

Caracteristici numerice ale variabilelor aleatoare. Momente de selecție. Legea numerelor mari. Teoreme limită centrală

Ne propunem să prezentăm legăturile între constantele numerice caracteristice unei repartiții probabilistice date și cele corespunzătoare datelor de selecție.

1. Caracteristici numerice ale variabilelor aleatoare

În lucrările de laborator anterioare precizarea repartiției unei variabile aleatoare se realiza prin intermediul funcției de repartiție sau a densității de repartiție. Adesea, manipularea acestor funcții este dificilă; din acest motiv se preferă o descriere prin intermediul unor constante numerice numite momente. Pentru variabila aleatoare $\xi = \left(\begin{matrix} x_i \\ p_i = P[\xi = x_i] \end{matrix} \right), i = \overline{1, n}$, se definesc momentele:

Variabila aleatoare ξ	Momente absolute de ordin k	Momente centrate de ordin k
Discretă	$M[\xi^k] = \sum_{i=1}^n x_i^k p_i$	$M[(\xi - M[\xi])^k] = \sum_{i=1}^n (x_i - M[\xi])^k p_i$
Continuă	$M[\xi^k] = \int_{-\infty}^{+\infty} x^k f(x) dx$	$M[(\xi - M[\xi])^k] = \int_{-\infty}^{+\infty} (x - M[\xi])^k f(x) dx$

Observații:

1. pentru $k = 1$ $M[\xi]$ se numește media (speranța matematică) a variabilei ξ ;
2. pentru $k = 2$, momentul centrat de ordin doi $M[(\xi - M[\xi])^2] = \sigma^2 = D[\xi]$ se numește dispersia variabilei ξ , iar σ reprezintă abaterea medie pătratică a variabilei aleatoare ξ .

2. Momente de selecție. Legea numerelor mari. Teoreme limită centrală

Practic, atât funcțiile de repartiție cât și momentele sunt folosite pentru a caracteriza diferite populații statistice (colectivități statistice). Populațiile statistice nu pot fi investigate prin considerarea tuturor elementelor componente, ci doar prin intermediul unor "eșantioane statistice". Astfel, dată fiind o populație de N indivizi, în urma a n experimente independente se obțin rezultatele x_1, x_2, \dots, x_n , numite variabile de selecție. Pe baza acestor date poate fi definită distribuția în frecvențe a variabilei

aleatoare $\left(\begin{matrix} x_i \\ f_i \end{matrix} \right), i = \overline{1, n}$ unde $\sum_{i=1}^n f_i = 1$ și momentele de selecție:

- **momentul de selecție de ordin r:** $M_r = \sum_{i=1}^k f_i x_i^r$
- **media de selecție** $\bar{x} = \sum_{i=1}^k f_i x_i$
- **momentul centrat de selecție de ordin r** $m_r = \sum_{i=1}^k f_i (x_i - \bar{x})^r$
- **dispersia de selecție** $\bar{s}^2 = \sum_{i=1}^k f_i (x_i - \bar{x})^2$
- **abaterea medie pătratică** \bar{s}

Conform legii numerelor mari frecvențele relative converg către probabilitățile de apariție a aceluiași valori $f_i \xrightarrow[n \rightarrow \infty]{c.p.} p_i$, iar momentele de selecție sunt estimări ale momentelor probabilistice.

Exemplu: În cele ce urmează vom ilustra convergența frecvenței relative către probabilitate, și vom evidenția diferența între momentele teoretice și cele de selecție. Pentru aceasta vom alege o variabilă uniform distribuită, care caracterizează aruncarea cu zarul. Se aruncă un zar, dacă apare o față cu număr impar de puncte, vom câștiga o sumă egală cu numărul de puncte de pe față, în caz contrar vom pierde o sumă egală cu numărul par de puncte ale feței. Mai întâi se simulează jocul:

```
% program ZARURI
% simulează un joc în care câștigăm suma = nr. puncte de pe față
%impară și pierdem suma = nr. puncte de pe față pară apărută în urma
%unei aruncări
nr_ar=input('Numar aruncari : ');
cistig=0; freq=zeros(1,6); aport_face=zeros(1,6);
for i=1:nr_ar
    face=fix(6*rand)+1;
    freq(face)=freq(face)+1;
    rest=face-2*fix(face/2);
    if rest~=0,
        aport_face(face)=face;
    else
        aport_face(face)=-face;
    end
    cistig=cistig+aport_face(face);
end
freq_rel=zeros(1,6);
disp(' Fata Cistig Frecventa Frecventa relativa ');
for j=1:6
    freq_rel(j)=freq(j)/nr_ar;
    m=[j aport_face(j) freq(j) freq_rel(j)] ;
    disp(m);
end
disp('Cistig mediu ');
disp(sum(aport_face.*freq_rel));
disp(' ');
```

Programul tipărește frecvența absolută și relativă cu care apare fiecare față a zarului. În final se va afișa câștigul mediu. Pentru diferite numere de aruncări, rezultatele vor apărea astfel:

Fața	Câștig	Frecv. abs.	Frecv. relativă	Fața	Câștig	Frecv. abs.	Frecv. relativă
1	1	17	0.17	1	1	1681	0.1681
2	-2	17	0.17	2	-2	1678	0.1678
3	3	16	0.16	3	3	1626	0.1626
4	-4	18	0.18	4	-4	1696	0.1696
5	5	16	0.16	5	5	1686	0.1686
6	-6	16	0.16	6	-6	1633	0.1633

Nr aruncări=100
Câștig mediu= -0.57;

Nr aruncări=10.000
Câștig mediu= -0.4949;

Prima rulare ne sugerează că jocul este defavorabil. Ne punem problema cât de defavorabil este în realitate? A doua rulare oferă o imagine mai exactă. Se observă că frecvența relativă a fiecăreia din cele 6 fețe este foarte apropiată de $1/6=0.1666$ (corespunde interpretării frecvențiale a probabilității), adică frecvențele relative converg în probabilitate către probabilitățile de apariție a valorilor măsurate când volumul selecției tinde la infinit (pentru un număr de 10000 de aruncări frecvența relativă se apropie de valoarea de 0.16666, pe când în cazul unui număr de 100 de aruncări diferența este mai mare).

De asemeni, se sugerează că pentru un număr foarte mare de aruncări, câștigul mediu ar trebui să fie:

$$M = 1(1/6) - 2(1/6) + 3(1/6) - 4(1/6) + 5(1/6) - 6(1/6) = -0.5$$

iar dispersia:

$$D = (1 + 0.5)^2 * (1/6) + (-2 + 0.5)^2 * (1/6) + (3 + 0.5)^2 * (1/6) + (-4 + 0.5)^2 * (1/6) + (5 + 0.5)^2 * (1/6) = 14.9 \quad (\sigma = 3.87)$$

Pentru a determina dispersia de selecție vom folosi următorul tabel:

Câștig	(Câștig-câștig mediu)*Frecvența relativă
1	$(1+0.4949)^2 * 0.1681$
-2	$(-2+0.4949)^2 * 0.1678$
3	$(3+0.4949)^2 * 0.1626$
-4	$(-4+0.4949)^2 * 0.1696$
5	$(5+0.4949)^2 * 0.1686$
-6	$(-6+0.4949)^2 * 0.1633$

$$S^2 = \sum_{i=1}^6 (\text{Câștig-câștig mediu})^2 * \text{frecvența relativă} = 14.86 \Rightarrow S = 3.85$$

Exercițiu 1: Determinați, prin simulare, media și dispersia de selecție a unei variabile aleatoare repartizate uniform în intervalul $[0,1]$; comparați cu valorile teoretice $M = 0.5$ și $D = 1/12$.

Exercițiu 2: Determinați prin simulare media și dispersia de selecție a unei variabile aleatoare repartizate exponențial negativ; comparați cu valorile teoretice $M=1/l$ și $D = 1/l$.

Exercițiu 3: O problema tipică legată de repartiția exponențial negativă este problema "cozilor de așteptare". Presupunem sosirea clienților la o stație PECO, deservită de un singur vânzător la momente aleatoare de timp. Fiecare client este servit imediat dacă nu este nimeni înaintea sa; în caz contrar va trebui să aștepte deservirea clienților din fața sa. Se pune problema cât timp va trebui să aștepte fiecare client?

Se presupune că intervalele de timp între sosirile succesive ale clienților sunt variabilele aleatoare X_1, X_2, \dots, X_n ce sunt independente și identic exponențial distribuite, cu funcția de repartiție: $F_x(t)=1-e^{-lt}$, respectiv $f_x(t)=le^{-lt}$. Presupunem, de asemeni că timpul de deservire pentru fiecare client este definit prin variabilele aleatoare Y_1, Y_2, \dots, Y_n independente, identic exponențial distribuite, cu funcțiile de repartiție: $F_y(t)=1-e^{-mt}$ și $f_y(t)=me^{-mt}$. Ne așteptăm ca timpul petrecut de un client la coadă să depindă de numărul de clienți din față să și de timpul de deservire al fiecăruia. Scrieți un program ce simulează $N(t)=$ numărul de clienți la coadă la momentul t , pentru $t=0:100$ și $l=1$ și $m=0.9$; $l=1$ și $m=1$; $l=1$ și $m=1.1$.

Observație:

Se poate realiza simularea pornind de la programul BUS PARADOX din laboratorul 3. În reprezentarea grafică pentru $l < m$, $N(t)$ rămâne de dimensiune rezonabilă; iar în caz contrar $N(t)$ crește în mod nelimitat.

Vom defini: l = rata sosirilor; m = rata deservirii și intensitatea traficului: $r = \frac{\text{rata sosirilor}}{\text{rata deserviri}} = \frac{1}{m}$.

Pentru $r < 1$, definim lungimea cozii (numărul de clienți) ca o variabilă aleatoare Z , cu media finită: $M(Z) = N$. Timpul petrecut la coadă este de asemeni o variabilă aleatoare W , cu media: $M(W) = T$. Astfel, putem conchide că atunci când un client ajunge la coadă, el se așteaptă să găsească N persoane

înaintea sa, iar în momentul când părăsește coada, va lăsa lT persoane după el. La echilibru, aceste valori trebuie să fie egale: $N = lT$. Cunoscând media variabilei aleatoare $N(t)$, să se estimeze $T = N/l$, adică media timpului de așteptare.

După cum s-a observat din exemplele anterioare, mediile de selecție (statistice) tind să se apropie de mediile (sau momentele) teoretice (probabilistice).

O serie de teoreme arată condițiile în care o variabilă cu o anumită repartiție converge către repartiția normală sau condițiile în care efectul cumulat al acțiunii unor variabile aleatoare, independent de repartițiile lor, converg către un fenomen repartizat normal (v. curs).

În particular fie un proces aleator alcătuit din experimente succesive de tip binomial și x_i variabile aleatoare de selecție asociate încercării i . Se cunoaște că dacă variabila aleatoare x este repartizată binomial de parametri n și p și $S_n = x_1 + \dots + x_n$ este numărul de succese la cele n experimentări, atunci pentru $a < b$:

$$\lim_{n \rightarrow \infty} P\left(a < \frac{S_n - np}{\sqrt{npq}} < b\right) = \frac{1}{\sqrt{2\pi}} \int_a^b e^{-\frac{x^2}{2}} dx$$

Astfel, dacă variabila aleatoare x are o distribuție de medie $M[x]$ și abatere medie pătratică $\sigma[x] = \sqrt{D[x]}$, atunci media de selecție este o variabilă aleatoare, ce va tinde în probabilitate la o repartiție normală cu media $M[x]$ și dispersia $D[x]/n$.

Pentru repartiția binomială se pot determina analitic: $M_x = np$ și $D_x = npq$. Practic s-a observat că pentru: $np > 5$, $nq > 5$ (condiții îndeplinite simultan), unde: $q = 1 - p$ = probabilitatea de eșec într-o singură experimentare, variabilă x va tinde la o repartiție normală de parametri: $M_{normal} = np$ și $D_{normal} = npq$, dacă n este suficient de mare.

Exercițiu 4: Reprezentați densitatea de probabilitate binomială pentru $p = 0.25$, $k = 0, \dots, n$ și $n=3; 10; 30; 50$. Pentru fiecare din cele 4 grafice obținute, reprezentați și densitatea de probabilitate normală corespunzătoare. Poate fi aproximată repartiția binomială cu o repartiție normală? Pentru ce valori ale lui n ?

Exercițiu 5: Presupunem un experiment de tip Bernoulli, de aruncare a monezii. Să se determine, prin simulare, media și dispersia de selecție pentru $n = 20; 30; 40; 60; 100$ și să se compare cu valorile teoretice $M=np$, $D=npq$. Dacă rezultatele în urma efectuării a n aruncări sunt:

x_1, x_2, \dots, x_n , să se determine: $S_n = x_1 + x_2 + \dots + x_n$ și $S_n^* = (S_n - np) / \sqrt{n \cdot p \cdot q}$. Cum este repartizată variabila S_n^* ? Determinați experimental: $P[-k < S_n^* < k]$, unde $k=1, 2, 3, 4$, iar n și p sunt constante.

Exercițiu 6: Să se determine probabilitatea ca o variabilă aleatoare repartizată binomial, cu caracteristicile $p=0.2$, $n=100$, să se afle în intervalul $[2, 10]$. Se vor considera eşantioane statistice de dimensiuni $n = 10; 100; 250; 500$.