

## Lucrarea 8

# METODE DE OPTIMIZARE

## 1. SCOPUL LUCRĂRII

*Prezentarea unor algoritmi de optimizare, implementarea acestora într-un limbaj de nivel înalt (în particular, C) și folosirea lor în rezolvarea unor probleme de electronică.*

## 2. PREZENTAREA TEORETICĂ

Metodele de optimizare se clasifică, în raport cu problema care se pune pentru funcția țintă sau scop, astfel:

1. Metode ce determină expresia analitică a funcției, care aproximează cel mai bine o funcție tabelată dată prin puncte;
2. Metode ce determină diferiți parametri ai funcției scop (țintă), pentru a obține un extrem al funcției.

### 2.1. METODA CELOR MAI MICI PĂTRATE

Presupunem că avem o funcție definită printr-un tabel de valori. Se mai spune că funcția este dată implicit, deci nu i se cunoaște forma în mod direct. Dacă tabelul este obținut în urma unor măsurători fizice, atunci elementele lui pot avea erori. Elementele care diferă mult de celelalte pot fi eliminate. Problema care se pune este să determinăm funcția analitică *care aproximează cel mai bine* datele din tabel sau curba care trece prin punctele tabelului.

### 2.2. COEFICIENTUL DE CORELAȚIE

Interpretarea erorilor de aproximație se poate face cu ajutorul coeficientului de corelație. Deși se calculează un minim al erorii pătratice medii, există și o interpretare grafică, din punct de vedere geometric. În final interesează cât de bună este potrivirea unei funcții alese de noi peste porțiunea din graficul unei funcții analitice necunoscute, pentru care cunoaștem doar o evoluție locală, dată de setul de perechi  $(x_i, y_j)$  de la intrare.

### 2.2.1. CORELAȚIA EȘANTIOANELOR (evenimentelor eșantionate)

Dacă avem o serie de  $n$  măsurători ale variabilelor  $X$  și  $Y$ , sub forma  $x_i$  și  $y_i$ , cu  $i = 1, 2, \dots, n$  atunci pentru estimarea corelației dintre  $X$  și  $Y$  se poate face pe baza *coeficientului de corelație produs-moment*, cunoscut sub numele de *coeficient Pearson*. Acesta mai este denumit și coeficientul de corelație al eșantioanelor. Acesta este important mai ales dacă atât  $X$  cât și  $Y$  sunt distribuite normal. Atunci coeficientul de corelație Pearson este cel mai bun estimat al corelației între  $X$  și  $Y$ . Acest coeficient se scrie astfel:

$$r_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{(n-1)s_x s_y} \quad (8.1)$$

unde  $\bar{x}$  și  $\bar{y}$  sunt *valorile medii* ale eșantioanelor  $x_i$  și  $y_i$ , iar  $s_x$  și  $s_y$  sunt *deviațiile standard* ale eșantioanelor  $x_i$  și  $y_i$ . Sumarea se face după  $i = \overline{1, n}$ .

Desfășcând sumele relația anterioară se poate rescrie:

$$r_{xy} = \frac{n \sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i \sum_{i=1}^n y_i}{\sqrt{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2} \sqrt{n \sum_{i=1}^n y_i^2 - (\sum_{i=1}^n y_i)^2}} \quad (8.2)$$

Reamintim că valoarea absolută a coeficientului de corelație trebuie să fie mai mică sau egală cu 1. Cu toate că formula anterioară sugerează un algoritm într-un singur pas pentru calculul corelației eșantioanelor, este recunoscută instabilitatea numerică a unui asemenea algoritm.

### 2.2.2. INTERPRETAREA GEOMETRICĂ A CORELAȚIEI

Coeficientul de corelație poate fi privit și drept cosinusul unghiului între doi vectori de eșantioane, generați de două valori aleatoare.

**Atenție:** această metodă funcționează doar cu date centrate, adică acele date care au fost deplasate cu media eșantioanelor, astfel încât au o medie aritmetică (*average*) egală cu 0. Există situații în practică în care se preferă un coeficient de corelație necentrat, dar care este incompatibil cu coeficientul Pearson.

Ca *exemplu*, să presupunem 5 țări pentru care produsul național brut este, respectiv: 1, 2, 3, 5 și 8 milioane dolari. Presupunem că gradul de sărăcie al aceluiași țări, păstrate în aceeași ordine este de 11%, 12%, 13%, 15%, și 18%. Atunci, să

considerăm pe  $\mathbf{x}$  și  $\mathbf{y}$  ca fiind doi vectori ordonați, cu 5 elemente, conținând datele exprimate anterior:

$$\mathbf{x} = (1, 2, 3, 5, 8)$$

și

$$\mathbf{y} = (0.11, 0.12, 0.13, 0.15, 0.18)$$

Urmând procedura de determinare a unghiului dintre doi vectori (pe baza produsului scalar), coeficientul de corelație necentrat va fi:

$$\cos \theta = \frac{\mathbf{x} \cdot \mathbf{y}}{\|\mathbf{x}\| \|\mathbf{y}\|} = \frac{2.93}{\sqrt{103}\sqrt{0.0983}} = 0.920814711 \quad (8.3)$$

Datele anterioare au fost alese astfel încât să existe o corelație foarte bună între ele:  
 $\mathbf{y} = 0.10 + 0.01 \mathbf{x}$

Coeficientul de corelație Pearson va trebui să fie exact 1. Centrând datele (deci deplasându-l pe  $\mathbf{x}$  cu valoarea  $E(x) = 3.8$  și pe  $\mathbf{y}$  cu valoarea  $E(y) = 0.138$ ) obținem:

$$\mathbf{x} = (-2.8, -1.8, -0.8, 1.2, 4.2)$$

și

$$\mathbf{y} = (-0.028, -0.018, -0.008, 0.012, 0.042),$$

de unde:

$$\cos \theta = \frac{\mathbf{x} \cdot \mathbf{y}}{\|\mathbf{x}\| \|\mathbf{y}\|} = \frac{0.308}{\sqrt{30.8}\sqrt{0.00308}} = 1 \quad (8.4)$$

așa cum ne așteptam.

### 2.2.3. INTERPRETAREA MĂRIMII CORELAȚIEI

Mai mulți autori oferă modalități de interpretare a coeficientului de corelație. De exemplu Cohen (1988) a sugerat următoarele interpretări ale corelației, cu referire la studiile psihologice (Tabel 8.1):

Tabel 8.1

Corelația	Valori negative	Valori pozitive
Mic ( <i>slabă</i> )	-0.29 to -0.10	0.10 to 0.29
Mediu ( <i>normală</i> )	-0.49 to -0.30	0.30 to 0.49
Mare ( <i>puternică</i> )	-1.00 to -0.50	0.50 to 1.00

După cum însuși Cohen a observat, toate criteriile de acest fel sunt într-o oarecare măsură arbitrare și nu ar trebui luate în sens strict. Aceasta deoarece interpretarea unui coeficient de corelație depinde de context și de scopurile avute în vedere. O corelație de

0.9 poate fi foarte scăzută dacă cineva verifică legile fizicii folosind instrumente de înaltă calitate, dar poate fi foarte ridicată în contextul științelor sociale unde apar influențe datorate unor factori complicați.

Pentru *problemele de regresie* la care ne referim în laborator, interpretarea se poate face conform tabelului indicat de Cohen, pentru că nu există factori esențiali care influențează datele preluate, alții decât erorile obișnuite de măsurare și interpretare, pentru care se respectă regulile specifice de eliminare a experimentelor eronate, de rotunjire a valorilor conform cu erorile de calcul acceptate sau de reprezentare normalizată (pentru valorile foarte mici sau foarte mari).

### 3. METODE DE REGRESIE

#### 3.1.1. REGRESIA LINIARĂ

Se consideră funcția tabelată:

Tabelul 8.2

$x$	$x_1$	$x_2$	$x_3$	$x_4$	.....	$x_m$
$y$	$y_1$	$y_2$	$y_3$	$y_4$	.....	$y_m$

unde  $m$  reprezintă *numărul de măsurători* sau de valori ale funcției. Se cere să se determine funcția liniară de forma generală

$$y = ax + b \quad (8.1)$$

care să aproximeze cel mai bine funcția tabelată *astfel ca eroarea să fie minimă*.

$$a = \frac{m \sum_{i=1}^m x_i y_i - \sum_{i=1}^m x_i \sum_{i=1}^m y_i}{m \sum_{i=1}^m x_i^2 - \left( \sum_{i=1}^m x_i \right)^2} \quad (8.2)$$

$$b = \frac{\sum_{i=1}^m x_i^2 \sum_{i=1}^m y_i - \sum_{i=1}^m x_i \sum_{i=1}^m x_i y_i}{m \sum_{i=1}^m x_i^2 - \left( \sum_{i=1}^m x_i \right)^2} \quad (8.3)$$

##### 3.1.1.1. Algoritm 8.1. Regresia liniară

```
void Reg_Lin
(
    întreg m, // numărul experiențelor
    real x[ ], // vectorul absciselor funcției
    real y[ ], // vectorul ordonatelor funcției
    real *pA, // adresa coeficientului lui x (pointer)
    real *pB // adresa termenului liber (pointer)
)
```

```

{ // declararea și definirea variabilelor locale
  real sx ; // variabila pentru suma absciselor
  real sy ; // variabila pentru suma ordonatelor
  real sxx ; // variabila pentru sumele de forma x2
  real sxy, // variabila pentru sumele de forma xy
  întreg i ; // contor pentru ciclurile 'for()'.

  // corpul de instrucțiuni al funcției
  sx= 0 ; sy = 0 ; sxy = 0 ; sxx = 0; // inițializare cu 0
  pentru i= 1÷ m
  {
    sx = sx + x[i] ;
    sy = sy + y[i] ;
    sxy = sxy + x[i]*y[i] ;
    sxx = sxx + x[i]*x[i] ;
  }
  *pA =  $\frac{m \cdot s_{xy} - s_x \cdot s_y}{m \cdot s_{xx} - s_x \cdot s_x}$  ; *pB =  $\frac{s_{xx} \cdot s_y - s_x \cdot s_{xy}}{m \cdot s_{xx} - s_x \cdot s_x}$  ;
}

```

**Obs.:**

- 1) Am marcat faptul că funcția nu întoarce nici o valoare prin cuvântul-cheie 'void', la fel ca în C.
- 2) Dimensiunea vectorilor folosiți de metodă se stabilește funcție de numărul 'm' al punctelor experimentale considerate.
- 3) Denumirile ultimelor două argumente ale funcției respectă o convenție de notație – și anume *notația ungară* – în care se utilizează și anumite indicii literale despre tipul variabilei. Aceste indicii literale *preced* numele variabilei. Aceste două argumente fiind de tip referință (deci pointer) denumirile variabilelor încep cu litera mică *p*, ca sugestie pentru pointeri.

**3.1.2. REGRESIA POLINOMIALĂ**

Dacă regresia liniară nu este satisfăcătoare se caută o funcție polinom de un anumit grad (2, 3, 4...*n*).

Fie funcția dată în tabelul (8.1). Considerăm că reprezentarea grafică a acestei funcții se aseamănă foarte mult cu curba unui polinom de gradul *n* de forma:

$$y = a_n x^n + a_{n-1} x^{n-1} + \dots + a_1 x + a_0 \quad (8.4)$$

Coeficienții polinomului se determină cu ajutorul sistemului:

$$\left\{ \begin{array}{l}
 ma_0 + \left( \sum_{i=1}^m x_i \right) a_1 + \left( \sum_{i=1}^m x_i^2 \right) a_2 + \dots + \left( \sum_{i=1}^m x_i^k \right) a_k + \dots + \left( \sum_{i=1}^m x_i^n \right) a_n = \sum y_i \\
 \left( \sum_{i=1}^m x_i \right) a_0 + \left( \sum_{i=1}^m x_i^2 \right) a_1 + \left( \sum_{i=1}^m x_i^3 \right) a_2 + \dots + \left( \sum_{i=1}^m x_i^{k+1} \right) a_k + \dots + \left( \sum_{i=1}^m x_i^{n+1} \right) a_n = \sum x_i y_i \\
 \dots \\
 \left( \sum_{i=1}^m x_i^p \right) a_0 + \left( \sum_{i=1}^m x_i^{p+1} \right) a_1 + \left( \sum_{i=1}^m x_i^{p+2} \right) a_2 + \dots + \left( \sum_{i=1}^m x_i^{p+k} \right) a_k + \dots + \left( \sum_{i=1}^m x_i^{p+n} \right) a_n = \sum x_i^p y_i \\
 \dots \\
 \left( \sum_{i=1}^m x_i^n \right) a_0 + \left( \sum_{i=1}^m x_i^{n+1} \right) a_1 + \left( \sum_{i=1}^m x_i^{n+2} \right) a_2 + \dots + \left( \sum_{i=1}^m x_i^{n+k} \right) a_k + \dots + \left( \sum_{i=1}^m x_i^{2n} \right) a_n = \sum x_i^n y_i
 \end{array} \right. \quad (8.5)$$

Sistemul obținut este un sistem liniar în necunoscutele  $a_0, a_1, a_2, \dots, a_n$  și se rezolvă cu una dintre metodele cunoscute în **Lucrarea 3 - Metode pentru rezolvarea sistemelor liniare de ecuații**.

### 3.1.2.1. Algoritm 8.2. Regresia polinomială

```

întreg Reg_Pol
(
    întreg m, // numărul de puncte cunoscute ale funcției
    real X[ ], // vectorul absciselor funcției
    real Y[ ], // vectorul ordonatelor funcției
    întreg n, // gradul polinomului de regresie
    real *coef // adresa de început a vectorului
                //coeficienților polinomului de regresie.
)
{ // declararea și definirea variabilelor locale
    întreg i, j, k ; // contoare
    real A[N][N] ; // matrice utilizată pentru
                  //rezolvarea sistemului (8.5).
    real B[N] ; //vectorul termenilor liberi (sistemul (8.5))

    // corpul de instrucțiuni al funcției
    pentru i= 1÷ n+1
    {
        pentru j= i ÷ n+1
        {
            A[i][j] = 0 ;
            pentru k= 1÷ n    A[i][j] = A[i][j] + pow( x[k], i+j-2) ;
            A[j][i] = A[i][j] ;
        }
        B[i] = 0 ;
        pentru k= 1÷ n    B[i] = B[i] + y[k] * pow( x[k], i-1) ;
    }
    // rezolvă sistemul 7.5
    dacă ( Gauss(n+1,A,B,coef) !=0 ) returnează True ;
    altfel returnează False ;
}

```

**Obs.:**

- 1) Am marcat faptul că funcția nu întoarce nici o valoare prin cuvântul-cheie 'void', la fel ca în C;
- 2) Dimensiunea 'N' a vectorilor folosiți de metodă se stabilește funcție de numărul 'm' al punctelor considerate, având în vedere că indexul minim al vectorilor în C este 0;
- 3) Funcția 'Gauss()' la care se face referire este cea din **Lucrarea 3 - Metode pentru rezolvarea sistemelor liniare de ecuații.**

**3.1.3. REGRESIA HIPERBOLICĂ**

Fie funcția numerică dată în tabelul 8.1. Se pune problema determinării funcției hiperbolice:

$$y = \frac{1}{ax+b} \quad (8.6)$$

care aproximează cel mai bine funcția numerică. Valorile lui  $a$  și  $b$  sunt:

$$a = \frac{\left(\sum_{i=1}^m x_i\right)\left(\sum_{i=1}^m \frac{1}{y_i}\right) - m \sum_{i=1}^m \frac{x_i}{y_i}}{\left(\sum_{i=1}^m x_i\right)^2 - m \sum_{i=1}^m x_i^2} \quad (8.7)$$

$$b = \frac{\left(\sum_{i=1}^m \frac{1}{y_i}\right)\left(\sum_{i=1}^m x_i^2\right) - \left(\sum_{i=1}^m \frac{x_i}{y_i}\right)\left(\sum_{i=1}^m x_i\right)}{m \sum_{i=1}^m x_i^2 - \left(\sum_{i=1}^m x_i\right)^2} \quad (8.8)$$

Înlocuim valorile lui  $a$  și  $b$  în funcția hiperbolică (8.6) și se obține funcția care aproximează cel mai bine funcția numerică din tabelul 8.1.

Pentru a liniariza rezolvarea sistemului s-a lucrat cu inversele valorilor lui  $y$ , adică  $1/y$ , motiv pentru care sumele  $sy$  și  $sxy$  conțin valorile inversate pentru  $y$ .

**3.1.3.1. Algoritm 8.3. Regresia hiperbolică**

```
void Reg_Hip
(
  întreg m,          // numărul experiențelor
  real x[ ],        // vectorul absciselor funcției numerice
  real y[ ],        // vectorul ordonatelor funcției numerice
  real *pA          // adresa coeficientului lui a al funcției
                  //hiperbolice
  real *pB          // adresa coeficientului lui b al funcției
                  //hiperbolice
)
```

```

{ // declararea și definirea variabilelor locale
real s_x; // variabila ce conține sumele absciselor
real s_y; // variabila ce conține suma inverselor
// ordonatelor.
real s_xx; // variabila ce conține pătratul absciselor
real s_xy; // variabila ce conține suma raportului
// dintre abscise și ordonate..
întreg i; // contor

// corpul de instrucțiuni al funcției
s_x = 0; s_y = 0; s_xy = 0; s_xx = 0;
pentru i= 1÷m
{ // urmează un corp de instrucțiuni, deci se
// folosește acolada deschisă.
s_x = s_x + x[i];
s_y = s_y +  $\frac{1}{y[i]}$ ;
s_xy = s_xy +  $\frac{x[i]}{y[i]}$ ;
s_xx = s_xx + x[i]*x[i];
}
*pA =  $\frac{m \cdot s_{xy} - s_x \cdot s_y}{m \cdot s_{xx} - s_x \cdot s_x}$ ; *pB =  $\frac{s_{xx} \cdot s_y - s_{xy} \cdot s_x}{m \cdot s_{xx} - s_x \cdot s_x}$ ;
}

```

**Obs.:**

- 1) Am marcat faptul că funcția nu întoarce nici o valoare prin cuvântul-cheie 'void', la fel ca în C;
- 2) Dimensiunea vectorilor folosiți de metodă se stabilește funcție de numărul 'm' al punctelor considerate, având în vedere că indexul minim al vectorilor în C este 0;
- 3) Denumirile ultimelor două argumente ale funcției respectă o convenție de notație – și anume *notația ungară* – în care se utilizează și anumite indicii literale despre tipul variabilei. Aceste indicii literale *preced* numele variabilei. Aceste două argumente fiind de tip referință (deci pointer) denumirile variabilelor încep cu litera mică *p*, ca sugestie pentru pointeri.

**3.1.4. REGRESIA EXPONENȚIALĂ**

Dacă se constată că funcția numerică din tabelul 8.1, reprezentată grafic, se aseamănă foarte mult cu o exponențială, atunci se consideră funcția exponențială, de forma generală:

$$y = a \cdot b^x \quad (8.9)$$

în care *a* și *b* sunt constante pozitive.



Pentru un calcul comod al constantelor  $a$  și  $b$  se logaritmează funcția (8.9):

$$\ln y = \ln a + x \ln b \quad (8.10)$$

și se determină constantele astfel încât eroarea pătratică de ansamblu să fie *minimă*.

$$a = \exp \left\{ \frac{\left[ \sum_{i=1}^m \ln y_i \right] \left[ \sum_{i=1}^m x_i^2 \right] - \left( \sum_{i=1}^m x_i \right) \left( \sum_{i=1}^m \ln y_i x_i \right)}{\left[ m \sum_{i=1}^m x_i^2 - \left( \sum_{i=1}^m x_i \right)^2 \right]} \right\} \quad (8.11)$$

$$b = \exp \left\{ \frac{\left[ m \sum_{i=1}^m x_i \ln y_i - \left( \sum_{i=1}^m x_i \right) \left( \sum_{i=1}^m \ln y_i \right) \right]}{\left[ m \sum_{i=1}^m x_i^2 - \left( \sum_{i=1}^m x_i \right)^2 \right]} \right\} \quad (8.12)$$

### 3.1.4.1. Algoritm 8.4. Regresia exponențială

```
void Reg_Exp
(
    întreg m, // numărul absciselor funcției
    real x[ ], // vectorul absciselor funcției numerice
    real y[ ], // vectorul ordonatelor funcției numerice
    real *pA, // adresa coeficientului lui a al funcției
                // exponențiale.
    real *pB // adresa coeficientului lui b al funcției
                // exponențiale.
)
{ // declararea și definirea variabilelor locale
    real s_x ; // suma absciselor
    real s_xx ; // suma pătratelor absciselor
    real s_y ; // suma logaritmilor din ordonate
    real s_xy ; // suma absciselor înmulțite cu logaritmul
                // ordonatelor.
    întreg i ; // contor pentru bucla 'for()'.
    // corpul de instrucțiuni al funcției
    s_x = 0 ; s_y = 0 ; s_xy = 0 ; s_xx = 0 ; // inițializare
    pentru i = 1 ÷ m
    {
        s_x = s_x + x[i] ;
        s_xx = s_xx + x[i]*x[i] ;
        s_y = s_y + log( y[i] ) ;
        s_xy = s_xy + x[i] * log( y[i] ) ;
    }
    *pA = exp( ( s_y * s_xx - s_x * s_xy ) /
                ( m * s_xx - s_x * s_x ) );
    *pB = exp( ( m * s_xy - s_x * s_y ) /
                ( m * s_xx - s_x * s_x ) );
}
```

**Obs.:**

- 1) Am marcat faptul că funcția nu întoarce nici o valoare prin cuvântul-cheie 'void', la fel ca în C;
- 2) Dimensiunea vectorilor folosiți de metodă se stabilește funcție de numărul 'm' al punctelor experimentale considerate, având în vedere că indexul minim al vectorilor în C este 0;
- 3) Denumirile ultimelor două argumente ale funcției respectă o convenție de notație – și anume *notația ungară* – în care se utilizează și anumite indicii literale despre tipul variabilei. Aceste indicii literale *preced* numele variabilei. Aceste două argumente fiind de tip referință (deci pointer) denumirile variabilelor încep cu litera mică *p*, ca sugestie pentru pointeri.

**3.1.5. REGRESIA GEOMETRICĂ**

Dacă funcția numerică din tabelul 8.1 se aseamănă cu o funcție de tip geometric, vom căuta să determinăm funcția de forma:

$$y = ax^b \quad (8.13)$$

care să aproximeze cel mai bine funcția numerică. Adică aceeași condiție de eroare pătratică, de ansamblu, minimă.

Și în această situație se recurge la o logaritmare a relației, pentru a aduce rezolvarea în domeniul liniar. Avem:

$$\ln y = \ln(a) + b \cdot \ln(x) \quad (8.13')$$

Se obțin următoarele valori pentru *a* și *b*:

$$a = \exp \frac{\left( \sum_{i=1}^m \ln(y_i) \right) \left( \sum_{i=1}^m \ln^2(x_i) \right) - \left( \sum_{i=1}^m \ln(x_i) \right) \left( \sum_{i=1}^m \ln(x_i) \ln(y_i) \right)}{m \left( \sum_{i=1}^m \ln^2(x_i) \right) - \left( \sum_{i=1}^m \ln(x_i) \right)^2} \quad (8.14)$$

$$b = \frac{m \left( \sum_{i=1}^m \ln(y_i) \ln(x_i) \right) - \left( \sum_{i=1}^m \ln(x_i) \right) \left( \sum_{i=1}^m \ln(y_i) \right)}{m \left( \sum_{i=1}^m \ln^2(x_i) \right) - \left( \sum_{i=1}^m \ln(x_i) \right)^2} \quad (8.15)$$

Cu aceste valori funcția  $y = ax^b$  aproximează cel mai bine funcția tabelată (8.1) care se aseamănă cel mai bine cu o funcție de tip geometric.

### 3.1.5.1. Algoritm 8.5. Regresia geometrică

```

void Reg_Geo
(
    întreg m,          // numărul de abscise
    real x[ ],        // vectorul absciselor funcției numerice
    real y[ ],        // vectorul ordonatelor funcției numerice
    real *pA,         // adresa coeficientului lui a al funcției
                        //geometrice
    real *pB          // adresa coeficientului lui b al funcției
                        //geometrice
)
{ // declararea și definirea variabilelor locale
    real sx ;          // suma logaritmilor absciselor
    real sy ;          // suma logaritmilor ordonatelor
    real sxy ;        // suma produsului între logaritmi
                        //absciselor și logaritmilor ordonatelor
    real sxx ;        // suma pătratelor logaritmilor absciselor
    întreg i ;        // contor

    // corpul de instrucțiuni al funcției
    sx = 0 ; sy = 0 ; sxx = 0 ; sxy = 0 ; // inițializare
    pentru i= 1÷ m
    {
        sx = sx + log(x[i]) ;
        sxx = sxx + log(x[i])*log(x[i]) ;
        sy = sy + log (y[i]) ;
        sxy = sxy + log(x[i])* log(y[i]) ;
    }

    *pA = exp  $\left( \frac{s_y \cdot s_{xx} - s_x \cdot s_{xy}}{m \cdot s_{xx} - s_x \cdot s_x} \right)$  ;
    *pB =  $\frac{m \cdot s_{xy} - s_x \cdot s_y}{m \cdot s_{xx} - s_x \cdot s_x}$  ;
}

```

#### Obs.:

- 1) Am marcat faptul că funcția nu întoarce nici o valoare prin cuvântul-cheie 'void', la fel ca în C;
- 2) Dimensiunea vectorilor folosiți de metodă se stabilește funcție de numărul 'm' al punctelor experimentale considerate, având în vedere că indexul minim al vectorilor în C este 0;
- 3) Denumirile ultimelor două argumente ale funcției respectă o convenție de notație – și anume *notația ungară* – în care se utilizează și anumite indicii literale despre tipul variabilei. Aceste indicii literale *preced* numele variabilei. Aceste două argumente fiind de tip referință (deci pointer) denumirile variabilelor încep cu litera mică *p*, ca sugestie pentru pointeri.

### 3.1.6. REGRESIA TRIGONOMETRICĂ

Se consideră funcția numerică dată în tabelul 8.1 și funcția trigonometrică de forma:

$$y = a + b \cdot \cos(\omega \cdot x) \quad (8.16)$$

care aproximează cel mai bine funcția numerică.

Valorile lui  $a$  și  $b$  sunt:

$$a = \frac{\left(\sum_{i=1}^m y_i\right)\left(\sum_{i=1}^m \cos^2 \omega x_i\right) - \left(\sum_{i=1}^m \cos \omega x_i\right)\left(\sum_{i=1}^m y_i \cos \omega x_i\right)}{m\left(\sum_{i=1}^m \cos^2 \omega x_i\right) - \left(\sum_{i=1}^m \cos \omega x_i\right)^2} \quad (8.17)$$

$$b = \frac{m\left(\sum_{i=1}^m y_i \cos \omega x_i\right) - \left(\sum_{i=1}^m \cos \omega x_i\right)\left(\sum_{i=1}^m y_i\right)}{m\left(\sum_{i=1}^m \cos^2 \omega x_i\right) - \left(\sum_{i=1}^m \cos \omega x_i\right)^2} \quad (8.18)$$

$$\omega = 2 \cdot \pi \cdot f = \frac{2 \cdot \pi}{T} \quad \text{unde } f \text{ - frecvența, } \omega \text{ - pulsația, iar } T \text{ - perioada.}$$

$\omega$  se stabilește funcție de periodicitatea funcției numerice date.

#### 3.1.6.1. Algoritmul 8.6. Regresia trigonometrică

```
void Reg_Tri
(
    întreg m, // numărul absciselor funcției numerice
    real x[ ], // vectorul absciselor funcției numerice
    real y[ ], // vectorul ordonatelor funcției numerice
    real *pA, // adresa coeficientului lui 'a' din expresia
              //funcției trigonometrice
    real *pB // adresa coeficientului lui 'b' din expresia
              //funcției trigonometrice
)
{ // declararea și definirea variabilelor locale
  real  $\omega$ ; // pulsația ( =2*PI*T)
  real s_y; // suma ordonatelor funcției numerice
  real s_cos_2x; // suma pătratelor cosinusurilor din abscise
  real s_cos_x; // suma cosinusurilor din abscise
  real s_ycosx; // suma produsului ordonatelor cu cosinusul
                // absciselor corespunzătoare.
  întreg i; // variabila de control a ciclului 'for()' și
            //index de vector.

  // corpul de instrucțiuni al funcției
  // inițializarea sumelor
  s_y = 0; s_cos_2x = 0; s_cos_x = 0; s_ycos_x = 0;
  pentru i= 1÷ m
```

```

{
  sy = sy + y[i] ;
  scos 2x = scos 2x + cos(ω xi) * cos(ω xi) ;
  scos x = scos x + cos(ω xi) ;
  sycos x = sycos x + yi * cos(ω xi) ;
}
*pA =  $\frac{s_y \cdot s_{\cos 2x} - s_{\cos x} \cdot s_{y \cos x}}{m \cdot s_{\cos 2x} - s_{\cos x} \cdot s_{\cos x}}$  ;      *pB =  $\frac{m \cdot s_{y \cos x} - s_{\cos x} \cdot s_y}{m \cdot s_{\cos 2x} - s_{\cos x} \cdot s_{\cos x}}$  ;
}

```

**Obs.:**

- 1) Am marcat faptul că funcția nu întoarce nici o valoare prin cuvântul-cheie 'void', la fel ca în C;
- 2) Dimensiunea vectorilor folosiți de metodă se stabilește funcție de numărul 'm' al punctelor experimentale considerate, având în vedere că indexul minim al vectorilor în C este 0;
- 3) Denumirile ultimelor două argumente ale funcției respectă o convenție de notație – și anume *notația ungară* – în care se utilizează și anumite indicii literale despre tipul variabilei. Aceste indicii literale *preced* numele variabilei. Aceste două argumente fiind de tip referință (deci pointer) denumirile variabilelor încep cu litera mică p, ca sugestie pentru pointeri.

### 3.1.7. REGRESIA MULTIPLĂ

Această regresie se referă la funcțiile de mai multe variabile.

Considerând o funcție numerică de  $n$  variabile  $y = f(x_1, x_2, \dots, x_n)$  și un tip de funcție analitică de  $n$  variabile care se aseamănă cu cea numerică, se pune problema determinării funcției analitice astfel ca ea să *aproximeze cel mai bine* funcția numerică.

Vom considera funcția numerică dată în figura 8.1.




Fig. 8.1 - Reprezentarea funcției multiple.

Considerăm că punctele  $z_1, z_2, \dots, z_n$  se află aproximativ pe un plan:

$$z = Ax + By + C \quad (8.19)$$

Se pune problema determinării acestui plan, adică a valorilor constantelor  $A, B, C$  astfel ca planul să aproximeze cel mai bine o funcția numerică de două variabile dată.

Valorile lui  $A, B, C$  sunt soluțiile sistemului:

$$\begin{cases} mnC + \left(\sum_{i=1}^m x_i\right)nA + \left(\sum_{j=1}^n y_j\right)mB = \sum_{i=1}^m \sum_{j=1}^n z_{ij} \\ \left(\sum_{i=1}^m x_i\right)nC + \left(\sum_{i=1}^m x_i^2\right)nA + \sum_{i=1}^m \sum_{j=1}^n x_i y_j = \sum_{i=1}^m \sum_{j=1}^n x_i z_{ij} \\ \left(\sum_{j=1}^n y_j\right)mC + \left(\sum_{i=1}^m \sum_{j=1}^n x_i y_j\right)A + \left(\sum_{j=1}^n y_j^2\right)mB = \sum_{i=1}^m \sum_{j=1}^n y_j z_{ij} \end{cases} \quad (8.20)$$

Utilizând una dintre metodele numerice de rezolvare a sistemelor liniare din capitolul 3 se determină  $A, B, C$ , deci planul căutat.

### 3.1.7.1. Algoritmul 8.7. Regresia multiplă

întreg **Reg\_Mul**

```
(
    întreg m, // numărul de argumente pe Ox
    întreg n, // numărul de argumente pe Oy
    real x[ ], // vectorul argumentelor pe axa Ox a funcției
                // numerice.
    real y[ ], // vectorul argumentelor pe axa Oy a funcției
                // numerice.
    real z[ ], // vectorul valorilor funcției numerice
    real *coef // adresa de început a vectorului
                // coeficienților planului.
)
{ // declararea și definirea variabilelor locale
    întreg i, j ; // indici
    real A[4][N] ; // matricea sistemului (8.20);
    real B[4] ; // vectorul termenilor liberi ai sistemului
                //(8.20)
    // corpul de instrucțiuni al funcției
    A[1][1] = m*n ; A[1][2] = 0 ;
    pentru i= 1÷ m A[1][2] = A[1][2] + n*x[i] ;
    A[2][1] = A[1][2] ; A[1][3] = 0 ;
    pentru i= 1÷ n A[1][3] = A[1][3] + m*y[i] ;
    A[3][1] = A[1][3] ; A[2][3]=0 ;
    B[1] = 0 ; B[2] = 0 ; B[3] ] = 0 ;
    pentru i= 1÷ m
        pentru j= 1÷ n
            {
                A[2][3] = A[2][3] + x[i]*y[j] ;
                B[1] = B[1] + z[i][j] ;
            }
    }
}
```

```

        B[2] = B[2] + x[i]*z[i][j] ;
        B[3] = B[3] + y[j]*z[i][j] ;
    }
    A[3][2]=A[2][3]; A[2][2]=0 ;
    pentru i= 1÷ m A[2][2] = A[2][2] + n*x[i]*x[i] ;
    A[3][3] = 0 ;

// rezolvă sistemul (8.20)
    pentru i= 1÷ n A[3][3] = A[3][3] + m*y[i]*y[i] ;
    dacă ( Gauss( 3, A, B, coef) != 0 ) returnează True ;
    altfel returnează False ;
}

```

**Obs.:**

- 1) Funcția ‘*Gauss()*’ la care se face referire este cea din **Lucrarea 3 - Metode pentru rezolvarea sistemelor liniare de ecuații**.
- 2) Dimensiunile matricelor și vectorilor folosiți de metodă se stabilește funcție de numerele ‘*m*’ și ‘*n*’, ale punctelor experimentale considerate pe fiecare axă de coordonate.

## 3.2. OPTIMIZAREA NELINIARĂ FĂRĂ RESTRICȚII

### 3.2.1. METODELE ALEATOARE DE CĂUTARE

Procesul este iterativ și pentru fiecare etapă se generează o succesiune de numere aleatoare având o densitate de probabilitate uniformă în domeniul de variație admis, cu care se modifică componentele vectorului.

*Metoda drumului aleator*, una dintre metodele des utilizate, constă în modificarea vectorului de poziție pentru noul punct astfel:

$$X_{k+1} = X_k + \alpha \cdot r \quad (8.21)$$

unde  $r$  este vectorul unitate care are direcția aleatoare,  $X_k$  este vectorul de poziție al punctului anterior și  $\alpha$  un scalar. Se calculează valoarea funcției în noul punct și se compară cu valoarea funcției în vechiul punct. Dacă, după un anumit număr de iterații valoarea lui  $F$  nu se micșorează, se reduce scalarul  $\alpha$  până ce valoarea lui devine mai mică decât o eroare de calcul dată,  $er > 0$ .

#### 3.2.1.1. Algoritmul 8.8. Metoda drumului aleatoriu

```

real Min_Aleator
(
    Adr_functie,          // Adresa unei funcții reale de două
                        // variabile reale(pointer la o funcție)
    real x0[ ],          // vectorul de start
    real eps             // eroarea de calcul
)

```

```

{ // declararea și definirea variabilelor locale
real gama0 ; // scalar
întreg contor ; // indice
real minim ; // minimul dintre valorile funcțiilor
real val_curentă ; // valoarea minimă curentă a funcției
real xcurent[ ] ; // valoarea anterioară și curentă a
// abscisei punctului.
întreg maxiter ; // numărul maxim de iterații

// corpul de instrucțiuni al funcției
randomize( ) ; // macro ce pregătește folosirea funcției
// 'random()' prin inițializarea
//generatorului de numere aleatoare.
gama0 = 1 ;
cât timp ( gama0 >eps)
{ // cât timp
contor = 0 ;
minim = *Adr_funcție( x0[0], x0[1]) ;
execută
{
x_curent[0]=x0[0] + gama0*pow(-1, random(101) mod 2);
x_curent[1]=x0[1] + gama0*pow(-1, random(101) mod 2);
val_curentă = *Adr_funcție( x_curent[0], x_curent[1]) ;
incrementează contor ;
}
cât timp( (contor <= maxiter) SI (val_curentă >= minim));
dacă ( val_curentă<minim)
{ // dacă
minim = val_curentă ;
x0[0] = x_curent[0] ;
x0[1] = x_curent[1] ;
}
dacă ( contor > maxiter) gama0 = gama0 - 0.001 ;
} // cât timp
returnează minim ;
}

```

**Obs.:**

Notățiile '*Adr\_funcție*' și '*\*Adr\_funcție*' sunt simbolice. Ele reprezintă, respectiv, adresa unei funcții (deci un pointer la o funcție) și apelul unei funcții, indirect, prin pointerul al aceasta. Pentru lămuriri consultați *Anexa B - "Noțiuni de C necesare desfășurării lucrărilor de laborator"*.

**3.2.2. METODA CĂUTĂRII UNIDIMENSIONALE**

Această metodă determină minimul unei funcții  $F(X)$  prin modificarea componentelor vectorului  $X$  pe rând, începând cu prima componentă. Se modifică prima componentă atâta timp cât se obține o valoare mai mică a funcției în punctul curent decât în cel precedent. Când această condiție nu mai este îndeplinită se trece la



următoarea componentă a vectorului  $X$  și se procedează la fel până se baleiază toate componentele vectorului considerând, în acest caz, că s-a realizat un ciclu. Se poate începe un nou ciclu luând ca punct inițial minimumul obținut. La fiecare iterație se determină un nou punct funcție de precedentul astfel:

$$X_{k+1} = X_k + pas \cdot E_k \quad (8.22)$$

unde  $E_k$  reprezintă vectorul  $E_k = (0, 0, \dots, 1, \dots, 0)$ , cifra 1 fiind pe locul  $k$ ,  $k=0, 1, \dots, n$ , iar  $pas$  reprezintă pasul cu care se modifică componentele. După un ciclu încheiat se trece la un nou ciclu cu vectorul inițial cel pentru care s-a obținut minimumul în ciclul încheiat (precedent), luând un nou pas mai mic, obținut din pasul precedent înmulțit cu o rație subunitară. Se continuă iterația până când  $pas < \varepsilon$  sau numărul de iterații depășesc un număr maxim dat.  $\varepsilon$  reprezintă eroarea de calcul a punctului de minim.

### 3.2.2.1. Algoritmul 8.9. Metoda căutării unidimensionale

```

real Min_Unidimensional
(
  Adr_functie, // Adresa unei funcții reale de două
               //variabile reale( pointer la o funcție)
  real x0[ ], // vectorul de start
  real eps // eroarea de calcul
)
{ // declararea și definirea variabilelor locale
  real pas ; // pasul de modificare al coordonatelor
  întreg i ; // contor
  real min_curent,min_prec; // minimumul curent respectiv prec.
  întreg nrp ; // numărul de pași
  real stânga = -1 ;
  real dreapta = 1 ;
  real direcție ;// direcția de deplasare: stânga sau dreapta.

  // corpul de instrucțiuni al funcției
  pas = 1 ;
  min_curent = *Adr_functie(x0[0], x0[1]) ;
  execută
  {
    pentru i= 0..1
    { // pentru( )
      nrp = 0 ;
      direcție = dreapta ;
      execută
      {
        min_prec = min_curent ;
        incrementează nrp ;
        x0[i]=x0[i]+directie*pas;
        min_curent = *Adr_functie( x0[0], x0[1]) ;
        dacă ( (nrp=1) ȘI (min_curent > min_prec)
        {
          x0[i] = x0[i]-2*pas ;
          min_curent = *Adr_functie(x0[0], x0[1]) ;

```

```

        incrementează nrp ;
        direcție = stânga ;
    }
    } cât timp( min_curent <= min_prec) ;
    x0[i] = x0[i] - direcție*pas ;
    min_curent = *Adr_functie( x0[0], x0[1]) ;
    } // pentru( )
    pas = pas - 0.0001 ;
    } cât timp( pas >= eps) ;
    returnează min_curent ;
}

```

**Obs.:**

Notățiile '*Adr<sub>f</sub>*' și '*(\*Adr<sub>f</sub>)*' sunt simbolice. Ele reprezintă, respectiv, adresa unei funcții (deci un pointer la o funcție) și apelul indirect al unei funcții, prin intermediul pointerului la aceasta. Pentru lămuriri consultați *Anexa B - "Noțiuni de C necesare desfășurării lucrărilor de laborator"*.

## 4. DESFĂȘURAREA LUCRĂRII

### 4.1. ÎNTREBĂRI

1. Care este diferența dintre metodele de optimizare și cele de interpolare?
2. O problema de optimizare se va soluționa întotdeauna cu succes deplin pentru orice valori ale unei funcții?
3. Prezentați pe scurt principiul de lucru al unei metode de regresie.
4. Ce poate influența precizia de calcul a oricărei metode de optimizare?
5. Cum se definește eroarea pătratică medie? Este aceasta o funcție de una sau de mai multe variabile?
6. Numiți câteva utilizări practice ale operației de regresie.

### 4.2. PROBLEME LABORATOR

1. Să se implementeze metodele 2.1.1—2.1.7 și 2.2.1—2.2.2 în limbajul ANSI C.
2. Se dau datele experimentale din tabelul 8.2:

*Tabelul 8.2.*

<i>X</i>	1	2	3	4	5	6	7	8	9
<i>Y</i>	1.44	1.728	2.0736	2.4883	2.9859	3.5831	4.2998	5.1597	6.191

Să se determine funcția care aproximează cel mai bine funcția tabelată cu metodele 2.1.1.— 2.1.5.

3. Se dă funcția:  $z = x^2 + y^2 - 2x - 4y + 3$ . Să se determine minimul funcției cu metodele *drumului aleator* și a *căutării unidimensionale*.

#### 4.2. TEME DE CASĂ

1. Presupunem că ecuația ce leagă curentul de tensiunea pe o diodă este:

$$i = I_0 e^{eV/\gamma kT}, \text{ cu } e = q \text{ și } kT/q \sim 25\text{mV}.$$

Se cer valorile  $I_0$  și  $\gamma$  (gamma) utilizând regresia liniară asupra tabelului:

<b>v (V)</b>	.2	.28	.36	.44	.52	.6
<b>ln(i)</b>	$\ln(10^{-9}) =$ -20.7232	$\ln(10^{-8}) =$ -18.4207	$\ln(10^{-7}) =$ -16.1181	$\ln(10^{-6}) =$ -13.8155	$\ln(10^{-5}) =$ -11.5129	$\ln(10^{-4}) =$ -9.2103

**Indicație:**

$$\ln(i/I_0) = (1/\gamma) * (v/uT) \Rightarrow \ln(i) - \ln(I_0) = a * x,$$

cu:  $a = 1/(\gamma * uT)$ , iar  $x = v$ .

Apoi:

$$\ln(i) = a * x + \ln(I_0),$$

ceea ce respectă definiția unei regresii liniare, de formă  $y = ax + b$ .

Din aplicarea regresiei liniare asupra tabelului vor rezulta chiar  $a$  și  $b$ . Din valoarea lui  $a$  se deduce  $\gamma$ , iar din valoarea lui  $b$  rezultă  $I_0$ .

**Obs.:**

Valorile de tip ordonată din tabel sunt de fapt valori numerice (*scalari*), anume funcția logaritm natural aplicată valorilor curentului din tabelul din problema interpolării. Această operație este necesară datorită logaritmării aplicate relației curentului, în deducerea teoretică. Se vor putea, astfel, scădea valori de aceeași natură, în expresia erorii pătratice.

#### BIBLIOGRAFIE

1. I. Rusu, "Metode numerice în electronică. Aplicații în limbaj C", Editura Tehnică, București, 1997.