

CURS 6: APROXIMAREA FUNCTIILOR PRIN REGRESIE

1 Metoda celor mai mici pătrate

1.1 Formularea problemei. Notății

Metoda celor mai mici pătrate (ale erorii) este cea mai uzuală metodă de aproximare a unei dependențe $y=y(x)$, date tabelar (ca în tabelul 1), printr-o funcție analitică, care se numește **funcție** (de obicei **polinomială**) **de regresie**. De aceea, metoda celor mai mici pătrate se mai numește și **regresie**, cu largă aplicabilitate în estimare, statistică și prelucrarea datelor.

x	x_1	x_2	$\dots$	x_n
y	y_1	y_2	$\dots$	y_n

Tabel 1 Dependența $y=y(x)$ dată prin tabel

Dependența $y=y(x)$ se poate reprezenta grafic în planul (x, y) , obținându-se așa-numitul „*nor de puncte*”. De cele mai multe ori, după alura norului de puncte se poate stabili forma exactă a funcției de regresie: dacă punctele se distribuie în jurul unei drepte, atunci se alege drept funcție de regresie un polinom de gradul I (regresie liniară), dacă se distribuie în jurul unei parabole sau a unei parabole cubice, atunci trebuie aleasă o funcție polinomială de gradul al II-lea, respectiv de gradul al III-lea etc. Dacă forma sugerată a norului de puncte nu corespunde unui caz simplu, atunci se procedează la regresia cu o funcție polinomială de grad superior, ales arbitrar în primă fază.

Dacă se notează cu $\hat{y}_i, i = \overline{1, n}$, valorile approximate (estimate) și cu f_{reg} funcția generală de regresie, atunci este valabilă relația:

$$(1) \quad \hat{y}_i = f_{reg}(x_i)$$

Funcția f_{reg} depinde de un set de m parametri, fie aceștia $a_i, i = \overline{1, m}$ (în particular, aceștia sunt coeficienții polinomului de regresie), care se determină din **minimizarea erorii pătratice** cumulate dintre valorile reale, y_i , și valorile approximate, $\hat{y}_i$:

$$(2) \quad E(a_1, a_2, \dots, a_m) \triangleq \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Funcția de eroare (2) este o expresie a **dispersiei** valorilor reale de la curba presupusă. Fiind o sumă de pătrate, această funcție prezintă un minim pozitiv (în cazul ideal, acesta este 0, corespunzând aproximării exacte), care se obține din anularea derivatelor sale parțiale în raport cu fiecare dintre parametrii $a_i, i = \overline{1, m}$. Rezultă astfel sistemul de m ecuații în necunoscutele $a_i, i = \overline{1, m}$, numit **sistemul ecuațiilor normale**:

$$(3) \quad \begin{cases} \frac{\partial E(a_1, a_2, \dots, a_m)}{\partial a_i} = 0, & i = \overline{1, m} \end{cases}$$

În cazul în care f_{reg} este funcție polinomială, sistemul (3) este liniar și compatibil determinat, soluția lui admitând o formă generală, care este prezentată în §1.5.

O aplicație imediată și intuitivă a metodei celor mai mici pătrate este trasarea grafică a unei dependențe de tipul celei din tabelul 1, presupunând că datele respective s-au obținut în urma măsurării variației variabilei dependente y în funcție de variația variabilei independente x . Măsurătorile fiind în general afectate de erori, se aplică întâi o metodă de regresie pentru determinarea unei aproximări analitice a dependenței respective. Prin reprezentarea grafică a norului de puncte de coordonate (x_i, y_i) , $i=1,2,\dots,n$, și a funcției de regresie $\hat{y} = \hat{y}(x)$ în același sistem de coordonate, se observă că aproximarea prin regresie corespunde trasării graficului „*printre puncte*” (figura 1).




Fig. 1 Trasarea graficului de regresie printre punctele norului de puncte

Algoritmii de regresie sunt practic înșiruirea relațiilor de calcul al coeficienților de regresie. De aceea se prezintă direct implementările Matlab ale celor mai uzuale cazuri de regresie – *liniară*, *parabolică* și *exponențială* – și a *cazului general de regresie polinomială*.

1.2 Aproximarea prin regresie liniară

Regresia liniară constă în aproximarea unui nor de puncte printr-o *dreaptă*; ca atare, relația de calcul al valorilor approximate (estimate), $\hat{y}_i$, $i = \overline{1, n}$, este:

$$(4) \quad \hat{y}_i = a \cdot x_i + b$$

Coeficienții a și b sunt soluțiile sistemului (3), particularizat pentru $m=2$:

$$(5) \quad \begin{cases} a = \frac{n \cdot S_{xy} - S_x \cdot S_y}{n \cdot S_{xx} - S_x^2}, & b = \frac{S_{xx} \cdot S_y - S_x \cdot S_{xy}}{n \cdot S_{xx} - S_x^2}, \end{cases}$$

unde s-au făcut notațiile: $S_x = \sum_{i=1}^n x_i$, $S_{xx} = \sum_{i=1}^n x_i^2$, $S_y = \sum_{i=1}^n y_i$, $S_{xy} = \sum_{i=1}^n x_i y_i$. Relațiile (5)

rezultă din dezvoltarea determinantilor implicați în sistemul (3).

Funcția Matlab de implementare a metodei de regresie liniară trebuie să primească drept date de intrare cei doi vectori, x și y , și să returneze valorile celor doi coeficienți de regresie,

a și b . Funcția Matlab `cmmp_lin` listată mai jos mai returnează și șirul de valori approximate, $\hat{y}_i$, $i = \overline{1, n}$, în vectorul `y_aprox`, precum și valoarea (minimizată) a erorii pătratice globale (conform relației (2)) în variabila `E`.

```
function [a,b,y_aprox,E]=cmmp_lin(x,y)
    %REGRESIE LINIARĂ pe un set de perechi de date (x,y);
    %dreapta de regresie are ecuația y=a*x+b;
    %x și y sunt vectori de aceeași dimensiune,
    %(recomandabil ca x să fie ordonat crescător/descrescător)

    n=length(x);
    %calculul sumelor
    Sx=sum(x); Sxx=sum(x.^2); Sy=sum(y); Syy=sum(x.*y);
    %calculul numitorului și numărătorilor din formulele lui a și b
    d=n*Sxx-Sx^2; da=n*Syy-Sx*Sy; db=Sxx*Sy-Sx*Syy;
    %calculul coeficienților de regresie, a și b
    a=da/d; b=db/d;

    %valorile approximate
    y_aprox=a*x+b;
    %eroarea globală
    E=sum((y-y_aprox).^2);
```

Ca o observație, se poate folosi și funcția `det` din biblioteca Matlab, care calculează determinantul unei matrice pătratice.

În exemplul de mai jos se arată o modalitate de verificare a funcției `cmmp_lin`.

Exemplul 1: Dându-se șirul de valori `x=[1 1.5 2 2.5 3 3.5 4 4.5 5 5.5 6]` (la cazul general, acestea nu trebuie să fie echidistante), se generează vectorul `y` după relația $y=2*x+7$ și se apelează funcția `cmmp_lin`.

```
x=[1 1.5 2 2.5 3 3.5 4 4.5 5 5.5 6]; y=2*x+7;
[a,b,y_aprox,E]=cmmp_lin(x,y)
```

Rezultatul este conform așteptărilor:

```
a =
    2

b =
    7

y_aprox =
    9    10    11    12    13    14    15    16    17    18    19

E =
    0
```

Se perturbă apoi valorile obținute cu formula $y=2*x+7$ (de exemplu, cu maxim $\pm 10\%$), rezultând `y1=[8.1 11 9.9 13.2 11.7 15.4 13.5 17.6 15.3 19.8 17.1]`. Apelul funcției `cmmp_lin` cu argumentele de intrare `x` și `y1` (existente în spațiul de lucru):

```
[a1,b1,y1_aprox,E1]=cmmp_lin(x,y1)
```

produce următoarele rezultate:

```

a1 =
    1.8757

b1 =
    7.3104

y1_aprox =
    Columns 1 through 7
    9.1860  10.1238  11.0617  11.9995  12.9373  13.8752  14.8130
    Columns 8 through 11
    15.7508  16.6887  17.6265  18.5643

E1 =
    4.5376

```

Evident, valorile coeficienților de regresie, a și b , vor fi cu atât mai deviate de la valorile 2, respectiv 7, cu cât perturbația setului y de la dreapta exactă $2x+7$ va fi mai mare. Rezultatele regresiei se vizualizează grafic prin reprezentarea norului de puncte și a graficului dreptei de regresie, $ax+b$ (pentru care se discretizează intervalul de variație al variabilei independente, x , cu un pas suficient de mic – rezultatul se depune în vectorul xx – și se calculează variabila dependentă, y , în fiecare valoare astfel obținută – rezultatul se depune în vectorul yy).




Fig. 2 Aproximarea unui nor de puncte prin regresie liniară

În urma comenzilor Matlab:

```

xx=min(x):(max(x)-min(x))/200:max(x);
yy=a*xx+b;
plot(x,y,'o',xx,yy,'-');grid;

```

se obține graficul din figura 2.

1.3 Aproximarea prin regresie parabolică

Dacă norul de puncte are alură de *parabolă*, atunci se poate aplica regresia parabolică. Relația de calcul al valorilor approximate, $\hat{y}_i$, $i = \overline{1, n}$, este în acest caz:

$$(6) \quad \hat{y}_i = a \cdot x_i^2 + b \cdot x_i + c$$

Coefficienții a , b și c sunt soluțiile sistemului (2.3), particularizat pentru $m=3$:

$$(7) \quad \begin{cases} a = \frac{\Delta_a}{\Delta}, & b = \frac{\Delta_b}{\Delta}, & c = \frac{\Delta_c}{\Delta}, \end{cases}$$

unde Δ este determinantul sistemului (2.3), iar Δ_a , Δ_b și Δ_c sunt determinanții de calcul ai coeficienților. Formele lor compacte, precum și formulele desfășurate sunt date mai jos.

$$\Delta = \begin{vmatrix} S_{4x} & S_{3x} & S_{xx} \\ S_{3x} & S_{xx} & S_x \\ S_{xx} & S_x & n \end{vmatrix} = nS_{xx}S_{4x} - S_x^2S_{4x} - nS_{3x}^2 + 2S_xS_{xx}S_{3x} - S_{xx}^3$$

$$\Delta_a = \begin{vmatrix} S_{2xy} & S_{3x} & S_{xx} \\ S_{xy} & S_{xx} & S_x \\ S_y & S_x & n \end{vmatrix} = nS_{xx}S_{2xy} - S_x^2S_{2xy} - nS_{3x}S_{xy} + S_xS_{3x}S_y + S_xS_{xx}S_{xy} - S_{xx}^2S_y$$

$$\Delta_b = \begin{vmatrix} S_{4x} & S_{2xy} & S_{xx} \\ S_{3x} & S_{xy} & S_x \\ S_{xx} & S_y & n \end{vmatrix} = nS_{4x}S_{xy} - S_xS_{4x}S_y - nS_{3x}S_{2xy} + S_xS_{xx}S_{2xy} + S_{xx}S_{3x}S_y - S_{xx}^2S_{xy}$$

$$\Delta_c = \begin{vmatrix} S_{4x} & S_{3x} & S_{2xy} \\ S_{3x} & S_{xx} & S_{xy} \\ S_{xx} & S_x & S_y \end{vmatrix} = S_{xx}S_{4x}S_y - S_xS_{4x}S_{xy} - S_{3x}^2S_y + S_{xx}S_{3x}S_{xy} + S_xS_{3x}S_{2xy} - S_{xx}^2S_{2xy}$$

S-au făcut notațiile: $S_x = \sum_{i=1}^n x_i$, $S_{xx} = \sum_{i=1}^n x_i^2$, $S_{3x} = \sum_{i=1}^n x_i^3$, $S_{4x} = \sum_{i=1}^n x_i^4$, $S_y = \sum_{i=1}^n y_i$,

$$S_{xy} = \sum_{i=1}^n x_i y_i, \quad S_{2xy} = \sum_{i=1}^n x_i^2 y_i.$$

Metoda de regresie parabolică este implementată printr-o funcție numită `cmmp_par`, care primește aceleași argumente de intrare ca și `cmmp_lin`, funcția destinată regresiei liniare, și anume seturile de date x și y . Pe lângă coeficienții de regresie, a , b și c , și eroarea globală, funcția mai returnează și perechea de vectori (xx, yy) , calculați pentru reprezentarea grafică a curbei de regresie (în maniera arătată la regresia liniară, exemplul 2.1).

```
function [a,b,c,E,xx,yy]=cmmp_par(x,y)
%REGRESIE PARABOLICĂ pe seturile de date (x,y);
%
%                                2
%curba de regresie are ecuația y = a*x + b*x + c;
%x și y sunt vectori de aceeași dimensiune,
%(recomandabil ca x să fie ordonat crescător/descrescător)

n=length(x);
%calculul sumelor
```

```

Sx=sum(x);Sxx=sum(x.^2);S3x=sum(x.^3);S4x=sum(x.^4);
Sy=sum(y);Sxy=sum(x.*y);S2xy=sum((x.^2).*y);
%calculul determinantilor
d=n*Sxx*S4x-Sx^2*S4x-n*S3x^2+2*Sx*Sxx*S3x-Sxx^3;
da=n*Sxx*S2xy-Sx^2*S2xy-n*S3x*Sxy+Sx*S3x*Sy+...
    Sx*Sxx*Sxy-Sxx^2*Sy;
db=n*S4x*Sxy-Sx*S4x*Sy-n*S3x*S2xy+Sx*Sxx*S2xy+...
    Sxx*S3x*Sy-Sxx^2*Sxy;
dc=Sxx*S4x*Sy-Sx*S4x*Sxy-S3x^2*Sy+Sxx*S3x*Sxy+...
    Sx*S3x*S2xy-Sxx^2*S2xy;
%calculul coeficienților de regresie
a=da/d;
b=db/d;
c=dc/d;

%vectori calculați în vederea unei eventuale reprezentări grafice
xx=min(x):(max(x)-min(x))/200:max(x);
yy=a*xx.^2+b*xx+c;
%eroarea globală
E=sum((y-a*x.^2-b*x-c).^2);

```

A se observa modul de plasare pe mai multe rânduri a unei formule neobișnuit de lungi (terminarea fiecărui rând cu caracterele „,...”).

Exemplul 2: Dându-se vectorul $x=[0 \ 0.3 \ 1 \ 1.4 \ 1.6 \ 2 \ 2.1 \ 2.4 \ 2.8 \ 3 \ 3.5 \ 3.7 \ 3.9 \ 4]$ și vectorul $y=x.^2-4*x-10$, apelul funcției `cmmp_par` cu returnarea numai a primelor patru argumente de ieșire:

```
[a,b,c,E]=cmmp_par(x,y)
```

va avea drept ecou la ecran:

```

a =
    1.0000

b =
   -4.0000

c =
  -10.0000

E =
  4.3108e-024

```

Rezultatele confirmă așteptările; câteva comentarii se impun. Se observă că valoarea erorii globale este foarte mică, practic 0; totuși, ea nu a fost afișată ca 0, ceea ce înseamnă că *nu este exact* 0, așa cum s-a obținut în cazul regresiei liniare pe un set de date perfect „curat”, neperturbat (exemplul 2.1). Nici coeficienții de regresie nu corespund *exact* valorilor curbei după care a fost generat vectorul y ; aceasta se constată reafișând coeficienții în formatul de afișare cu 15 zecimale:

```

format long
a

```

```

a =
    0.999999999999995

b
b =
   -3.999999999999985

c
c =
   -9.999999999999946

```

Rezultatele confirmă o intuiție firească: erorile de calcul cresc cu cât ordinul regresiei crește (cu cât numărul coeficienților de regresie este mai mare).

Exemplul 3: Regresia parabolică se aplică acum pe seturi de date legate printr-o lege liniară; de exemplu, fie cele din exemplul 2.1: $x=[1 \ 1.5 \ 2 \ 2.5 \ 3 \ 3.5 \ 4 \ 4.5 \ 5 \ 5.5 \ 6]$ și $y=2*x+7$.

Rezultatul așteptat în urma apelului funcției `cmmp_par` este ca parabola de regresie să aibă coeficientul a aproximativ nul (parabola se reduce la o dreaptă). Într-adevăr, comanda:

```
[a,b,c,E]=cmmp_par(x,y)
```

are ca rezultat:

```

a =
    0

b =
    2

c =
    7

E =
    0

```

Rezultatul este de această dată exact, coeficienții sunt determinați fără eroare.

Rămânând în continuare la exemplul 2.1 și apelând funcția `cmmp_par` pentru setul y perturbat, $y1=[8.1 \ 11 \ 9.9 \ 13.2 \ 11.7 \ 15.4 \ 13.5 \ 17.6 \ 15.3 \ 19.8 \ 17.1]$:

```
[a1,b1,c1,E1]=cmmp_par(x,y1)
```

se obține:

```

a1 =
   -0.1305

b1 =
    2.8592

c1 =
    5.7909

```

```
E1 =
    21.4862
```

Eroarea globală obținută prin regresie parabolică (21.4862) este mai mare decât cea prin regresie liniară (4.5376, din exemplul 2.1), ceea ce arată că respectivul nor de puncte *se aproximează mai bine printr-o dreaptă decât printr-o parabolă*.

De aici se desprinde o concluzie generală: în cazul aplicării regresiei polinomiale unui set dat de date, mai întâi trebuie determinat *ordinul* regresiei care asigură eroarea minimă. Se va reveni la această problemă când se va discuta cazul general de regresie polinomială (§2.1.5).

1.4 Aproximarea prin regresie exponențială

Regresia exponențială se aplică atunci când variabila dependentă are valori de semn constant (are fie numai valori pozitive, fie numai valori negative, și atunci se consideră $|y|$ ca variabilă dependentă). Fără a reduce generalitatea se poate, deci, presupune că y conține numai valori pozitive. Norul de puncte se aproximează printr-o *curbă exponențială*; valorile estimate, $\hat{y}_i > 0$, $i = \overline{1, n}$, determinându-se cu:

$$(8) \quad \hat{y}_i = C \cdot e^{\alpha \cdot x_i}, \quad C > 0$$

Prin logaritmarea relației (2.8) și introducerea schimbării de variabilă $\hat{z} \triangleq \ln(\hat{y})$, $\hat{z} > 0$, se obține:

$$(9) \quad \hat{z}_i = \underbrace{\alpha}_{A} \cdot x_i + \underbrace{\ln(C)}_B,$$

care este un model de **regresie liniară** pentru seturile de date x și $z \triangleq \ln(y)$, cu coeficienții $A = \alpha$ și $B = \ln(C) > 0$. Aceștia se pot, deci, determina adaptând formulele (2.5):

$$(10) \quad \begin{cases} A = \frac{n \cdot S_{xz} - S_x \cdot S_z}{n \cdot S_{xx} - S_x^2}, & B = \frac{S_{xx} \cdot S_z - S_x \cdot S_{xz}}{n \cdot S_{xx} - S_x^2}, \end{cases}$$

unde s-au făcut notațiile: $S_x = \sum_{i=1}^n x_i$, $S_{xx} = \sum_{i=1}^n x_i^2$, $S_z = \sum_{i=1}^n z_i = \sum_{i=1}^n \ln(y_i) = \ln\left(\prod_{i=1}^n y_i\right)$,

$S_{xz} = \sum_{i=1}^n x_i z_i = \sum_{i=1}^n x_i \ln(y_i)$. Relația (2.8) se poate rescrie sub forma:

$$\hat{y}_i = e^{A \cdot x_i + B}, \quad B > 0$$

Având în vedere reducerea de mai sus, funcția Matlab pentru regresia exponențială, numită `cmmp_exp`, constă în esență în apelarea funcției `cmmp_lin`, de regresie liniară. Semnificația argumentelor de ieșire ale funcției `cmmp_exp` este aceeași ca în cazul funcției `cmmp_par`, de regresie parabolică; ea este listată și comentată mai jos.

```
function [A,B,E,xx,yy]=cmmp_exp(x,y)
    %REGRESIE după o CURBA EXPONENTIALĂ a unui set de date (x,y);
    %
    %                                A*x+B
    %curba de regresie are ecuația y=e;
```

```

%x și y sunt vectori de aceeași dimensiune;
%(recomandabil ca x să fie ordonat crescător/descrescător);
%y conține valori pozitive

%regresia de acest tip se reduce la regresia liniară prin
%logaritmare naturală a valorilor din y
z=log(y);
[A,B,E1,y_aprox1]=cmmp_lin(x,z);

%șiruri de valori calculate în vederea unei eventuale reprezentări grafice
xx=min(x):(max(x)-min(x))/200:max(x);
yy=exp(A*xx+B);
%eroarea globală
E=sum((y-exp(A*x+B)).^2);

```

Funcția returnează coeficienții A și B (o modificare minoră, folosind relațiile introduse în formula (2.9), este necesară pentru a întoarce valorile coeficienților C și α).

Exemplul 4: Pornind de la seturile de date $x = [-3 \ -2 \ 0 \ 0.5 \ 1.5 \ 3 \ 4]$ și $y = [0.2725 \ 0.4493 \ 1.2214 \ 1.5683 \ 2.5857 \ 5.4739 \ 9.0250]$ (generat cu relația $y = e^{0.5x+0.2}$: $y = \exp(0.5x+0.2)$), apelul funcției `cmmp_exp`: cu primele trei argumente de ieșire:

```
[A,B,E]=cmmp_exp(x,y)
```

furnizează rezultatul așteptat:

```

A =
    0.5000

B =
    0.2000

E =
    1.6424e-030

```

Eroarea globală nu este exact 0, din cauza erorilor introduse de logaritmare inițială.

Exemplul 5: Se perturbă acum ușor valorile lui y din exemplul 2.4 cu maxim $\pm 25\%$, obținându-se șirul $y1 = [0.2998 \ 0.4044 \ 1.3435 \ 1.4115 \ 2.8443 \ 4.9266 \ 9.9275 \ 8.9768]$.

Făcând abstracție de modul de generare a datelor, alura norului de puncte poate corespunde la fel de bine și unei curbe exponențiale, dar și unei parabole. Se vor încerca ambele tipuri de regresie – exponențială și parabolică – și se vor compara erorile globale.

Se apelează întâi funcția `cmmp_exp`, pentru regresia exponențială:

```
[A,B,E1]=cmmp_exp(x,y1)
```

obținându-se:

```

A =
    0.4641

B =
    0.1791

```

```
E1 =  
69.5620
```

Deci norul de puncte poate fi aproximat prin $\hat{y}_{exp} = e^{0.4641 \cdot x + 0.1791}$, cu eroarea globală de 69.562.

Apelul funcției `cmmp_par`, pentru regresie parabolică:

```
[a, b, c, E2] = cmmp_par(x, y1)
```

conduce la:

```
a =  
0.2457  
  
b =  
0.9255  
  
c =  
1.1475  
  
E2 =  
66.1489
```




Fig. 3 Aproximarea prin regresie parabolică și exponențială a unui nor de puncte

Deci norul de puncte mai admite și aproximarea $\hat{y}_{par} = 0.2457 \cdot x^2 + 0.9255 \cdot x + 1.1475$, cu eroarea globală de 66.1489.

Se observă că eroarea globală are valori mari în ambele cazuri, dar că este mai mică în cazul regresiei parabolice (66.1489) decât în cazul regresiei exponențiale (69.562). Deci, deși datele inițiale, neperturbate, corespundeau unei dependențe exponențiale, perturbarea lor a fost suficient de semnificativă pentru a modifica *tipul* dependenței: datele perturbate ale variabilei dependente, y , respectă mai degrabă o lege parabolică în raport cu variabila independentă, x .

Reprezentarea norului de puncte și trasarea graficelor curbelor de regresie obținute mai sus în același sistem de coordonate se realizează prin următorul bloc de comenzi:

```
[A, B, E1, xx1, yy1] = cmmp_exp(x, y1);
```

```
[a,b,c,E2,xx2,yy2]=cmmppar(x,y1);
plot(x,y,'ko',xx1,yy1,'k--',xx2,yy2,'k-');grid;
```

care produce rezultatele din figura 2.3.

1.5 Cazul general de regresie polinomială

Dacă alura norului de puncte nu corespunde niciunuia din cazurile de mai sus, atunci se efectuează regresia după o curbă polinomială de grad cel puțin 3. Notând cu m numărul coeficienților de regresie – care este, deci, cel puțin 4 – valorile approximate, $\hat{y}_i$, $i = \overline{1, n}$, sunt date de relația generală:

$$(11) \quad \hat{y}_i = a_m \cdot x_i^{m-1} + a_{m-1} \cdot x_i^{m-2} + \dots + a_2 \cdot x_i + a_1$$

Să observăm că există o cerință generală: pentru a face regresie polinomială cu m parametri este necesar să se dispună de cel puțin m perechi de date (x_i, y_i) . Deci trebuie îndeplinită condiția $n \geq m$. Notând cu $\underline{c} = [a_i]_{i=\overline{1, m}}$ vectorul coeficienților de regresie, sistemul (2.3) este liniar pătratic; el se poate pune sub forma compactă:

$$(2.3') \quad S \cdot \underline{c} = \underline{t}$$

unde $S = [s_{ji}]_{j=\overline{1, m}, i=\overline{1, m}}$ este matricea sistemului, iar $\underline{t} = [t_j]_{j=\overline{1, m}}$ este vectorul termenilor liberi, ale căror elemente se calculează după relațiile:

$$(12) \quad s_{ji} = \sum_{k=1}^n x_k^{j+i-2}, \quad t_j = \sum_{k=1}^n y_k \cdot x_k^{j-1}$$

Matricea S fiind nesară, sistemul (2.3') este compatibil determinat și are soluția:

$$(13) \quad \underline{c} = S^{-1} \cdot \underline{t}$$

Mai jos este prezentată funcția Matlab `cmmpp_gen`, care reprezintă o implementare posibilă a cazului general de regresie polinomială. Spre deosebire de funcțiile de regresie prezentate până acum, această funcție mai primește încă un argument de intrare, și anume pe m , numărul de parametri de regresie (pe lângă vectorii x și y). Pentru simplitate, formula (2.13) s-a realizat prin apelul funcției `inv` din biblioteca Matlab (implementarea de algoritmi numerici pentru calculul inverselor matriciale va fi discutată pe larg mai târziu în această lucrare). Primul argument de ieșire al funcției de mai jos, `coef`, este vectorul coeficienților polinomului de regresie, în ordine *crescătoare* a puterilor variabilei. Celelalte argumente de ieșire au aceeași semnificație ca în cazul celorlalte funcții.

```
function [coef,E,y_aprox,xx,yy]=cmmpp_gen(x,y,m)
%metoda CMMP de aproximare a dependenței y=f(x)
%printr-un POLINOM DE GRADUL m-1 (altfel spus, regresie cu m parametri);
%coeficienții polinomului de regresie se returnează în coef,
%care este de dimensiune m, în ordine crescătoare a puterilor variabilei;
%x și y au aceeași dimensiune;
%(recomandabil ca x să fie ordonat crescător/descrescător);
%n>m (numărul de perechi de date trebuie sa fie mai mare
% decât numărul parametrilor de regresie)
```

```

n=length(x);
%calculul elementelor matricei și al termenilor liberi
for j=1:m,
    t(j)=0;
    for i=1:m,
        s(j,i)=0;
        for k=1:n,
            s(j,i)=s(j,i)+x(k)^(j+i-2);
        end;
    end;
    for k=1:n,
        t(j)=t(j)+y(k)*(x(k)^(j-1));
    end;
end;

coef=inv(s)*t';
coef=coef'; %operație de transpunere pentru ca vectorul coef să rezulte de tip linie

%calculul valorilor approximate ale variabilei dependente
for k=1:n,
    y_aprox(k)=0;
    for i=1:m,
        y_aprox(k)=y_aprox(k)+coef(i)*(x(k)^(i-1));
    end;
end;

%eroarea globală
E=(y-y_aprox)*(y-y_aprox)'; %echivalent cu E=(y-y_aprox).^2

%generarea vectorilor de valori pentru o eventuală reprezentare grafică
xx=min(x):(max(x)-min(x))/200:max(x);
for k=1:length(xx),
    yy(k)=0;
    for i=1:m,
        yy(k)=yy(k)+coef(i)*(xx(k)^(i-1));
    end;
end;
end;

```

Observație: Dacă se dorește obținerea coeficienților de regresie în ordine *descrescătoare* a puterilor variabilei (ceea ce corespunde manierei Matlab de returnare a rezultatelor de acest tip), atunci se poate folosi funcția Matlab `fliplr` (engl. *flip left-right*, oglindire stânga-dreapta; alte funcții din aceeași clasă sunt `flipud` – engl. *flip up-down* – și `rot90`). Avantajul acestei variante este că `y_aprox` și `yy` se pot calcula mai elegant, și anume apelând o altă funcție din bibliotecă, `polyval`, de calcul al valorii unui polinom dat prin vectorul coeficienților în ordine descrescătoare a puterilor variabilei într-o valoare dată (a se vedea și §1.3.3.8, exercițiul propus 4). Ultimele trei blocuri de comenzi din funcția `cmmmp_gen` se rescriu sub forma:

```

coef=inv(s)*t';
coef=fliplr(coef');

%calculul valorilor approximate ale variabilei dependente
for k=1:n,
    y_aprox(k)=polyval(coef,x(k));
end;
%eroarea globală
E=(y-y_aprox)*(y-y_aprox)';

%generarea vectorilor de valori pentru o eventuală reprezentare grafică
xx=min(x):(max(x)-min(x))/200:max(x);
for k=1:length(xx),
    yy(k)=polyval(coef,xx(k));
end;

```

O problemă anticipată în paragrafele anterioare constă în modul *cum se stabilește gradul polinomului de regresie*, altfel spus numărul parametrilor de regresie, m . Având în vedere condiția $m \leq n$, în primă fază se poate considera $m=n$, adică efectuarea unei regresii de *grad maxim* admis de seturile respective de date. Este posibil ca această regresie să nu fie necesară, caz în care unul sau mai mulți coeficienți polinomiali, începând cu cel de rang maxim, $m-1$, să fie aproape nuli sau, în orice caz, mult mai mici în valoare absolută decât ceilalți. În acest caz, o a doua iterație de regresie se va face cu gradul egal cu rangul primului coeficient nenul (în ordine descrescătoare a puterilor variabilei).

Exemplul 6: Pentru seturile de date $x=[3 \ 3.3 \ 3.7 \ 3.9 \ 4.7 \ 4.8 \ 4.9 \ 5 \ 5.25]$ și $y=[3 \ 5 \ 10 \ 14 \ 43 \ 49 \ 56 \ 63 \ 84]$ (de lungime $n=9$) se efectuează întâi regresia de gradul $n-1$, adică de gradul 8:

```
[coef,E]=cmmmp_gen(x,y,length(x)-1)
```

Rezultatul apelului de mai sus constă în primul rând în afișarea unui mesaj de avertizare asupra apropierei de singularitate a matricei sistemului (a cărei inversă se calculează), numărul ei de condiționare – calculat în $RCOND$ – fiind mic (comparabil cu epsilon mașină). Interpretorul avertizează astfel că este posibil ca acuratețea rezultatelor să nu fie bună.

```

Warning: Matrix is close to singular or badly scaled.
Results may be inaccurate. RCOND = 7.158432e-024

```

Setările implicite din mediul Matlab prevăd ca avertizările de acest gen să fie ignorate de către interpretor și să nu oprească execuția programelor; astfel, după mesajul de eroare se afișează rezultatele de mai jos:

```

coef =
    1.0e+004 *
    Columns 1 through 7
    -4.2489    6.7751   -4.4086    1.4564   -0.2303    0.0038    0.0044
    Columns 8 through 9
    -0.0006    0.0000

E =
    816.4324

```

Se observă că ultimele două elemente, de rang 7 și 8, din vectorul `coef` sunt mult mai

mici decât restul coeficienților. Deci procedura de regresie se poate repeta cu gradul polinomului de regresie micșorat cu două unități (gradul 6):

```
[coef,E]=cmmmp_gen(x,y,length(x)-3)
```

Rezultatele sunt din nou însoțite de același mesaj de eroare, dar eroarea globală are o valoare mult mai mică:

```
Warning: Matrix is close to singular or badly scaled.
Results may be inaccurate. RCOND = 1.281806e-019

coef =
    1.0e+004 *
    0.8818   -1.2970    0.7868   -0.2519    0.0449   -0.0042    0.0002

E =
    0.2157
```

Dacă se scade în continuare gradul polinomului de regresie la 5:

```
[coef,E]=cmmmp_gen(x,y,length(x)-4)
```

se observă că valoarea erorii globale crește (rămânând de același ordin de mărime), dar nu se mai afișează mesajul de eroare:

```
coef =
    17.9262   -7.4289   -3.7338    3.0191   -0.7671    0.0888

E =
    0.3205
```

Dacă nivelul maxim admisibil al erorii de aproximare o permite, scăderea gradului regresiei poate continua în aceeași manieră, ținând cont că rangul maxim este ocupat de un coeficient cu un ordin de mărime mai mic în modul decât ceilalți (0.0888).

Dacă nu se continuă scăderea gradului, se pune problema care dintre ultimele două rezultate se reține drept rezultat final. În general, trebuie evitate rezultatele de încredere diminuată (însoțite de avertizări de genul celor de mai sus); în cazul de față, ultimul rezultat ar trebui ales, cu atât mai mult cu cât eroarea de aproximare față de cazul imediat superior nu este cu mult mai mare. Ca atare, seturile de date x și y se găsesc aproximativ în dependență:

$$y \cong \hat{y} = 0.0888x^5 - 0.7671x^4 + 3.0191x^3 - 3.7338x^2 - 7.4289x + 17.9262$$

În biblioteca Matlab există o funcție care implementează cazul general de regresie polinomială, ea se numește `polyfit`. Această funcție primește ca date de intrare cele două seturi de date, precum și *gradul* polinomului de regresie (funcția `cmmmp_gen`, scrisă mai sus, primește *numărul* coeficienților polinomiali) și returnează coeficienții polinomului în ordine *descrescătoare* a puterilor variabilei (în timp ce `cmmmp_gen` îi returnează în ordine *crescătoare*).

De pildă, pentru aceleași seturi de date $x=[2 \ 4 \ 5 \ 7 \ 8]$ și $y=[1 \ 1.4 \ 2.3 \ 1.2 \ 0.4]$, pentru ca cele două funcții să calculeze același polinom, de exemplu de gradul 3, ele se vor apela cu:

```
[coef1]=polyfit(x,y,4);
[coef2]=cmmmp_gen(x,y,5);
```

și vor furniza rezultatele `coef1=[0.0406 -0.8733 6.4739 -19.0567 19.5556]` și `coef2=[19.5556 -19.0567 6.4739 -0.8733 0.0406]`, care exprimă același polinom de regresie, $0.0406 \cdot x^4 - 0.8733 \cdot x^3 + 6.4739 \cdot x^2 - 19.0567 \cdot x + 19.5556$.