell'MSE per $\hat{f}_k(x)$:

$$MSE(\hat{f}_k(x)) = E((f(x) - \hat{f}_k(x))^2) = (f(x) - E(\hat{f}_k(x)))^2 + V(\hat{f}_k(x))$$

mettiamoli insieme per ottenere un errore complessivo

$$R(k) = E\left(\frac{1}{n} \sum_{i=1}^n (\hat{f}_k(x_i) - f(x_i))^2\right)$$



La scelta di k potrebbe basarsi su $R(k)$, ha senso scegliere $k = \operatorname{argmin}_k R(k)$.

Stimatore di $R()$

L'obiettivo è stimare

$$R(k) = E \left(\frac{1}{n} \sum_{i=1}^n (\hat{f}_k(x_i) - f(x_i))^2 \right)$$

(principalmente per individuare il valore ottimale di k .)



Uno stimatore naïf sarebbe

$$\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{f}_k(x_i))^2$$

ma questo è ovviamente una sottostima in quanto ...

Stimatore di $R()$: validazione incrociata uno a uno

Uno stimatore migliore per $R(k)$ è

$$CV(k) = \hat{R}(k) = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{f}_{k,-i}(x_i))^2$$

dove $\hat{f}_{k,-i}(x_i)$ è il lisciatore stimato **senza** l' i -esima osservazione.
Si noti che

$$\begin{aligned} E(Y_i - \hat{f}_{k,-i}(x_i))^2 &= E(Y_i - f(x_i) + f(x_i) - \hat{f}_{k,-i}(x_i))^2 \\ &= \sigma^2 + E(f(x_i) - \hat{f}_{k,-i}(x_i))^2 \\ &\approx \sigma^2 + E(f(x_i) - \hat{f}_k(x_i))^2 \end{aligned}$$

Cioè, \hat{R} è, approssimativamente, uno stimatore non distorto dell'errore di previsione

$$E(\hat{R}) \approx R + \sigma^2$$

Lisciatori lineari

Discutiamo della stima dell'errore per una classe di lisciatori che comprende quelli visti sopra e molti altri: i **lisciatori lineari**, ovvero dei lisciatori per i quali esiste, per ogni x , un vettore $\ell(x) = (\ell_1(x), \dots, \ell_n(x))^T$ tale che

$$\hat{f}(x) = \sum_{i=1}^n \ell_i(x) Y_i$$

il che significa che

$$\hat{\mathbf{f}} = \begin{bmatrix} \hat{f}(x_1) \\ \vdots \\ \hat{f}(x_n) \end{bmatrix} = \begin{bmatrix} \ell_1(x_1) & \cdots & \ell_n(x_1) \\ \vdots & & \\ \ell_1(x_n) & \cdots & \ell_n(x_n) \end{bmatrix} \mathbf{Y} = \mathbf{L}\mathbf{Y}$$

La matrice L è la **matrice di lisciamento**, si definiscono anche i gradi di libertà del lisciatore come

$$\nu = \text{tr}(L)$$

Lisciatori lineari

I precedenti lisciatori sono tutti lisciatori lineari, ricaviamo le matrici L ad essi associati. (Senza perdita di generalità, si assume che le x_i siano ordinate).

- regressogramma: L è diagonale a blocchi e assume valore pari al reciproco del numero di osservazioni in ciascun blocco.
- medie mobili
 - vicini più vicini: L è 0 ovunque tranne che su una striscia intorno alla diagonale dove vale $1/k$.
 - raggio: L è analoga al caso precedente se le x_i sono equidistanziate, altrimenti...

Validazione incrociata uno a uno per lisciatori lineari

Per un lisciatore lineare definito dalla matrice L

$$CV = \hat{R}(k) = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{f}_{k,-i}(x_i))^2 = \frac{1}{n} \sum_{i=1}^n \left(\frac{Y_i - \hat{f}_k(x_i)}{1 - L_{ii}} \right)^2$$

sicché non necessita di ricalcolare il lisciatore ma solo di conoscere L_{ii} .



Un'ulteriore semplificazione è costituita dal **criterio di validazione incrociata generalizzata** che prevede di sostituire L_{ii} con il suo valore medio

$$GCV = \frac{1}{n} \sum_{i=1}^n \left(\frac{Y_i - \hat{f}(x_i)}{1 - \nu/n} \right)^2$$

Derivazione delle formule per CV e GCV

Definiamo $\hat{f}_{-i}(x_i)$. Essendo

$$\hat{f}(x_i) = \sum_{j=1}^n \ell_j(x_i) y_j$$

e assumendo $\sum_{j=1}^n \ell_j(x_i) = 1$ (le costanti sono mantenute), definiamo

$$\hat{f}_{-i}(x_i) = \frac{\sum_{j \neq i} \ell_j(x_i) y_j}{\sum_{j \neq i} \ell_j(x_i)} = \frac{\sum_{j \neq i} \ell_j(x_i) y_j}{1 - \ell_i(x_i)} = \frac{\sum_{j \neq i} \ell_j(x_i) y_j}{1 - L_{ii}}$$



Si noti che potremmo definire $\hat{f}_{-i}(\cdot)$ come il lisciatore ri-stimato senza (x_i, y_i) , la definizione è equivalente per lo stimatore a raggio, non per i k più vicini.

Derivazione delle formule per CV e GCV

Con la formula sopra si ottiene

$$\begin{aligned}
 y_i - \hat{y}_{-i} &= y_i - \frac{1}{1 - L_{ii}} \sum_{j \neq i} \ell_j(x_i) y_j \\
 &= y_i - \frac{1}{1 - L_{ii}} \left(\sum_{j=1}^n \ell_j(x_i) y_j - L_{ii} y_i \right) \\
 &= y_i - \frac{1}{1 - L_{ii}} (\hat{y}_i - L_{ii} y_i) \\
 &= \frac{1}{1 - L_{ii}} ((1 - L_{ii}) y_i - \hat{y}_i + L_{ii} y_i) = \frac{1}{1 - L_{ii}} (y_i - \hat{y}_i)
 \end{aligned}$$

e quindi la formula del GCV.

Altri criteri

Si noti che, essendo $(1 - x)^{-2} \approx 1 + 2x$ in un intorno di 0, il GCV è approssimativamente uguale al C_p di Mallow.

$$GCV = \frac{1}{n} \sum_{i=1}^n \left(\frac{Y_i - \hat{f}(x_i)}{1 - \nu/n} \right)^2 \approx \frac{1}{n} \sum_{i=1}^n \left(Y_i - \hat{f}(x_i) \right)^2 + \frac{2\nu\hat{\sigma}^2}{n} = C_p$$

Più in generale, molti criteri usati per la scelta del grado di lisciamento (k) hanno la forma

$$B(k) = \Lambda(n, k) \frac{1}{n} + \sum_{i=1}^n \left(Y_i - \hat{f}(x_i) \right)^2$$

per qualche funzione $\Lambda(\cdot, \cdot)$

Indice

- 1 Regressione non parametrica, caso gaussiano
- 2 Regressione col metodo del nucleo**
- 3 Spline
- 4 Verosimiglianza (somma dei quadrati) penalizzata
- 5 Stima della varianza
- 6 Altre basi
- 7 Più esplicative

Kernel regression

Con i metodi descritti sin qui, man mano che ci si muove lungo l'asse x , si calcola $\hat{f}(x)$ come media di differenti gruppi di osservazioni y_i .



Questo porta a una stima finale poco "liscia".



Un modo di lisciare maggiormente è di usare una media pesata dove il peso delle osservazioni decresce man mano che ci si allontana da x .

Stimatore di Nadaraya-Watson

Lo stimatore di Nadaraya-Watson è un lisciatore lineare

$$\hat{f}(x) = \sum_{i=1}^n \ell_i(x) Y_i$$

in cui

$$\ell_i(x) = \frac{K\left(\frac{x-x_i}{h}\right)}{\sum_{j=1}^n K\left(\frac{x-x_j}{h}\right)}$$

dove $K()$ è un nucleo.

Nuclei

Si ha

$$\hat{f}_n(x) = \frac{\sum_{i=1}^n K\left(\frac{x-X_i}{h}\right) Y_i}{\sum_{i=1}^n K\left(\frac{x-X_i}{h}\right)}$$

dove K è tale che

- $K(x) \geq 0$
- $\int K(x) dx = 1$
- $\int xK(x) dx = 0$
- $\int x^2 K(x) dx > 0$


Esempi di nuclei

	$K(u)$
Uniform	$\frac{1}{2} I_{[-1,1]}(u)$
Triangle	$(1 - u) I_{[-1,1]}(u)$
Triweight	$\frac{35}{32} (1 - u^2)^3 I_{[-1,1]}(u)$
Quartic	$\frac{15}{16} (1 - u^2)^2 I_{[-1,1]}(u)$
Gaussian	$\frac{1}{\sqrt{2\pi}} e^{-u^2/2}$
Epanechnikov	$\frac{3}{4} (1 - u^2) I_{[-1,1]}(u)$
Cosine	$\frac{\pi}{4} \cos\left(\frac{\pi}{2} u\right) I_{[-1,1]}(u)$

Kernel functions


Uniform

$$\frac{1}{2} I_{[-1,1]}(u)$$




Triangle

$$(1 - |u|) I_{[-1,1]}(u)$$




Triweight

$$\frac{35}{32} (1 - u^2)^3 I_{[-1,1]}(u)$$




Quartic

$$\frac{15}{16} (1 - u^2)^2 I_{[-1,1]}(u)$$




Cosine

$$\frac{\pi}{4} \cos\left(\frac{\pi}{2} u\right) I_{[-1,1]}(u)$$




Epanechnikov

$$\frac{3}{4} (1 - u^2) I_{[-1,1]}(u)$$



Gaussian

$$\frac{1}{\sqrt{2\pi}} e^{-u^2/2}$$



Nadaraya-Watson estimator: risk


Si mostra che, se x_i proviene dalla densità $g()$, per $h_n \rightarrow 0$ e $nh_n \rightarrow \infty$

$$R = \frac{h_n^4}{4} \left(\int u^2 K(u) du \right)^2 \int \left(f''(x) + 2f'(x) \frac{g'(x)}{g(x)} \right)^2 dx + \frac{\sigma^2 \int K^2(u) du}{nh_n} \int \frac{1}{g(x)} dx + o(nh_n^{-1}) + o(h_n^4)$$



Dove si nota che

- la varianza decresce con h
- la distorsione cresce con h^4
- la distorsione cresce con f''
- la distorsione cresce con $f'(x) \frac{g'(x)}{g(x)}$: *design bias*

Design bias e boundary bias



Boundary bias



N-W come mimimo

Notiamo che lo stimatore di N-W in x , $\hat{f}(x)$, è la soluzione di

$$\operatorname{argmin}_a \sum_{i=1}^n K_i \left(\frac{x_i - x}{h} \right) (Y_i - a)^2$$

cioè, lo stimatore di N-W è, localmente, uno stimatore dei minimi quadrati pesati.



Si potrebbe allora impiegare i minimi quadrati pesati ma con un polinomio anzichè una costante, per ogni valore di x si approssima $f()$ in un intorno di x con il polinomio

$$p_x(u; a) = a_0 + a_1(u - x) + \frac{a_2}{2!}(u - x)^2 + \dots + \frac{a_p}{p!}(u - x)^p$$

N-W come mimimo \rightarrow polinomi locali

Si potrebbe allora impiegare i minimi quadrati pesati ma con un polinomio anzichè una costante, per ogni valore di x si approssima $f()$ in un intorno di x con il polinomio

$$p_x(u; \mathbf{a}) = a_0 + a_1(u - x) + \frac{a_2}{2!}(u - x)^2 + \dots + \frac{a_p}{p!}(u - x)^p$$

e si stima $\mathbf{a}(x)$ (rendiamo esplicita la dipendenza da x) minimizzando

$$\hat{\mathbf{a}}(x) = \underset{\mathbf{a}}{\operatorname{argmin}} \sum_{i=1}^n K_i \left(\frac{x_i - x}{h} \right) (Y_i - p_x(X_i; \mathbf{a}))^2$$

e definiamo il seguente stimatore di $f(x)$

$$\hat{f}(x) = p_x(x, \hat{\mathbf{a}}) = \hat{a}_0(x)$$

Polinomi locali, notazione matriciale

Sia

$$X_x = \begin{bmatrix} 1 & x_1 - x & \cdots & \frac{1}{p!}(x_1 - x)^p \\ \vdots & \vdots & & \vdots \\ 1 & x_n - x & \cdots & \frac{1}{p!}(x_n - x)^p \end{bmatrix}$$

$$W_x = \text{diag} \left\{ K_i \left(\frac{x_i - x}{h} \right), i = 1, \dots, n \right\}$$

allora la somma dei quadrati pesata è

$$(Y - X_x a)^T W_x (Y - X_x a)$$

e

$$\hat{a} = (X_x^T W_x X_x)^T X_x^T W_x Y$$

Polinomi locali, notazione matriciale

$$\hat{\alpha} = (X_x^T W_x X_x)^T X_x^T W_x Y$$

Lo stimatore $\hat{f}(x) = \hat{\alpha}_0(x)$ è dunque

$$\hat{f}(x) = e_1^T (X_x^T W_x X_x)^T X_x^T W_x Y$$

dove $e_1^T = (1, 0, \dots, 0)$.

Quindi $\hat{f}(x)$ è un lisciatore lineare

$$\hat{f}(x) = \sum_{i=1}^n \ell_i(x) Y_i$$

dove

$$\ell(x)^T = (\ell_1(x), \dots, \ell_n(x))^T = e_1^T (X_x^T W_x X_x)^T X_x^T W_x$$

Lisciatore lineare locale

Posto $p = 1$, si ottiene lo stimatore lineare locale

$$\ell_i(x) = \frac{b_i(x)}{\sum_{j=1}^n b_j(x)}$$

dove

$$b_i(x) = K\left(\frac{x_i - x}{h}\right) (S_{n,2}(x) - (x_i - x)S_{n,1}(x))$$

$$S_{n,j}(x) = \sum_{i=1}^n K\left(\frac{x_i - x}{h}\right) (x_i - x)^j, \quad j = 1, 2$$

Lisciatore lineare locale: distorsione e varianza

Si mostra che il rischio in x è

$$R_x = \frac{h_n^4}{4} \left(\int u^2 K(u) du \right)^2 f''(x)^2 + \frac{\sigma^2 \int K^2(u) du}{g(x)nh_n} + o(nh_n^{-1}) + o(h_n^4)$$

Lisciatore lineare locale: distorsione e varianza

Si mostra che il rischio in x è

$$R_x = \frac{h_n^4}{4} \left(\int u^2 K(u) du \right)^2 f''(x)^2 + \frac{\sigma^2 \int K^2(u) du}{g(x)nh_n} + o(nh_n^{-1}) + o(h_n^4)$$

Se lo confrontiamo con quello dello stimatore di N-W notiamo che è scomparso il *design bias*.

$$R = \frac{h_n^4}{4} \left(\int u^2 K(u) du \right)^2 \int \left(f''(x) + 2f'(x) \frac{g'(x)}{g(x)} \right)^2 dx + \frac{\sigma^2 \int K^2(u) du}{nh_n} \int \frac{1}{g(x)} dx + o(nh_n^{-1}) + o(h_n^4)$$


Graphical representation

Graphical representation


Graphical representation: comparison

Boundary bias

N-W versus local linear, same bandwidth




Design bias and boundary bias



LIDAR: modello polinomiale

Assumiamo che $f()$ sia (approssimabile da) un polinomio

$$f(x; \beta) = \beta_0 + \beta_1 x + \beta_2 x^2 + \dots + \beta_p x^p$$



Il ruolo di k è svolto da p , al crescere di p

- aumenta la varianza
- diminuisce la distorsione

Problema: elevata correlazione dei $\hat{\beta}_j$


	x	$I(x^2)$	$I(x^3)$	$I(x^4)$
x	1.00	-0.00	-0.92	0.00
$I(x^2)$	-0.00	1.00	0.00	-0.96
$I(x^3)$	-0.92	0.00	1.00	-0.00
$I(x^4)$	0.00	-0.96	-0.00	1.00

LIDAR: modello lineare a tratti

In alternativa, si potrebbe usare un modello lineare a tratti

$$f(x; \beta) = \beta_{0,j} + \beta_{1,j}x \text{ se } c_{j-1} \leq x < c_j, j = 1, \dots, J$$

avendo suddiviso il supporto di x in intervalli (cfr costante a tratti).



Il ruolo di k è svolto da J , al crescere di J

- aumenta la varianza
- diminuisce la distorsione

Problema: la funzione che si ottiene non è continua.

Indice

- 1 Regressione non parametrica, caso gaussiano
- 2 Regressione col metodo del nucleo
- 3 Spline**
- 4 Verosimiglianza (somma dei quadrati) penalizzata
- 5 Stima della varianza
- 6 Altre basi
- 7 Più esplicative

Spline lineare: esempio con due nodi

Una soluzione più sofisticata si ottiene con

$$y_i = \beta_1 + \beta_2 x_i + \beta_3 (x_i - \nu_1)_+ + \beta_4 (x_i - \nu_2)_+ + \varepsilon_i$$

dove

$$(x)_+ = \begin{cases} x & \text{se } x > 0 \\ 0 & \text{altrimenti} \end{cases}; \quad (x - \nu)_+ = \begin{cases} x - \nu & \text{se } x > \nu \\ 0 & \text{altrimenti} \end{cases}$$


- $\varepsilon_i \sim IID(\mathcal{N}(0, \sigma^2))$,
- ν_1 e ν_2 , detti nodi, sono valori fissati nel supporto di x
- β_i sono stimati come al solito:

$$\hat{\beta} = \underset{\beta}{\operatorname{argmin}} \sum_{i=1}^n (y_i - f(x_i; \beta))^2$$

dove

$$f(x_i; \beta) = \beta_1 + \beta_2 x_i + \beta_3 (x_i - \nu_1)_+ + \beta_4 (x_i - \nu_2)_+$$

Spline lineare: esempio con due nodi



È un modello lineare con esplicative

$$x_i, (x_i - \nu_1)_+, (x_i - \nu_2)_+$$

La funzione $\hat{f}(x)$ è una combinazione lineare delle funzioni

$$B_0(x) = x$$

$$B_1(x) = (x - \nu_1)_+$$

$$B_2(x) = (x - \nu_2)_+$$

dette funzioni base (in blu nel grafico).

Spline lineare: K nodi

Più in generale, si fissano K nodi

$$\nu_1, \dots, \nu_K$$

e si stima il modello lineare (attenzione alla notazione!)


$$y_i = \beta_1 + \beta_2 x_i + \sum_{k=1}^K b_k (x_i - \nu_k)_+ + \varepsilon_i$$

La funzione spline è rappresentata da


$$f(x) = \beta_1 + \beta_2 x + \sum_{k=1}^K b_k (x - \nu_k)_+$$

ed è tanto più liscia quanti meno nodi si usano (minore K).

Spline lineare: K nodi



Spline lineare: K nodi



Base con potenze troncate

Una naturale estensione della base lineare è data dalle potenze


$$y_i = \beta_1 + \beta_2 x_i + \dots + \beta_{p+1} x_i^p + \sum_{k=1}^K b_k (x_i - \nu_k)_+^p + \varepsilon_i$$

sicché la spline di ordine p con K nodi è


$$f(x) = \beta_1 + \beta_2 x + \dots + \beta_{p+1} x^p + \sum_{k=1}^K b_k (x - \nu_k)_+^p$$

- Una spline di grado p ha $p - 1$ derivate continue,
- $p = 3$ è adeguato per gli scopi usuali.





Base con potenze troncate



Base con potenze troncate



TPB: diversi gradi



Levigatezza (smoothness) della spline e numero di nodi

Per quanto visto sin qui, la spline è più o meno liscia (meno o più flessibile) a seconda del numero di nodi (fissato il grado):

- 0 nodi: si riduce a un polinomio di grado p ;
- al crescere del numero di nodi, la funzione è sempre più flessibile (meno liscia);
- tanti nodi quante le osservazioni distinte: $\hat{f}(x)$ interpola i punti esattamente;
- più nodi delle osservazioni distinte: il modello non è identificato.

(Si noti anche che la posizione dei nodi determina in quali regioni la spline è più o meno liscia.)



D'altra parte, più sono i nodi, più sono i parametri da stimare, quindi la maggior flessibilità si “paga” in termini di variabilità degli stimatori.

Levigatezza della spline e numero di nodi: distorsione v. varianza

La scelta del numero di nodi ha un ruolo analogo alla scelta del numero k di vicini più vicini, implicando un *trade off* tra distorsione e varianza

- più nodi \leftrightarrow meno liscia \leftrightarrow meno dist. più varianza;
- meno nodi \leftrightarrow più liscia \leftrightarrow più dist. meno varianza;

La scelta del grado di levigatezza della spline è cruciale.




In linea di principio, potremmo individuare il livello ottimale di levigatezza scegliendo il numero di nodi che minimizza l'errore quadratico medio: occorrerebbe stimare funzioni spline corrispondenti a diverse scelte sul numero di nodi (glissiamo sul problema della loro posizione) e calcolare/stimare per ciascuna l'MSE.



Questa strategia è ragionevole ma complessa dal punto di vista numerico, nel seguito opteremo per un'alternativa.


Numero di nodi e distorsione

Spline di ordine 1 (in rosso) per diverse scelte dei nodi (rappresentati sull'asse x), in verde la vera $f(x)$.



Numero di nodi e distorsione

Spline di ordine 2 (in rosso) per diverse scelte dei nodi (rappresentati sull'asse x), in verde la vera $f(x)$.



Levigatezza della spline: nodi fissati

Una strategia differente prevede di fissare i nodi e quindi imporre qualche restrizione sui coefficienti tale che cambiando la restrizione si cambi il grado di levigatezza.

o
invece di stimare i coefficienti col metodo dei minimi quadrati, aggiungere una penalizzazione che favorisca funzioni più lisce.

Operando così, il grado di levigatezza dipende da un numero, che varia nel continuo.

Indice

- 1 Regressione non parametrica, caso gaussiano
- 2 Regressione col metodo del nucleo
- 3 Spline
- 4 Verosimiglianza (somma dei quadrati) penalizzata**
- 5 Stima della varianza
- 6 Altre basi
- 7 Più esplicative

Penalizzazione per la ruvidità

Dati i nodi e quindi una base, i parametri sono determinati minimizzando

$$\sum_{i=1}^n (y_i - f(x_i, \beta, \mathbf{b}))^2 + \lambda S(f(x, \beta, \mathbf{b}))$$

dove

- $S(f(x, \beta, \mathbf{b}))$ è una misura di quanto “ruvida” è $f()$,
- $\lambda > 0$ è (almeno per ora) una costante fissata.

Penalizzazione: tipo ridge

Una penalizzazione semplice è data da

$$S(f(x)) = \sum_{i=1}^K b_i^2 = \mathbf{b}^T \mathbf{b}$$

Si può mostrare che usare una penalizzazione di questo tipo equivale a porre un vincolo del tipo

$$\sum_{i=1}^K b_i^2 < C$$

per qualche C .

TPB in notazione matriciale

Consideriamo la base delle potenze troncate

$$f(x) = \beta_1 + \beta_2 x + \dots + \beta_{p+1} x^p + \sum_{k=1}^K b_k (x - \nu_k)_+^p$$

e poniamo

$$\theta = \begin{bmatrix} \beta_1 \\ \vdots \\ \beta_{p+1} \\ b_1 \\ \vdots \\ b_K \end{bmatrix}, \quad X = \begin{bmatrix} 1 & x_1 & x_1^2 & \vdots & x_1^p & (x_1 - \nu_1)_+^p & \dots & (x_1 - \nu_K)_+^p \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_i & x_i^2 & \vdots & x_i^p & (x_i - \nu_1)_+^p & \dots & (x_i - \nu_K)_+^p \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_n & x_n^2 & \vdots & x_n^p & (x_n - \nu_1)_+^p & \dots & (x_n - \nu_K)_+^p \end{bmatrix}$$

Quindi $f(x) = X\theta$ e il modello è

$$y = X\theta + \varepsilon$$

Penalizzazione e TPB

Consideriamo la penalizzazione ridge

$$S(f(x, \theta)) = \theta^T D \theta$$

dove $D = \text{diag}(0_{p+1}, 1_K)$,



Il minimo di

$$\sum_{i=1}^n (y_i - f(x_i, \theta))^2 + \lambda \theta^T D \theta$$

si ha per

$$\hat{\theta} = (X^T X + \lambda D)^{-1} X^T y$$

Quindi la spline, scritta in forma di lisciatore lineare, è

$$\hat{y} = X(X^T X + \lambda D)^{-1} X^T y$$

Quanti sono i parametri?

“Nominalmente” il modello ha $K + p + 1$ parametri (e la varianza)



Però, questi non possono variare liberamente per via della penalizzazione.



Il numero effettivo di parametri è valutato come la traccia della matrice di lisciamiento

$$\text{trace}(X(X^T X + \lambda D)^{-1} X^T)$$



(Analogamente, si ricordi che nel ML, il numero di parametri è la traccia della matrice di proiezione.)

Penalizzazione: derivata seconda

Un'alternativa è impiegare una derivata della funzione spline

$$S(f(x)) = \int (f^{(q)}(t))^2 dt$$

dove $q \leq$ grado della spline. (In genere $q = 2$ per una spline cubica.)

Si noti che, se la base è $B() = (B_1(), \dots, B_K())$, sicchè

$$\hat{f}(x) = \mathbf{b}^T B(x)$$

allora

$$S(f(x)) = \int (f^{(q)}(t))^2 dt = \mathbf{b}^T D \mathbf{b}$$


dove

$$D = \int_a^b B^{(q)}(x) [B^{(q)}(x)]^T dx$$


(In certi casi si usano approssimazioni.)

Funzioni e le loro derivate seconde

Si riportano tre funzioni e i quadrati delle derivate seconde.



Spline penalizzate



Nel grafico si riportano 3 spline stimate usando 40 nodi con diversi pesi per la penalizzazione (tipo ridge).

Spline penalizzate e non

Quindi quanti nodi?

Il trucco della penalizzazione fa sì che possiamo fissare i nodi all'inizio, come però?

- L'idea è che, siccome si usa la penalizzazione, la scelta dei nodi è poco importante purché
 - non siano troppo pochi (in generale: da 20 a 40 minimo),
 - ci siano osservazioni tra i nodi (almeno 4-5 osservazioni tra uno e l'altro)
- Si possono fissare tanti nodi quante le osservazioni, può essere però computazionalmente oneroso e, in genere, non è necessario.
- Strategie tipiche per la scelta della posizione dei nodi sono
 - quantili empirici di x
 - nodi equispaziati.

Da qui in poi, i nodi ν_1, \dots, ν_K sono fissati in qualche modo.

(Si noti che possiamo verificare se i nodi sono in numero sufficiente stimando il modello con un numero maggiore e verificando se le cose cambiano.)

Indice

- 1 Regressione non parametrica, caso gaussiano
- 2 Regressione col metodo del nucleo
- 3 Spline
- 4 Verosimiglianza (somma dei quadrati) penalizzata
 - Scelta di λ
 - Perché le spline
- 5 Stima della varianza
- 6 Altre basi

Scelta di λ

Il ruolo di λ è analogo alla scelta del numero di vicini o della banda.



Lo stesso criterio: validazione incrociata, può essere impiegato per la scelta.



Si noti che la spline è un lisciatore lineare, quindi i risultati visti in generale per i lisciatori lineari si possono impiegare anche ora.



Inoltre, anche la formula per il GCV è valida.

Errore quadratico complessivo



Let

$$\begin{aligned}
 R(\hat{f}) &= E \left(\sum_{i=1}^n (\hat{f}(x_i) - f(x_i))^2 \right) \\
 &= \sum_{i=1}^n [(E(\hat{f}(x_i)) - f(x_i))^2 + V(\hat{f}(x_i))] \\
 &= (E(L\mathbf{y}) - \mathbf{f})^T (E(L\mathbf{y}) - \mathbf{f}) + \sum_{i=1}^n V(L\mathbf{y})_{ii} \\
 &= \mathbf{f}^T (L - I)^T (L - I) \mathbf{f} + \text{trace}[V(L\mathbf{y})] \\
 &= \mathbf{f}^T (L - I)^T (L - I) \mathbf{f} + \text{trace}[LV(\mathbf{y})L^T] \\
 &= \mathbf{f}^T (L - I)^T (L - I) \mathbf{f} + \sigma_\varepsilon^2 \text{trace}[LL^T]
 \end{aligned}$$

In questa scomposizione, la prima parte rappresenta il quadrato della distorsione, la seconda è la varianza.



Errore quadratico complessivo

Esempio di scomposizione di R in distorsione e varianza



Gradi di libertà e penalizzazione

Il coefficiente λ determina la levigatezza della funzione stimata, è rilevante studiare come variano i gradi di libertà di \hat{f} ($df = \text{tr}(L)$) in funzione di λ .



Spline in R: `gam` (`mgcv`)

ci sono numerosi pacchetti per la stima di spline in R, uno dei più potenti e versatili è il pacchetto `mgcv` di Wood.



Le funzioni del pacchetto presentano molte opzioni, nella forma più semplice, comunque:

```
fit=gam(y~s(x))
fit.s=summary(fit)
plot(fit)
```

si effettua una stima scegliendo via GCV il parametro di lisciamo λ (la scelta dei nodi è fatta in maniera predefinita di cui non ci preoccupiamo, volendo si possono cambiare).

Stimare una spline con gam

Tra gli argomenti della funzione `s()`


`k` dimensione della base

`fx` se usare una penalizzazione

```
fit2=gam(y~s(x,k=3))  
fit4=gam(y~s(x,k=10))  
plot(fit2)  
plot(fit8)
```


LIDAR: GAM

```
plot(lidar$range, lidar$logratio, pch=20, xlab="x", ylab="y", ylim=c(-1, 0.2))
```




LIDAR: GAM

```
fit=gam(logratio~s(range),data=lidar)  
plot(fit)
```




LIDAR: GAM

```
plot(lidar$range, lidar$logratio, pch=20, xlab="x", ylab="y", ylim=c(-1, 0.2))  
curve(predict(fit, newdata=data.frame(range=x)), add=TRUE)
```



LIDAR: GAM

```
plot(lidar$range, lidar$logratio, pch=20, xlab="x", ylab="y", ylim=c(-1, 0.2))
xx=seq(min(lidar$range), max(lidar$range), length=100)
pr=predict(fit, newdata=data.frame(range=xx),
           se.fit=TRUE)
matlines(xx, cbind(pr$fit-2*pr$se.fit, pr$fit, pr$fit+2*pr$se.fit),
         type="l", lty=c(2,1,2), col="black")
```



LIDAR: GAM

```
summary(fit)
```

```
Family: gaussian
Link function: identity
```

```
Formula:
logratio ~ s(range)
```

```
Parametric coefficients:
```

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	-0.291156	0.005327	-54.65	<2e-16

```
(Intercept) ***
```

```
---
```

```
Signif. codes:
```

```
0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```
Approximate significance of smooth terms:
```

	edf	Ref.df	F	p-value
s(range)	7.874	8.67	297.8	<2e-16 ***

```
---
```


```
Signif. codes:
```

```
0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```
R-sq.(adj) = 0.921  Deviance explained = 92.4%
GCV = 0.0065345  Scale est. = 0.0062721  n = 221
```

LIDAR: GAM


```
plot(lidar$range, lidar$logratio, pch=20, xlab="x", ylab="y", ylim=c(-1, 0.2))
curve(predict(fit, newdata=data.frame(range=x)), add=TRUE)
fit1=gam(logratio~s(range, fx=TRUE, k=3), data=lidar)
curve(predict(fit1, newdata=data.frame(range=x)), add=TRUE, col="red")
```



Qualche esperimento con gam

“Verifichiamo” che il numero di nodi è indifferente purché abbastanza grande.


```
sim=data.frame(x=seq(0,1,length=200)) #sort(runif(150,0,1))
sim$m=sin(2*pi*sim$x^3)
sim$y=sim$m+rnorm(nrow(sim),0,0.4)
plot(sim$x,sim$y)
```



Qualche esperimento con gam

```
fit0=gam(y~s(x),data=sim)
fit1=gam(y~s(x,k=5),data=sim)
fit2=gam(y~s(x,k=12),data=sim)
fit3=gam(y~s(x,k=30),data=sim)
```

Qualche esperimento con gam



Indice

- 1 Regressione non parametrica, caso gaussiano
- 2 Regressione col metodo del nucleo
- 3 Spline
- 4 Verosimiglianza (somma dei quadrati) penalizzata
 - Scelta di λ
 - Perché le spline
- 5 Stima della varianza
- 6 Altre basi

Spline


Una spline di ordine p con nodi ν_1, \dots, ν_K è un polinomio a tratti continuo con derivate continue fino all'ordine $p - 1$.



Il termine spline deriva dal nome di un attrezzo da disegno (una striscia di metallo flessibile usata per agevolare il disegno di curve).



Una **spline cubica** è una spline di ordine $p = 3$ (continua con derivata seconda continua).



A spline, or the more modern term flexible curve, consists of a long strip fixed in position at a number of points that relaxes to form and hold a smooth curve passing through those points for the purpose of transferring that curve to another material. (Wikipedia)

Le spline naturali cubiche sono interpolanti ottimali

Sia

- (x_i, y_i) , $i = 1, \dots, n$: dove $x_i < x_{i+1}$
- $g(x)$ la spline cubica naturale che interpola i punti (naturale significa che $g''(x_1) = g''(x_n) = 0$)

allora $g()$ è l'interpolante più liscia nel senso che minimizza

$$J(f) = \int_{x_1}^{x_n} f''(x)^2 dx$$

tra le funzioni f che interpolano i punti, sono assolutamente continue e hanno derivata prima continua.



In altre parole, le spline cubiche naturali sono le funzioni più lisce per interpolare dei punti.

Dimostrazione

Sia $f()$ interpolante (x_i, y_i) e sia $h = f - g$

$$\begin{aligned} \int_{x_1}^{x_n} f''(x)^2 dx &= \int_{x_1}^{x_n} (g''(x) + h''(x))^2 dx \\ &= \int_{x_1}^{x_n} g''(x)^2 dx + \int_{x_1}^{x_n} g''(x)h''(x) dx + \int_{x_1}^{x_n} h''(x)^2 dx \end{aligned}$$

Dimostrazione

Sia $f()$ interpolante (x_i, y_i) e sia $h = f - g$

$$\int_{x_1}^{x_n} f''(x)^2 dx = \int_{x_1}^{x_n} g''(x)^2 dx + \int_{x_1}^{x_n} g''(x)h''(x) dx + \int_{x_1}^{x_n} h''(x)^2 dx$$

Si ha anche, integrando per parti

$$\begin{aligned} \int_{x_1}^{x_n} g''(x)h''(x) dx &= g''(x_n)h'(x_n) - g''(x_1)h'(x_1) - \int_{x_1}^{x_n} g'''(x)h'(x) dx \\ &= - \int_{x_1}^{x_n} g'''(x)h'(x) dx \\ &= - \sum_{i=1}^{n-1} g'''(x_i^+) \int_{x_1}^{x_n} h'(x) dx \\ &= - \sum_{i=1}^{n-1} g'''(x_i^+) (h(x_{i+1}) - h(x_i)) = 0 \end{aligned}$$

Dimostrazione

Sia $f()$ interpolante (x_i, y_i) e sia $h = f - g$

$$\int_{x_1}^{x_n} f''(x)^2 dx = \int_{x_1}^{x_n} g''(x)^2 dx + \int_{x_1}^{x_n} g''(x)h''(x) dx + \int_{x_1}^{x_n} h''(x)^2 dx$$

Si ha anche, integrando per parti

$$\int_{x_1}^{x_n} g''(x)h''(x) dx = 0$$

Quindi

$$\int_{x_1}^{x_n} f''(x)^2 dx = \int_{x_1}^{x_n} g''(x)^2 dx + \int_{x_1}^{x_n} h''(x)^2 dx \geq \int_{x_1}^{x_n} g''(x)^2 dx$$

dove si ha l'eguaglianza sse $h''(x) = 0$ per $x_1 < x < x_n$ cioè solo se $f = g$.

Conseguenza

La proprietà sopra significa che se minimizzo

$$\sum_{i=1}^n (y_i - f(x_i))^2 + \lambda \int f''(x)^2 dx$$

tra tutte le funzioni f continue con derivata prima continua su $[x_1, x_n]$, allora il minimo è una spline cubica naturale.



DIM: supponiamo che f^* minimizzi l'espressione sopra e non sia una spline cubica naturale, allora si prenda la spline cubica naturale che interpola $(x_i, f^*(x_i))$, questa comporta la medesima somma dei quadrati degli scarti, ma con una minore penalizzazione.

Indice

- 1 Regressione non parametrica, caso gaussiano
- 2 Regressione col metodo del nucleo
- 3 Spline
- 4 Verosimiglianza (somma dei quadrati) penalizzata
- 5 Stima della varianza**
- 6 Altre basi
- 7 Più esplicative

Stima della varianza

La varianza dell'errore σ^2 può essere stimata, analogamente a quanto si fa nel ML, con

$$\hat{\sigma}^2 = \frac{\sum_{i=1}^n (y_i - \hat{f}(x_i))^2}{n - \text{df}} = \frac{RSS}{n - \text{df}}$$

dove i gradi di libertà della spline sono $\text{tr}(L)$.

Si noti però che

$$\begin{aligned} E(RSS) &= E((y - \hat{y})^T (y - \hat{y})) \\ &= E(y^T (L - I)^T (L - I) y) \\ &= f^T (L - I)^T (L - I) f + \sigma^2 \text{tr}((L - I)^T (L - I)) \\ &= f^T (L - I)^T (L - I) f + \sigma^2 (\text{tr}(LL^T) - 2\text{tr}(L) + n) \end{aligned}$$

quindi, assumendo che la distorsione sia trascurabile, uno stimatore non distorto per σ^2 è

$$\tilde{\sigma}^2 = \frac{RSS}{n - 2\text{tr}(L) + \text{tr}(LL^T)}$$

Stima della varianza

La varianza dell'errore σ^2 può essere stimata, analogamente a quanto si fa nel ML, con

$$\hat{\sigma}^2 = \frac{\sum_{i=1}^n (y_i - \hat{f}(x_i))^2}{n - \text{df}} = \frac{RSS}{n - \text{df}}$$

dove i gradi di libertà della spline sono $\text{tr}(L)$.

Si noti però che

$$\begin{aligned} E(RSS) &= E((y - \hat{y})^T (y - \hat{y})) \\ &= f^T (L - I)^T (L - I) f + \sigma^2 (\text{tr}(LL^T) - 2\text{tr}(L) + n) \end{aligned}$$

quindi, assumendo che la distorsione sia trascurabile, uno stimatore non distorto per σ^2 è



$$\tilde{\sigma}^2 = \frac{RSS}{n - 2\text{tr}(L) + \text{tr}(LL^T)}$$

Dove si ha che

- $n - 2\text{tr}(L) + \text{tr}(LL^T)$ sono i GdL residui del modello
- $2\text{tr}(L) - \text{tr}(LL^T)$ è una misura alternativa dei GdL del modello

Gradi di libertà: le due misure

Le due misure dei gradi di libertà differiscono in particolare per valori "centrali" di λ .



Indice

- 1 Regressione non parametrica, caso gaussiano
- 2 Regressione col metodo del nucleo
- 3 Spline
- 4 Verosimiglianza (somma dei quadrati) penalizzata
- 5 Stima della varianza
- 6 Altre basi**
- 7 Più esplicative

Spline: diverse rappresentazioni

- In termini generali la rappresentazione è

$$y_i = \beta_1 + \sum_{k=1}^K b_k B_k(z_i) + \text{other variables} + \varepsilon_i$$

per un dato insieme di funzioni note B_1, \dots, B_K che è detta **base**.

- Questo fa sì che lo spazio di funzioni in cui cerchiamo un'approssimazione di f contiene funzioni del tipo

$$s(z) = \sum_{k=1}^K b_k B_k(z)$$

- Ci sono diverse scelte di $B_k(z)$ che fan sì che si ottengano forme flessibili a partire da un numero ridotto di $B_k(z)$ (basso K),
- una buona scelta di queste funzioni rende gli stimatori più efficienti.

Basi alternative

La base a polinomi troncati è la più agevole da trattare dal punto di vista teorico, non è ottimale dal punto di vista computazionale.



Il problema principale è che la matrice di disegno X ha colonne fortemente correlate, il che può comportare instabilità numerica.



Esistono numerose alternative

- B -spline
- P -spline
- base radiale
- ...

Si tenga presente che, in linea di principio, un cambio di base non comporta un cambiamento del modello.

B-spline: costruzione della base

- siano $\tau_1 < \dots < \tau_K$ i nodi interni;
- sia $[a, b]$ il supporto di x ($a < \tau_1$, $b > \tau_K$);
- fissati, arbitrariamente, $\xi_1 \leq \dots \leq \xi_M \leq a$ e $\chi_M \geq \dots \geq \chi_1 \geq b$ (ad es. $\xi_j = a$ e $\nu_j = b$);
- si ha allora la sequenza ν_1, \dots, ν_{K+2M} .



B-spline: costruzione della base

Sia $B_{i,m}$ l' i -esima funzione base di ordine $m < M$, $i = 1, \dots, K + 2M - m$, questa è definita ricorsivamente da

$$B_{i,1}(x) = \begin{cases} 1 & \text{if } \nu_i \leq x < \nu_{i+1} \\ 0 & \text{altrimenti} \end{cases}$$


per $i = 1, \dots, K + 2M - 1$ e

$$B_{i,m}(x) = \frac{x - \nu_i}{\nu_{i+m-1} - \nu_i} B_{i,m-1}(x) + \frac{\nu_{i+m} - x}{\nu_{i+m} - \nu_{i+1}} B_{i+1,m-1}(x)$$

$i = 1, \dots, K + 2M - m$.

Per $M = 4$ si ottengono $K + 4$ spline cubiche.

B-spline



B-spline: matrice di penalizzazione

Fissato $M = 4$, la matrice di penalizzazione ha elemento i, j

$$\Omega_{ij} = \int_a^b B_i''(x) B_j''(x) dx$$

Wand and Ormerod (2009) propongono, per il calcolo di Ω ,

$$\Omega = (\tilde{B}'')^T \text{diag}(w) \tilde{B}''$$

where

$$[\tilde{B}'']_{ij} = \tilde{B}_j(\tilde{x}_i) \in \mathcal{M}_{3(K+7) \times (K+4)}$$

$$\tilde{x} = \left(\nu_1, \frac{\nu_1 + \nu_2}{2}, \nu_2, \dots, \nu_{K+7}, \frac{\nu_{K+7} + \nu_{K+8}}{2}, \nu_{K+8} \right)$$

$$w = \left(\frac{1}{6}(\Delta\nu)_1, \frac{4}{6}(\Delta\nu)_1, \frac{1}{6}(\Delta\nu)_1, \dots, \frac{1}{6}(\Delta\nu)_{K+7}, \frac{4}{6}(\Delta\nu)_{K+7}, \frac{1}{6}(\Delta\nu)_{K+7} \right)$$

where $(\Delta\nu)_h = \nu_{h+1} - \nu_h$.

P-spline

Le P -spline sono costituite da


- una base di B -spline, di solito su nodi equidistanti
- la penalizzazione

$$\sum_{i=1}^{K-1} (b_{i+1} - b_i)^2$$

ovvero

$$\mathbf{b}^T \begin{bmatrix} 1 & -1 & 0 & \cdot & \cdot \\ -1 & 2 & -1 & \cdot & \cdot \\ 0 & -1 & 2 & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \end{bmatrix} \mathbf{b}$$

Un esempio di P -spline



Due P -spline, per quella a sinistra

$$\sum_{i=1}^{K-1} (b_{i+1} - b_i)^2 = 9.95$$

mentre per quella a destra


$$\sum_{i=1}^{K-1} (b_{i+1} - b_i)^2 = 1.45$$

(pannello di mezzo: funzioni base moltiplicate per i rispettivi coefficienti, cioè la cui somma è la curva finale.)

Base radiale

La base radiale di ordine m con nodi ν_1, \dots, ν_K è

$$1, x, \dots, x^m, B_k(x) = |x - \nu_k|^m$$



Con matrice di penalizzazione

$$[D]_{ij} = |\nu_i - \nu_j|^3$$

Indice

- 1 Regressione non parametrica, caso gaussiano
- 2 Regressione col metodo del nucleo
- 3 Spline
- 4 Verosimiglianza (somma dei quadrati) penalizzata
- 5 Stima della varianza
- 6 Altre basi
- 7 Più esplicative**

Più esplicative

Supponiamo che le osservazioni includano più esplicative

$$x_i, z_i, u_{i1}, \dots, u_{iq}$$

Si possono ipotizzare diversi modelli

- componenti parametriche e una componente non parametrica

$$y_i = \beta^T u_i + f(x_i) + \varepsilon_i$$

- componenti parametriche e non parametriche

$$y_i = \beta^T u_i + f_x(x_i) + f_z(z_i) + \varepsilon_i$$

- componenti parametriche e non parametrica multipla

$$y_i = \beta^T u_i + f(x_i, z_i) + \varepsilon_i$$

Componenti parametriche e non parametrica

Data per la spline f la rappresentazione

$$f(x_i) = b_0 + b_1 x_i + \sum_{j=1}^K B_j(x_i) b_{1+j}$$

con matrice di penalizzazione S il modello

$$y_i = \beta^T \mathbf{u} + f(x_i) + \varepsilon_i$$

è stimato minimizzando la funzione obiettivo

$$\sum_{i=1}^n (y_i - \beta^T \mathbf{u}_i - f(x_i))^2 + \lambda \mathbf{b}^T S \mathbf{b}$$

in forma matriciale

$$\|\mathbf{y} - H\boldsymbol{\theta}\|^2 + \lambda \boldsymbol{\theta}^T S' \boldsymbol{\theta}$$

dove

$$H = [U \ X], \quad \boldsymbol{\theta}^T = (\boldsymbol{\beta}, \mathbf{b}), \quad S' = ?$$

Componenti parametriche e non parametriche

Siano le due spline f_x , f_z rappresentate da

$$f_x(x_i) = b_0 + b_1 x_i + \sum_{j=1}^{K_B} B_j(x_i) b_{1+j}$$

$$f_z(z_i) = d_1 z_i + \sum_{j=1}^{K_D} D_j(z_i) d_{1+j}$$

con penalizzazioni S_B, S_D .

Si noti che la rappresentazione di f_z non include l'intercetta per garantire l'identificabilità del modello

$$y_i = \beta^T \mathbf{u}_i + f_x(x_i) + f_z(z_i) + \varepsilon_i$$

Componenti parametriche e non parametriche

Il modello

$$y_i = \beta^T u_i + f_x(x_i) + f_z(z_i) + \varepsilon_i$$

è stimato minimizzando la funzione obiettivo

$$\sum_{i=1}^n (y_i - \beta^T u_i - f_x(x_i) - f_z(z_i))^2 + \lambda \mathbf{b}^T S_x \mathbf{b} + \lambda \mathbf{d}^T S_z \mathbf{d}$$

in forma matriciale

$$\|\mathbf{y} - H\boldsymbol{\theta}\|^2 + \lambda \mathbf{b}^T S_x \mathbf{b} + \lambda \mathbf{d}^T S_z \mathbf{d}$$

dove

$$H = [U \ X \ Z], \quad \boldsymbol{\theta}^T = (\beta, \mathbf{b}, \mathbf{d})$$

Componente non parametrica multivariata

Il modello

$$y_i = \beta^T u_i + f(x_i, z_i) + \varepsilon_i$$

richiede si definisca una spline bivariata.

- in linea di principio questo funziona allo stesso modo
- **problema della dimensionalità**
 - l'onere computazionale può crescere esponenzialmente con la dimensione
 - MSE: se il campione ha dimensione n e la spline dimensione d allora tipicamente

$$\text{MSE} \approx \frac{c}{n^{4/(4+d)}}$$

cioè la numerosità campionaria richiesta per mantenere l'MSE a un livello prespecificato cresce esponenzialmente con d :

$$n \approx (c/\delta)^{d/4}$$

Regressione non lineare in breve

Dettagli tecnici a parte, i punti essenziali sono che

- possiamo specificare un modello per y in cui

$$y_i = s(z_i) + \beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip} + \varepsilon_i$$

$$y_i = s(z_i) + \text{eff. lineari altre var.} + \text{error}$$

dove $s(\cdot)$ è una funzione liscia.

- disponiamo di strumenti per stimare $s(\cdot)$ con un prefissato grado di lisciamento (fix K , fix λ).
- disponiamo di strumenti per stimare $s(\cdot)$ con un grado di lisciamento ottimale.

Con questa strategia la forma della relazione tra y e z può essere qualunque (o quasi) senza bisogno di fare specifiche assunzioni.

Indice


- 1 Regressione non parametrica, caso gaussiano
- 2 Regressione col metodo del nucleo
- 3 Spline
- 4 Verosimiglianza (somma dei quadrati) penalizzata
- 5 Stima della varianza
- 6 Altre basi
- 7 Più esplicative

BPD data

La displasia broncopolmonare (BPD) è una malattia tipica dei bambini nati prematuramente, la cui insorgenza è plausibilmente legata al peso alla nascita (birthweight).

Per 223 bambini si è osservato

- birthweight
- insorgenza di displasia broncopolmonare (BPD)



La v. risposta è dicotomica \Rightarrow GLM.

Modelli additivi generalizzati

La generalizzazione a risposta non gaussiana funziona in modo analogo all'estensione da ML a GLM.

LM $Y_i \sim \mathcal{N}(\mu_i, \sigma^2)$ $E(Y_i) = \eta_i$ $\eta_i = \mu_i = \mathbf{x}_i\boldsymbol{\beta}$	→	GLM $Y_i \sim \text{Expon}(\theta_i, \phi_i)$ $g(E(Y_i)) = \eta_i$ $\eta_i = \mathbf{x}_i\boldsymbol{\beta}$
---	---	---

AM $Y_i \sim \mathcal{N}(\mu_i, \sigma^2)$ $E(Y_i) = \eta_i$ $\eta_i = \mu_i = f(\mathbf{x}_i)$	→	GAM $Y_i \sim \text{Expon}(\theta_i, \phi_i)$ $g(E(Y_i)) = \eta_i$ $\eta_i = f(\mathbf{x}_i)$
--	---	--

dove

$$\ell(\boldsymbol{\beta}, \mathbf{b}, \phi) = \sum_{i=1}^n \log(p(y_i; \theta_i)) = \sum_{i=1}^n (y_i\theta_i - r_i(\theta_i))/\phi + c(\phi; y_i)$$

Modelli additivi generalizzati

La generalizzazione a risposta non gaussiana funziona in modo analogo all'estensione da ML a GLM. Data una spline

$$f(x) = \beta_1 + \beta_2 x + \sum_{j=1}^K \beta_{1+j} B_j(x)$$

il criterio dei minimi quadrati penalizzati

$$\sum_{i=1}^n (y_i - f(x_i))^2 + \lambda S(f(x))$$

diventa il criterio della verosimiglianza penalizzata

$$\ell(\beta, \mathbf{b}, \phi) - \lambda S(f(x))$$

dove

$$\ell(\beta, \mathbf{b}, \phi) = \sum_{i=1}^n \log(p(y_i; \theta_i)) = \sum_{i=1}^n (y_i \theta_i - r_i(\theta_i)) / \phi + c(\phi; y_i)$$

P-IRLS

In termini pratici si usa poi l'algoritmo IRLS usato nei GLM, con passo **1** calcolare pseudodati

$$z_i^{[k]} = g'(\mu_i^{[k]})(y_i - \mu_i^{[k]}) + \eta_i^{[k]}$$

e la matrice diagonale dei pesi

$$W_{ii}^{[k]} = \frac{1}{V(\mu_i^{[k]})g'(\mu_i^{[k]})^2}$$

2 porre

$$\beta^{[k+1]} \leftarrow \underset{\beta}{\operatorname{argmin}} \left\| \sqrt{W^{[k]}}(z^{[k]} - X\beta) \right\|^2$$

In un modello additivo la funzione obiettivo nel secondo passo è

$$\beta^{[k+1]} \leftarrow \underset{\beta}{\operatorname{argmin}} \left\| \sqrt{W^{[k]}}(z^{[k]} - X\beta) \right\|^2 + \lambda \beta^T S \beta$$

Indice

- 1 Regressione non parametrica, caso gaussiano
- 2 Regressione col metodo del nucleo
- 3 Spline
- 4 Verosimiglianza (somma dei quadrati) penalizzata
- 5 Stima della varianza
- 6 Altre basi
- 7 Più esplicative

Errore di previsione con dati non Gaussiani

Con dati Gaussiani, la scelta di λ è basata sulla stima dell'errore

$$\sum_{i=1}^n (\hat{f}(x_i) - y_i)^2$$

ottenuta via CV, da cui il criterio del GCV (per via della linearità delle spline come lisciatori).



La stessa strategia può essere usata ora **ma** il lisciatore non è lineare, quindi il GCV e le derivazioni teoriche sono approssimate.

GCV per i GAM

L'obiettivo nella stima GAM può essere scritto in termini della devianza

$$D(\beta) = 2(\ell(\beta_{\max}) - \ell(\beta))$$

come

$$D(\beta) + \sum_{j=1}^d \lambda_j \beta^T S_j \beta$$

la cui approssimazione quadratica è, per un λ fissato,

$$\left\| \sqrt{W}(z - X\beta) \right\|^2 + \sum_{j=1}^d \lambda_j \beta^T S_j \beta$$

GCV per i GAM

L'obiettivo nella stima GAM può essere scritto come

$$D(\beta) + \sum_{j=1}^d \lambda_j \beta^T S_j \beta$$

la cui approssimazione quadratica è, per un λ fissato,

$$\left\| \sqrt{W}(z - X\beta) \right\|^2 + \sum_{j=1}^d \lambda_j \beta^T S_j \beta$$

da cui il GCV (valido localmente)

$$\frac{n \left\| \sqrt{W}(z - X\beta) \right\|^2}{n - \text{tr}(L)}$$

GCV per i GAM

L'obiettivo nella stima GAM può essere scritto come

$$D(\beta) + \sum_{j=1}^d \lambda_j \beta^T S_j \beta$$

la cui approssimazione quadratica è, per un λ fissato,

$$\left\| \sqrt{W}(z - X\beta) \right\|^2 + \sum_{j=1}^d \lambda_j \beta^T S_j \beta$$

da cui il GCV (valido localmente) e quindi il GCV applicabile globalmente

$$\frac{n \left\| \sqrt{W}(z - X\beta) \right\|^2}{n - \text{tr}(L)} \rightarrow \frac{nD(\hat{\beta})}{n - \text{tr}(L)}$$

UBRE

Ricordando che la CV nasce dal rischio di previsione, $E((m(x) - \hat{m}(x))^2)$,
cioè

$$E(\|\boldsymbol{\mu} - Ly\|^2) = \frac{1}{n} E(\|y - Ly\|^2) - \sigma^2 + 2\text{tr}(L) \frac{\sigma^2}{n}$$

dove il parametro di scala σ^2 è noto si può impiegare l'UBRE (Unbiased Risk Estimator)

$$\frac{1}{n} \|y - Ly\|^2 - \sigma^2 + 2\text{tr}(L) \frac{\sigma^2}{n}$$



L'UBRE è appropriato per i GAM in cui il parametro di scala è noto.

Calcolo dell'UBRE

A partire da

$$D(\beta) + \sum_{j=1}^d \lambda_j \beta^T S_j \beta$$

e dall'approssimazione quadratica

$$\left\| \sqrt{W}(z - X\beta) \right\|^2 + \sum_{j=1}^d \lambda_j \beta^T S_j \beta$$


si ottiene il criterio UBRE

$$\frac{1}{n} \left\| \sqrt{W}(z - X\beta) \right\|^2 - \sigma^2 + \frac{2\sigma^2}{n} \text{tr}(L)$$

$$\frac{1}{n} D(\hat{\beta}) - \sigma^2 + \frac{2\sigma^2}{n} \text{tr}(L)$$

BPD data - modello stimato


```
fit=gam(BPD~s(birthweight),
        data=bpd,
        family=binomial)
plot(fit)
```



BPD data - modello stimato

```

curve(predict(fit,newdata=data.frame(birthweight=x)),
       from=400,to=1800,ylab="")
rug(bpd$birthweight[bpd$BPD==0],side=1)
rug(bpd$birthweight[bpd$BPD==1],side=3)
    
```




BPD data - modello stimato

```


curve(predict(fit,newdata=data.frame(birthweight=x),
      type="response"),
      from=400,to=1800,ylab=""),
rug(bpd$birthweight[bpd$BPD==0],side=1)
rug(bpd$birthweight[bpd$BPD==1],side=3)

```




BPD data - modello stimato

```
xx=seq(450,1730,length=100)
pr=predict(fit,newdata=data.frame(birthweight=xx),
           type="response",se.fit=TRUE)
matplot(xx,cbind(pr$fit-2*pr$se.fit,pr$fit,pr$fit+2*pr$se.fit),
        type="l",lty=c(2,1,2),col="black")
```



BPD data - modello stimato

```
xx=seq(450,1730,length=100)
pr=predict(fit,newdata=data.frame(birthweight=xx),
           se.fit=TRUE)
matplot(xx,cbind(pr$fit-2*pr$se.fit,pr$fit,pr$fit+2*pr$se.fit),
        type="l",lty=c(2,1,2),col="black")
```



Regressione semiparametrica, i rischi

