

VI. AJUSTE DE CURVAS

- * MOTIVAÇÃO: i) OBTOR UM VALOR APROXIMADO DE UMA FUNÇÃO NUM PONTO FORA DO INTERVALO EM QUE ELA É CONHECIDA (i.e., FAZER EXTRAPOLAÇÃO)
- ii) FAZER INTERPOLAÇÃO OU EXTRAPOLAÇÃO DE VALORES CORRUMPIDOS POR ERRO.

* APLICAÇÕES: i) AJUSTE DE DADOS TABULARES

⇒ CASO DISCRETO

ii) APROXIMAÇÃO DE FUNÇÕES

⇒ CASO CONTÍNUO

- CASO DISCRETO: DADA UMA TABELA DE PONTOS

$$(x_1, f(x_1)), (x_2, f(x_2)), \dots, (x_m, f(x_m))$$

COM x_1, x_2, \dots, x_m EM $[a, b]$

E n FUNÇÕES CONTÍNUAS EM $[a, b]$,

OBTIVER AS n CONSTANTES

$$\alpha_1, \alpha_2, \dots, \alpha_n$$

TAIS QUE A FUNÇÃO

$$p(x) = \alpha_1 g_1(x) + \alpha_2 g_2(x) + \dots + \alpha_n g_n(x)$$

SE APROXIME AO MÁXIMO DE $f(x)$.

6.2
- CASO CONTÍNUO: DADA UMA FUNÇÃO $f(x)$ CONTÍNUA EM UM INTERVALO $[a, b]$, E n FUNÇÕES CONTÍNUAS EM $[a, b]$, OBTER AS n CONSTANTES

$\alpha_1, \alpha_2, \dots, \alpha_n$
TAIS QUE A FUNÇÃO

$$\varphi(x) = \alpha_1 g_1(x) + \alpha_2 g_2(x) + \dots + \alpha_n g_n(x)$$

SE APROXIME AO MÁXIMO DE $f(x)$.

- CRITÉRIOS PARA A APROXIMAÇÃO

\Rightarrow DIVERSAS POSSIBILIDADES:

e.g., MINIMAX

MINIMIZAÇÃO DO DESVIO ABSOLUTO

CRITÉRIO DOS MÍNIMOS QUADRADOS

* O CRITÉRIO DOS MÍNIMOS QUADRADOS É O MAIS CONVENIENTE EM TERMOS PRÁTICOS, E TAMBÉM APRESENTA VANTAGENS DO PONTO DE VISTA TEÓRICO (e.g., QUANDO SE CONSIDERA A DISTRIBUIÇÃO ESTATÍSTICA DOS ERROS)

* ABORDAGEM DOS MÍNIMOS QUADRADOS

1. CASO DISCRETO:

\Rightarrow CONJUNTO DE m PONTOS TABULADOS

$$(x_1, f(x_1)), (x_2, f(x_2)), \dots, (x_m, f(x_m))$$

\Rightarrow CONJUNTO DE n FUNÇÕES

$$g_1(x), g_2(x), \dots, g_n(x)$$

OBSERVAÇÕES: i) CONSIDERAREMOS SEMPRE QUE

$$m \geq n$$

ii) CONSIDERAREMOS QUE AS FUNÇÕES $g_i(x)$ TEMHAM SIDO ADEQUADAMENTE ESCOLHIDAS

e.g., Pela análise do diagrama de dispersão (Gráfico Cartesiano dos pontos tabulados)

\Rightarrow OBJETIVO: ENCONTRAR O CONJUNTO DE COEFICIENTES

$$\alpha_1, \alpha_2, \dots, \alpha_n$$

tais que a função

$$\varphi(x) = \alpha_1 g_1(x) + \alpha_2 g_2(x) + \dots + \alpha_n g_n(x)$$

se aproxime ao máximo de $f(x)$, de acordo com o critério dos mínimos quadrados.

- CRITÉRIO DOS MÍNIMOS QUADRADOS:

6.4

\Rightarrow O CONJUNTO DE COEFICIENTES $\{\alpha_i\}$ DEVE MINIMIZAR A MEDIDA

$$F(\alpha_1, \alpha_2, \dots, \alpha_m) = \sum_{k=1}^m [f(x_k) - \varphi(x_k)]^2 =$$

$$= \sum_{k=1}^m [f(x_k) - \alpha_1 g_1(x_k) - \alpha_2 g_2(x_k) - \dots - \alpha_m g_m(x_k)]^2$$

OBSERVAÇÃO: SE O MODELO AJUSTA EXATAMENTE OS DADOS,
i.e., SE $f(x_k) = \varphi(x_k)$

$$\text{E } F(\{\alpha_i\}) = 0$$

TEMOS O EQUIVALENTE À INTERPOLAÇÃO,
QUE É PORTANTO UM CASO PARTICULAR DENTRO
DO AJUSTE DE CURVAS.

* MINIMIZAÇÃO DE $F(\{\alpha_i\})$:

\Rightarrow ENCONTRAR O CONJUNTO $\{\bar{\alpha}_i\}$ TAL QUE

$$\left. \frac{\partial F}{\partial \alpha_j} \right|_{\{\bar{\alpha}_i\}} = 0$$

PARA

$$j = 1, 2, 3, \dots, m$$

INTRODUZINDO A EXPRESSÃO PARA $F(\alpha_i)$, OBTENEMOS

6.5

$$0 = 2 \sum_{k=1}^m \left[f(x_k) - \alpha_1 g_1(x_k) - \dots - \alpha_m g_m(x_k) \right] [-g_j(x_k)]$$

PARA $j=1, 2, 3, \dots, m$

i.e.,

$$0 = \sum_{k=1}^m f(x_k) g_j(x_k) - \alpha_1 \sum_{k=1}^m g_1(x_k) g_j(x_k) - \dots - \alpha_m \sum_{k=1}^m g_m(x_k) g_j(x_k)$$

PARA $j=1, 2, 3, \dots, m$

REESCREVENDO,

$$\alpha_1 \sum_{k=1}^m g_1(x_k) g_j(x_k) + \dots + \alpha_m \sum_{k=1}^m g_m(x_k) g_j(x_k) = \sum_{k=1}^m f(x_k) g_j(x_k)$$

PARA $j=1, 2, 3, \dots, m$

DEFININDO

$$\begin{cases} a_{1j} = \sum_{k=1}^m g_1(x_k) g_j(x_k) \equiv a_{j1} \\ \vdots \\ a_{mj} = \sum_{k=1}^m g_m(x_k) g_j(x_k) \equiv a_{mj} \end{cases}$$

$$b_j = \sum_{k=1}^m f(x_k) g_j(x_k)$$

OBTENEMOS

$$a_{j1} \alpha_1 + a_{j2} \alpha_2 + \dots + a_{jm} \alpha_m = b_j$$

PARA $j=1, 2, 3, \dots, m$

$$\begin{cases} a_{11}x_1 + a_{12}x_2 + \dots + a_{1m}x_m = b_1 \\ a_{21}x_1 + a_{22}x_2 + \dots + a_{2m}x_m = b_2 \\ \vdots \\ a_{m1}x_1 + a_{m2}x_2 + \dots + a_{mm}x_m = b_m \end{cases}$$

i.e., $A\tilde{x} = \tilde{b}$

com $A = \{a_{ij}\}$, $a_{ij} = a_{ji} = \sum_{k=1}^m g_i(x_k)g_j(x_k)$

$$\tilde{b} = (b_1, b_2, \dots, b_m)^T, \quad b_i = \sum_{k=1}^m f(x_k)g_i(x_k)$$

$$\tilde{x} = (x_1, x_2, \dots, x_m)^T$$

OBSERVAÇÕES: i) AS EQUAÇÕES DESSE SISTEMA LINEAR SÃO CHAMADAS EQUAÇÕES KNOWNS.

ii) Podemos reescrever A e \tilde{b} como

$$A = \{a_{ij}\} = \{\langle \tilde{g}_i, \tilde{g}_j \rangle\}$$

$$\tilde{b} = (b_i)^T = (\langle \tilde{f}, \tilde{g}_i \rangle)^T$$

onde $\tilde{g}_i = (g_i(x_1), g_i(x_2), \dots, g_i(x_m))^T$

$$\tilde{f} = (f(x_1), f(x_2), \dots, f(x_m))^T$$

$$\text{onde } \langle \tilde{x}, \tilde{y} \rangle = \sum_{i=1}^m x_i y_i$$

é o PRODUTO ESCALAR DE \tilde{x} POR \tilde{y} .

iii) Se as funções $\{g_i(x)\}$ forem tais que

6.7

os vetores $\underline{g}_1, \underline{g}_2, \dots, \underline{g}_m$ sejam linearmente independentes, então o sistema linear $A\underline{x} = \underline{b}$ admite solução única, e esta solução é o ponto em que a função $F(\underline{x})$ atinge o seu mínimo.

- Ajuste de curvas com polinômios ortogonais

* Dado um conjunto de pontos $\{x_1, x_2, \dots, x_m\}$ é fácil construir um conjunto de polinômios de graus $0, 1, \dots, m$ que são ortogonais com relação ao produto escalar

$$\langle \underline{g}_i, \underline{g}_j \rangle \equiv \sum_{k=1}^m g_i(x_k) g_j(x_k)$$

i.e.,

Para tais polinômios:

$$\langle \underline{g}_i, \underline{g}_j \rangle \begin{cases} = 0, & \text{se } i \neq j \\ \neq 0, & \text{se } i = j \end{cases}$$

* Neste caso, a matriz A do sistema normal será uma matriz diagonal, com entradas

$$a_{ii} \neq 0 \quad i = 1, 2, \dots, m$$

e a solução das equações normais é facilmente obtida.

2. CASO CONTÍNUO:

\Rightarrow FUNÇÃO $f(x)$ CONTÍNUA NO INTERVALO $[a, b]$

\Rightarrow CONJUNTO DE n FUNÇÕES: $g_1(x), g_2(x), \dots, g_n(x)$

OBJETIVO: ENCONTRAR O CONJUNTO DE COEFICIENTES

$$\alpha_1, \alpha_2, \dots, \alpha_n$$

TAL QUE A FUNÇÃO

$$\varphi(x) = \alpha_1 g_1(x) + \alpha_2 g_2(x) + \dots + \alpha_n g_n(x)$$

SE APROXIME AO MÁXIMO DA FUNÇÃO $f(x)$,

DE ACORDO COM O CRITÉRIO DOS MÍNIMOS

QUADRADOS, $F(\{\alpha_i\}) = \text{MÍNIMO}$, ONDE

$$\begin{aligned} F(\{\alpha_i\}) &= \int_a^b [f(x) - \varphi(x)]^2 dx \\ &= \int_a^b \left[f(x) - \sum_{k=1}^n \alpha_k g_k(x) \right]^2 dx \end{aligned}$$

MINIMIZAÇÃO DE $F(\{\alpha_i\})$:

\Rightarrow ENCONTRAR O CONJUNTO $\{\bar{\alpha}_i\}$ TAL QUE

$$\left. \frac{\partial F}{\partial \alpha_j} \right|_{\{\bar{\alpha}_i\}} = 0$$

PARA

$$j = 1, 2, 3, \dots, n$$

DIFERENCIANDO $F\{\alpha_i\}$ COM RELAÇÃO A α_j , OBTENEMOS

6.9

$$0 = 2 \int_a^b \left[f(x) - \sum_{k=1}^n \alpha_k g_k(x) \right] g_j(x) dx$$

PARA $j = 1, 2, 3, \dots, n$

REESCREVENDO,

$$\sum_{k=1}^n \alpha_k \int_a^b g_k(x) g_j(x) dx = \int_a^b f(x) g_j(x) dx$$

PARA $j = 1, 2, 3, \dots, n$

DEFININDO

$$a_{kj} = \int_a^b g_k(x) g_j(x) dx \quad k, j = 1, 2, 3, \dots, n$$
$$b_j = \int_a^b f(x) g_j(x) dx \quad j = 1, 2, 3, \dots, n$$

OBTENEMOS O SISTEMA LINEAR

$$\begin{cases} a_{11}\alpha_1 + a_{12}\alpha_2 + \dots + a_{1n}\alpha_n = b_1 \\ a_{21}\alpha_1 + a_{22}\alpha_2 + \dots + a_{2n}\alpha_n = b_2 \\ \vdots \\ a_{n1}\alpha_1 + a_{n2}\alpha_2 + \dots + a_{nn}\alpha_n = b_n \end{cases}$$

ISTO É,

6.10

$$A \underline{\alpha} = \underline{b}$$

$$\text{com } A = \{a_{ij}\}, a_{ij} = a_{ji} = \int_a^b g_i(x) g_j(x) dx$$

$$\underline{b} = (b_1, b_2, \dots, b_m)^T, b_i = \int_a^b f(x) g_i(x) dx$$

$$\underline{\alpha} = (\alpha_1, \alpha_2, \dots, \alpha_m)^T$$

OBSERVAÇÕES: i) Assim como no caso discreto, podemos escrever

$$a_{ij} = \langle g_i, g_j \rangle \text{ e } b_i = \langle f, g_i \rangle$$

USANDO A DEFINIÇÃO DO PRODUTO ESCALAR DE DUAS FUNÇÕES NO INTERVALO $[a, b]$:

$$\langle p, q \rangle = \int_a^b p(x) q(x) dx$$

ii) Se as funções $\{g_i(x)\}$ forem LINEARMENTE INDEPENDENTES, o sistema normal admite solução ÚNICA, e esta solução é o ponto em que a função $F(\{\alpha_i\})$ atinge o seu mínimo.

iii) Para FUNÇÕES ORTOGONAIS $\{g_i(x)\}$, o sistema normal torna-se DIAGONAL, e a sua solução é facilmente obtida, pois $\langle g_i, g_j \rangle = 0$ se $i \neq j$.

3. CASO NÃO LINEAR

6.11

* MOTIVAÇÃO: EM ALGUMAS SITUAÇÕES PODE SER NECESSÁRIO O EMPREGO DE FUNÇÕES NÃO LINEARES NOS PARÂMETROS α_i , PARA O AJUSTE DE CURVAS,

$$\text{e.g., } \varphi(x) = \alpha_1 e^{-\alpha_2 x}$$

$$\text{ou}$$
$$\varphi(x) = \alpha_1 x^{\alpha_2}$$

NESTES CASOS, PARA APLICAR O MÉTODO DOS MÍNIMOS QUADRADOS, É PRECISO QUE SE EFETUE ANTES A LINEARIZAÇÃO DAS FUNÇÕES DE APROXIMAÇÃO, ATRAVÉS DE UMA TRANSFORMAÇÃO ADEQUADA,

$$\text{e.g., } \log \varphi(x) = \log(\alpha_1) - \alpha_2 x$$

ou

$$\log \varphi(x) = \log(\alpha_1) + \alpha_2 \log x$$

* OBSERVAÇÕES: 1) UMA VEZ OBTIDOS OS PARÂMETROS PARA O PROBLEMA LINEARIZADO, EFETUA-SE A TRANSFORMAÇÃO INVERSA, PARA OBTENÇÃO DOS PARÂMETROS ORIGINAIS.

2) OS PARÂMETROS ASSIM OBTIDOS NÃO SÃO ÓTIMOS, NO CRITÉRIO DOS MÍNIMOS QUADRADOS, PORQUE SE OTIMIZOU A SOLUÇÃO MENOS PARA O PROBLEMA LINEARIZADO.