


Aproksymacja funkcji

1. Sformułowanie problemu



Rys. 1. Aproksymacja liniowa funkcji.

Dane:

$$x_0, x_1, \dots, x_n \quad (1.1)$$

oraz

$$y_0 = f(x_0), y_1 = f(x_1), \dots, y_n = f(x_n) \quad (1.2)$$

Postać funkcji $y = f(x)$ nie znana lub znana.


Poszukiwana jest funkcja $F(x)$ o następujących właściwościach:

$$F(x) \approx f(x) \quad \text{w przedziale } x_{\min} < x < x_{\max} \quad (1.3)$$

gdzie:

$$x_{\min} = \min x_i \quad (1.4a)$$

$$x_{\max} = \max x_i \quad (1.4b)$$



Rys. 2. Aproksymacja nieliniowa danych pomiarowych.

Funkcję $F(x)$ nazywa się funkcją aproksymującą.

Funkcję $F(x)$ można przedstawić w postaci liniowej kombinacji założonych z góry funkcji $\varphi_0(x), \varphi_1(x), \dots, \varphi_l(x)$

$$y \approx F(x) = a_0\varphi_0(x) + a_1\varphi_1(x) + \dots + a_l\varphi_l(x) \quad (1.5)$$

gdzie $l \ll n$.

Współczynniki a_k dobieramy w taki sposób, aby jak najlepiej było spełnione przyjęte przez nas kryterium zgodności $F(x)$ z $f(x)$. Kryterium tym może być np. spełnienie warunku, aby miara sumarycznego błędu dla $i = 0, 1, \dots, n$ była jak najmniejsza.

Błąd aproksymacji funkcji $f(x)$ funkcją $F(x)$ oblicza się następująco

$$\Delta y_i = y_i - F(x_i) = y_i - a_0 \varphi_0(x_i) - a_1 \varphi_1(x_i) - \dots - a_l \varphi_l(x_i) \quad (1.6)$$

Metoda najmniejszych kwadratów

Kryterium doboru współczynników funkcji aproksymującej, a_k

$$S = \sum_{i=0}^n [y_i - F(x_i)]^2 = \min \quad (1.7)$$

Gdy funkcja $y = f(x)$ jest dana równaniem, kryterium (1.7) przyjmuje formę

$$S = \int_a^b [y - F(x)]^2 dx = \min \quad (1.8)$$

Warunek konieczny i wystarczający na minimum funkcji (1.7) lub (1.8)

$$\frac{\partial S}{\partial a_0} = \frac{\partial S}{\partial a_1} = \dots = \frac{\partial S}{\partial a_l} = 0 \quad (1.9)$$

2. Aproksymacja metodą najmniejszych kwadratów ciągu punktów wielomianem

Jest dany ciąg $n + 1$ par danych (x_i, y_i) , $i = 0, 1, 2, \dots, n$. Należy dokonać aproksymacji wielomianem stopnia l , przy $l + 1 \leq n + 1$.

$$F(x) = a_0 + a_1 x + a_2 x^2 + \dots + a_l x^l \quad (2.1)$$

Kryterium dokładności aproksymacji

$$S = \sum_{i=0}^n [y_i - F(x_i)]^2 = \min \quad (2.2)$$

Warunek konieczny i wystarczający

$$\frac{\partial S}{\partial a_0} = \frac{\partial S}{\partial a_1} = \dots = \frac{\partial S}{\partial a_l} = 0 \quad (2.3)$$

Po obliczeniu pochodnych (2.3) otrzymujemy układ $l + 1$ równań normalnych

$$\begin{aligned}
 a_0 S_0 + a_1 S_1 + \dots + a_l S_l &= T_0 \\
 a_0 S_1 + a_1 S_2 + \dots + a_l S_{l+1} &= T_1 \\
 a_0 S_2 + a_1 S_3 + \dots + a_l S_{l+2} &= T_2
 \end{aligned} \tag{2.4}$$

.....

$$a_0 S_l + a_1 S_{l+1} + \dots + a_l S_{2l} = T_l$$

$$\text{gdzie: } S_k = \sum_{i=0}^n x_i^k \tag{2.5}$$

$$T_k = \sum_{i=0}^n y_i x_i^k \tag{2.6}$$

Wyznacznik układu (4) jest niezerowy dla wszystkich x_i parami różnych. Dla dużych l macierz układu (4) może być źle uwarunkowana.

Aproxymacja wielomianem pierwszego stopnia

Dla $l = 1$

$$F(x) = a_0 + a_1 x \tag{2.7}$$

W celu wyznaczenia współczynników a_0 oraz a_1 należy rozwiązać następujący układ dwóch równań liniowych

$$\begin{aligned}
 a_0 S_0 + a_1 S_1 &= T_0 \\
 a_0 S_1 + a_1 S_2 &= T_1
 \end{aligned} \tag{2.8}$$

gdzie:

$$S_0 = \sum_{i=0}^n x_i^0 = n + 1 \tag{2.9}$$

$$S_1 = \sum_{i=0}^n x_i^1 = \sum_{i=0}^n x_i = x_0 + x_1 + \dots + x_n \tag{2.10}$$

$$S_2 = \sum_{i=0}^n x_i^2 = x_0^2 + x_1^2 + \dots + x_n^2 \tag{2.11}$$

$$T_0 = \sum_{i=0}^n y_i x_i^0 = \sum_{i=0}^n y_i = y_0 + y_1 + \dots + y_n \tag{2.12}$$

$$T_1 = \sum_{i=0}^n y_i x_i^1 = \sum_{i=0}^n y_i x_i = x_0 y_0 + x_1 y_1 + \dots + x_n y_n \tag{2.13}$$

Rozwiązaniem układu (8) są

$$a_0 = \frac{s_2 T_0 - s_1 T_1}{s_0 s_2 - s_1^2} \quad (2.14)$$

$$a_1 = \frac{s_0 T_1 - s_1 T_0}{s_0 s_2 - s_1^2} \quad (2.15)$$

Po wykorzystaniu zależności (9) - (13) otrzymujemy

$$a_0 = \frac{\sum_{i=0}^n x_i^2 \cdot \sum_{i=0}^n y_i - \sum_{i=0}^n x_i \cdot \sum_{i=0}^n x_i y_i}{(n+1) \cdot \sum_{i=0}^n x_i^2 - \left(\sum_{i=0}^n x_i \right)^2} \quad (2.16)$$

$$a_1 = \frac{(n+1) \cdot \sum_{i=0}^n x_i y_i - \sum_{i=0}^n x_i \cdot \sum_{i=0}^n y_i}{(n+1) \cdot \sum_{i=0}^n x_i^2 - \left(\sum_{i=0}^n x_i \right)^2} \quad (2.17)$$

3. Sprowadzanie aproksymacji nieliniowych do zagadnienia liniowego

Należy wyznaczyć współczynniki A oraz n następującego równania aproksymacyjnego

$$Ae^{\frac{2}{x}} = \sqrt[n]{y} \quad (3.1)$$

dla danych k par punktów x_i, y_i . Równanie (3.1) logarytmujemy stronami i otrzymujemy

$$\ln A - \frac{2}{x} \ln e = \frac{1}{n} \ln y \quad (3.2a)$$

$$\ln y = n \ln A - \frac{2n}{x} \quad (3.2b)$$

Wprowadzamy nowe zmienne

$$x^* = \frac{1}{x} \quad (3.3a)$$

$$y^* = \ln y \quad (3.3b)$$

i otrzymujemy równanie liniowe

$$y^* = a_0 + a_1 x^* \quad (3.4)$$

gdzie

$$a_0 = n \ln A \quad (3.5)$$

$$a_1 = -2n$$

W celu znalezienia współczynników a_0 oraz a_1 , należy punkty x_i, y_i , dla $i = 1, 2, \dots, k$, przeliczyć wzorami (3.3a) i (3.3b)

$$x_i^* = \frac{1}{x_i} \quad (3.6)$$

$$y_i^* = \ln y_i$$

Po obliczeniu a_0 oraz a_1 , wykorzystujemy wzory (3.5), by obliczyć A oraz n .

4. Spotykane typy funkcji aproksymujących $F(x)$

1. Kombinacje liniowe funkcji

$$F(x) = a_0 \varphi_0(x) + a_1 \varphi_1(x) + \dots + a_l \varphi_l(x) \quad (4.1)$$

gdzie funkcje $\varphi_i(x)$ mogą być np. wielomianami ortogonalnymi. Poszukujemy wartości a_0, a_1, \dots, a_l .

2. Funkcje trygonometryczne

$$F(x) = \sum_{i=1}^l a_i \sin ix \quad (4.2)$$

Poszukujemy wartości a_1, a_2, \dots, a_l .

3. Funkcje wymierne

$$F(x) = \frac{P_n(x)}{Q_m(x)} \quad (4.3)$$

gdzie

$$P_n(x) = a_0 + a_1x + \dots + a_nx^n \quad (4.3a)$$

$$Q_m(x) = b_0 + b_1x + \dots + b_mx^m \quad (4.3b)$$

Poszukujemy wartości a_0, a_1, \dots, a_n oraz b_0, b_1, \dots, b_m .

4. Funkcje wykładnicze

$$F(x) = A_0 \exp(a_0x) + A_1 \exp(a_1x) + \dots + A_k \exp(a_kx) \quad (4.4)$$

Poszukujemy wartości a_0, a_1, \dots, a_k oraz A_0, A_1, \dots, A_k .

5. Oszacowanie dokładności aproksymacji

W metodzie najmniejszych kwadratów za miarę dokładności aproksymacji można przyjąć wartość minimalizowanej sumy kwadratów:

- dla przypadku dyskretnego

$$S = \sum_{i=0}^n p(x_i) [y_i - F(x_i)]^2 \quad (5.1)$$

- dla przypadku ciągłego

$$S = \int_a^b p(x) [y - F(x)]^2 dx \quad (5.2)$$

Odchylenie średniokwadratowe

- dla przypadku dyskretnego

$$\Delta S = \sqrt{\frac{\sum_{i=0}^n [y_i - F(x_i)]^2}{n+1}} \quad (5.3)$$

- dla przypadku ciągłego

$$\Delta S = \sqrt{\frac{\int_a^b [y - F(x)]^2 dx}{b-a}} \quad (5.4)$$