

Serii temporale

O mulțime de observații rezultate din măsurători efectuate în perioade succesive de timp, notată $\{x_t, t \in T\}$, (unde $T \subseteq \mathbf{R}$, se referă la *timp*) se numește *serie temporală* sau *serie dinamică*.

Datele x_t se pot referi la observații în timp discret (zile, săptămâni, luni, trimestre, ani etc.) sau pot fi date obținute în timp continuu.

Valorile succesive din baza de date reprezintă măsurători consecutive, prelevate la intervale de timp egale, măsurători ce ilustrează dinamica unui anumit proces în timp.

O caracterizare concisă a prognozei:

„Am văzut viitorul și seamănă mult cu prezentul, numai că e mai lung.”
(Kehlog Albran, *Profitul*).

Suntem interesați de proprietățile statistice ale seriilor temporale care vor descrie viitorul, în sensul descrierii comportamentului acestora în viitor, la fel de bine cum descriu și prezentul.

Analiza seriilor temporale urmărește:

- înțelegerea evoluției seriei în trecut (identificarea naturii fenomenului reprezentat de secvența observațiilor care sunt analizate);
- prognoza evoluției viitoare pe baza datelor cunoscute.

Seriile temporale se vizualizează prin tabele sau prin grafice.

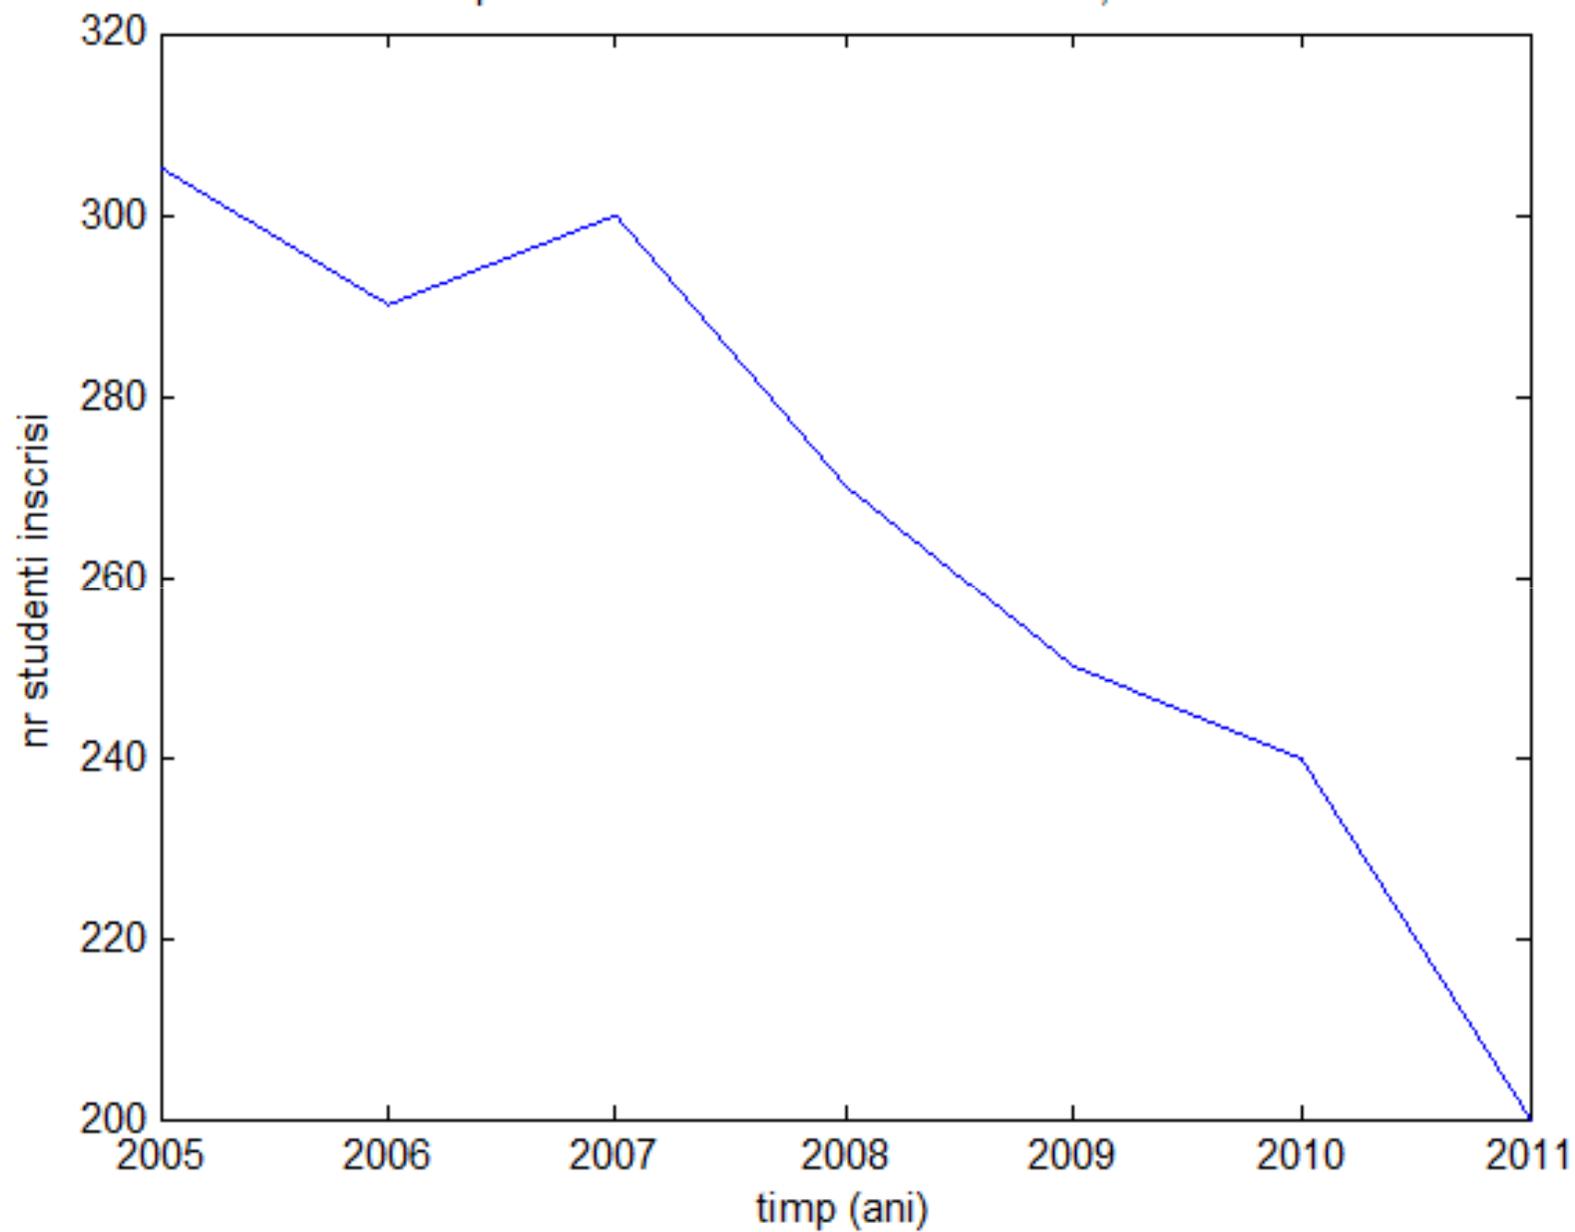
1. Exemplu

Înscrierile în anul I al unei facultăți, din ultimii 7 ani, sunt prezentate în tabelul de mai jos:

anul	2005	2006	2007	2008	2009	2010	2011
Studenti înscriși	305	290	300	270	250	240	200

```
>> t=2005:2011; x=[305 290 300 270 250 240 200];  
>> plot(t,x,'k')
```

seria temporală: situația înscrierilor în anul I, în ultimii 7 ani



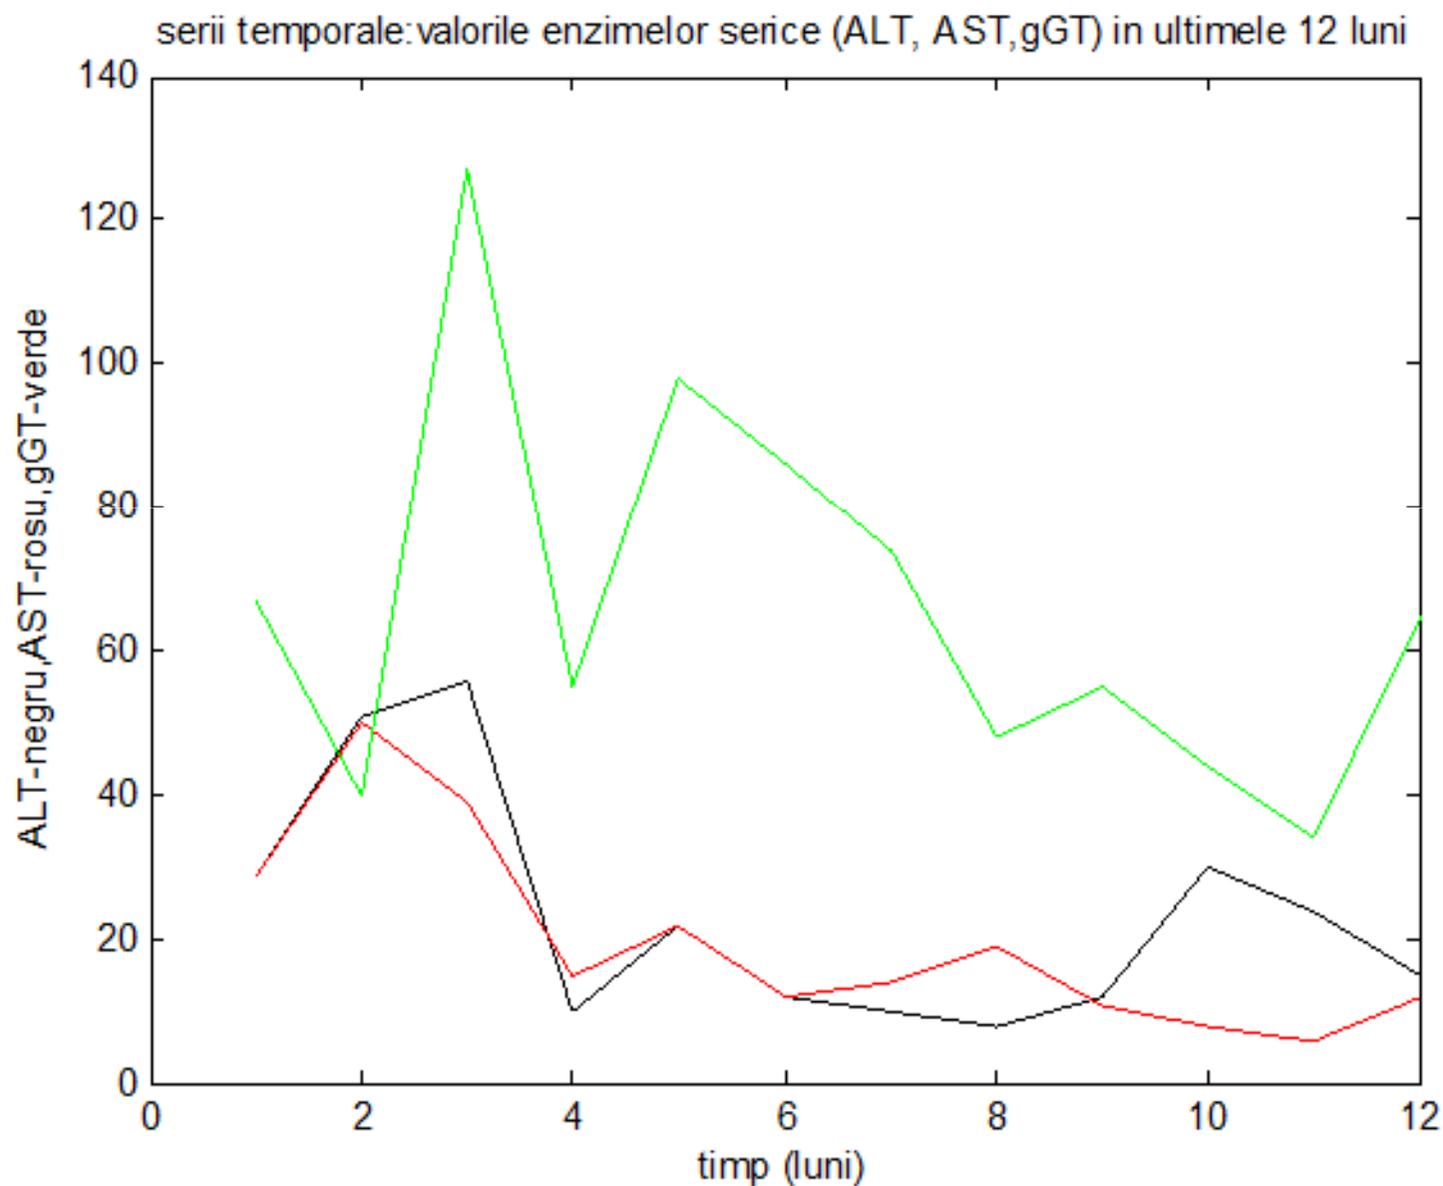
2. Exemplu

Tabelul următor prezintă valorile pentru principalele enzime serice prelevate timp de 12 luni consecutiv, de la un pacient diagnosticat cu hepatită cronică C: *alanina transaminasă (ALT)*, *aspartate transaminase (AST)*, *gamma glutamyl transpeptidase (gGT)*:

I	F	M	A	M	I	I	A	S	O	N	D
29	51	56	10	22	12	10	8	12	30	24	15
29	50	39	15	22	12	14	19	11	8	6	12
67	40	127	55	98	86	74	48	55	44	34	65

Vom reprezenta în același sistem de axe cele trei serii temporale, vizualizare ce va permite medicilor să urmărească evoluția simultană, în timpul unui an, a celor trei parametrii biochimici.

```
>> t=1:12; ALT=[29 51 56 10 22 12 10 8 12 30 24 15];  
>> AST=[29 50 39 15 22 12 14 19 11 8 6 12];  
>> gGT=[67 40 127 55 98 86 74 48 55 44 34 65];  
>> plot(t,ALT,'k',t,AST,'r',t,gGT,'g')
```



Comportarea (*pattern-ul*) datelor unei serii temporale este descrisă de către cele patru componente ale acesteia:

- trendul,
- componenta ciclică,
- componenta sezonieră,
- componenta incidentală.

Trendul

Trendul (tendința) se referă la o componentă generală, liniară sau de cele mai multe ori neliniară, care se schimbă cu trecerea timpului și nu se repetă.

Deplasarea graduală a seriei temporale este percepută ca o direcție, **un trend**.

Trendul se datorează de exemplu schimbărilor în tehnologie, schimbărilor în preferințele consumatorilor, schimbărilor caracteristicilor demografice ale populației etc.

3. Exemplu

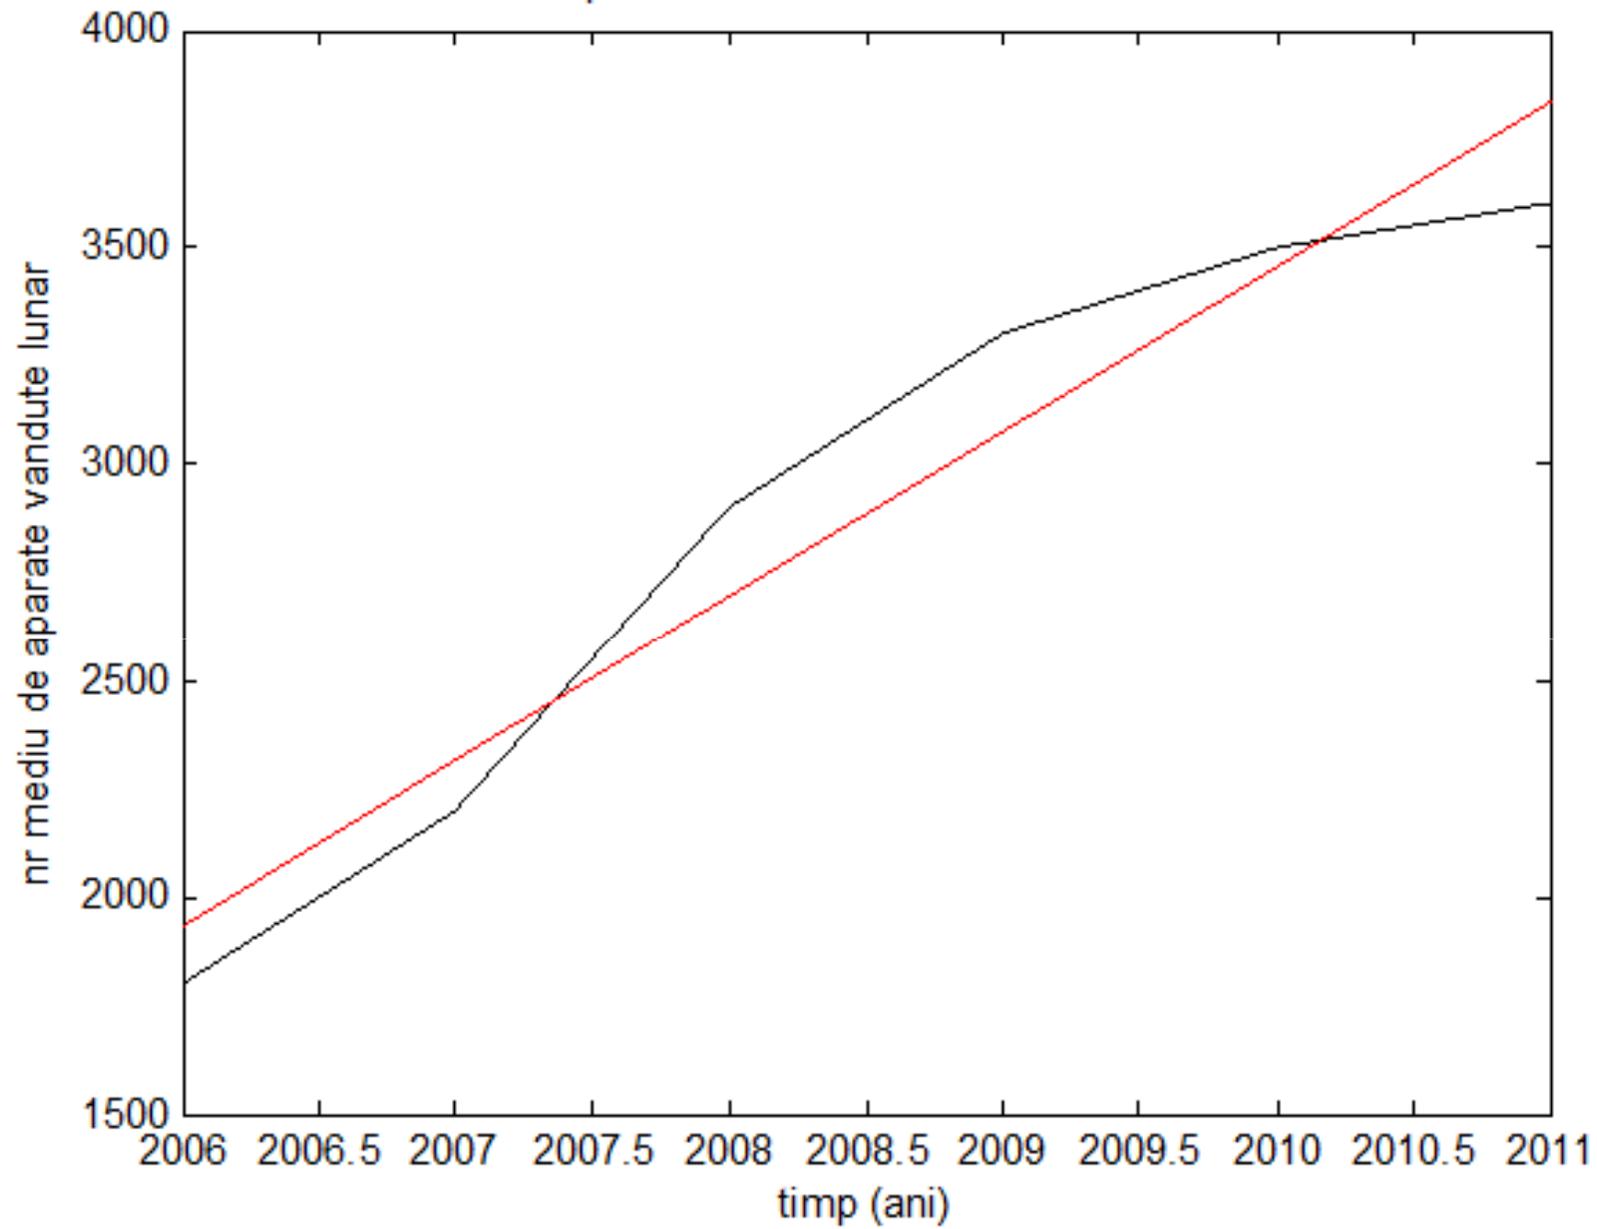
O firmă ce produce echipamente fotografice prezintă un **trend** ascendent al vânzărilor, după cum arată datele următoare care prezintă anul și numărul mediu de aparate vândute lunar în anul respectiv:

anul	2006	2007	2008	2009	2010	2011
Nr mediu	1800	2200	2900	3300	3500	3600

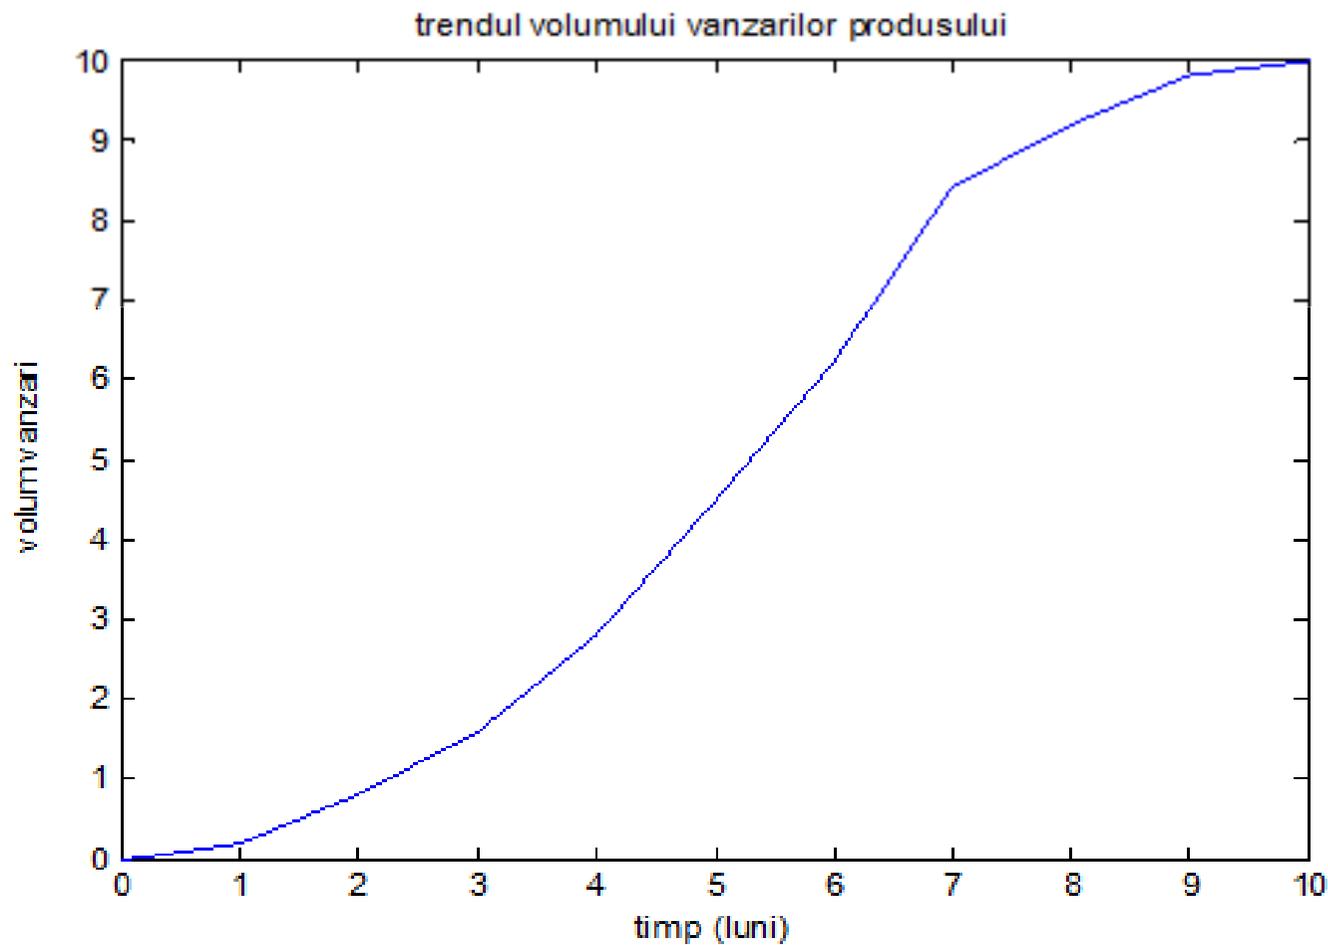
Pentru reprezentarea grafică am utilizat formula trendului liniar, ce va fi prezentată ulterior.

```
>>t=2006:2011;x=[1800 2200 2900 3300 3500 360];  
>>b=(t*x'-6*mean(x)*mean(t))/(t*t'-6*(mean(t))^2);  
>> a=mean(x)-b*mean(t);  
>>plot(t,x,'k',t,a+b*t,'r')
```

seria temporală: volumul mediu lunar al vanzarilor



Prezentăm simularea vânzărilor unui produs, de la introducerea lui pe piață, urmată de perioada de creștere a vânzărilor și în final de saturația pieței.



Nu există tehnici de identificare automată a trendului în seriile temporale. Dacă tendința este monotonă (crescătoare sau descrescătoare), vizualizarea datelor este suficientă pentru identificarea acesteia.

Analiza trendului este necesară și atunci când studiem mai multe serii temporale corespunzătoare aceleiași perioade de timp.

Se analizează motivele pentru care două sau mai multe asemenea serii temporale au aceeași direcție (sunt puternic corelate), chiar dacă, la prima vedere, acest fapt pare inexplicabil.

Componenta ciclică

Componenta ciclică: Valorile (datele) seriei temporale nu vor fi toate pe linia trendului. Orice secvență periodică de puncte, a cărei durată este cel puțin o unitate de măsură a timpului (de exemplu un an), se numește *componenta ciclică* a seriei temporale.

Asemenea componente pot apare de exemplu în economie: perioade de inflație mai modeste urmate de perioade de inflație rapidă.

Componenta sezonieră

Componenta sezonieră: O serie temporală poate prezenta o formă regulată într-o perioadă de timp mai mică de un an.

Componenta seriei temporale ce prezintă variații ale datelor influențate de anotimpuri este *componenta sezonieră*.

De exemplu, un producător de piscine știe că volumul vânzărilor este mic în perioada de toamnă-iarnă, în timp ce primăvara și vara atinge maximum posibil. Producătorii de echipament de schi au un pattern al vânzărilor opus celui prezentat.

Astfel, volumul traficului prezintă variații „sezoniere” în timpul unei zile cu valori maxime în timpul orelor de vârf, corespunzătoare orelor de începere, respectiv, încheiere a programului de lucru, minime în timpul nopții și moderate în rest.

În domeniul vânzărilor se observă o creștere semnificativă în preajma Sărbătorilor de Crăciun și de Paște. după Sărbătorile de Crăciun și Paște crește semnificativ numărul internărilor în spital.

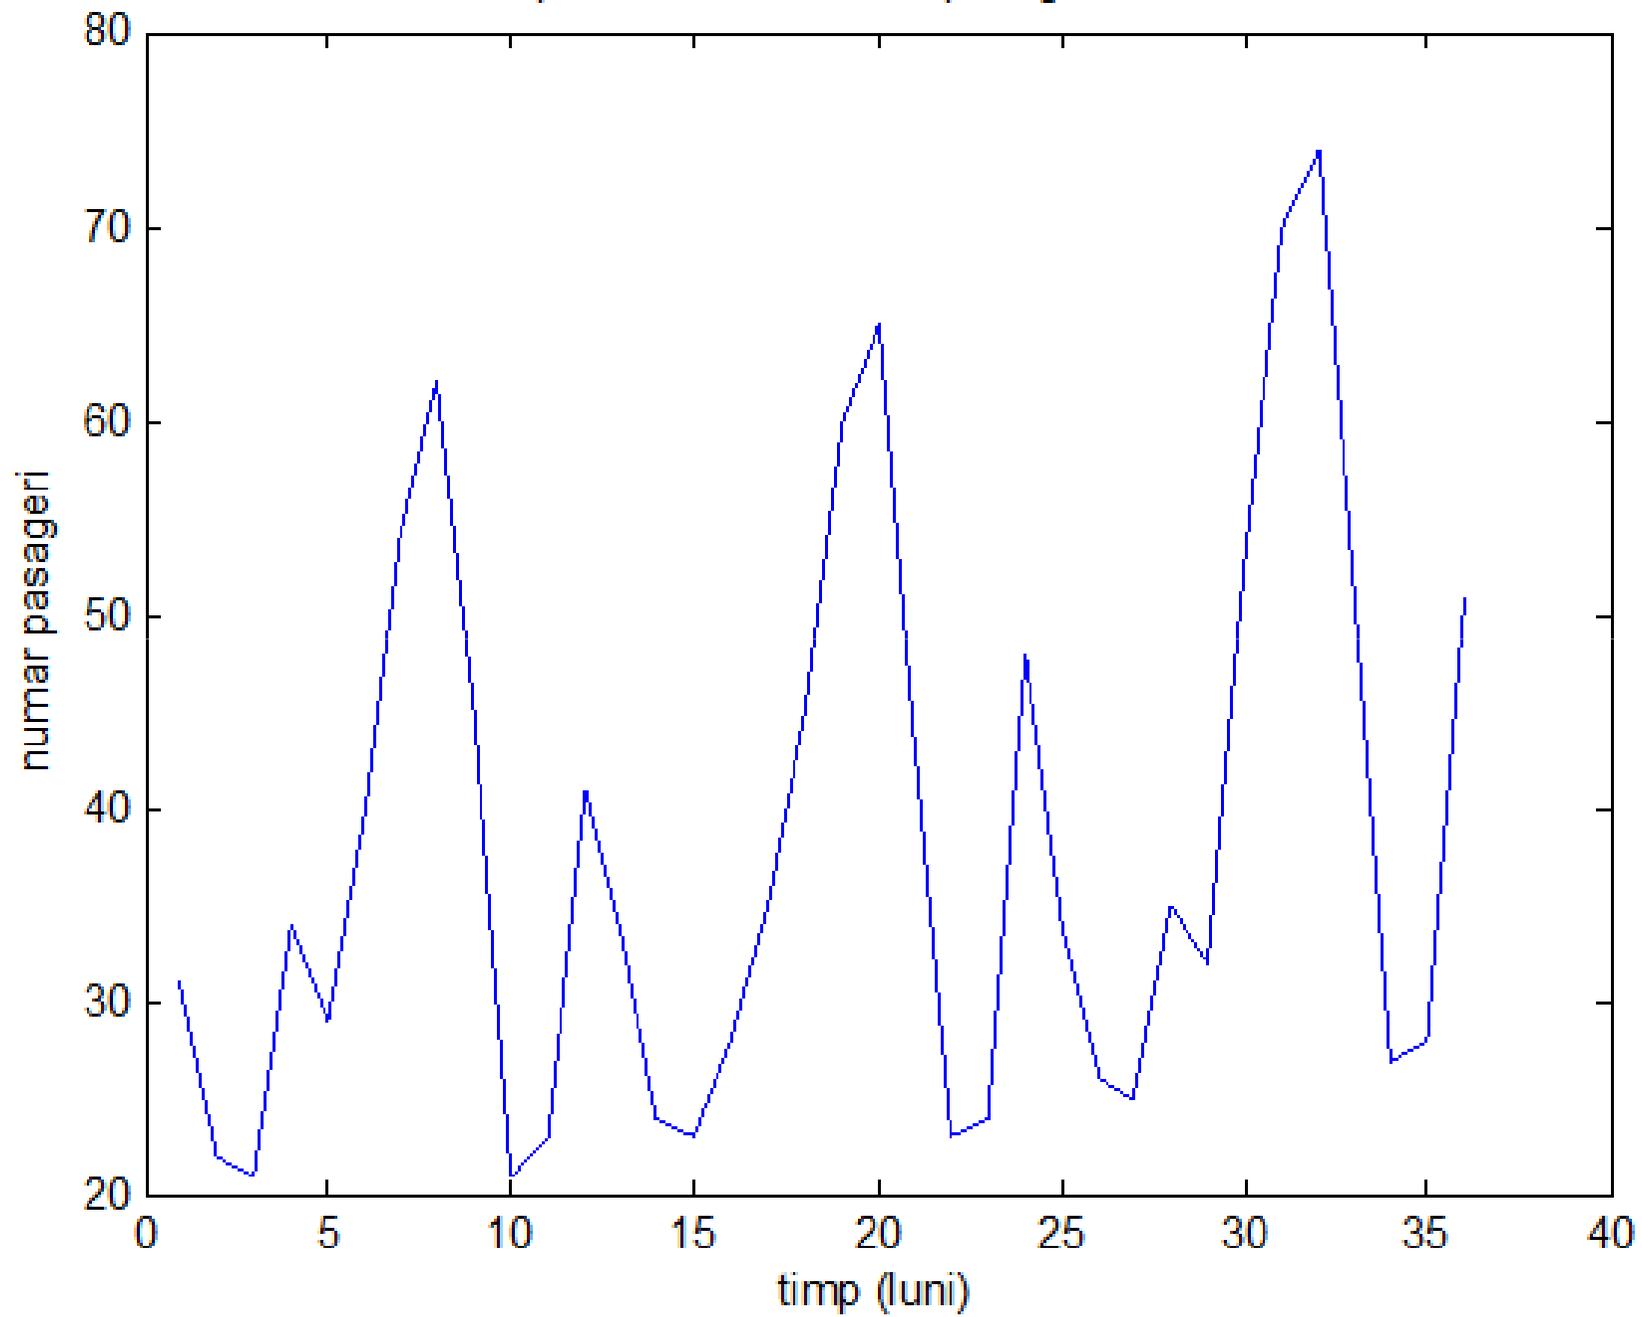
4.Exemplu

Pe un aeroport, numărul de pasageri (în zeci de mii) pentru zborurile internaționale, înregistrat lunar în ultimii trei ani, este dat în următorul tabel:

luna	I	F	M	A	M	I	I	A	S	O	N	D
I	31	22	21	34	29	40	54	62	45	21	23	41
II	33	24	23	28	35	45	60	65	44	23	24	48
III	34	26	25	35	32	53	70	74	50	27	28	51

```
>> t=1:36;x=[31 22 21 34 29 40 54 62 45 21 23 41 33 24 23 28 35 45  
60 65 44 23 24 48 34 26 25 35 32 53 70 74 50 27 28 51];  
>> plot(t,x)
```

seria temporală a traficului de pasageri în ultimii 3 ani



Componenta incidentală

Componenta incidentală este factorul rezidual care apare din datele actuale ale seriei vs. datele prognozate conform trendului componentei ciclic și componentei sezoniere. Această componentă este datorată factorilor de scurtă durată, pe care nu-i putem anticipa.

Metode de netezire (smoothing methods)

Într-o serie temporală întâlnim uneori variații întâmplătoare, caz în care apelăm la tehnici de reducere a efectelor acestor variații.

Tehnicile ce utilizează *metode de netezire* (smoothing methods) se aplică seriilor temporale *aproape stabile*, (serii ce nu prezintă modificări semnificative ale trend-ului, ale componentei ciclice sau ale celei sezoniere).

Tehnicile de netezire permit, pe de o parte, prognoza comportamentului viitor al seriei temporale și, pe de altă parte, relevă mai clar trendul acesteia, componentele sezoniere și ciclice. Vom prezenta două tehnici de netezire:

1. Mediile mobile
2. Metodele de netezire exponențială

Mediile mobile

Calculul mediilor mobile este cea mai simplă metodă de netezire a datelor, ușor de înțeles și de folosit, care permite și prognoza comportării ulterioare a seriei temporale.

Media mobilă este media aritmetică a ultimelor n valori ale datelor,

$$\text{media mobilă} = \frac{p_M + p_{M-1} + \dots + p_{M-n+1}}{n}$$

unde p_{M-i} , $i = 0, \dots, n-1$ sunt cele n valori precedente.

Orice nouă dată va înlocui pe cea mai veche dată din media mobilă, calculându-se astfel o nouă medie. Astfel media se va schimba o dată cu apariția unei noi date, de unde și termenul de medie mobilă.

Pentru a obține o cât mai bună prognoză în cazul seriei temporale $\{x_t, t \in \{1, \dots, p\}\}$, avem de găsit numărul optim de date ce vor fi introduse în media mobilă.

O abordare posibilă constă în a încerca diferite variante și de a o alege pe aceea care minimizează media pătratelor erorii (*mean squared error* MSE).

Dacă stabilim că acest număr n este optim pentru datele cunoscute (trecut), presupunem că va fi optim și pentru viitor, și vom face prognoza utilizând media mobilă pentru n date.

Etapele rezolvării problemei sunt:

- calcularea mediilor mobile pentru $n \in \{3, 4, 5, \dots\}$, M_{n+i} , $1 \leq i \leq p - n$
- presupunând că M_{n+i} este prognoza pentru săptămâna numerotată $n+i$, calculăm pătratul erorii comise cu această prognoză:

$$er_i = (M_{n+i} - x_{n+i})^2$$

- pentru a aprecia acuratețea prognozei vom lua în considerare media pătratelor erorii – MSE

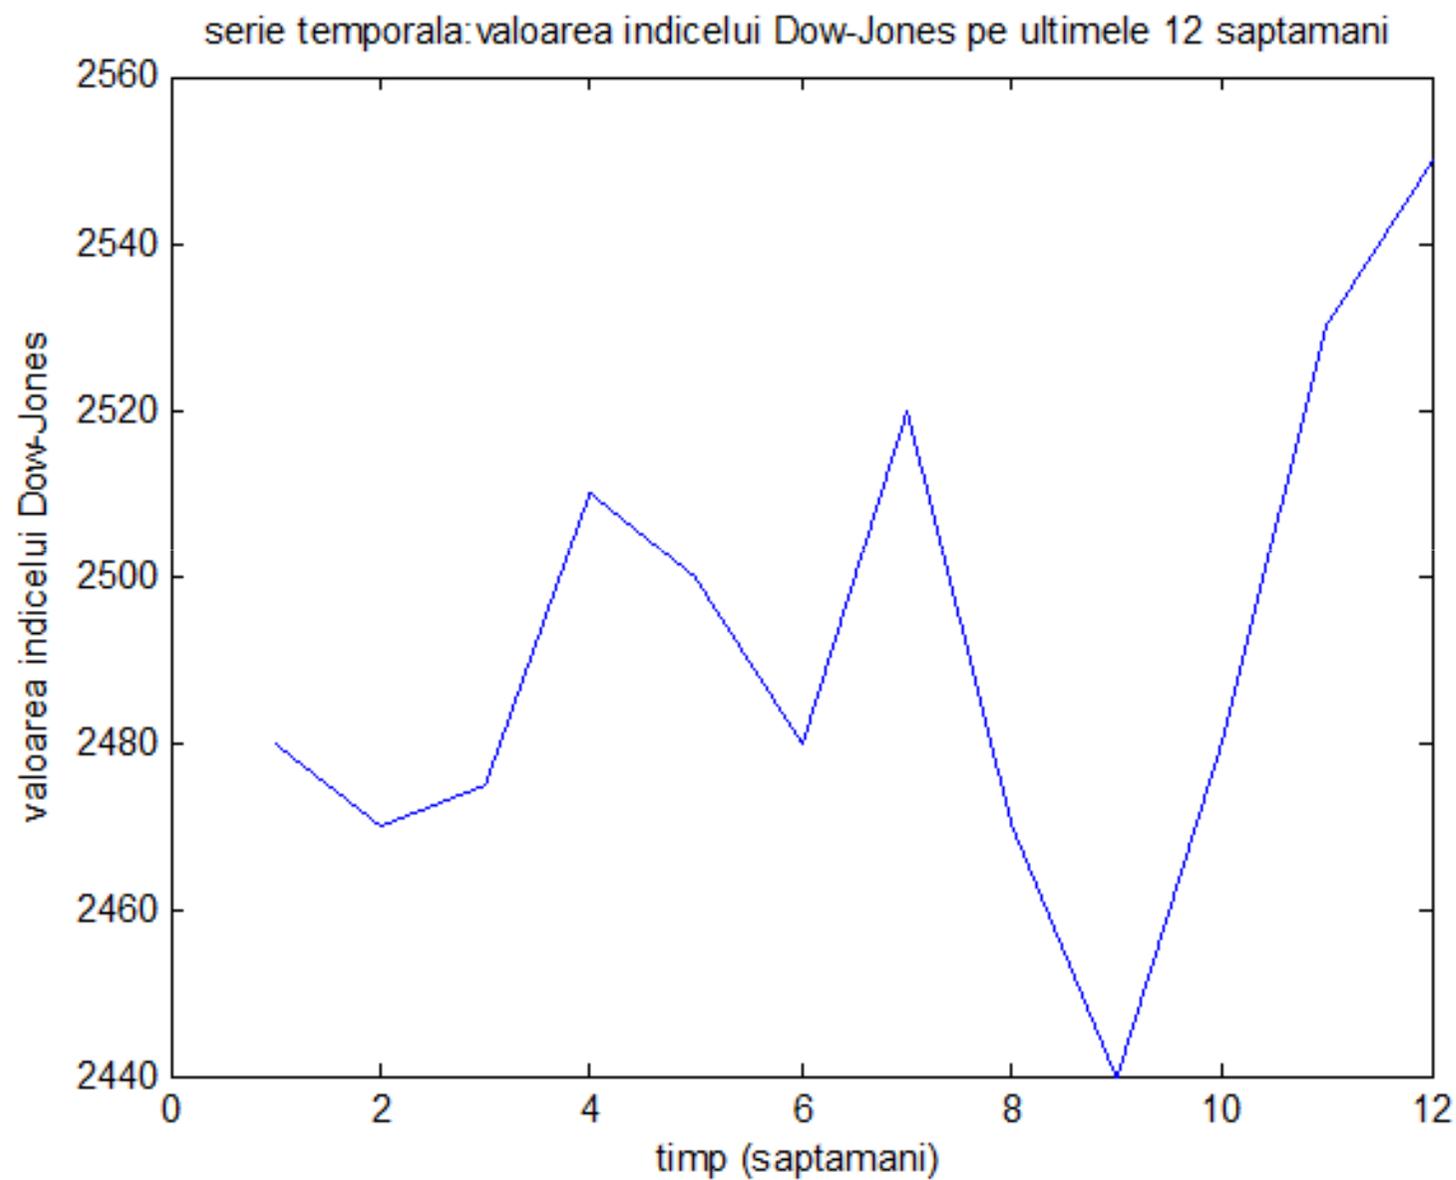
Pentru prognoză, dacă seria temporală nu are trend, este folosită media mobilă.

5.Exemplu

Indicele Dow Jones (Dow Jones Industrial Average sau Dow 30) este cel mai vechi indice al burselor din New York și cel mai vechi indice bursier din lume (1884). Indicele urmărește evoluția pe piața bursieră a 30 de firme americane importante, care s-au schimbat de-a lungul timpului (numai General Electric a rămas din 1884 până azi). Dow Jones permite studiul evoluției economiei americane în ultimii 120 ani. Prezentăm indicele Dow Jones la închidere, pe 12 săptămâni

săptămâna	Dow Jones		săptămâna	Dow Jones
1	2480		7	2520
2	2470		8	2470
3	2475		9	2440
4	2510		10	2480
5	2500		11	2530
6	2480		12	2550

```
>> t=1:12;  
>> x=[2480 2470 2475 2510 2500 2480 2520 2470 2440 2480 2530 2550];  
>> plot(t,x)
```



Vom calcula media mobilă pentru 3, 4 și respectiv 5 săptămâni și media pătratelor erorii (*MSE*) în cele trei cazuri:

```
>> x=[2480 2470 2475 2510 2500 2480 2520 2470 2440 2480 2530 2550];  
>> for t=4:12; m3(t)=(x(t-1)+x(t-2)+x(t-3))/3;end  
>> for t=4:12; e3(t)=(x(t)-m3(t))^2;end  
>> for t=5:12; m4(t)=(x(t-1)+x(t-2)+x(t-3)+x(t-4))/4;end  
>> for t=5:12; e4(t)=(x(t)-m4(t))^2;end  
>> for t=6:12; m5(t)=(x(t-1)+x(t-2)+x(t-3)+x(t-4)+x(t-5))/5;end  
>> for t=6:12; e5(t)=(x(t)-m5(t))^2;end
```

```
>> [x' m3' e3' m4' e4' m5' e5']
```

```
ans =
```

```
1.0e+003 *
```

2.4800	0	0	0	0	0	0
2.4700	0	0	0	0	0	0
2.4750	0	0	0	0	0	0
2.5100	2.4750	1.2250	0	0	0	0
2.5000	2.4850	0.2250	2.4838	0.2641	0	0
2.4800	2.4950	0.2250	2.4888	0.0766	2.4870	0.0490
2.5200	2.4967	0.5444	2.4913	0.8266	2.4870	1.0890
2.4700	2.5000	0.9000	2.5025	1.0562	2.4970	0.7290
2.4400	2.4900	2.5000	2.4925	2.7563	2.4960	3.1360
2.4800	2.4767	0.0111	2.4775	0.0063	2.4820	0.0040
2.5300	2.4633	4.4444	2.4775	2.7563	2.4780	2.7040
2.5500	2.4833	4.4444	2.4800	4.9000	2.4880	3.8440

Din tabelul generat de MATLAB, se observă că e_3 , e_4 , e_5 care sunt vectori cu 9, respectiv 8, respectiv 7 componente, sunt considerați a fi vectori cu 12 componente, scufundarea în spațiul 12-dimensional fiind realizată prin atribuirea valorii zero componentelor lipsă. Dacă vom calcula mediile pătratelor erorii aplicând direct instrucțiunea `mean`, obținem rezultate viciate, deoarece se face împărțirea la 12 componente și nu la 9, respectiv 8, respectiv 7.

Pentru a nu renunța la utilizarea instrucțiunii `mean`, vom ține seama că:

$$\text{MSE}_k = 12 / (12 - k) * \text{mean}(e_k), \quad k \in \{3, 4, 5\}$$

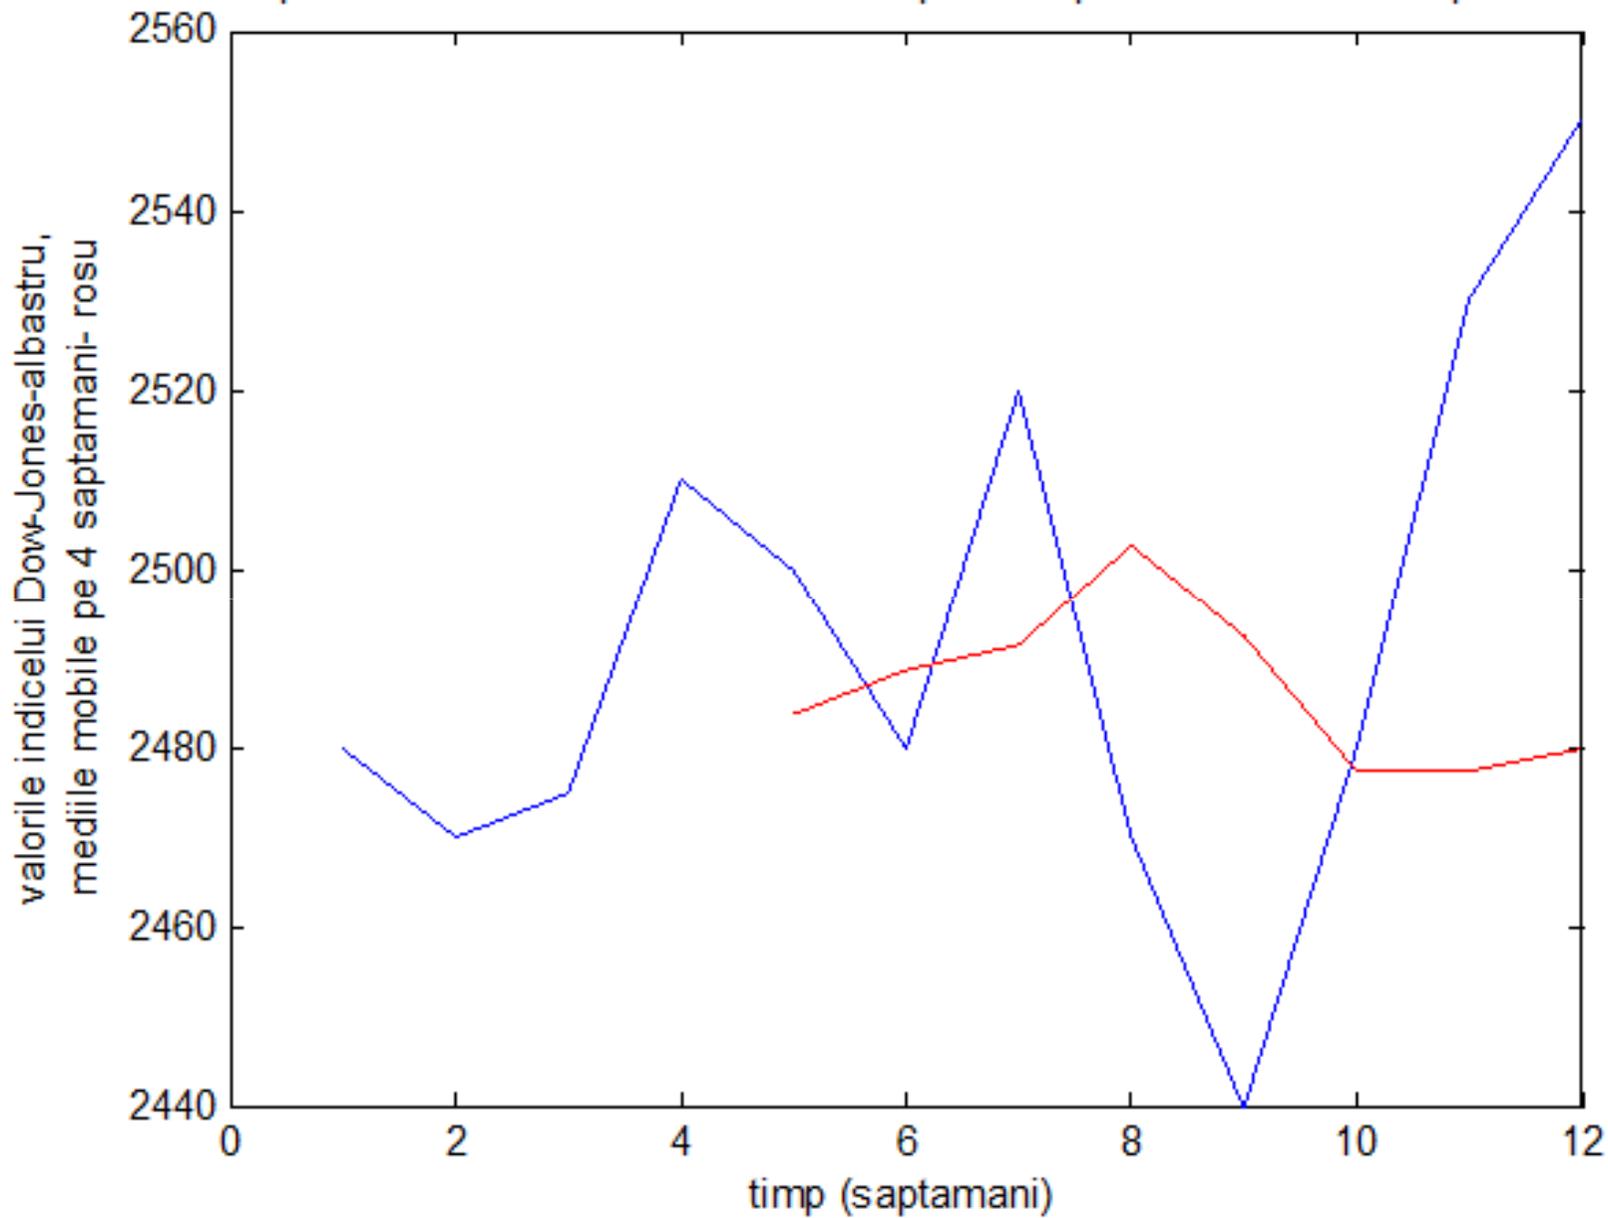
Astfel:

```
>> MSE3=12/9*mean(e3);  
>> MSE4=12/8*mean(e4);  
>> MSE5=12/7*mean(e5);  
>> [MSE3 MSE4 MSE5]  
ans =  
1.0e+003 *  
1.6133 1.5803 1.6507
```

Remarcăm că media mobilă pentru $n = 4$ conduce la cea mai mică valoare a mediei pătratelor erorii și astfel aceasta va fi folosită în prognoză.

```
>>t1=5:12; plot(t,x,'b',t1,m4(t1),'r')
```

seriile temporale: valorile indicelui Dow-Jones pe 12 saptamanii si seria temporală netezita

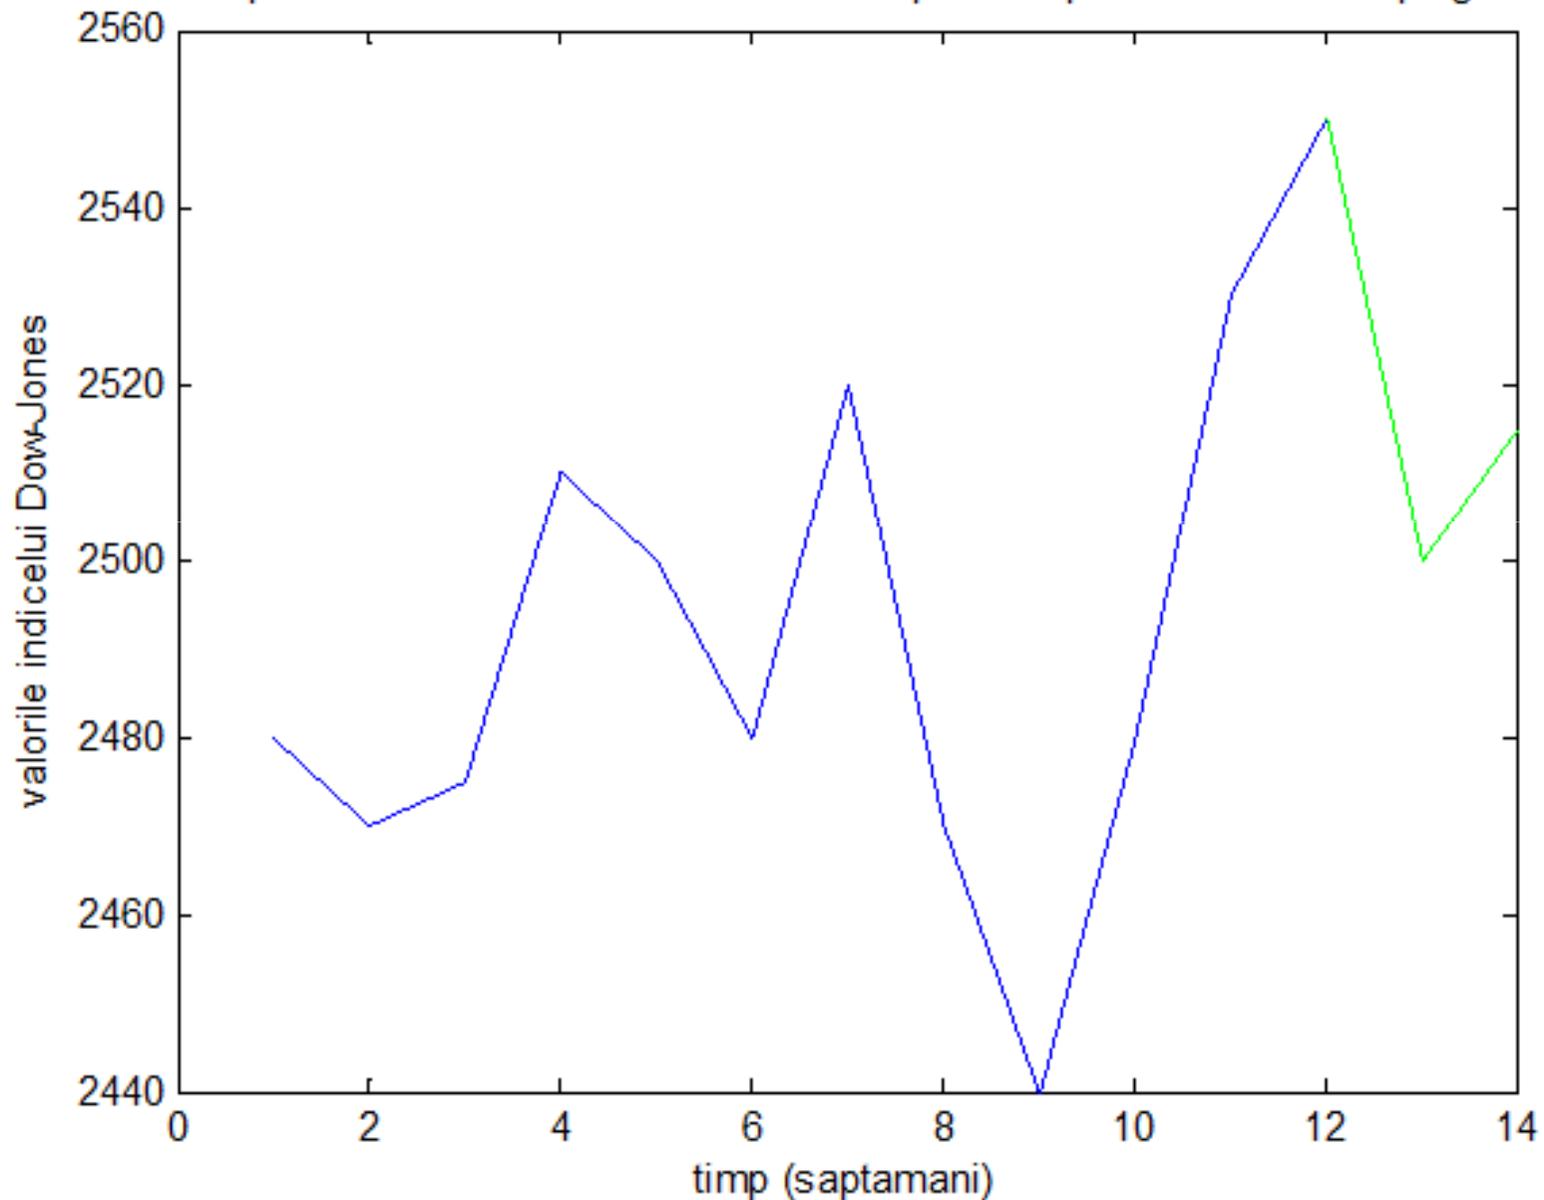


Astfel prognoza indicelui Dow-Jones pentru săptămâna a 13-a, respectiv a 14-a va fi:

```
>> p13=(x(9)+x(10)+x(11)+x(12))/4;  
>> p14=(x(10)+x(11)+x(12)+p13)/4;  
>> [p13 p14]  
ans =  
    2500    2515
```

```
>> t1=12:14;x1=[ x(12) p13 p14];  
>> plot(t,x,'b', t1,x1,'g')
```

seria temporală a valorilor indicelui Dow-Jones pe 12 săptămâni și valorile prognozate.



Medie mobilă ponderată

O formă mai sofisticată de medie mobilă, care ține cont de importanța valorilor mediate este așa-numita **medie mobilă ponderată** (*weighted moving average*–WMA), dată de formula:

$$WMA_M = \frac{np_M + (n-1)p_{M-1} + \dots + 2p_{M-n+2} + p_{M-n+1}}{n + (n-1) + \dots + 2 + 1} .$$

Media mobilă ponderată implică acordarea unor ponderi specifice fiecărei date utilizate. De obicei datelor cele mai recente li se atribuie ponderile cele mai mari.

Problemă: care este numărul n (numărul de date introduse în media mobilă) care permite cea mai bună prognoză?

Etapele rezolvării problemei sunt aceleași ca în cazul mediei mobile.

Reluăm datele din exemplul nr 5, referitoare la valorile indicelui Dow-Jones pe ultimele 12 săptămâni. Vom calcula mediile mobile ponderate pentru $n \in \{3, 4, 5\}$, pătratele erorilor comise și cea mai mică valoare a mediei pătratelor erorii ne va da numărul n optim.

```
>> x=[2480 2470 2475 2510 2500 2480 2520 2470 2440 2480 2530 2550];  
>> for t=4:12; mp3(t)=(3*x(t-1)+2*x(t-2)+x(t-3))/6;end  
>> for t=4:12; ep3(t)=(x(t)-mp3(t))^2;end  
>> for t=5:12; mp4(t)=(4*x(t-1)+3*x(t-2)+2*x(t-3)+x(t-4))/10;end  
>> for t=5:12; ep4(t)=(x(t)-mp4(t))^2;end  
>> for t=6:12; mp5(t)=(5*x(t-1)+4*x(t-2)+3*x(t-3)+2*x(t-4)+x(t-5))/15;end  
>> for t=6:12; ep5(t)=(x(t)-mp5(t))^2;end
```

```
>> [x' mp3' ep3' mp4' ep4' mp5' ep5']
```

```
ans =
```

```
1.0e+003 *
```

2.4800	0	0	0	0	0	0
2.4700	0	0	0	0	0	0
2.4750	0	0	0	0	0	0
2.5100	2.4742	1.2840	0	0	0	0
2.5000	2.4917	0.0694	2.4885	0.1323	0	0
2.4800	2.4992	0.3674	2.4950	0.2250	2.4923	0.1521
2.5200	2.4917	0.8028	2.4915	0.8123	2.4900	0.9000
2.4700	2.5033	1.1111	2.5030	1.0890	2.5010	0.9610
2.4400	2.4883	2.3361	2.4900	2.5000	2.4920	2.7040
2.4800	2.4633	0.2778	2.4690	0.1210	2.4733	0.0444
2.5300	2.4650	4.2250	2.4700	3.6000	2.4727	3.2871
2.5500	2.4983	2.6694	2.4910	3.4810	2.4900	3.6000

Folosim aceeași tehnică pentru calculul mediei pătratelor erorilor:

```
>> MSEp3=12/9*mean(ep3);  
>> MSEp4=12/8*mean(ep4);  
>> MSEp5=12/7*mean(ep5);  
>> [ MSEp3 MSEp4 MSEp5]  
ans =  
 1.0e+003 *  
 1.4603  1.4951  1.6641
```

Valoarea minimă a mediei pătratelor erorii este în cazul $n = 3$ și astfel vom folosi media ponderată pe trei săptămâni pentru a prognoza valoarea indicelui Dow Jones pe următoarele săptămâni.

```
>> p13=(x(10)+2*x(11)+3*x(12))/6; p14=(x(11)+2*x(12)+3*p13)/6  
>> [p13 p14]  
ans =  
 1.0e+003 *  
 2.5317  2.5375
```

Observăm că în acest exemplu este preferabilă utilizarea mediei mobile ponderate și nu a mediei mobile, (MSEp3 ia cea mai mică valoare).

Netezirea exponențială

O metodă simplă, deseori utilizată, care permite prognoza pentru perioadă de timp $t + 1$ în funcție de valoarea seriei și valoarea prognozei pentru perioadă de timp t , este *netezirea exponențială*.

Prezentăm modelul matematic:

$$P_{t+1} = \alpha \cdot x_t + (1 - \alpha) \cdot P_t, \text{ unde:}$$

- P_{t+1} este prognoza pentru perioadă de timp $t + 1$.
- x_t este valoarea seriei pentru perioadă de timp t .
- P_t este prognoza pentru perioadă de timp t .
- $\alpha \in [0, 1]$ este constanta de netezire.

Alegerea valorii atribuite lui P_1 este importantă.

Metode des întâlnite de inițializare:

- considerăm $P_1 = x_1$.
- considerăm P_1 ca fiind media aritmetică a primelor patru sau cinci observații.

Se poate demonstra (prin inducție) că:

prognoza pentru orice perioadă de timp t este media ponderată a valorilor anterioare ale seriei temporale.

Această metodă de netezire se numește *exponențială*, deoarece ponderile sunt proporționale cu termenii unei progresii geometrice

$$\{1, 1 - \alpha, (1 - \alpha)^2, \dots\}, \alpha \in [0, 1].$$

Reamintim că o progresie geometrică este versiunea discretă a unei funcții exponențiale.

În alegerea constantei de netezire $\alpha \in [0,1]$, vom ține seama că valoarea prognozată P_{t+1} depinde de prognoza P_t și de eroarea prognozei anterioare $x_t - P_t$:

$$P_{t+1} = \alpha \cdot x_t + (1 - \alpha) \cdot P_t = P_t + \alpha \cdot (x_t - P_t) .$$

În general, alegem valoarea lui α care minimizează media pătratelor erorii (*mean squared error* MSE). Putem folosi *metoda incrementală*:

- dăm parametrului valorile $\{0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9\}$;
- calculăm media pătratelor erorii corespunzătoare MSE ;
- alegem acel α pentru care obținem cel mai mic MSE .

6. Exemplu

Reluăm datele privitoare la indicele Dow-Jones din exemplul nr 5 și folosim metoda incrementală:

```
>> x=[2480 2470 2475 2510 2500 2480 2520 2470 2440 2480 2530 2550];  
>> for j=1:9 p(1,j)=x(1);end  
>> for j=1:9  
for t=2:12 p(t,j)=0.1*j*x(t-1)+0.1*(10-j)*p(t-1,j);end;  
end  
>> p  
p =  
1.0e+003 *  
2.4800 2.4800 2.4800 2.4800 2.4800 2.4800 2.4800 2.4800 2.4800  
2.4800 2.4800 2.4800 2.4800 2.4800 2.4800 2.4800 2.4800 2.4800  
2.4790 2.4780 2.4770 2.4760 2.4750 2.4740 2.4730 2.4720 2.4710  
2.4786 2.4774 2.4764 2.4756 2.4750 2.4746 2.4744 2.4744 2.4746  
2.4817 2.4839 2.4865 2.4894 2.4925 2.4958 2.4993 2.5029 2.5065  
2.4836 2.4871 2.4905 2.4936 2.4962 2.4983 2.4998 2.5006 2.5006  
2.4832 2.4857 2.4874 2.4882 2.4881 2.4873 2.4859 2.4841 2.4821  
2.4869 2.4926 2.4972 2.5009 2.5041 2.5069 2.5098 2.5128 2.5162  
2.4852 2.4881 2.4890 2.4885 2.4870 2.4848 2.4819 2.4786 2.4746  
2.4807 2.4784 2.4743 2.4691 2.4635 2.4579 2.4526 2.4477 2.4435  
2.4806 2.4788 2.4760 2.4735 2.4718 2.4712 2.4718 2.4735 2.4763
```

```
>>for j=1:9 for t=1:12 er(t,j)=(p(t,j)-x(t))^2:end;end
>>MSE=mean(er)
MSE =
  1.0e+003 *
    0.9769    0.9854    1.0014    1.0106    1.0092    0.9990    0.9842    0.9688
0.9556
```

Așadar pentru prognoza valorilor indicelui Dow-Jones pentru săptămâna a 13-a vom considera $\alpha = 0.9$ și astfel:

```
>>p13=0.9*x(12)+0.1*p(12,9)
p13 =
  2.5475e+003
```

O altă măsură a acurateții erorii este *media valorilor absolute ale erorii* (mean absolute deviation *MAD*).

Diferența între *MSE* și *MAD* constă în faptul că *MSE* este influențată de erorile mari de prognoză, fiind media pătratelor erorilor.

Specialiștii au păreri contradictorii asupra alegerii uneia sau alteia dintre cele două metode. Preferăm utilizarea *MSE*.

În cazul unei serii temporale care are trend nu poate fi folosită netezirea exponențială prezentată.

Situația este remediată prin introducerea unei a doua ecuații cu a doua constantă γ , aleasă coroborat cu prima constantă de netezire α .

Matematic, următoarele două ecuații descriu *netezirea dublu exponențială*:

$$P_t = \alpha \cdot x_t + (1 - \alpha)(P_{t-1} + b_{t-1}), \alpha \in [0, 1],$$

$$b_t = \gamma \cdot (P_t - P_{t-1}) + (1 - \gamma) \cdot b_{t-1}, \gamma \in [0, 1].$$

Prima ecuație exprimă prognoza P_t în funcție de valoarea x_t a seriei temporale, de valoarea anterioară P_{t-1} și de valoarea anterioară a trendului b_{t-1} .

A doua ecuație actualizează trendul, care este exprimat ca diferența dintre ultimele două valori prognozate P_{t-1}, P_t .

Există mai multe metode pentru alegerea valorilor inițiale.

Dacă în general alegem $P_1 = x_1$, pentru b_1 avem mai multe variante:

$$b_1 = x_2 - x_1;$$

$$b_1 = \frac{(x_2 - x_1) + (x_3 - x_2) + (x_4 - x_3)}{3};$$

$$b_1 = \frac{x_n - x_1}{n-1}.$$

Problema ce urmează a fi rezolvată este alegerea acelor parametrii α și γ care corespund valorii minime a mediei pătratelor erorii (MSE).

Propunem utilizarea metodei incrementale.

Pentru a prognoza valoarea următoare din seria temporală se utilizează formula:

$$F_{t+1} = P_t + b_t,$$

în timp ce pentru prognoza următoarelor m perioade avem:

$$F_{t+m} = P_t + m \cdot b_t,$$

Exemplu

Reluăm exemplul nr 1, referitor la înscrierile în anul I al unei facultăți, din ultimii 7 ani și aplicăm tehnica de netezire dublu exponențială, folosind metoda incrementală:

- calculăm probabilitățile pentru $\alpha \in \{0.1 * j, j = 1 : 9\}$ și $\gamma \in \{0.1 * k, k = 1 : 9\}$;
- evaluăm media pătratelor erorilor în cele $81 * 7$ cazuri;
- alegem acele valori ale lui α și γ care au determinat cea mai mică valoare a MSE

```

>> x=[305 290 300 270 250 240 200];
>> for j=1:9
for k=1:9 P(1,j,k)=x(1);end;
end
for j=1:9
for k=1:9 b(1,j,k)=x(2)-x(1);end;
end
>> for j=1:9
for k=1:9 b(1,j,k)=x(2)-x(1);end;
end
>> for t=2:7
for j=1:9
for k=1:9
P(t,j,k)=0.1*j*x(t)+0.1*(10-j)*(P(t-1,j,k)+b(t-1,j,k));
b(t,j,k)=0.1*k*(P(t,j,k)-P(t-1,j,k))+0.1*(10-k)*b(t-1,j,k);
end
end
end
>> for t=1:7
for j=1:9
for k=1:9
er(t,j,k)=(x(t)-P(t,j,k))^2;
end
end
end
er

```

Vor fi afișate 9 matrice cu 7 linii și 9 coloane, notate $er(:,:,j)$, care reprezintă eroarea pentru $\gamma = 0.1 * j$. Vom calcula media erorilor pe cei 7 ani, pentru fiecare parametru în parte și apoi vom stabili care este cea mai mică medie:

```
>> for j=1:9
for k=1:9
mean(er(:,j,k));
end
end
>> mean(er)
```

Obținem 9 vectori de 9 componente, notați $ans(:,:,j)$, corespunzători lui $\gamma = 0.1 * j$

```
>> min(min(mean(er)))
```

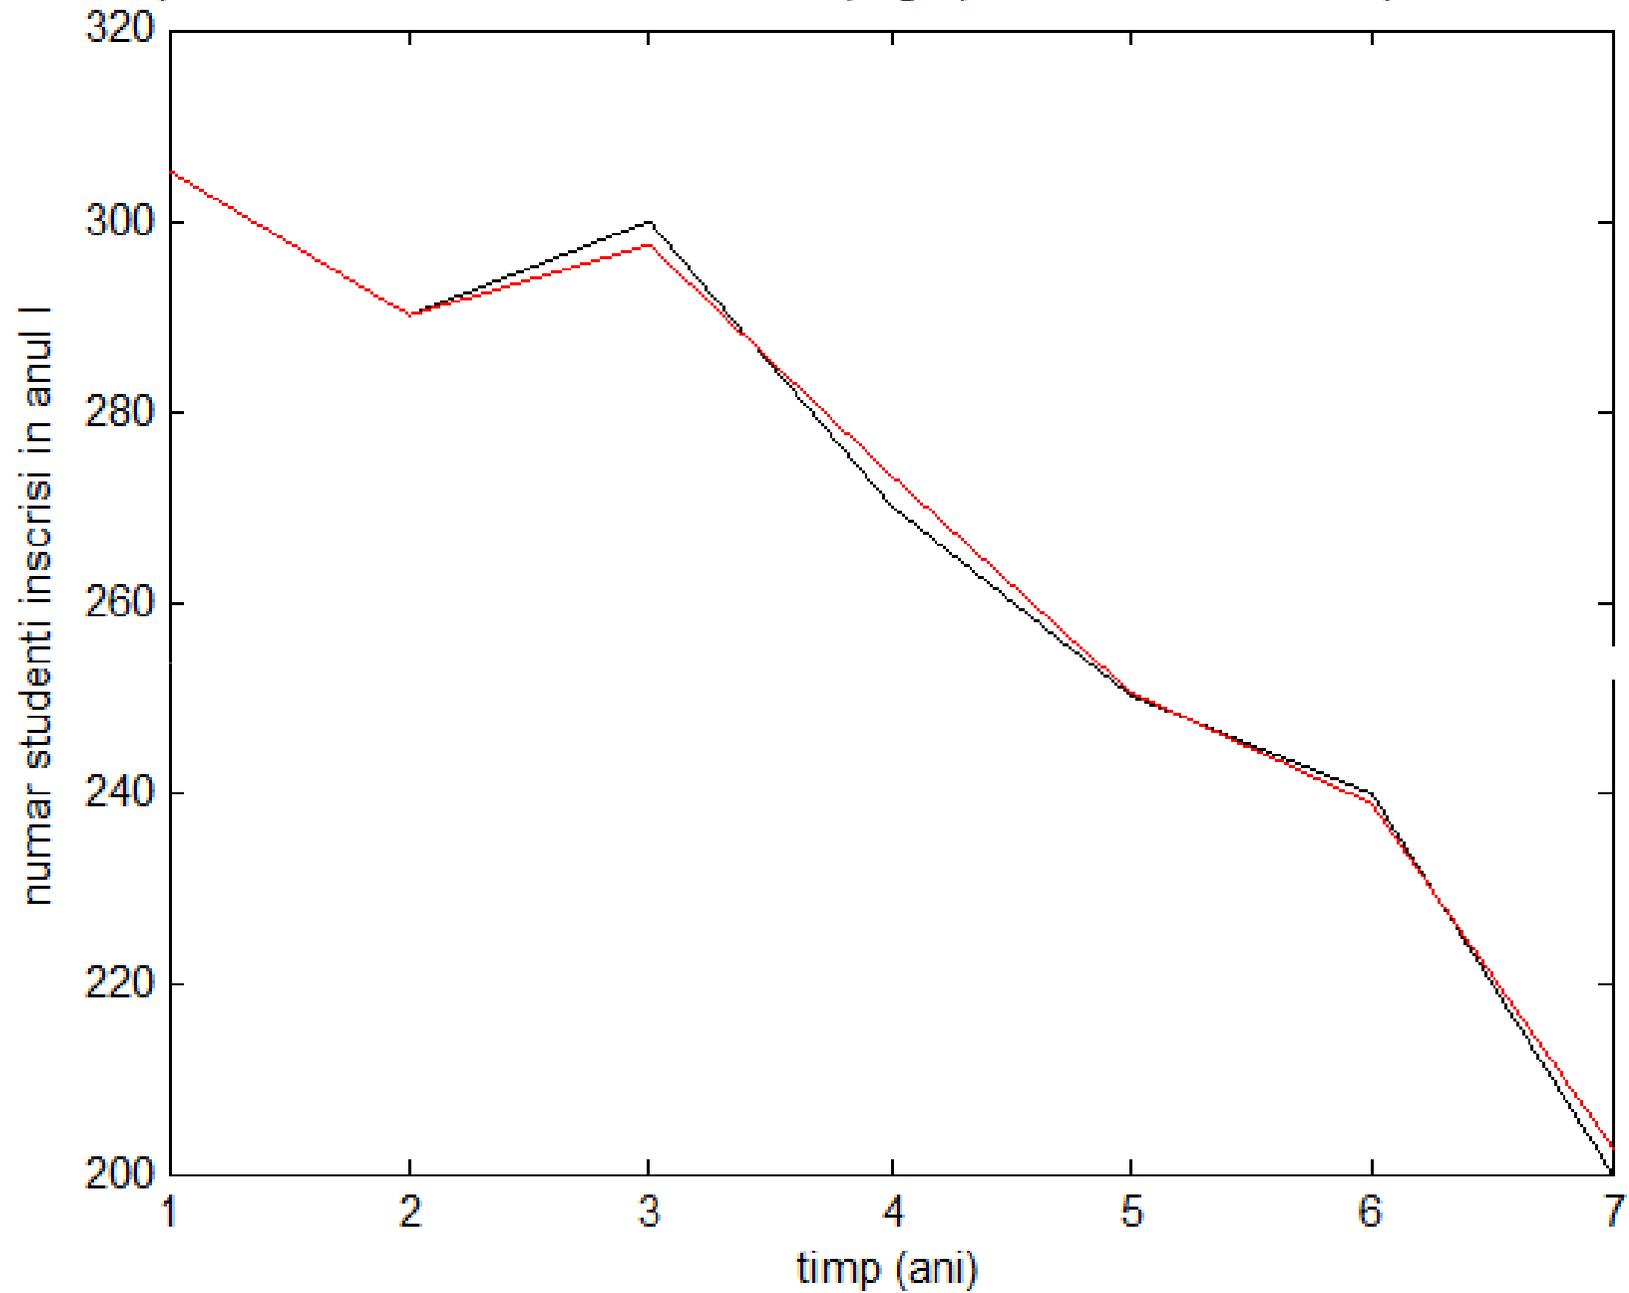
ans =

2.2131

Valoarea minimă a mediei pătratelor erorilor este obținută pentru $\alpha = 0.9$ și $\gamma = 0.1$ și astfel am determinat valorile parametrilor ce vor fi utilizați în netezirea dublu exponentială a seriei temporale.

```
>> for t=2:7  
P(t)=0.9*x(t)+0.1*(P(t-1)+b(t-1));  
b(t)=0.9*(P(t)-P(t-1))+0.1*b(t-1);  
end  
>> t=1:7;  
>> plot(t,x,'k', t,P,'-.k')
```

seria temporală cu studenții înscriși în anul I (negru) și netezirea dublu exponențială a acesteia



Facem prognoza pe următorii patru ani:

```
>> F(8)=P(7)+b(7); for t=2:4 F(7+t)=P(7)+t*b(7);end % F provine de la forecasting
```

```
>> F'
```

```
ans =
```

```
168.8439
```

```
135.0760
```

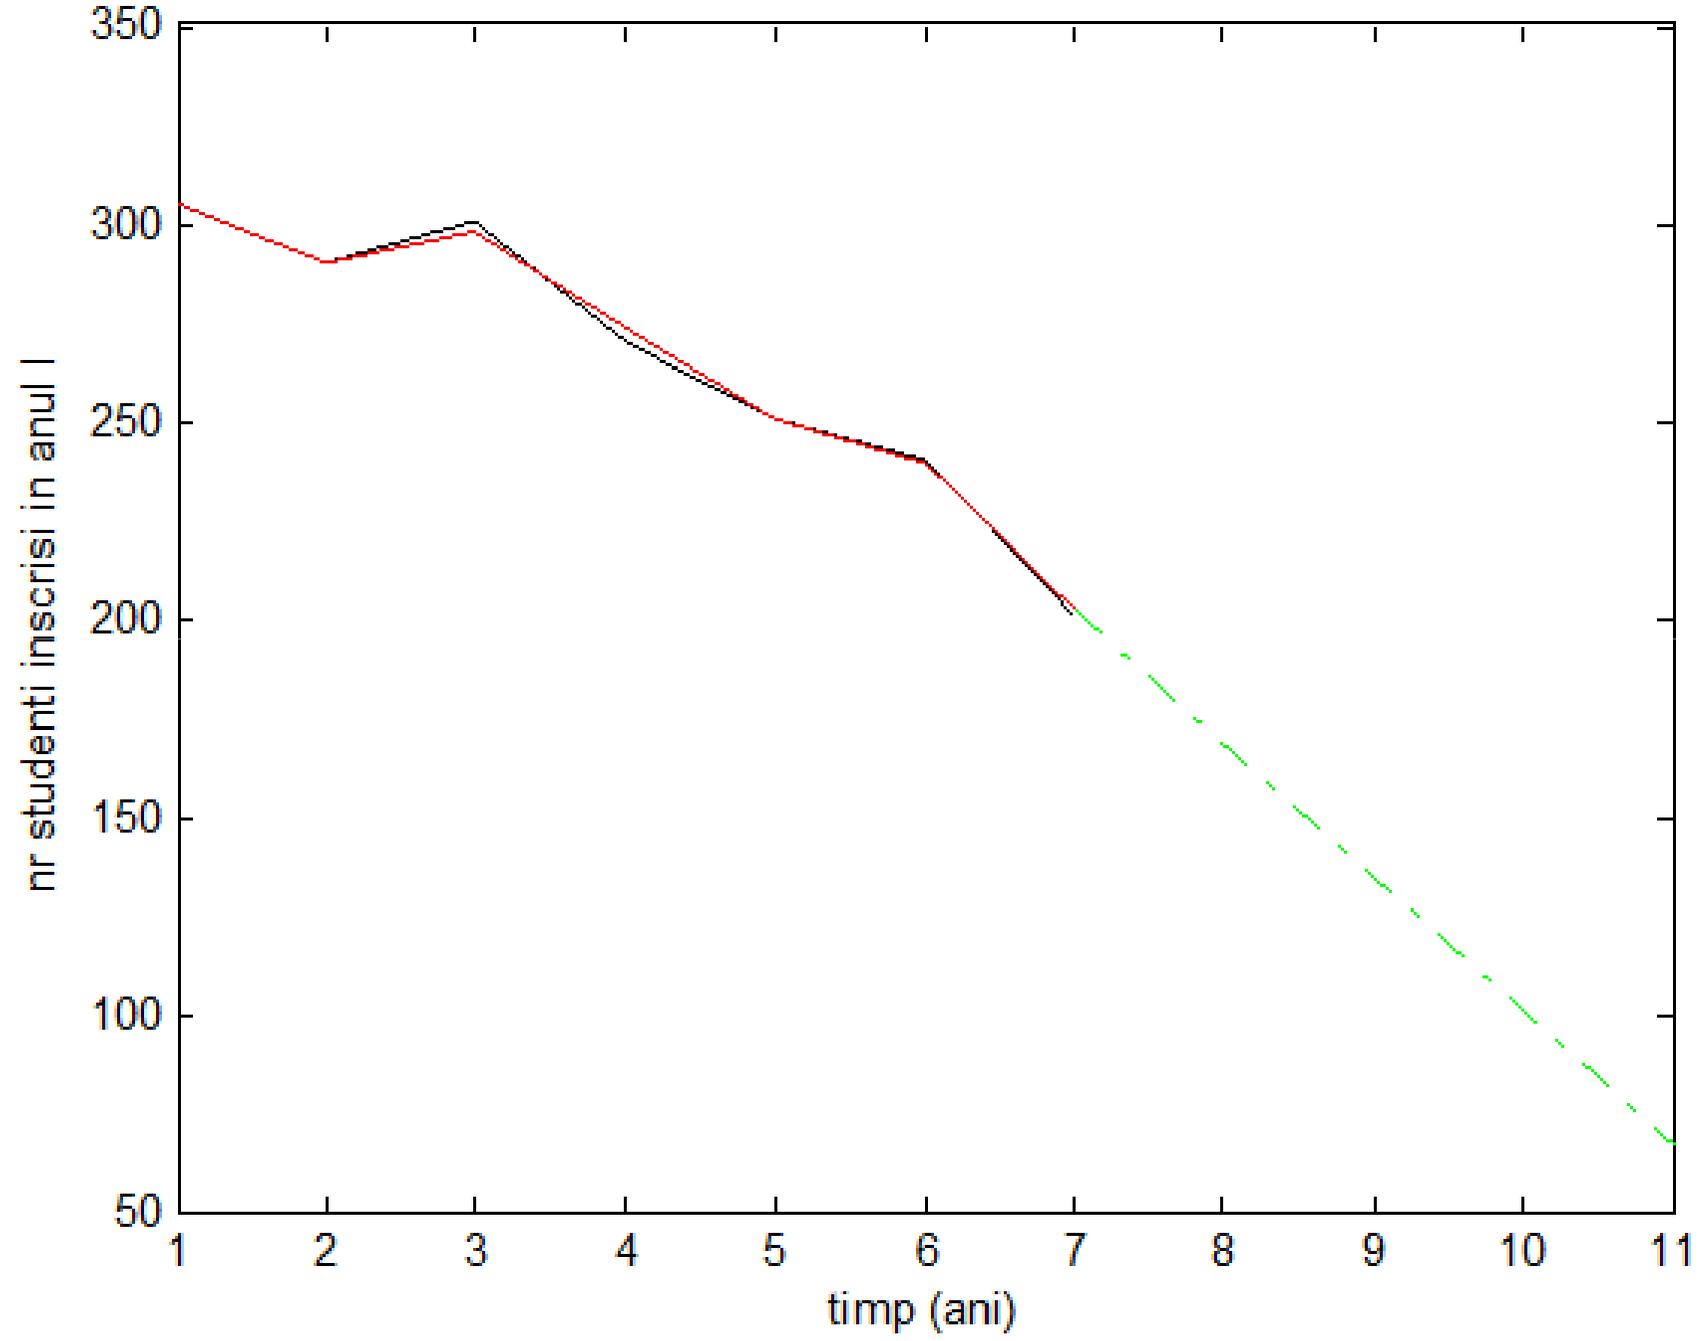
```
101.3081
```

```
67.5402
```

```
>> t=1:7;t1=7:11; F=[ P(7) F(8) F(9) F(10) F(11)];
```

```
>> plot (t,x,'k',t,P,'r', t1,F,'g-')
```

seria temporală cu nr studenți înscriși, netezirea ei dublu exponențială, prognoza pe 4 ani



Prognoza utilizând trendul

În cazul în care valorile unei serii temporale prezintă timp îndelungat un trend liniar, putem prognoza valorile viitoare folosind regresia liniară pentru identificarea trendului.

Componenta trendului nu va reflecta orice variație a seriei temporale ca funcție de timp, ci, direcția în care variază seria temporală, în cazul nostru creșterea valorilor în funcție de timp.

Matematic, avem:

$$T_t = a + bt,$$

unde:

- T_t este valoarea trend-ului seriei temporale în perioada de timp t ;
- b_0 este interceptorul liniei trendului;
- b_1 este panta liniei trend-ului.

Conform formulelor pentru calculul dreptei de regresie, avem:

$$b = \frac{\sum_{t \in T} t \cdot x_t - \frac{1}{n} \sum_{t \in T} t \cdot \sum_{t \in T} x_t}{\sum_{t \in T} t^2 - \frac{1}{n} \left(\sum_{t \in T} t \right)^2}; \quad a = \bar{x} - b \cdot \bar{t}$$

unde:

- x_t este valoarea actuală a seriei temporale in perioada de timp t ;
- n este numărul perioadelor de timp, $n = \text{card}(T)$;
- \bar{x} este media valorilor seriei temporale, $\bar{x} = \frac{1}{n} \sum_{t \in T} x_t$;
- \bar{t} este media valorilor lui t , adică $\bar{t} = \frac{1}{n} \sum_{t \in T} t$

Considerând că valorile seriei temporale din trecut sunt un bun indicator pentru valorile viitoare, putem spune că ecuația:

$$T_t = a + bt$$

poate fi utilizată pentru a prognoza valori viitoare.

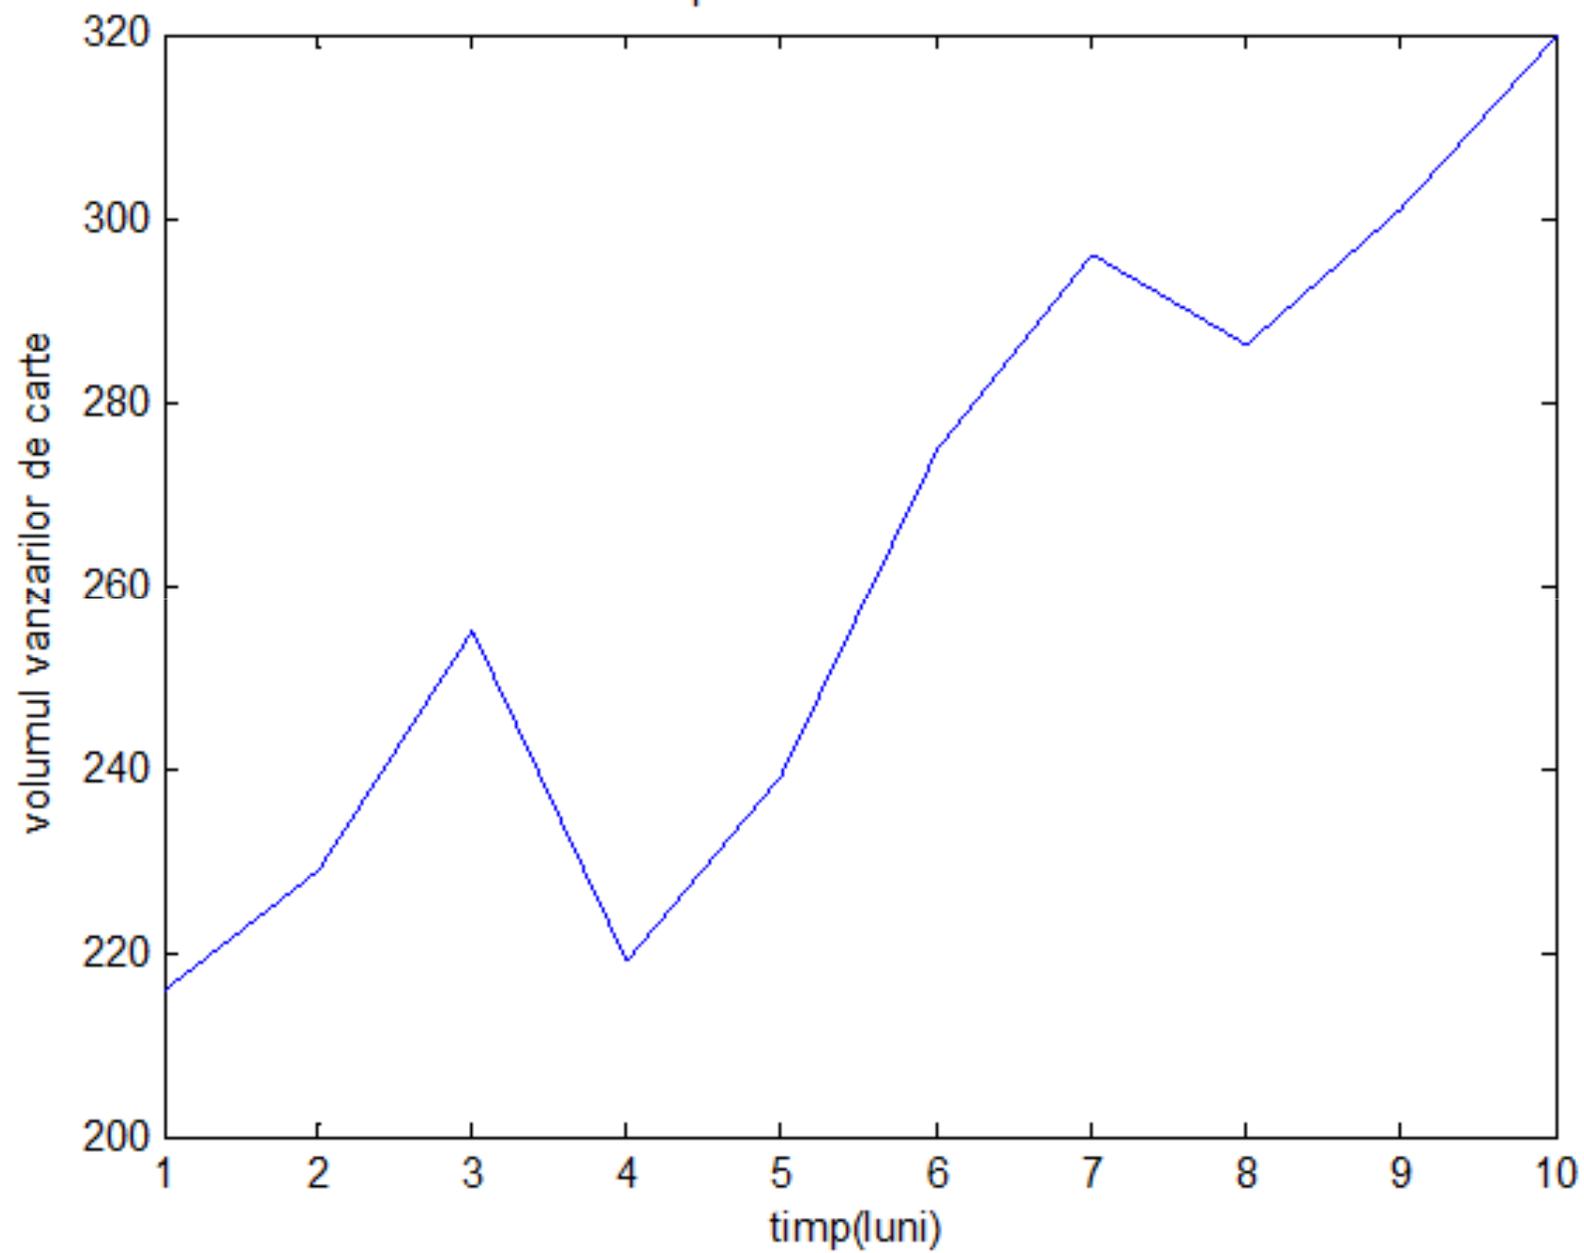
7.Exemplu

Vânzările de carte (număr de cărți) dintr-o librărie virtuală în ultimele 10 luni sunt:

luna	1	2	3	4	5	6	7	8	9	10
vânzări	216	229	255	219	239	275	296	286	301	320

```
>> t=1:10;  
>>x=[216 229 255 219 239 275 296 286 301 320];  
>>plot(t,x,'k')
```

seria temporală a vanzarilor de carte



Determinăm ecuația trendului acestei serii temporale:

```
>>b=(t*x'-10*mean(t)*mean(x))./(t*t'-10*mean(t)^2)
```

```
b =
```

```
11.2848
```

```
>>a=mean(x)-b*mean(t)
```

```
a =
```

```
201.5333
```

și astfel folosind trendul putem prognoza volumul vânzărilor pe următoarele 3 luni:

```
>> T11=a+11*b
```

```
T11 =
```

```
325.6667
```

```
>> T12=a+12*b
```

```
T12 =
```

```
336.9515
```

```
>> T13=a+13*b
```

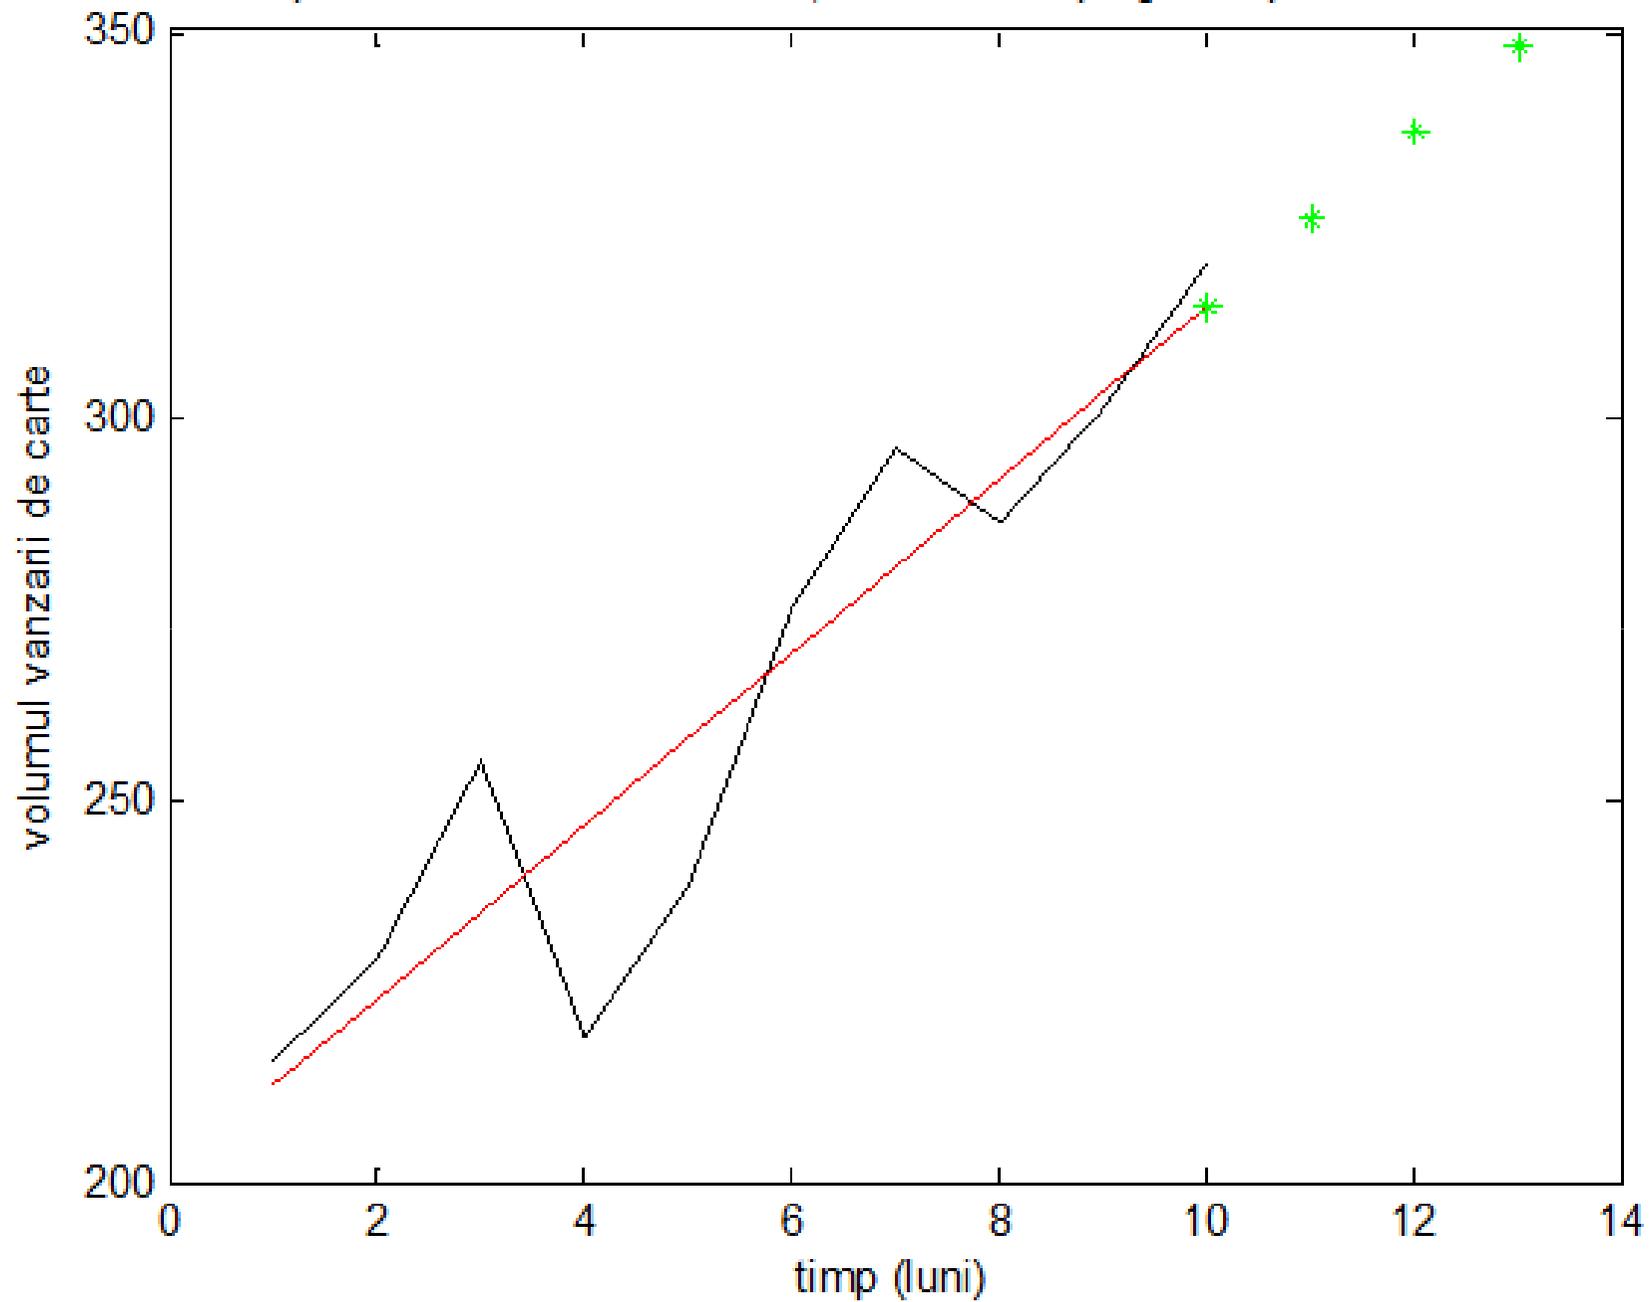
```
T13 =
```

```
348.2364
```

```
>>T=a+b*t;
```

```
>> plot(t,x,'k',t,T,'r', 10,T(10),'g*',11,T11,'g*',12,T12,'g*',13,T13,'g*')
```

seria temporală a vanzarilor de carte, trendul ei și prognoza pe următoarele 3 luni



Prognoza utilizând trendul și componenta sezonieră

Considerăm că valoarea reală a seriei temporale, $\{x_t, t \in T\}$ poate fi descrisă prin *modelul multiplicativ* de o serie temporală:

$$x_t = T_t \cdot S_t \cdot I_t,$$

unde T_t , S_t , I_t este trendul, componenta sezonieră, respectiv cea incidentală corespunzătoare perioadei de timp t .

Componentă incidentală este cea care dă efectele aleatoare din seria temporală, efecte care nu pot fi explicate de trend sau componenta sezonieră.

Tehnica de lucru constă în:

- eliminarea componentei sezoniere;
- realizarea prognozei utilizând trendul;
- reintroducerea componentei sezoniere în scopul ajustării prognozei.

Dacă reușim să eliminăm efectele sezoniere ale unei serii temporale, putem de exemplu compara valorile seriei temporale în perioade succesive.

Dacă nu, putem face comparații între valorile seriei temporale dintr-o anumită perioadă din acest an și aceeași perioadă a anului trecut.

Considerăm o serie temporală $\{x_t, t \in T\}$, unde $T = \{1, 2, \dots, 4 \cdot n\}$, unde n este numărul de ani luați în considerare ($4 \cdot n$ fiind numărul de trimestre), de forma $x_t = T_t \cdot S_t \cdot I_t$.

1. Existența pattern-ului sezonier impune identificarea computațională a fiecărei influențe trimestriale sezoniere. Calculăm o medie mobilă pentru a izola componenta sezonieră S și componenta incidentală I . Folosim datele din fiecare an și anume cele 4 trimestre:

$$\text{media mobila (1)} = \frac{x_1 + x_2 + x_3 + x_4}{4},$$

$$\text{media mobila (2)} = \frac{x_2 + x_3 + x_4 + x_5}{4}, \dots$$

Valorile calculate nu corespund trimestrelor din seria temporală. Valoarea *media mobila* (1) corespunde ultimei jumătăți a trimestrului al 2-lea și primei jumătăți a trimestrului al 3-lea în timp ce *media mobila* (2) corespunde ultimei jumătăți a trimestrului al 3-lea și primei jumătăți a trimestrului al 4-lea.

În aceste condiții vom considera media mobilă corespunzătoare trimestrului al 3-lea ca fiind media aritmetică a celor două medii calculate, așa numita *media mobilă centrată* (*centered moving average- CMA*):

$$CMA(3) = \frac{\text{media mobila}(1) + \text{media mobila}(2)}{2}$$

Continuăm calculul asociind următoarelor trimestre ($4 \leq i \leq 4 \cdot n - 2$) mediile mobile centrate corespunzătoare $CMA(i)$, $4 \leq i \leq 4 \cdot n - 2$, obținând astfel seria temporală corespunzătoare mediilor mobile centrate.

Această serie temporală este „netezită” în sensul că nu apar influențele sezoniere și incidentale.

Dacă numărul de puncte din media mobilă este impar, punctul din mijloc va corespunde unei perioade din seria temporală, caz în care nu va mai fi nevoie să centram media mobilă.

2. Împărțind fiecare observație din seria temporală cu media mobilă centrată corespunzătoare putem identifica efectul sezonier – incidental al seriei temporale.

Astfel *componenta sezonier-incidentală* corespunzătoare celui de-al i -lea trimestrului este:

$$CSI(i) = \frac{x_i}{CMA(i)}, \quad 3 \leq i \leq 4 \cdot n - 2.$$

Să considerăm componenta sezonier-incidentală pentru al 3-lea trimestru din primii $n-1$ ani:

Deoarece putem presupune că fluctuațiile de la an la an ale componentei sezonier-incidentale se datorează în principal componentei incidentale, putem calcula media celor $n-1$ valori, eliminând astfel influența incidentală.

Se obține astfel o estimare a influenței sezoniere din al 3-lea trimestru, estimare cunoscută sub numele de *indicele sezonier în trimestrul al treilea* - $IS(3)$:

$$IS(3) = \frac{\sum_{j=0}^{n-2} CS(4j+3)}{n-1} .$$

Analog calculăm indicii sezonieri pentru fiecare trimestru în parte:

$$IS(4) = \frac{\sum_{j=0}^{n-2} CS(4j+4)}{n-1} ;$$

$$IS(1) = \frac{\sum_{j=1}^{n-1} CS(4j+1)}{n-1} ;$$

$$IS(2) = \frac{\sum_{j=1}^{n-1} CS(4j+2)}{n-1} ;$$

Modelul multiplicativ cere ca media indicilor sezonieri să fie 1, condiție ce nu este îndeplinită în general.

Pentru a obține media indicilor sezonieri egală cu unitatea este necesară o ajustare, prin împărțirea fiecărui indice sezonier la media indicilor sezonieri:

$$IS_a(i) = \frac{IS(i)}{\frac{1}{4} \sum_{i=1}^4 IS(i)}, 1 \leq i \leq 4 .$$

3. Împărțind fiecare observație (termen) al seriei temporale la indicele sezonier corespunzător ajustat înlăturăm efectul sezonier al seriei temporale:

$$x'_{4k+i} = \frac{x_{4k+i}}{IS_a(i)}, 0 \leq k \leq n-1, 1 \leq i \leq 4.$$

4. Putem estima trendul liniar al seriei temporale din care am eliminat componenta sezonieră $\{x'_j, j \in T = \{1, 2, \dots, 4 \cdot n\}\}$.

$$T_t = a + bt,$$

unde:

$$b = \frac{\sum_{j=1}^{4n} j \cdot x'_j - \frac{1}{4n} \sum_{j=1}^{4n} j \cdot \sum_{i=1}^{4n} x'_i}{\sum_{j=1}^{4n} j^2 - \frac{1}{4n} \left(\sum_{j=1}^{4n} j \right)^2}; \quad a = \frac{1}{4n} \left(\sum_{j=1}^{4n} x'_j - b \cdot \sum_{j=1}^{4n} j \right).$$

Putem prognoza, pe baza trend-ului, comportarea seriei temporale pentru cele patru trimestre din următorul an (al $n+1$ -lea):

$$T_{4n+i} = a + b(4n+i), i \in \{1, 2, 3, 4\};$$

Luăm în considerare efectul sezonier asupra prognozei, înmulțind T_i cu indicele sezonier ajustat:

$$T'_{4n+i} = IS_a(i) \cdot T_{4n+i}, i \in \{1, 2, 3, 4\}.$$

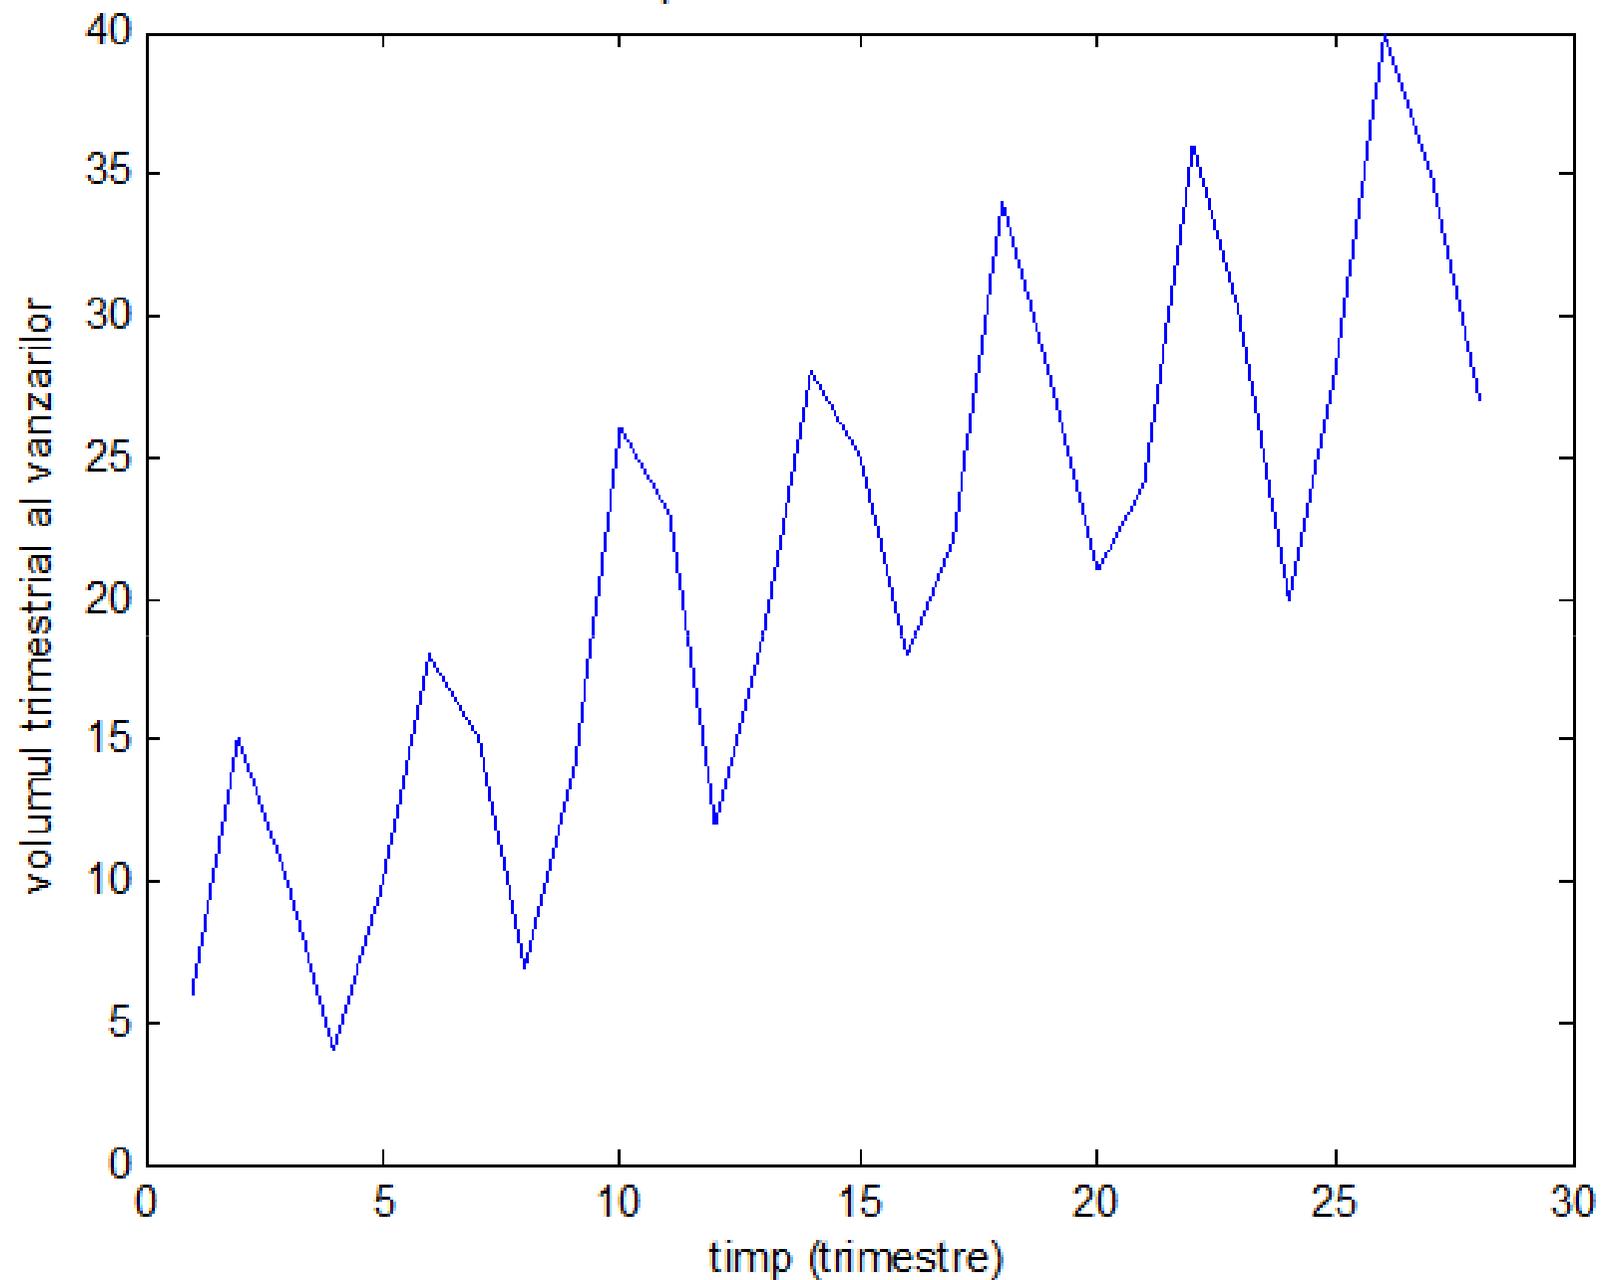
8. Exemplu

Firma X este dealer autorizat al firmei pentru vânzarea de automobile. Următorul tabel prezintă situația vânzărilor trimestriale pe ultimii 7 ani:

anul	trim I	trim II	trim III	trim IV	total
1	6	15	10	4	35
2	10	18	15	7	50
3	14	26	23	12	75
4	19	28	25	18	90
5	22	34	28	21	105
6	24	36	30	20	110
7	28	40	35	27	130

```
>> t=1:28;  
>>V=[6 15 10 4 10 18 15 7 14 26 23 12 19 28 25 18 22 34 28 21 24 36 30  
20 28 40 35 27];% V=vanzari trimestriale  
>> plot(t,V)
```

seria temporală a vânzării trimestriale



Se observă că în trimestrul al patrulea al fiecărui an volumul vânzărilor este minim, în timp ce în trimestrul al doilea al fiecărui an volumul crește, ceea ce indică existența unui pattern sezonier.

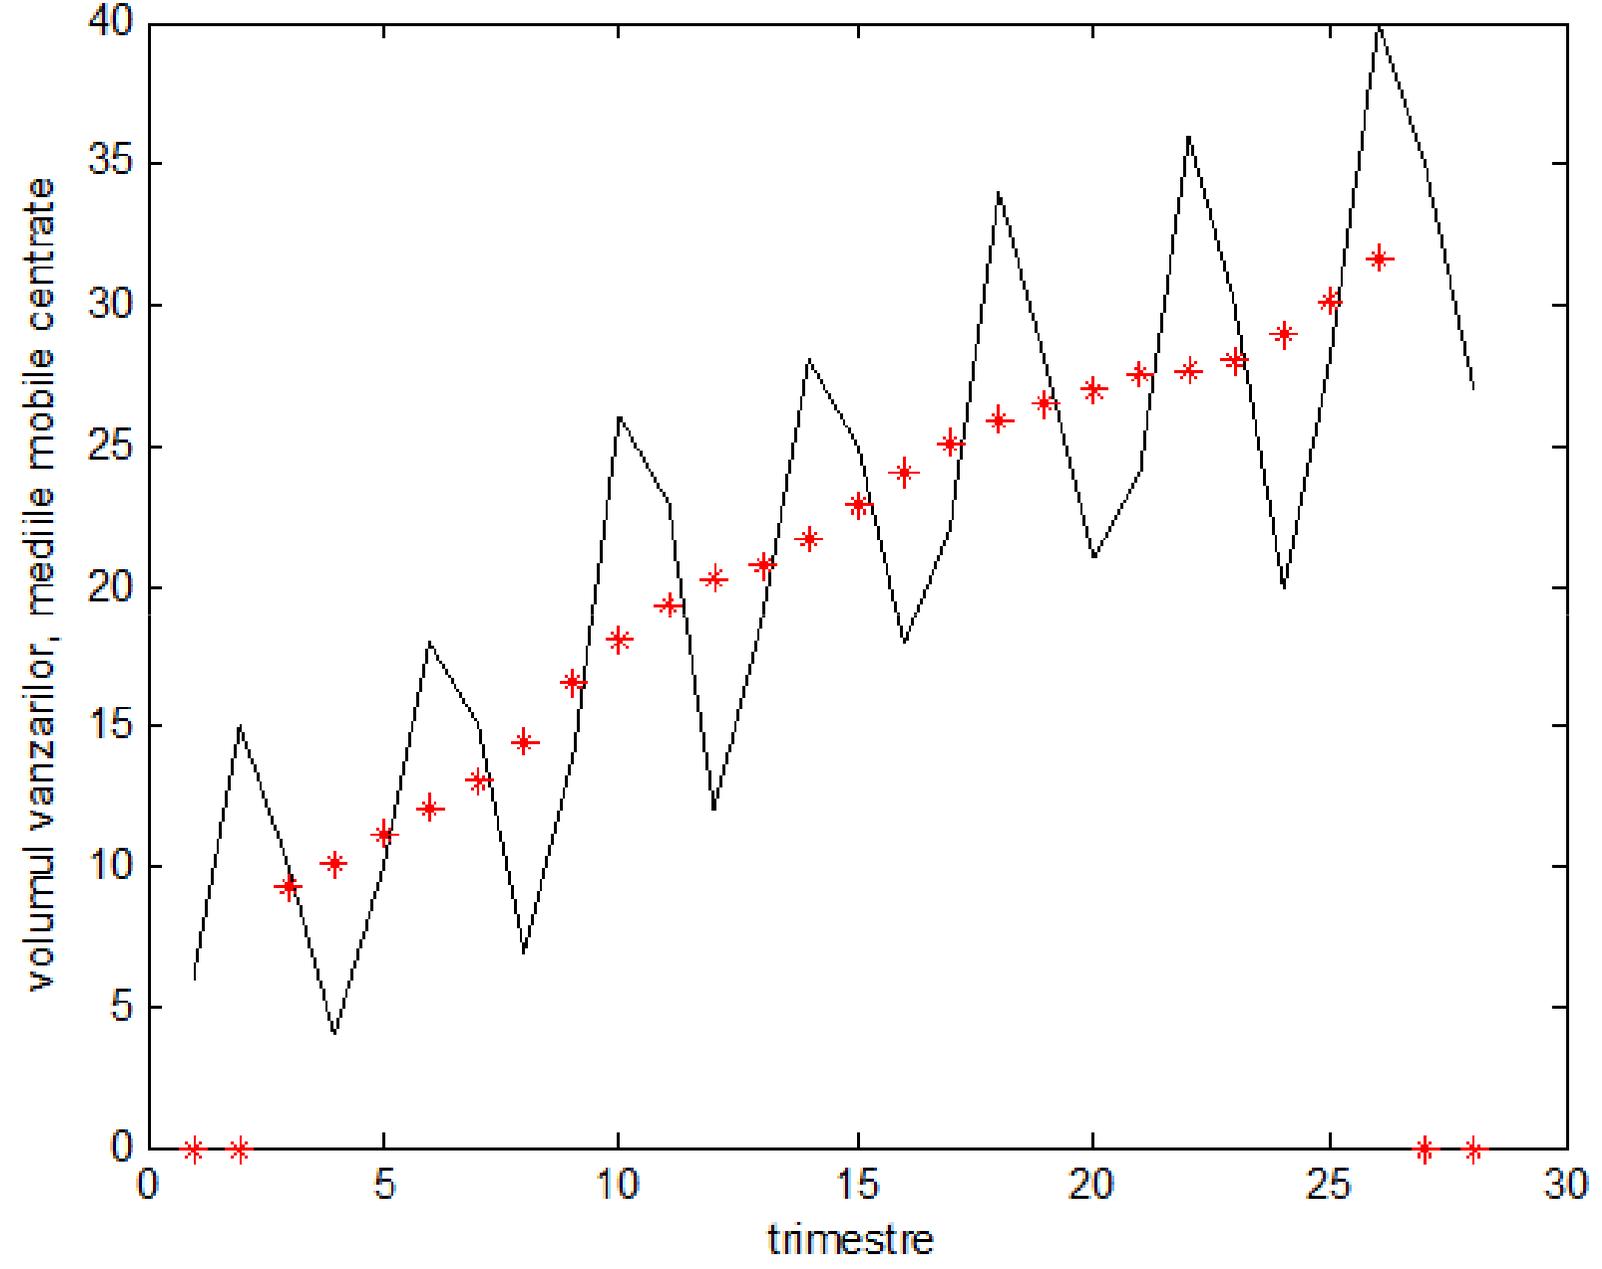
Vom determina mediile mobile pe 4 trimestre, mediile mobile centrate.

```
>> t=1:28;V=[6 15 10 4 10 18 15 7 14 26 23 12 19 28 25 18 22 34 28 21 24  
36 30 20 28 40 35 27];% V=vanzari trimestriale  
>> for i=5:29 M(i-2)=1/4*(V(i-4)+V(i-3)+V(i-2)+V(i-1));end % M media mobila  
trimestriala  
>> M(28)=0;  
>> for i=3:26 MC(i)=1/2*(M(i)+M(i+1)); end % MC media mobila centrata  
>> for i=27:28 MC(i)=0;end
```

Prezentăm graficul seriei temporale și graficul seriei temporale corespunzătoare mediilor mobile centrate:

```
>> plot(t,V,'k',t,MC,'r*')
```

seria temporală a volumului vânzării și seria corespunzătoare a mediilor mobile centrate



Calculăm componenta sezonier-incidentală:

```
>> for i=3:26 CS(i)=V(i)/MC(i);end  
>> for i=27:28 CS(i)=0;end %CS componenta sezoniera  
>> [V' M' MC' CS'];
```

Calculăm indicii sezonieri pentru fiecare trimestru, și indicii sezonieri ajustați:

```
>> for i=1:2  
I(i)=1/6*(CS(i+4)+CS(i+8)+CS(i+12)+CS(i+16)+CS(i+20)+CS(i+24));end  
>>for i=3:4  
I(i)=1/6*(CS(i)+CS(i+4)+CS(i+8)+CS(i+12)+CS(i+16)+CS(i+20));end % I  
indicele sezonier  
>> I  
I =  
    0.8901    1.3481    1.1072    0.6146  
>> Ia=I/mean(I) %Ia indicele sezonier ajustat  
Ia =  
    0.8991    1.3617    1.1183    0.6208
```

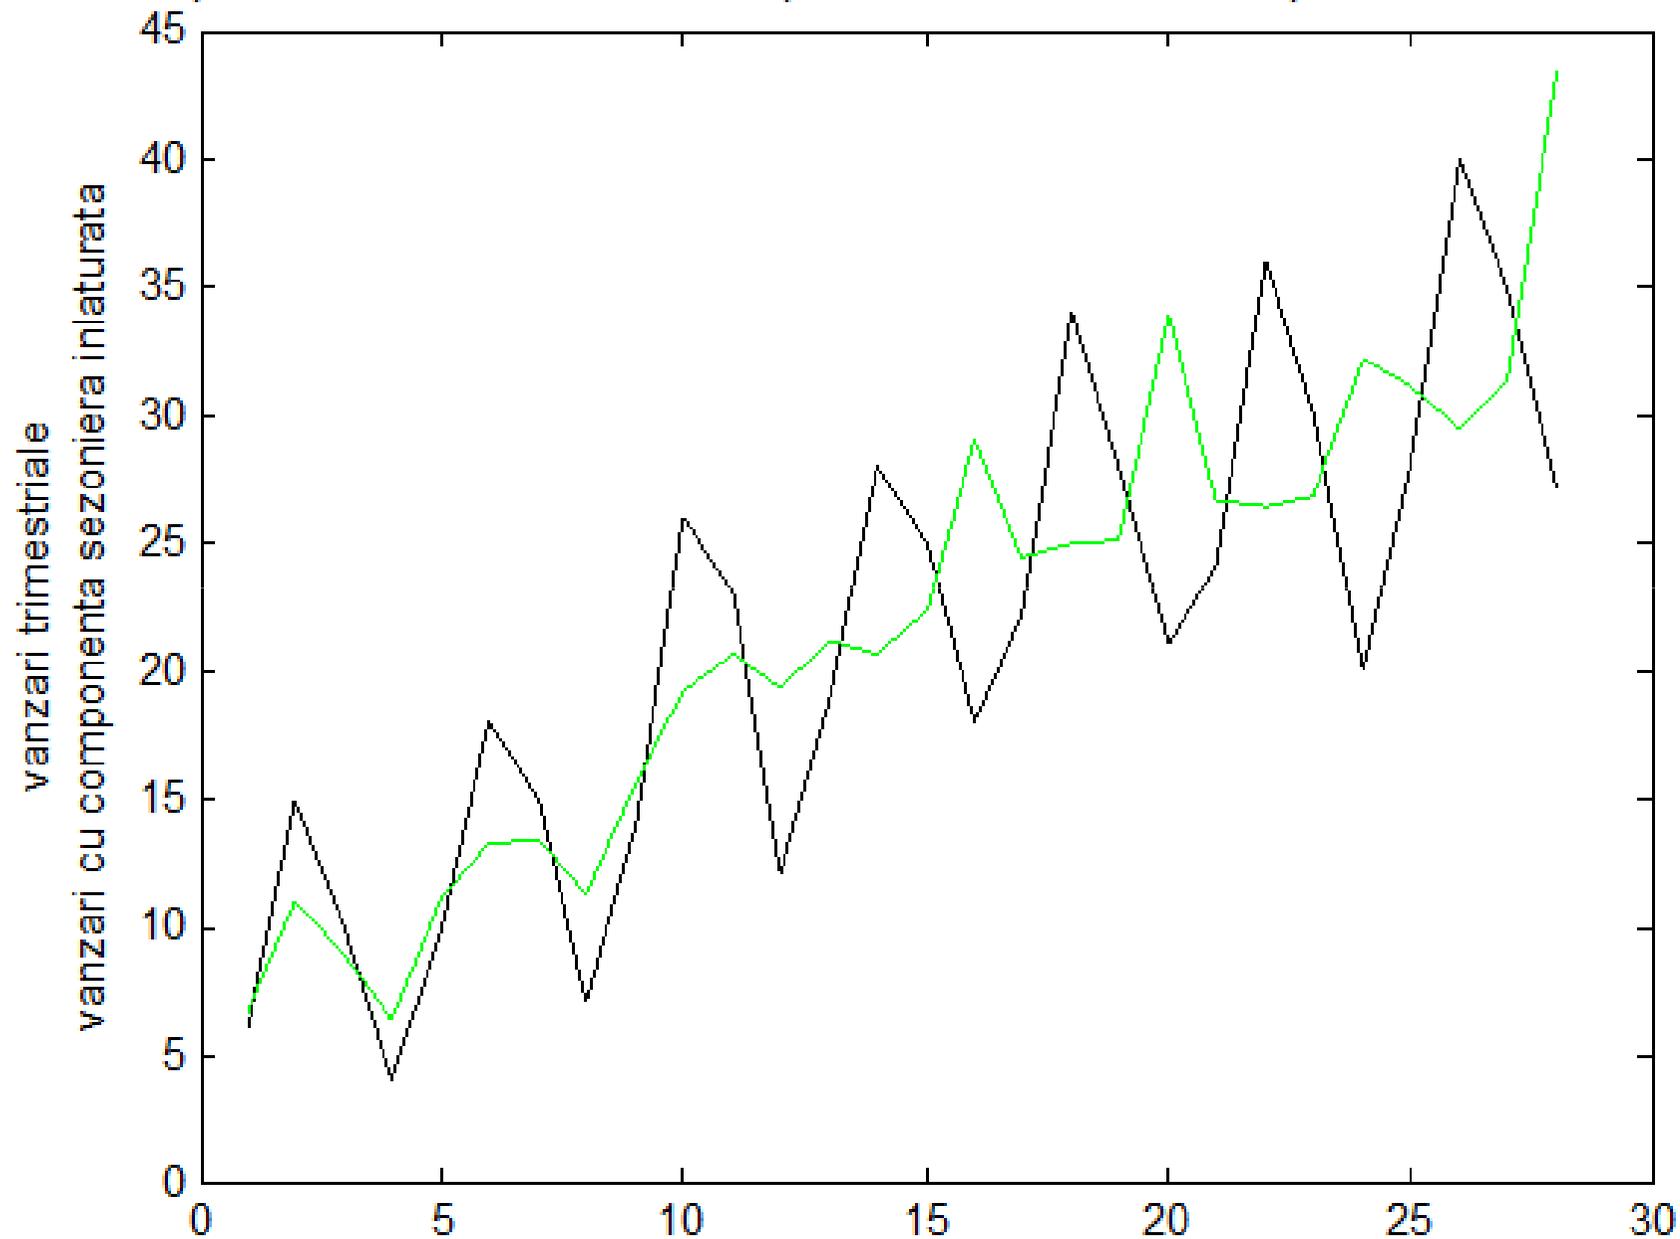
Observăm că cele mai bune vânzări sunt în al 2-lea trimestru, cu 36.17% peste medie. Cel mai slab trimestru pentru vânzări este al 4-lea cu 37.92% sub medie.

Împărțind fiecare observație (termen) al seriei temporale la indicele sezonier corespunzător ajustat, înlăturăm efectul sezonier al seriei temporale.

Vom prezenta graficele seriei vânzărilor trimestriale și al seriei vânzărilor trimestriale cu efectul sezonier înlăturat.

```
>> IS=[1a 1a 1a 1a 1a 1a];  
>> for i=1:28 VDS(i)=V(i)/IS(i);end % VDS vanzari cu factorul sezonier  
indepartat  
>>plot(t, V,'k',t,VDS,'g.')
```

seria temporală a vânzării și seria temporală a vânzării cu componenta sezonieră înlăturată



Utilizând seria temporală fără componenta sezonieră putem estima volumul vânzărilor ca funcție de timp.

```
>> b=(t*VDS'-28*mean(t)*mean(VDS))./(norm(t)^2-28*mean(t)^2)
```

```
b =
```

```
1.0547
```

```
>> a=mean(VDS)-b*mean(t)
```

```
a =
```

```
6.3315
```

Astfel ecuația trendului liniar al seriei temporale este:

$$T_t = 6.3315 + 1.0547 \cdot t$$

Prognozăm pe baza trendului volumul vânzărilor în cel de-al 8-lea an și luăm apoi în considerare și efectul sezonier:

```
>> for t=29:32; Vp(t)=a+b*t;end %Vp vanzari prognozate
>> for i=1:4 VP(i+28)=Vp(i+28)*I(i);end % VP vanzari prognozate tinand
    cont de indicele sezonier
>> [ Vp' VP']
ans =
    36.9166    32.8609
    37.9712    51.1876
    39.0259    43.2079
    40.0806    24.6352
```

Considerăm o serie temporală $\{x_t, t \in T\}$ unde $T = \{1, 2, \dots, 12 \cdot n\}$, unde n este numărul de ani luați în considerare ($12 \cdot n$ fiind numărul de luni), de forma $x_t = T_t \cdot S_t \cdot I_t$, serie ce prezintă un pattern sezonier.

1. Vom identifica fiecare influență lunară sezonieră, pentru a o izola, calculând o medie mobilă pe 12 luni:

$$\text{media mobilă (1)} = \frac{\sum_{i=1}^{12} x_i}{12},$$
$$\text{media mobilă (2)} = \frac{\sum_{i=2}^{13} x_i}{12}, \dots$$

Vom considera media mobilă corespunzătoare trimestrului al 11-lea ca fiind media aritmetică a celor două medii calculate, așa numita *media mobilă centrată* (*centered moving average- CMA*):

$$CMA(11) = \frac{\text{media mobila}(1) + \text{media mobila}(2)}{2}$$

Asociem următoarelor trimestre ($12 \leq i \leq 12 \cdot n - 2$) mediile mobile centrate corespunzătoare $CMA(i)$, $12 \leq i \leq 12 \cdot n - 2$.

Am obținut astfel seria temporală corespunzătoare mediilor mobile centrate, serie care este „netezită” în sensul că nu apar influențele sezoniere și incidentale.

2. Fiecare observație din seria temporală se împarte cu media mobilă centrată corespunzătoare pentru a identifica efectul sezonier –incidental al seriei temporale.

Componenta sezonier-incidentală corespunzătoare celui de-al i -lea trimestru este:

$$CSI(i) = \frac{x_i}{CMA(i)}, \quad 11 \leq i \leq 12 \cdot n - 2$$

Să considerăm componenta sezonier-incidentală pentru luna a 11-a din primii $n-1$ ani. Fluctuațiile de la an la an ale componentei sezonier-incidentale se datorează în principal componentei incidentale, astfel putem calcula media celor $n-1$ valori, eliminând astfel influența incidentală.

Se obține o estimare a influenței sezoniere din al luna a 11-a, estimare cunoscută sub numele de *indicele sezonier în luna a 11-a- IS(11)* :

$$IS(11) = \frac{\sum_{j=0}^{n-2} CS(12j+11)}{n-1}$$

Analog calculăm indicii sezonieri pentru fiecare lună în parte:

$$IS(12) = \frac{\sum_{j=0}^{n-2} CS(12j + 12)}{n-1};$$

$$IS(k) = \frac{\sum_{j=1}^{n-1} CS(4j + k)}{n-1}, 1 \leq k \leq 10;$$

Pentru a obține media indicilor sezonieri egală cu unitatea, împărțim fiecare indice sezonier la media indicilor sezonieri.

$$IS_a(i) = \frac{IS(i)}{\frac{1}{12} \sum_{i=1}^{12} IS(i)}, 1 \leq i \leq 12$$

3. Împărțind fiecare observație (termen) al seriei temporale la indicele sezonier corespunzător ajustat, înlăturăm efectul sezonier al seriei temporale.

$$x'_{12k+i} = \frac{x_{12k+i}}{IS_a(i)}, 0 \leq k \leq n-1, 1 \leq i \leq 12$$

4. Putem estima trendul liniar al seriei temporale căreia i-am eliminat componenta sezonieră $\{x'_j, j \in T = \{1, 2, \dots, 12 \cdot n\}\}$:

$$T_t = a + bt,$$

unde:

$$b = \frac{\sum_{j=1}^{12n} j \cdot x'_j - \frac{1}{12n} \sum_{j=1}^{12n} j \cdot \sum_{i=1}^{12n} x'_j}{\sum_{j=1}^{12n} j^2 - \frac{1}{12n} \left(\sum_{j=1}^{12n} j \right)^2}; \quad a = \frac{1}{12n} \left(\sum_{j=1}^{12n} x'_j - b \cdot \sum_{j=1}^{12n} j \right)$$

$\{x'_j, j \in T = \{1, 2, \dots, 12 \cdot n\}\}$ este seria temporală fără componenta sezonieră.

Putem prognoza, pe baza trendului, comportarea seriei temporale pentru următoarele 12 luni:

$$T_{4n+i} = a + b(4n + i), 1 \leq i \leq 12;$$

Luăm în considerare efectul sezonier asupra prognozei, înmulțind T_i cu indicele sezonier ajustat:

$$T'_{4n+i} = IS_a(i) \cdot T_{4n+i}, 1 \leq i \leq 12$$

Exemplu

Reluăm exemplul nr 4 cu numărul de pasageri (în mii) înregistrat pentru zborurile internaționale pe un aeroport, din ultimele 36 de luni. Folosind tehnica prezentată dorim să prognozăm numărul de pasageri pentru următorul an.

```
>>N=[31 22 21 34 29 40 54 62 45 21 23 41 33 24 23 28 35 45 60 65 44 23  
24 48 34 26 25 35 32 53 70 74 50 27 28 51];% N numarul de pasageri (mii)  
>> for i=13:37  
M(i-2)=1/12*(N(i-12)+N(i-11)+N(i-10)+N(i-9)+N(i-8)+N(i-7)+N(i-6)+N(i-5)+N(i-  
4)+N(i-3)+N(i-2)+N(i-1));  
end % M media mobila lunara  
>> M(36)=0;  
>> for i=11:34  
MC(i)=1/2*(M(i)+M(i+1));  
end % MC media mobila centrata  
>> for i=35:36  
MC(i)=0;  
end
```

Exemplu

Reluăm exemplul nr 4 cu numărul de pasageri (în mii) înregistrat pentru zborurile internaționale pe un aeroport, din ultimele 36 de luni. Folosind tehnica prezentată dorim să prognozăm numărul de pasageri pentru următorul an.

```
>>N=[31 22 21 34 29 40 54 62 45 21 23 41 33 24 23 28 35 45 60 65 44 23  
24 48 34 26 25 35 32 53 70 74 50 27 28 51];% N numarul de pasageri (mii)  
>> for i=13:37  
M(i-2)=1/12*(N(i-12)+N(i-11)+N(i-10)+N(i-9)+N(i-8)+N(i-7)+N(i-6)+N(i-5)+N(i-  
4)+N(i-3)+N(i-2)+N(i-1));  
end % M media mobila lunara  
>> M(36)=0;  
  
>> for i=11:34  
MC(i)=1/2*(M(i)+M(i+1));  
end % MC media mobila centrata  
>> for i=35:36  
MC(i)=0;  
end
```

```
>> for i=11:34
NS(i)=N(i)/MC(i);
end
```

```
>> for i=35:36
NS(i)=0;
end %NS componenta sezoniera
```

```
>> [N' M' MC' NS'];
```

```
>> for i=1:10
I(i)=1/2*(NS(i+12)+NS(i+24));
end
```

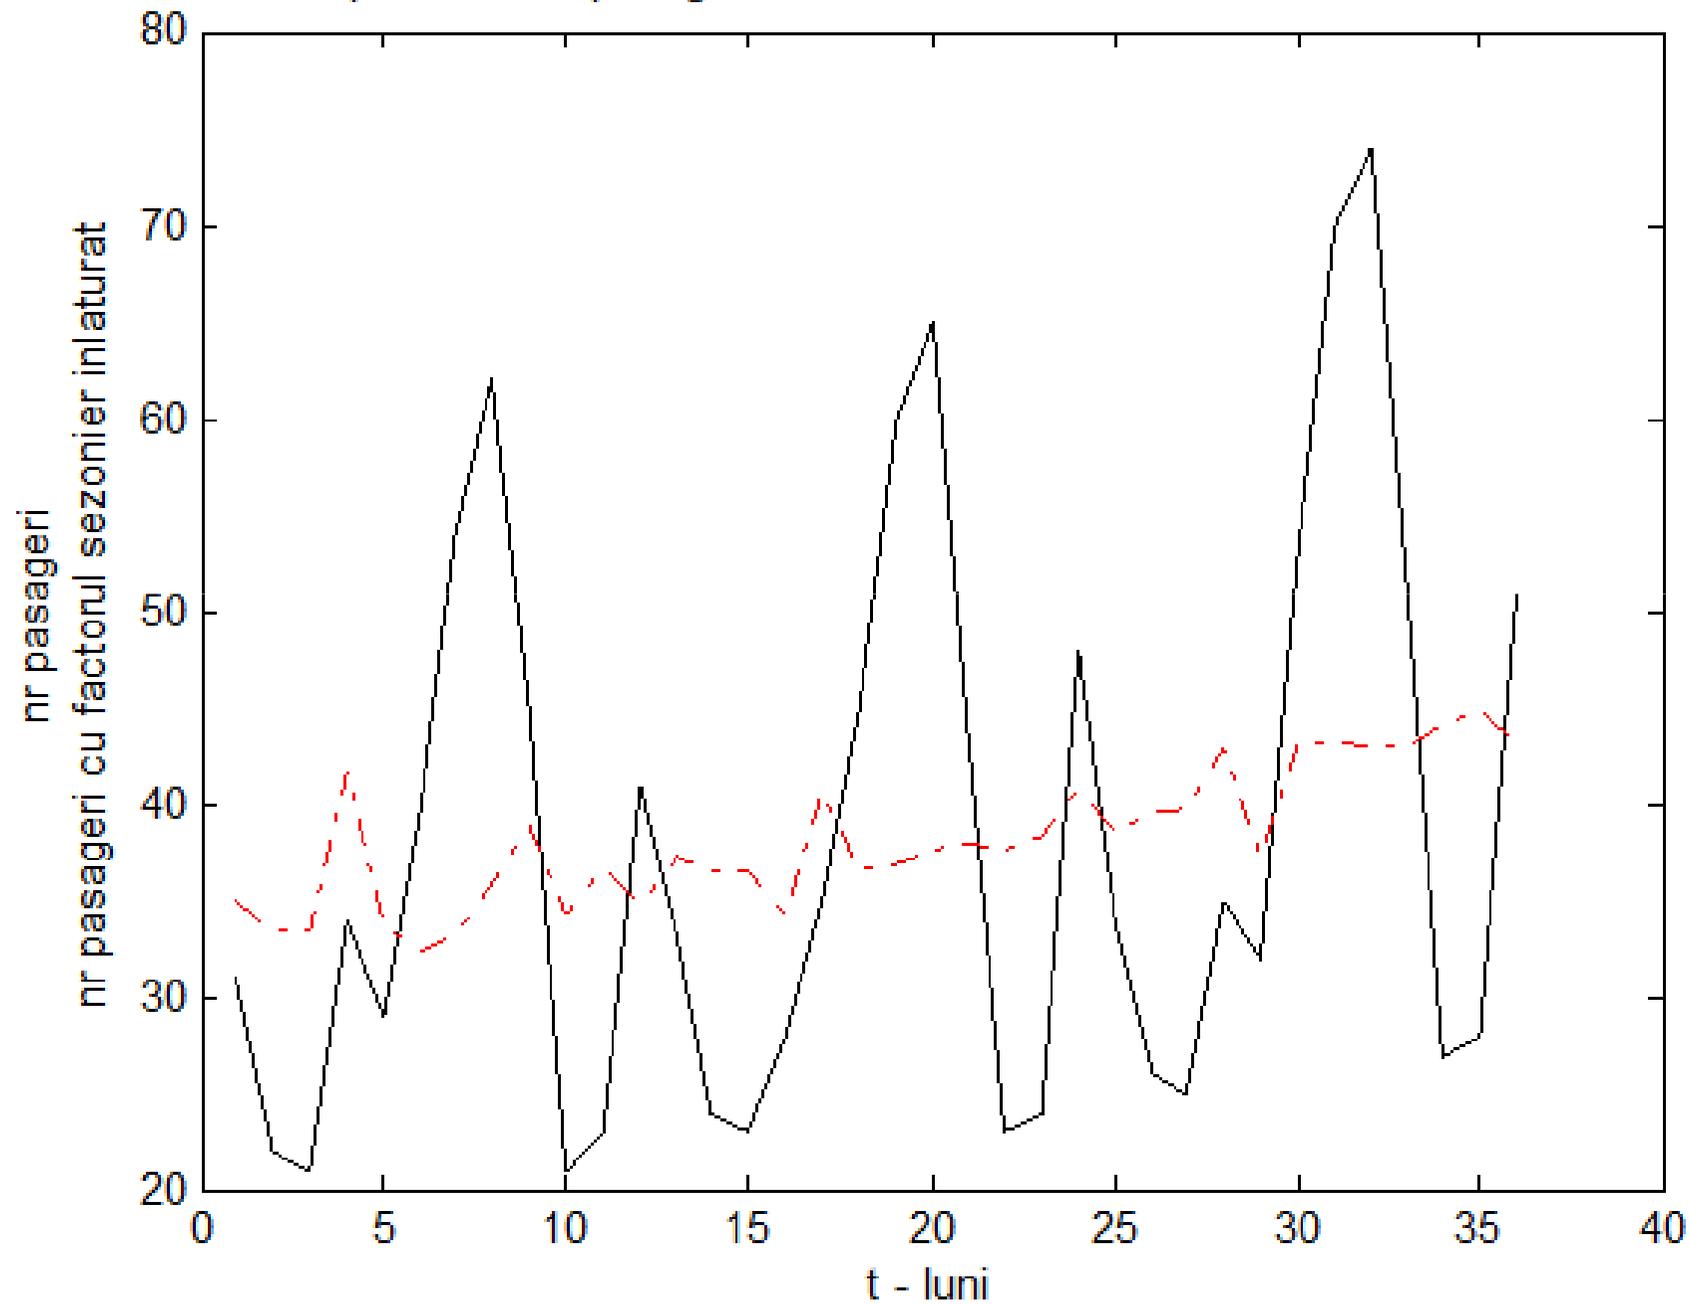
```
>> for i=11:12
I(i)=1/2*(NS(i)+NS(i+12));
end % I indicele sezonier
```

```
>> I
    0.9100    0.6768    0.6483    0.8410    0.8856    1.2693    1.6690    1.7755
    1.1939    0.6294    0.6437    1.2118
```

```
>> la=l/mean(l) ; %la indicele sezonier ajustat
la =
    0.8839    0.6574    0.6297    0.8168    0.8602    1.2329    1.6211    1.7246
    1.1597    0.6114    0.6252    1.1771
>> IS=[la la la ];
>> for i=1:36
NDS(i)=N(i)/IS(i);
end % NDS nr pasageri cu factorul sezonier indepartat
>> [N' NDS'];

>> t=1:36; plot(t, N,'k',t,NDS,'k -.)
```

seria temporală cu nr pasagerilor și aceeași serie cu factorul sezonier înlăturat



Calculăm trendul:

```
>> b=(t*NDS'-28*mean(t)*mean(NDS))./(norm(t)^2-28*mean(t)^2)
```

```
b =
```

```
1.0161
```

```
>> a=mean(NDS)-b*mean(t)
```

```
a =
```

```
19.4582
```

Facem prognoza pe următorul an:

```
>> for t=37:48;
```

```
Np(t)=a+b*t;
```

```
end %Np numar de pasageri prognozat
```

```
>> for i=1:12
```

```
NP(i+36)=Np(i+36)*I(i);
```

```
end % NP numar de pasageri prognozat tinand cont de indicele sezonier
```

```
>> [ Np' NP']
```

```
ans =
```

57.0525	51.9169
58.0685	39.3002
59.0846	38.3027
60.1007	50.5418
61.1167	54.1257
62.1328	78.8624
63.1488	105.3927
64.1649	113.9262
65.1810	77.8212
66.1970	41.6671
67.2131	43.2653
68.2291	82.6819

Modele dinamice, bazate pe serii temporale

Seriile temporale mai sunt cunoscute și sub numele de *serii dinamice*, datorită faptului că ilustrează cinetica (dinamica) unui fenomen evoluând în timp real.

De aceea, în conexiune cu seriile temporale, putem vorbi și de *modelele dinamice*, adică modelele ce captează *mișcarea* unui anumit fenomen în raport cu timpul.

Modelele dinamice explică comportamentul actual al variabilei dependente cu ajutorul valorilor actuale și din trecut ale variabilelor.

De exemplu modelul

$$y_t = \beta_1 + \beta_2 \cdot x_t + \beta_3 \cdot x_{t-1} + u_t$$

arată că y_t este explicat prin valoarea actuală a variabilei x , x_t și prin valoarea din trecut x_{t-1} .

Se iau în considerare:

- modele cu valori din trecut ale variabilelor independente; aceste modele sunt generalizări ale modelelor regresive, prin adăugarea valorii x_{t-1} în lista variabilelor independente (predictorilor). Specificul acestui tip de model este introducerea unei variabile aleatoare în lista variabilelor independente.
- modele cu valori din trecut ale variabilelor dependente, modele ce includ valori din trecut ale variabilei dependente, de exemplu:

$$y_t = \gamma \cdot y_{t-1} + \beta_1 + \beta_2 \cdot x_{2t} + \dots + \beta_k \cdot x_{kt} + u_t \quad (*)$$

Modele explicative

Aceste modele sunt caracterizate de ecuația:

$$y_t = f(x_t, u_t)$$

unde f este o funcție determinată de un număr finit de parametri necunoscuți, x_t este o variabilă observabilă, numită și *variabilă exogenă*, iar u_t reprezintă o variabilă aleatoare de medie zero, aleasă în funcție de situația reală modelată (factor de disturbare/zgomot/eroare).

În principal, aceste modele se împart în două cazuri:

- modele *statice*, în care variabila exogenă x_t nu conține informații din trecutul lui y_t , iar u_t sunt mutual independente,
- modele *dinamice* în care fie x_t conține informații privind trecutul lui y_t , fie u_t sunt autocorelate.

9. Exemplu

Agenții economici iau decizii asupra viitorului, bazându-se pe propriile previziuni asupra unor condiții necunoscute.

De exemplu, dacă se decide reabilitarea sistemului de încălzire, bazându-se pe prețul preconizat al combustibililor și al echipamentelor, cel mai simplu model fiind

$$y_t = \beta_1 + \beta_2 \cdot x_t^p + u_t \quad (1)$$

unde x_t^p este prețul preconizat.

Valorile preconizate ale prețului sunt stabilite pe baza situațiilor existente în trecut și astfel putem modela prețul preconizat x_t^p astfel:

$$x_t^p = x_{t-1}^p + \lambda(x_{t-1} - x_{t-1}^p), \lambda \in [0,1] \quad (2)$$

unde x_{t-1} este prețul echipamentelor și combustibililor în momentul $t-1$ și x_{t-1}^p este prețul preconizat pentru momentul $t-1$.

Așadar prețul preconizat este suma prețului preconizat pentru momentul anterior și eroarea observată în prognozarea prețului în momentul anterior, ponderată cu parametrul $\lambda \in [0,1]$.

Dinamica din construcția pretului prognozat, duce la o dinamică în datele observate:

Conform (1) avem:

$$y_{t-1} = \beta_1 + \beta_2 \cdot x_{t-1}^p + u_{t-1}$$

și astfel:

$$x_{t-1}^p = \frac{1}{\beta_2} \cdot (y_{t-1} - \beta_1 - u_{t-1})$$

Conform (2):

$$x_t^p = \lambda \cdot x_{t-1} + (1 - \lambda) \cdot x_{t-1}^p = \lambda \cdot x_{t-1} + \frac{1 - \lambda}{\beta_2} (y_{t-1} - \beta_1 - u_{t-1}) \quad (3)$$

Înlocuind în (1) valoarea obținută pentru prețul preconizat în (3), obținem:

$$y_t = (1 - \lambda) \cdot y_t + \lambda \beta_1 + \lambda \beta_2 \cdot x_{t-1} + (u_t + (1 - \lambda)u_{t-1})$$

Notând $\varepsilon_t = u_t + (1 - \lambda)u_{t-1}$, obținem ecuația unui model de tip (*).

Modele de ajustare

În acest caz, pe baza observațiilor obținute analizând datele reale, putem formula un model matematic ilustrat de o ecuație de forma:

$$y_t = f(t, u_t)$$

unde f este o funcție determinată de un număr finit de parametri necunoscuți, iar u_t reprezintă o variabilă aleatoare de medie zero, aleasă în funcție de situația reală modelată.

Vom menționa că ipotezele asupra variabilei u_t ca și estimarea funcției f se fac plecând de la:

1. *ajustările globale*, în care toate observațiile se bucură de aceeași considerație, având roluri egale în estimății, sau
2. *ajustările locale*, în care fiecare observație își are rolul său în determinarea parametrilor modelului.

10. Exemplu

În cazul în care agenții economici nu se pot adapta pe deplin la schimbarea condițiilor , are loc un fenomen similar cu cel din exemplul nr 9.

De exemplu, o dată cu trecerea anilor, o firmă are nevoie de lărgirea sediului. Costurile necesare modificărilor dorite restricționează mărimea construcției. Putem modela dimensiunile dorite utilizând regresia liniară:

$$y_t^* = \beta_1 + \beta_2 \cdot x_t + u_t$$

Vom face legătura între dimensiunea dorită și cea observată printr-un proces de ajustare parțială:

$$y_t - y_{t-1} = \lambda \cdot (y_t^* - y_{t-1}) + v_t, \quad \lambda \in [0,1]$$

ceea ce va conduce la o relație între y și x :

$$y_t = (1 - \lambda)y_{t-1} + \lambda\beta_1 + \lambda\beta_2 \cdot x_t + \varepsilon_t, \quad \lambda \in [0,1]$$

unde am notat $\varepsilon_t = v_t + \lambda \cdot u_t$

Modele autopredictive

În aceste modele se presupune că prezentul este influențat de trecut, deci matematic vorbind, un asemenea model este ilustrat de o ecuație de forma:

$$y_t = f(y_{t-1}, y_{t-2}, \dots, u_t),$$

unde u_t reprezintă și aici factorul de perturbare, fiind reprezentat de o variabilă aleatoare.

Să considerăm cel mai simplu model autoregresiv

$$y_t = \beta_0 + \beta_1 y_{t-1} + u_t$$

care poate fi scris astfel:

$$\begin{aligned} y_t &= \beta_0 + \beta_1(\beta_0 + \beta_1 y_{t-2} + u_{t-1}) + u_t = \\ &= \beta_0 + \beta_1 \beta_0 + \beta_1^2 y_{t-2} + \beta_1 u_{t-1} + u_t = \\ &= \beta_0(1 + \beta_1 + \dots + \beta_1^n) + \beta_1^{n-1} y_{t-n} + u_t + \beta_1 u_{t-1} + \beta_1^n u_{t-n} \end{aligned}$$

Dacă $|\beta_1| \geq 1$, atunci y_t va crește exponențial

Dacă $|\beta_1| < 1$, procesul se *stabilizează* deoarece:

$$\beta_0 (1 + \beta_1 + \dots + \beta_1^n) \xrightarrow{n \rightarrow \infty} \frac{\beta_0}{1 - \beta_1}$$

$$\beta_1^{n-1} y_{t-n} \xrightarrow{n \rightarrow \infty} 0$$

$$u_t + \beta_1 u_{t-1} + \beta_1^n u_{t-n} \xrightarrow{n \rightarrow \infty} N\left(0, \frac{\sigma^2}{1 - \beta_1^2}\right)$$

În cazul modelelor complicate, varianta cea mai simplă pentru studiul stabilității, este simularea modelului.

Dacă modelul este instabil, simulările vor avea o formă explozivă.

Dacă însă este stabil, simulările vor converge.

Modelul *ARIMA*

Modelul *ARIMA* (*Auto-Regressive Integrated Moving Average*) a fost dezvoltat de către Box și Jenkins (1976), devenind unul dintre cele mai utilizate modele de prognoză, datorită puterii și flexibilității dovedite în aplicațiile concrete.

Modelul necesită totuși o pregătire serioasă din partea utilizatorului, în ciuda simplității matematice aparente.

Așa cum arată și numele, *ARIMA* include atât o componentă autoregresivă cât și una de tip medie mobilă.

Modelul ARIMA include trei tipuri de parametri:

- parametri autoregresivi (p);
- defazajul transformării diferențiate (d);
- parametri medie mobilă (q).

Astfel, un model ARIMA în notația Box & Jenkins va fi de forma

ARIMA (p, d, q).

De exemplu, un model de tip ARIMA (1, 2, 1) înseamnă că se referă la $p = 1$ parametri autoregresivi, $d = 2$ defazajul și $q = 1$ parametri medie mobilă.

Sunt cazuri în care nu este nevoie de transformarea diferențiată, adică. $d = 0$.

Cel mai adesea aceasta este aleasă $d = 1$ sau $d = 2$, atunci când este într-adevăr necesară.

În ceea ce privește alegerea celorlalți doi parametri, valorile uzuale rareori depășesc 2.

ARIMA (0,1,0) = mers la întâmplare (random walk).

Ecuția modelului este dată de:

$$\hat{x}_t = \mu + x_{t-1}$$

unde \hat{x}_t reprezintă prognoza pentru seria temporală la momentul t și μ este o constantă

ARIMA (0,1,0) poate fi considerat un model regresiv degenerat, în care

$$DIFF(x) = \hat{x}_t - x_{t-1}$$

este variabila dependentă și singura variabila independentă fiind constantă μ

Să remarcăm că ecuația mersului la întâmplare fără creștere este cea de sus, dar fără constanta μ .

ARIMA (1,1,0) = model autoregresiv cu diferente de ordinul întâi

(differenced first-order autoregressive model).

În cazul în care erorile obținute cu modelul mersului la întâmplare sunt autocorelate, se poate eventual rezolva problema prin adăugarea unei funcții a cărei variabilă este diferența dintre valorile variabilei dependente, cu o perioadă în urmă. Obținem următoarea ecuație de predicție:

$$\hat{x}_t - x_{t-1} = \mu + \phi(x_{t-1} - x_{t-2})$$

ecuație ce poate fi scrisă

$$\hat{x}_t = \mu + x_{t-1} + \phi(x_{t-1} - x_{t-2}),$$

unde constanta este notată cu μ și coeficientul autoregresiv cu ϕ .

ARIMA (0,1,1) fără constantă = *netezire* simplu exponențială

ARIMA (0,1,1) fără constantă = *netezire* simplu exponențială (modelul SES-simple exponential smoothing)

este un alt model utilizat pentru corectarea erorilor autocorelate din modelul mersului la întâmplare.

Pentru anumite serii temporale, utilizând modelul mersului la întâmplare nu se obțin rezultate la fel de bune cum ar fi cele obținute folosind media mobilă a valorilor trecute. *Spre exemplu* o serie ce prezintă fluctuații de zgomot în jurul unei medii ce variază lent.

Aceasta înseamnă că în loc de a folosi cea mai recentă observație pentru a prognoza următoarea observație este preferabilă utilizarea mediei ultimelor observații în scopul de a filtra zgomotul și a estima cu acuratețe media locală.

Ecuția de predicție a modelului este:

$$\hat{x}_t = x_{t-1} - \theta \cdot \varepsilon_{t-1},$$

unde ε_{t-1} este eroarea la momentul $t-1$, iar θ reprezintă coeficientul erorii de decalaj al prognozei și corespunde aceluși coeficientului $1 - \alpha$ din formula netezirii exponențiale.

ARIMA (0,1,1) cu constantă = *netezire* simplu exponențială cu creștere

Implementând netezirea simplu exponențială ca un model ARIMA, câștigăm o oarecare flexibilitate deoarece:

- In primul rând este acceptat un coeficient negativ, corespunzător unui factor de netezire supraunitar, care nu este acceptat în procedura de netezire exponențială.
- In al doilea rând aveți posibilitatea de a introduce un factor constant în modelul ARIMA, cu scopul de a estima un trend ce nu are media nulă.

ARIMA (0,1,1) cu constantă are următoarea ecuație de prognoză:

$$x_t = \mu + x_{t-1} - \theta \cdot \varepsilon_{t-1}$$

Traectoria prognozelor pe termen lung este o dreaptă de pantă μ , față de cazul netezirii exponențiale când este o linie orizontală.

ARIMA mixt (1, 1, 1).

Acest model are ecuația de prognoză:

$$x_t = \xi + x_{t-1} + \phi(x_{t-1} - x_{t-2}) + \theta \cdot \varepsilon_{t-1}$$

unde \hat{x}_t reprezintă prognoza pentru seria temporală la momentul t , μ este o constantă, ϕ este coeficientul de regresie, ε_{t-1} este eroarea la momentul t , iar θ reprezintă coeficientul erorii de decalaj al prognozei

Se observă clar mixarea celor două componente (autoregresivă și medie mobilă).

Uneori acest model poate duce la apariția fenomenului de *overfitting* al datelor și nu este exclus ca să nu obținem coeficienți unici.

11. Exemplu

Vom ilustra modelul de mai sus printr-o aplicație concretă privind un tratament clasic în bolile hepatice.

Considerăm studiul tratamentului cu interferon al hepatitei cronice *C*.

Astfel, vom fi interesați de prognoza evoluției stării unui pacient având hepatită cronică *C*, care a urmat un tratament standard de 6 luni cu interferon.

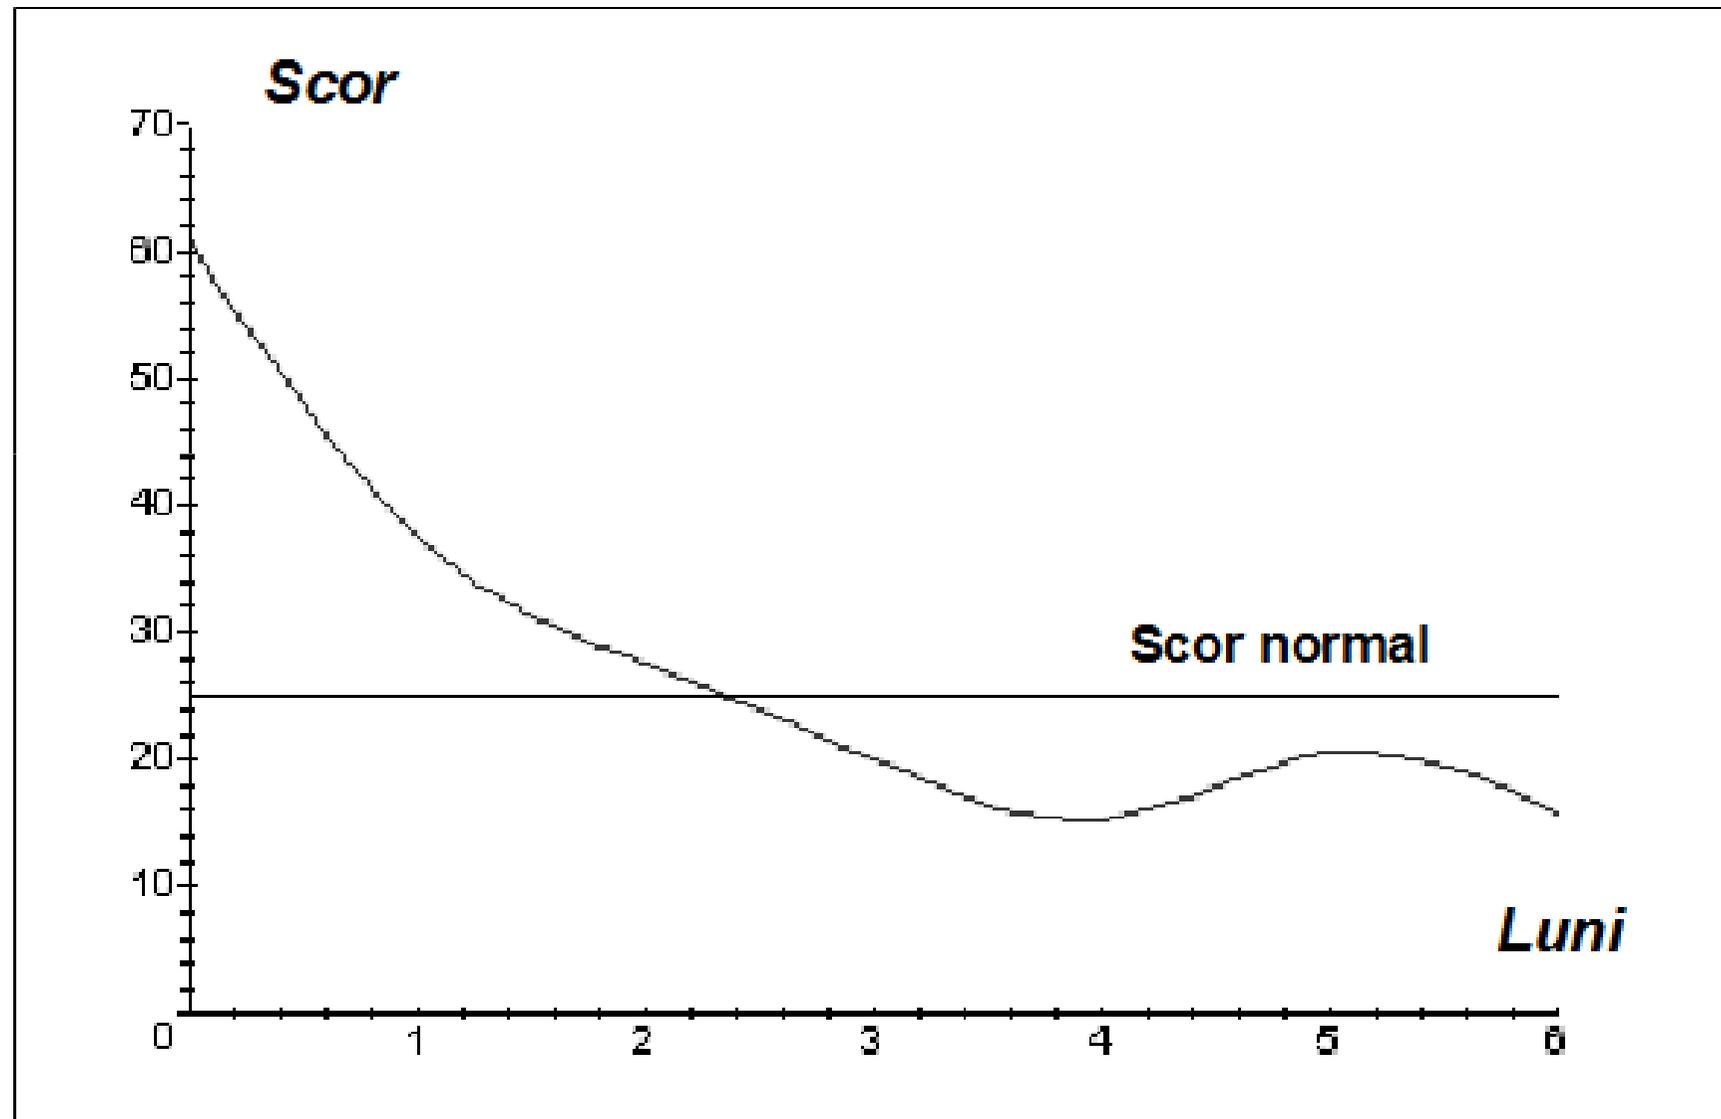
Importanța prognozei rezidă în faptul că, pe de-o parte tratamentul cu interferon este foarte costisitor și, pe de altă parte, o fracțiune deloc neglijabilă dintre pacienți nu răspund pozitiv la acest tratament, continuarea acestuia nefiind eficientă din toate punctele de vedere.

Din această cauză este importantă crearea unui model predictiv, suficient de sigur, care să prevadă comportamentul clinic al unui pacient în următoarele 3 – 6 luni, pentru a se decide astfel dacă este vorba de un așa-numit *responder*, adică un pacient cu răspuns pozitiv la tratament, sau un *non-responder*, adică un pacient cu răspuns negativ la tratament, pentru care continuarea tratamentului nu-și mai are rostul.

Pentru modelarea comportamentului clinic al pacienților a fost ales clasicul model *mixt ARIMA* de tipul (1, 1, 1).

Deoarece procesarea computerizată a acestui model, ca de altfel și gradul de încredere în prognoză, cere un număr relativ ridicat de date temporale (de la 20 în sus), a fost folosit procedeul de *interpolare B-spline cubică*, care induce curbe suficient de netede la noduri, fiind astfel compatibile cu procesul clinic asociat tratamentului. Pornind de la datele înregistrate în primele 6 luni, prin divizarea perioadei de timp respective și interpolarea nodurilor obținute, s-a creat baza de date suficientă pentru aplicarea modelului *ARIMA*.

Prezentăm mai jos graficul curbei de interpolare *B*-spline pentru scor, care reprezintă singura posibilitate de prognozare a evoluție stării de sănătate a unui pacient.



Plecând de la aceste date procesate prin interpolarea *B-spline*, prezentăm mai jos curba de prognoză *ARIMA* și intervalul de încredere (95%) corespunzător pentru următoarele 6 luni (săptămânile 25-49), privind comportamentul clinic virtual al unui pacient de tip responder.

