

20

MÉTODO DE  
GILBERT-BACKUS

### 7.3. SOLUTION IN TERMS OF KERNELS

From  $M$  measurements  $\int K_1(x) f(x) dx, \int K_2(x) f(x) dx, \dots, \int K_M(x) f(x) dx$  one can evidently only obtain information on the projection of  $f(x)$  on to the function subspace spanned by the kernels  $K_1(x), K_2(x), \dots, K_M(x)$ . In other words, the most general solution which can be legitimately obtained is:

$$f(x) = \xi_1 K_1(x) + \xi_2 K_2(x) + \dots + \xi_M K_M(x) + \psi(x)$$

where  $\psi(x)$  is any (arbitrarily large) function orthogonal to the set of functions  $K_1(x), K_2(x), \dots, K_M(x)$ . Making this substitution into the fundamental integral equation one gets:

$$g_i = \int \sum_j K_i(x) K_j(x) \xi_j dx$$

$$\text{or } g = C\xi$$

$C$  being the covariance matrix  $\|\int K_i(x) K_j(x) dx\|$ . We have already seen that  $C$  is highly ill-conditioned (possesses very small eigenvalues) and the above equation is no more amenable to direct inversion than those encountered earlier. However, it does have the advantage that components orthogonal to the kernels are explicitly excluded from the solution, whereas in other methods they may tend to creep in. However, further smoothing of the solution by some means is still necessary in most instances and this is now less easy since explicit reference is no longer made to  $f(x)$  or  $f$  in the equation  $g = C\xi$ .

## GILBERT - BACKUS

$$g(y) = \int_a^b k(x, y) f(x) dx$$

TRIVIALIDAD EN TERMINOS  
DE ORDENADAS DISCRETAS

$$g(y_j) = \int_a^b k(x, y_j) f(x) dx$$

INVIRTIENDO FORMALMENTE

$$f(x_k) = \sum_j H_{kj} g(y_j)$$

$H_{kj}$  OPERADOR INVERSO

FORMALMENTE, SERÁ PUES

$$f(x_k) = \sum_j H_{kj} \int_a^b k(x, y_j) f(x) dx$$

$$= \int_a^b \left[ \sum_j H_{kj} k(x, y_j) \right] f(x) dx$$

$$\Rightarrow \left[ \sum_j H_{kj} k(x, y_j) \right] = S(x; x_k)$$

ESTA TRIVIALIDAD FORMAL  
SUGIERE LA IDEA  
SI ES POSIBLE ENCONTRAR  
COMBINACIONES LINEALES DE LOS  
DATOS  $g(y_j)$ , CON COEFICIENTES  
 $w(\gamma_j)$ , TALES QUE

$$s(x) = \sum_j w(\gamma_j) \cdot k(x, y_j)$$

SEA UNA FUNCION DE  $x$ ,  
LO MAS ESTRECHA POSIBLE  
ALREDEDOR DE ALGUN VALOR  
 $x_k$  DE  $x$  PRESCRITO:

LA FUNCION  $s(x)$  SERA'  
EN PRINCIPIO, DIFERENTE  
PARA CADA VALOR  $x_k$   
PRESCRITO.

SI, ALREDEDOR DE UN  $x_k$  PRESCRITO  
ENCONTRAMOS UNA FUNCION

$$S^k(x) = \sum_j w^k(\gamma_j) k(x, \gamma_j)$$

los pesos dependen de  $x_k$

MUY ESTRECHA, ALREDEDOR DE  $x^k$ :

$$S^k(x) \sim \delta(x - x_k)$$

EN

$$g(\gamma) = \int_a^b k(x, \gamma) f(x) dx$$

HACIENDO

$$\sum_j w(\gamma_j) g(\gamma_j) =$$

$$= \int_a^b \underbrace{\sum_j k(x, \gamma_j) w(\gamma_j)}_{\delta(x - x_k)} f(x) dx.$$

$$\approx \int_a^b \delta(x - x_k) f(x) dx = f(x_k)$$

HACIENDOLO PARA TODO  $x_k$

SE RESUELVE EL PROBLEMA

## PROBLEMA :

DADO  $x_k$

ENCONTRAR EL CONJUNTO DE COEFICIENTES  $\overset{k}{W}(y_j)$  ASOCIADOS, TAL QUE

$$S(x) = \sum_j^k W(y_j) K(x, y_j)$$

SEA UNA FUNCION DE  $x$  MUY ESTRECHA, ALREDEDOR DE  $x_k$

---

PARA MEDIR LA ANCHURA DE  $S(x)$  GILBERT + BACKUS PROponen LA FUNCIONAL

$$\int_a^b (x - x_k)^2 S(x)^2 dx$$

YA QUE (SALVO PARA FUNCIONES CATASTROFICAS), CUANTO MENOR SEA LA ANCHURA DE  $S(x)$ , MENOR SERA LA INTEGRAL

EN LA INTEGRAL ANTERIOR

$$\int_a^b (x - x_k)^2 S^k(x)^2 dx$$

QUE TENEMOS QUE MINIMIZAR

$$S^k(x)^2 = \sum_j W^k(y_j) \sum_L W^k(y_L) K(x, y_j) K(x, y_L)$$

LLAMANDO LA MATRIZ

$$N^k = \{ N_{jL}^k \}$$

$$N_{jL}^k = \int_a^b (x - x_k)^2 K(x, y_j) K(x, y_L) dx$$

TIENE QUE SER

$$\sum_j \sum_L W^k(y_j) W^k(y_L) N_{jL}^k$$

MINIMO

LO QUE NOS PROPORCIONARA'  
LOS COEFICIENTES  $W^k(y_j)$

MINIMIZAR LA FUNCIONAL

$$F = \overline{W}^k * \underline{N}^k \overline{W}^k$$

$$\sum_L N^k(l, j) W_j^k + \sum_L W_j^k N^k(j, l) = 0$$

$$2 \sum_L N^k(l, j) W_j^k = 0$$

SISTEMA HOMOGENEO  
INFINITAS SOLUCIONES.

NORMALIZACION DE  $S(x)$

$$\int_a^b S(x) dx = 1$$

O SEA

$$\sum_j W^k(y_j) \int_a^b K(x, y_j) dx = 1$$

NOTACION

$$\mathcal{K}(y_j) = \int_a^b K(x, y_j) dx$$

SON CONOCIDAS  
A PARTIR DEL NUCLEO

LIGADURA

$$\sum_j W^k(y_j) \mathcal{K}(y_j) = 1$$

$$\bar{W}^* \cdot \bar{\mathcal{K}} = 1$$

## MINIMIZAR LA FUNCIONAL

$$F = \bar{W}^k \sum_{j=1}^k \bar{w}^k_j + \beta \bar{w}^k \cdot \bar{x}$$

$$2 \sum_{j=1}^k \bar{w}^k_j + \beta \bar{x} = 0$$

$\beta$  ES UN MULTIPLICADOR DE LAGRANGE

$$\bar{w}^k = -\frac{\beta}{2} \sum_{j=1}^{k-1} \bar{x}$$


---

PROPORCIONA LOS COEFICIENTES

$w^k(y_j)$  PARA EL VALOR DADO  $x_i$

COMO

$$S(x) = \sum_j w^k(y_j) \cdot k(x, y_j)$$

TIENE QUE SER DE AREA UNIDAD

ES DECIR  $\sum_j w^k(y_j) \cdot \delta(y_j) = 1$

SE DETERMINA  $\beta$  CON LO CUAL

$$\bar{w}^k = -\frac{\sum_{j=1}^{k-1} \bar{x}}{\bar{x}^* \sum_{j=1}^{k-1} \bar{x}}$$


---

LUEGO PARA CADA  $x_k$

ENCONTRAMOS EL CONJUNTO  
DE COEFICIENTES  $W^k(y_j)$

QUE NOS PROPORCIONAN

$$S(x) = \sum_j^{k^*} W^k(y_j) K(x, y_j)$$

QUE ES UNA FUNCION, ESTRECHA  
ALREDEDOR DE  $x_k$  Y NORMALIZADA

DE ESTA FORMA


$$\sum_j W^k(y_j) g(y_j) = \int_c^s S(x) f(x) dx$$
$$\approx f(x_k)$$

NOS PERMITE ESTIMAR EL  
VALOR DE  $f(x_k)$

PERO PARA CADA  $x_k$  HAY QUE  
INVERTIR LA MATRIZ

$$N_{jL} = \int_a^s (x - x_k)^2 K(x, y_j) K(x, y_L) dx$$

$$K(x, y) = x e^{-y x} \quad u(0 \leq x \leq 1)$$



Scanning functions synthesized from the kernel functions  $x e^{-y x}$  by means of

Arrows indicate  $x_0$ , the central value (about which  
spread of the scanning functions was minimized).

It is apparent therefore that the Backus-Gilbert method offers little advantage over other inversion techniques when *applied to the construction of approximate numerical solutions*. Indeed it is rather laborious and expensive to apply in practice because the inversion equation (6.45) must be recomputed for each source function value  $y_0$  (see e.g. Twomey (1977) p 184 for discussion of efficiency). Its real value seems to reside in the following: that it is capable of quantifying the resolving power of the observations; of assessing the significance of features in a given source function model; and of theoretically determining the intrinsic information content of one data set as opposed to another. For these reasons, the Backus-Gilbert method is probably better suited to experimental design than to construction of approximate pointwise source function models.

EN CIERTO MODO INDICA QUE  
PROPORCION DE CADA  $g(y)$   
PROVIENE DE UNA  $f(x_k)$   
DETERMINADA

$w^k(y_i)$  PROPORCION DE:  
 $g(y_j)$  QUE PROVIENE DE  $f(x_k)$   
SUMANDO SOBRE TODAS LAS  
 $g(y_j)$  AFECTADAS POR ESTA  
PROPORCIÓN, TENDREMOS  
 $f(x_k)$

ALGO COMO ESTO HACEN TAMBIÉN  
LOS MÉTODOS ESTADÍSTICOS (LUCY)


## EL MÉTODO DE GILBERT-BACKUS

ES, EN REALIDAD, UN MÉTODO DE  
**INVERSIÓN APROXIMADA** QUE PUEDE  
JUSTIFICARSE TEÓRICAMENTE

DESAFORTUNADAMENTE NO SE  
PUEDE OBTENER UNA APROXIMACIÓN  
TAN GRANDE COMO SE QUIERA  
TAMPOCO PARECE SER NECESARIO  
VISTO LO VISTO EN ESTE TIPO  
DE PROBLEMAS.

PERO ES DIFICILMENTE VIABLE  
SUELE SER UTILIZADO CUANDO  
NO SE TIENE NINGUNA IDEA DEL  
COMPORTAMIENTO DE  $f(x)$

O CUANDO NO SE TIENE  
NINGUNA IDEA SOBRE LA CALIDAD  
DE UNA SOLUCIÓN OBTENIDA  
CON OTRO MÉTODO.



GONG(|<3)+MDI|144(|>=3) MOLA (corrected sectoral splittings) + RLS

