

Introdução

Um dado geofísico resulta da sobreposição de efeitos determinísticos e aleatórios. Na inversão de dados geofísicos, considera-se a parte determinística como aquela associada às propriedades físicas do substrato. Esta parte pode ser prevista por funcionais da forma $g(x_i, \bar{p})$. Nesta formulação, os parâmetros \bar{p} representam a distribuição de propriedade física envolvida, x_i um parâmetro de aquisição de dados por exemplo: posição de medida, distância entre eletrodos (sondagens EL), período (sondagens MT), O valor numérico assumido pelo funcional expressa o valor teórico associado ao modelo físico-matemático em questão. Ao proceder o ajuste de dados teóricos com dados reais estamos "modelando" os dados, ou seja associando a eles um modelo físico. Nestes casos, o ajuste ocorre de forma aproximada o que gera um resíduo entre os valores previstos e os medidos. Este resíduo pode ser atribuído tanto como decorrente de erros mensurais como da incapacidade do modelo em ajustar perfeitamente os dados. Isto é explicitamente notado quando se emprega modelos interpretativos muito simples em terrenos comparativamente mais complexos. Nesta ótica torna-se razoável atribuir um modelo também ao resíduo, seja um modelo decorrente de uma formulação determinística ou probabilística. Nos dois casos, o resíduo não pode ser confundido com as incertezas intrínsecas ao processo de medida.

A modelagem dos resíduos numa concepção probabilística leva-nos aos estimadores de verossimilhança máxima (EVM) que, como veremos nesta aula, correspondem a estimadores de mínimos quadrados ponderados, cujos pesos são definidos de acordo com a representação prevista para o resíduo.

Função de verossimilhança

Admitindo que o ruído (resíduo) η_i perturba ativamente a parte determinística do dado, o valor medido, d_i , de um problema linear pode ser escrito

$$d_i = \bar{g}_i^t \bar{p} + \eta_i \quad (1)$$

ou para um conjunto de \underline{n} dados

$$\bar{d} = \bar{G} \bar{p} + \bar{\eta} \quad (2)$$

A parte aleatória (residual) é então

$$\bar{\eta} = \bar{d} - \bar{G} \bar{p} \quad (3)$$

que a partir de agora será caracterizada por meio de funções de densidade de probabilidade (fdp) e seus parâmetros. Como indica a equação (1), cada dado é contaminado pela realização de uma VA específica, η_i . Considerando que tais variáveis sejam independentes temos que a probabilidade

conjunta, ou de realização do conjunto de dados geofísicos, será o produto das probabilidades de cada evento particular, ou seja:

$$L(\bar{\eta}) = \prod_{i=1}^n f(\eta_i) \quad . \quad (4)$$

O termo $L(\bar{\eta})$ é denominado função de verossimilhança e assumirá um valor máximo quando todos os termos do produtório forem máximos (nenhum próximo a zero), ou justamente quando a realização de cada uma das variáveis aleatórias estiver numa faixa de valores com maior probabilidade. A equação (3) nos mostra que podemos obter diferentes resíduos $\bar{\eta}$ simplesmente variando os parâmetros \bar{p} . Podemos conceber $L(\bar{\eta}) \equiv L'(\bar{p})$ e considerar que ao maximizar $L(\bar{\eta})$ estaremos encontrando um conjunto de parâmetros que além de satisfazer um modelo determinístico para os parâmetros satisfaz um modelo probabilístico para os resíduos. A este estimador dá-se o nome de estimador de máxima verossimilhança.

Observe que maximizar $L(\bar{p})$ eqüivale a minimizar um funcional Q tal que:

$$Q = -\log[L(\bar{\eta})] = \sum_{i=1}^n -\log[f(\eta_i)] \quad (5)$$

pois a função logarítmica é monotônica crescente. O mínimo do Q que é obtido determinando o ponto com gradiente nulo (poderia ser ponto de máximo ou inflexão?):

$$\nabla_{\bar{p}} \left\{ \sum_{i=1}^n -\log[f(d_i - \bar{g}_i^t \bar{p})] \right\} = 0 \quad (6)$$

Em tese, a equação (6) pode ser aplicada para qualquer fdp embora, na prática, a complexidade matemática a pode dificultar sua implementação.

Ruído/resíduo Gaussiano

Considerando que o ruído pode ser modelado pela fdp de Gauss, ou normal, tem-se que

$$f(\eta_i) = \frac{1}{\sigma_i \sqrt{2\pi}} \exp \left[-\frac{1}{2} \left(\frac{\eta_i - E\{\eta_i\}}{\sigma_i} \right)^2 \right] \quad (7)$$

ou, assumindo que $E\{\eta_i\} = 0$, que

$$f(\eta_i) = \frac{1}{\sigma_i \sqrt{2\pi}} \exp \left[-\frac{1}{2} \left(\frac{\eta_i}{\sigma_i} \right)^2 \right] \quad (8)$$

sendo σ_i o desvio padrão do i -ésimo resíduo. O funcional a ser minimizado, correspondente à equação (5), é então

$$Q = \sum_{i=1}^n -\log \left(\frac{1}{\sigma_i \sqrt{2\pi}} \exp \left[-\frac{1}{2} \left(\frac{\eta_i}{\sigma_i} \right)^2 \right] \right) = \sum_{i=1}^n -\log \left(\frac{1}{\sigma_i \sqrt{2\pi}} \right) + \log \left(\exp \left[-\frac{1}{2} \left(\frac{\eta_i}{\sigma_i} \right)^2 \right] \right) \quad (9)$$

ou

$$Q = \sum_{i=1}^n -\log\left(\frac{1}{\sigma_i \sqrt{2\pi}}\right) + \sum_{i=1}^n \frac{1}{2} \left(\frac{d_i - \bar{g}_i^t \bar{p}}{\sigma_i} \right)^2 \quad (10)$$

O gradiente da equação (10) é

$$\nabla_{\bar{p}}(Q) = 0 + \sum_{i=1}^n \frac{1}{2} \nabla_{\bar{p}} \left[\left(\frac{d_i - \bar{g}_i^t \bar{p}}{\sigma_i} \right)^2 \right] = \frac{1}{2} \nabla_{\bar{p}} [(\bar{d} - \bar{G} \bar{p})^t \bar{C}_d^{-1} (\bar{d} - \bar{G} \bar{p})] \quad (11)$$

ou

$$\nabla_{\bar{p}}(Q) = \bar{G}^t \bar{C}_d^{-1} (\bar{d} - \bar{G} \bar{p}) \quad (12)$$

sendo

$$\bar{C}_d = \begin{pmatrix} \sigma_1^2 & 0 & \dots & 0 \\ 0 & \sigma_2^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma_n^2 \end{pmatrix} \quad (13)$$

O ponto de mínimo é obtido fazendo $\nabla_{\bar{p}}(Q) = 0$ que fornece

$$\hat{\bar{p}} = (\bar{G}^t \bar{C}_d^{-1} \bar{G})^{-1} \bar{G}^t \bar{C}_d^{-1} \bar{d} \quad (14)$$

ou quando todos resíduos tiverem o mesmo desvio padrão que

$$\hat{\bar{p}} = (\bar{G}^t \bar{G})^{-1} \bar{G}^t \bar{d} \quad (15)$$

As equações (14) e (15) são as expressões do EMQ ponderado e simples, respectivamente, vistos na Aula 2, os quais podem ser considerados como sendo um EVM caso a matriz de pesos for composta pelas variâncias de cada resíduo. Quando as premissas forem verdadeiras, o EMQ modela a parte aleatória dos dados, caso contrário ele pode distorcer a estimativa dos parâmetros ao tentar modelar o resíduo através da parte determinística do modelo. Neste caso pode-se cogitar empregar outros modelos para o resíduo, por exemplo utilizando outras funções de densidade de probabilidade.

Fdp de Poisson

A fdp de Poisson é

$$f(\eta_i) = k e^{-|\eta_i|} \quad (16)$$

O funcional Q a ser minimizado é então

$$Q = \sum_{i=1}^n -\log(k e^{-|\eta_i|}) = \sum_{i=1}^n -\log(k) + \sum_{i=1}^n |\eta_i| \quad (17)$$

ou

$$Q = \sum_{i=1}^n -\log(k) + \sum_{i=1}^n |d_i - \bar{g}_i^t \bar{p}| \quad (18)$$

indicando que o EVM com esta fdp eqüivale a minimizar o valor absoluto dos resíduos. Na secção 3 será apresentado um algoritmo para obter o ponto de mínimo uma vez que a função módulo não é diferenciável.

FDP de Cauchy

A fdp de Cauchy é

$$f(\eta_i) = \frac{1}{\pi} \frac{\omega}{\eta_i^2 + \omega^2} \quad (19)$$

sendo ω a meia largura da distribuição. O funcional a ser minimizado é então

$$Q = \sum_{i=1}^n -\log\left(\frac{1}{\pi} \frac{\omega}{\eta_i^2 + \omega^2}\right) = \sum_{i=1}^n -\log\left(\frac{\omega}{\pi}\right) + \sum_{i=1}^n \log(\eta_i^2 + \omega^2) \quad (20)$$

ou

$$Q = \sum_{i=1}^n -\log\left(\frac{\omega}{\pi}\right) + \sum_{i=1}^n \log[(d_i - \bar{g}_i^t \bar{p})^2 + \omega^2]$$

cujo gradiente é

$$\nabla_{\bar{p}}(Q) = 0 + \sum_{i=1}^n \nabla_{\bar{p}} \{\log[(d_i - \bar{g}_i^t \bar{p})^2 + \omega^2]\} = \sum_{i=1}^n \frac{\nabla_{\bar{p}}(d_i - \bar{g}_i^t \bar{p})^2}{(d_i - \bar{g}_i^t \bar{p})^2 + \omega^2} \quad (22)$$

ou

$$\nabla_{\bar{p}}(Q) = \sum_{i=1}^n -\frac{2(d_i - \bar{g}_i^t \bar{p})\bar{g}_i}{(d_i - \bar{g}_i^t \bar{p})^2 + \omega^2} \quad (23)$$

O estimador é obtido fazendo o gradiente ser nulo

$$\sum_{i=1}^n \frac{d_i \bar{g}_i}{(d_i - \bar{g}_i^t \bar{p})^2 + \omega^2} = \sum_{i=1}^n \frac{\bar{g}_i^t \bar{p} \bar{g}_i}{(d_i - \bar{g}_i^t \bar{p})^2 + \omega^2} \quad (24)$$

ou

$$\sum_{i=1}^n \bar{g}_i w_i d_i = \sum_{i=1}^n \bar{g}_i w_i \bar{g}_i^t \hat{\bar{p}} \quad (25)$$

ou

$$\overline{\overline{G}}^t \overline{\overline{W}} \overline{\overline{d}} = \overline{\overline{G}}^t \overline{\overline{W}} \overline{\overline{G}} \hat{\bar{p}} \quad (26)$$

ou finalmente que

$$\hat{\bar{p}} = (\overline{\overline{G}}^t \overline{\overline{W}} \overline{\overline{G}})^{-1} \overline{\overline{G}}^t \overline{\overline{W}} \overline{\overline{d}} \quad (27)$$

sendo $\overline{\overline{W}}$ uma matriz cujo i-ésimo elemento diagonal é

$$w_{ii} = \frac{1}{(d_i - \bar{g}_i^t \hat{\bar{p}})^2 + \omega^2} \quad (28)$$

Observe que o elemento diagonal de $\overline{\overline{W}}$ é função dos próprios parâmetros a serem estimados impedindo que se obtenha uma forma explícita para o EVM neste caso. A solução é então obtida de forma iterativa empregando algoritmo dado a seguir.

Algoritmo para Minimização de Funcionais dos Resíduos

As três exemplos anteriores, cada um com uma diferente função de densidade de probabilidade, levaram à minimização de um funcional dos resíduos genericamente designado por

$$Q = \sum_{i=1}^n U(r_i) \quad (29)$$

sendo

$$r_i = d_i - \overline{g}_i^t \overline{p}. \quad (30)$$

Dependendo da fdp adotada $U(r)$ na equação (29) será de um tipo específico. Para a distribuição de Gauss $U(r_i) = r_i^2$ e para a de Poisson $U(r_i) = |r_i|$, por exemplo. Para se obter o ponto de mínimo de Q é necessário calcular as derivadas deste funcional em relação a cada um dos m parâmetros:

$$\frac{\partial}{\partial p_j}(Q) = \sum_{i=1}^n \frac{\partial}{\partial p_j}[U(d_i - \overline{g}_i^t \overline{p})] = \sum_{i=1}^n -U'(d_i - \overline{g}_i^t \overline{p}) \frac{\partial(\overline{g}_i^t \overline{p})}{\partial p_j} \quad (31)$$

Definindo

$$q_i = U'(d_i - \overline{g}_i^t \overline{p}). \quad (32)$$

e considerando que

$$\frac{\partial}{\partial p_j}(\overline{g}_i^t \overline{p}) = \frac{\partial(\overline{p}^t \overline{g}_i)}{\partial p_j} = g_{i,j} \quad (33)$$

tem-se

$$\overline{\overline{G}}^t \overline{q} = \overline{0}_m \quad (34)$$

permitindo escrever

$$\overline{q} = \overline{\overline{W}} r \quad (35)$$

sendo $\overline{\overline{W}}$ uma matriz diagonal. Para resíduos com distribuição gaussiana, por exemplo,

$$q_i = 2r_i \quad (36)$$

indicando que $w_i = 2$, ou seja: igual para todos os dados. Os pesos correspondentes à distribuição de Poisson são

$$w_i = \frac{1}{|r_i|}. \quad (37)$$

A equação (35) fornece

$$\overline{\overline{G}}^t \overline{\overline{W}} r = \overline{0}_m \quad (38)$$

ou

$$\overline{\overline{G}}^t \overline{\overline{W}} (\overline{\overline{d}} - \overline{\overline{G}} \overline{\overline{p}}) = \overline{\overline{0}}_m \quad (39)$$

que fornece

$$\hat{\overline{\overline{p}}} = (\overline{\overline{G}}^t \overline{\overline{W}} \overline{\overline{G}})^{-1} \overline{\overline{G}}^t \overline{\overline{W}} \overline{\overline{d}} \quad (40)$$

A implementação do algoritmo apresentado pode ser feita segundo

passo 1- Obter a estimativa de mínimos quadrados $\hat{\overline{\overline{p}}} = (\overline{\overline{G}}^t \overline{\overline{G}})^{-1} \overline{\overline{G}}^t \overline{\overline{d}}$

passo 2- $k=1$

passo 3- $\overline{\overline{p}}_k = \hat{\overline{\overline{p}}}$

passo 4- $k=k+1$

passo 5- calcular os resíduos $r_i = d_i - \overline{\overline{g}}_i^t \overline{\overline{p}}$

passo 6- fazer a matriz $\overline{\overline{W}}$ ($w_{ij} = 1/|r_i|$ caso a fdp seja de Poisson)

passo 7- calcular $\overline{\overline{p}}_{k+1} = \overline{\overline{p}}_k + (\overline{\overline{G}}^t \overline{\overline{W}}_k \overline{\overline{G}})^{-1} \overline{\overline{G}}^t \overline{\overline{W}}_k (\overline{\overline{d}} - \overline{\overline{G}} \overline{\overline{p}}_k)$

passo 8- se $|\overline{\overline{p}}_{k+1} - \overline{\overline{p}}_k| \leq \varepsilon$, fim

passo 9- retorne ao passo 4

Outros Funcionais

Vide Anderson(1982) e Beltrão et al (1991).

E- Referências/Leitura Adicional

Anderson, K. R., 1982, Robust earthquake location using M-estimates: Physics of the Earth and Plan. Inter., 30, 119-130.

Beltrão, J. F., Silva, J. B. C. & Costa, J. C., 1991, Robust polynomial fitting for regional gravity estimation: Geophysics, 56, 80-89.

Claerbout, J. & Muir, F., 1973, Robust modeling with erratic data: Geophysics, 38, 826-844.

Constable, C. G., 1988, Parameter estimation in non-Gaussian noise: Geophys. J., 94, 131-142.

Gersztenkorn, A. Bednar, J. B. & Lines, L. R., 1986, Robust iterative inversion for the one-dimensional acoustic wave equation: Geophysics, 51, 357-368.

Silva, J. B. C. & Cutrim, A. O., 1989, A robust maximum likelihood method for gravity and magnetic interpretation: Geoexploration, 26, 1-31.