



Neural Network Interest Group

Título/Title:

Estimação de FDPs

Autor(es)/Author(s):

J.P. Marques de Sá

Relatório Técnico/Technical Report No. 2 /2005

Título/*Title*:

Estimação de FDPs

(Tutorial Baseado no livro de Luc Devroye, Gábor Lugosi (2001), Springer-Verlag)

Autor(es)/*Author(s)*:

J.P. Marques de Sá

Relatório Técnico/*Technical Report* No. 2 /2005

Publicado por/*Published by*: NNIG. <http://paginas.fe.up.pt/~nnig/>

Dezembro de 2005



© INEB: FEUP/INEB, Rua Dr. Roberto Frias, 4200-465, Porto, Portugal

Estimação de FDPs

Texto Tutorial

baseado no livro de

Luc Devroye, Gábor Lugosi (2001). Springer-Verlag

J.P. Marques de Sá

INEB, Dezembro 2005

Índice

1	Varição Total	5
1.1	Definição	5
1.2	Distância L_1	5
1.3	Propriedades	7
2	Escolhendo uma Estimativa.....	7
2.1	Estimativa de Scheffé	7
2.2	Outros critérios de escolha	13
3	Estimação Usando Kernel	14
3.1	Aproximação funcional por convolução.....	14
3.2	Estimativa de kernel	15

1 Variação Total

1.1 Definição

Dada uma estimativa $f_n(x | X_1, \dots, X_n)$ baseada em X_1, \dots, X_n i.i.d. de $f(x)$, como avaliar a qualidade de estimação de probabilidades de f_n ?

Critério da **variação total**:


$$\sup_A \left| \int_A f_n - \int_A f \right|$$

A é qualquer conjunto de Borel

Trata-se do supremo, para qualquer conjunto de Borel, das probabilidades (áreas) calculadas pelas duas fdp's.

(Nota: é supremo e não max porque, como se sabe, os conjuntos de Borel podem ser construídos com intervalos abertos)

Exemplo:



1.2 Distância L_1

Medimos a semelhança entre duas fdp's pela sua distância L_1 : $\int |f - g|$


Há várias razões para usar L_1 :

1-

Teorema (identidade de Scheffé). Sejam f e g duas funções definidas em \mathfrak{R}^d tal que $\int f = \int g = 1$. Seja \mathcal{B} a classe de todos os conjuntos de Borel em \mathfrak{R}^d . Então:

$$\sup_{B \in \mathcal{B}} \left| \int_B f_n - \int_B f \right| = \frac{1}{2} \int |f - g|$$

Exemplo:



2-

Se $\int |f - g| < 0.04$ então, pelo teorema anterior, as diferenças em probabilidade são no máximo 0.02. Pelo contrário a interpretação de $\int (f - g)^2 < 0.04$ ou de $\int f \log(f/g) < 0.04$ não é evidente.

1.3 Propriedades

1. A variação total é invariante para transformações monotónicas dos eixos.
2. A variação total decresce para um qualquer mapeamento arbitrário, tal como a distância L_1 . Por exemplo, se f^+ e g^+ são as fdps de $\|X\|$ e $\|Y\|$, então

$$\int |f^+ - g^+| \leq \int |f - g|$$

3. A *convolução* também diminui a variação total:

$$\int |f * K - g * K| \leq \int |K| \int |f - g|$$

A demonstração deste facto baseia-se na *desigualdade de Young*:

$$\int |f * K| \leq \int |f| \int |K|$$

2 Escolhendo uma Estimativa

Dadas duas estimativas f_n e g_n de X_1, \dots, X_n i.i.d. de $f(x)$, escolhemos uma delas usando L_1 :

$$\arg \min \left(\int |f_n - f|, \int |g_n - f| \right)$$

Ou, de forma mais geral, queremos construir uma estimativa ϕ_n tal que:

$$\int |\phi_n - f| \approx \min \left(\int |f_n - f|, \int |g_n - f| \right)$$

Trata-se de um problema difícil.

2.1 Estimativa de Scheffé

Seja:


1. $\mu_n(A) = (1/n) \sum_{i=1}^n I_{x_i \in A}$ a *medida empírica* de A .
2. $A(f_n, g_n) = \{x : f_n(x) > g_n(x)\}$ o *conjunto de Scheffé* do par (f_n, g_n)

A *estimativa de Scheffé* é definida como:

$$f_n^* = \begin{cases} f_n & \text{se } \left| \int_A f_n - \mu_n(A) \right| < \left| \int_A g_n - \mu_n(A) \right| \\ g_n & \text{noutro caso} \end{cases}$$

Esta definição não é simétrica em f_n e g_n !

Exemplo:



<pre>>> s = scheffeset(f,g); [-1.95,1.95] >> c = empmeasure(a,x,s) c = 0.6667 (10 pontos em 15) >> d = distemp(f,a,x,s) d = 0.2690 >> d = distemp(g,a,x,s) d = 0.0178</pre> <p style="text-align: right;">Escolhe g</p>	<pre>>> s = scheffeset(g,f); [-6,-1.9]∪[1.9,6] >> c = empmeasure(a,x,s) c = 0.3333 (5 pontos em 15) >> d = distemp(f,a,x,s) d = 0.2758 >> d = distemp(g,a,x,s) d = 0.1300</pre> <p style="text-align: right;">Escolhe f</p>
---	---

Teorema

Sejam duas estimativas f_n e g_n de X_1, \dots, X_n i.i.d. de $f(x)$ com área unitária. Para a estimativa de Scheffé, temos:

$$\int |f_n^* - f| \leq 3 \min\left(\int |f_n - f|, \int |g_n - f|\right) + 4 \max_{A \in \mathcal{A}} \left| \int_A f - \mu_n(A) \right|$$

com $\mathcal{A} = \{\{f_n > g_n\}, \{g_n > f_n\}\}$


Suponhamos k fdp's candidatas, f_{ni} , e que escolhemos a que vence para o maior número de $k(k-1)/2$ pares de comparações. Chamemos-lhe a fdp vencedora do torneio Scheffé.

Teorema

Para a vencedora do torneio Scheffé temos: $\int |f_n^* - f| \leq 9 \min_i \left(\int |f_{ni} - f|\right) + 16\Delta$,


onde Δ é o supremo para todos os conjuntos de Scheffé de $\left| \int_A f - \mu_n(A) \right|$

Exemplo 1




```
>> expscheffe(50,0.3,0.05); %h1=1; h2=0.3
Distancia L1 de f a fn:      0.2005
Distancia L1 de f a gn:      0.1816
Variação total em {fn>gn} de fn face `a dist. empirica:  0.2330
Variação total em {fn>gn} de gn face `a dist. empirica:  0.1853
A estimativa Scheffe e´ gn
Variação total em {fn>gn} de f face `a dist. empirica:  0.1747
Variação total em {gn>fn} de f face `a dist. empirica:  0.2019
Majorante:      1.3524
```

Exemplo 2



```
>> expscheffe(250,0.3,0.01); %h1=1; h2=0.3
Distancia L1 de f a fn:      0.0743
Distancia L1 de f a gn:      0.0639
Variação total em {fn>gn} de fn face `a dist. empirica:    0.0466
Variação total em {fn>gn} de gn face `a dist. empirica:    0.0276
A estimativa Scheffe e´ gn
Variação total em {fn>gn} de f face `a dist. empirica:      0.0279
Variação total em {gn>fn} de f face `a dist. empirica:      0.0244
Majorante:      0.3034
```

Exemplo 3



```
>> expscheffe(20,1,1,0.05);
```

```
Distancia L1 de f a fn:      0.4662
```

```
Distancia L1 de f a gn:      0.4075
```

```
Variação total em {fn>gn} de fn face `a dist. empirica:      0.0425
```

```
Variação total em {fn>gn} de gn face `a dist. empirica:      0.2590
```


```
A estimativa Scheffe e' fn
```

```
Variação total em {fn>gn} de f face `a dist. empirica:      0.2186
```

```
Variação total em {gn>fn} de f face `a dist. empirica:      0.1042
```

```
Majorante:      2.0968
```

Exemplo 4



```
>> expscheffe(250,1,2,0.05);
```

```
Distancia L1 de f a fn:      0.1542
```

```
Distancia L1 de f a gn:      0.6704
```

```
Variacao total em {fn>gn} de fn face `a dist. empirica:  0.0100
```

```
Variacao total em {fn>gn} de gn face `a dist. empirica:  0.3615
```

```
A estimativa Scheffe e' fn
```

```
Variacao total em {fn>gn} de f face `a dist. empirica:  0.0059
```

```
Variacao total em {gn>fn} de f face `a dist. empirica:  0.0034
```

```
Majorante:      0.4861
```

Exemplo 5

Se f_n e g_n são fdp's normais que estimam f , é possível mostrar que:

$$E\left[\int |f_n^* - f| - 3 \min\left(\int |f_n - f|, \int |g_n - f|\right)\right] \leq \frac{8}{\sqrt{n}}$$

Desigualdades deste tipo existem para outras situações de f_n e g_n ; o factor "3" é inescapável.

A estimativa de Scheffé parece ser a única que oferece garantias de majorante do erro.

2.2 Outros critérios de escolha

Escolha de Máxima Verosimilhança

O problema com este critério é que mesmo em situações idealizadas não minimiza L_1 .


Exemplo:

Seja:

f : uniforme em $[0,1]$

f_n : uniforme em $[-1,1]$

g_n : uniforme em $[\delta, 1+\delta]$



Dado X_1, \dots, X_n i.i.d. de $f(x)$, a escolha de máxima verosimilhança (m.v.) consiste em escolher:

$$\phi_n(x) \stackrel{\text{def}}{=} \arg \max \left(\prod_{i=1}^n f_n(x_i), \prod_{i=1}^n g_n(x_i) \right)$$

Seja N o número de pontos que cai em $[0, \delta]$, uma v.a. binomial (n, δ) . Então g_n é escolhido sse $N = 0$.

Dado que as distâncias L_1 são $\int |f_n - f| = 1$ e $\int |g_n - f| = 2\delta$, a melhor escolha para $\delta < 1/2$ é g_n . Ora, vejamos a diferença entre a distância L_1 média de ϕ_n face a f e a distância de g_n face a f (o mesmo é dizer a diferença entre o erro médio da escolha m.v. e o erro da escolha óptima):

$$\begin{aligned} E[\int |\phi_n - f|] - \int |g_n - f| &= (P(N=0) \times 2\delta + P(N>0) \times 1) - 2\delta = \\ &= P(N>0) + (1 - P(N>0))2\delta - 2\delta = (1 - 2\delta)P(N>0) = \\ &= (1 - 2\delta)(1 - (1 - \delta)^n) \xrightarrow{n \rightarrow \infty} 1 - 2\delta \end{aligned}$$

Isto é, à medida que δ decresce, sendo o erro da escolha g_n desprezável, obtém-se com $n \rightarrow \infty$ uma escolha de m.v. com erro catastrófico!


Escolha baseada na distância L_2

Mesmo em casos simples de funções de quadrado integrável a escolha baseada na distância L_2 pode levar a decisões incorrectas.

Exemplo

Seja:

f : uniforme em $[0,1]$
 f_n : $1-\varepsilon$ em $[0,1]$ e ε^3 em $[1,1+1/\varepsilon^2]$
 g_n : uniforme em $[-\varepsilon^2,1-\varepsilon^2]$



Temos:

$$\int |f_n - f| = 2\varepsilon; \quad \int |g_n - f| = 2\varepsilon^2$$

Logo a escolha acertada é claramente g_n .

Contudo:

$$\int (f_n - f)^2 = \varepsilon^2 + \varepsilon^4 < 2\varepsilon^2 = \int (g_n - f)^2$$

3 Estimação Usando Kernel

A variação total de uma fdp relativamente a uma estimativa discreta como μ_n é 1. Precisamos de suavizar μ_n por forma a diminuir a variação total. Fazemos isso recorrendo à convolução com um kernel.

3.1 Aproximação funcional por convolução

$$\text{Convolução: } f * g(x) = \int f(y)g(x-y)dy = \int g(y)f(x-y)dy$$

Se f e g são as fdp's de X e Y , $f * g$ é a fdp de $X+Y$.

Se g é concentrada em torno de 0, $f * g$ aproxima-se de f .

Teorema

Seja K uma qualquer função integrável em \mathfrak{R}^d ($\int |K| < \infty$) e f uma fdp em \mathfrak{R}^d .

Designando $K_h(x) = (1/h)^d K(x/h)$, $x \in \mathfrak{R}^d$ $h > 0$, temos:

$$\lim_{h \rightarrow 0} \int |f * K_h - f \int K| = 0$$

•

3.2 Estimativa de kernel

Kernel: função K tal que $\int |K| < \infty$ e $\int K = 1$.

Para escolher f_n tal que $\int |f_n - f|$ seja pequeno fazemos uso do facto de que $\int |f * K_h - f|$ é pequeno quando h é pequeno e aproximamos $f * K_h$ por $\mu_n * K_h$.

A estimativa de kernel é:

$$f_n(x) = \mu_n * K_h = \frac{1}{n} \sum_{i=1}^n K_h(x - X_i) = \frac{1}{nh^d} \sum_{i=1}^n K\left(\frac{x - X_i}{h}\right)$$

"Variable kernel estimate": $h = h(x)$

"Data-dependent kernel estimate": $h = h(X_1, \dots, X_n)$

Consistência das estimativas de kernel:

Teorema

Seja K um kernel fixo e h dependente apenas de n . Se $h \rightarrow 0$ e $nh^d \rightarrow \infty$ quando $n \rightarrow \infty$, então $E[|f_n - f|] \rightarrow 0$.

•


FTYPE

case 0: uniforme(-1,1);

case 1: normal(0,1);

case 2: exp(1);

case 3: lognormal(0,1);
 case 4: cauchy(0);



KERNELTYPE

- 0 % uniform
- 1 % gaussian
- 2 % Epanechnikov
- 3 % Cauchy

