

O METODĂ DE STABILIRE A VOLUMULUI OPTIM PENTRU UN EŞANTION

ŞTEFAN ŞTEFĂNESCU

INTENȚII ȘI NOTAȚII

În această lucrare vom sugera utilizarea unei tehnici de simulare stocastică pe calculator pentru a stabili gradul de reprezentativitate al unui eșantion de volum dat ce va fi selectat aleator. Reprezentativitatea eșantionului va fi determinată în raport cu o caracteristică aleasă X a populației studiate. Se va estima probabilitatea ca valorile $h(X)$ să aparțină unui interval de încredere precizat, unde h este o funcție specificată (de exemplu media variabilei X). Prin procedeul de simulare propus poate fi determinat volumul optim al unui eșantion atunci când se cere o anume acuratețe rezultatelor.

În cadrul acestui studiu vom adopta următoarele **notații**:

Mulțimea $W \equiv \{w_1, w_2, w_3, \dots, w_m\}$ semnifică o populație cu m „indivizi” w_i , $1 \leq i \leq m$.

Prin p este desemnat un parametru (sau grup de parametri) ce caracterizează populația W .

Variabila X definește o caracteristică a populației studiate (de exemplu, vârstă, sex, studii, naționalitate etc.). În general, variabila X este asociată răspunsului dat de membrii populației W la o anumita întrebare din chestionar.

Valorile $x_1, x_2, x_3, \dots, x_{m-1}, x_m$ sunt realizările variabilei X . Astfel prin x_i , $1 \leq i \leq m$, vom desemna codul de răspuns la întrebarea X dat de cel de al i -lea individ al populației W .

Submulțimea $E \subset W$, $E \equiv \{e_1, e_2, e_3, \dots, e_{n-1}, e_n\}$ caracterizează un eșantion de volum n cu „indivizi” e_j , $1 \leq j \leq n$.

Valorile $x_1^{(k)}, x_2^{(k)}, x_3^{(k)}, \dots, x_{n-1}^{(k)}, x_n^{(k)}$ reprezintă codurile răspunsurilor la întrebarea X date de cei n indivizi ai eșantionului $E^{(k)} \subset W$. Dacă individul $e_j^{(k)}$ din eșantionul $E^{(k)}$, $1 \leq j \leq n$, este cel de al i -lea element w_i al populației W atunci, în mod evident avem $x_j^{(k)} = x_i$.

Variabila s reprezintă numărul de „simulații” ce sunt efectuate în procesul de estimare.

$p^{(k)}$ este o estimare a parametrului p , valoare ce este obținută numai prin utilizarea informației din eșantionul $E^{(k)}$.

Prin Λ_E este desemnată variabila (aleatoare) ale cărei realizări sunt estimăriile $p^{(k)}$ rezultate prin luarea în considerare a tuturor celor n eșantioanele $E^{(k)}$, $1 \leq k \leq v$, de volum n ce se pot alcătui cu cei m membri ai populației W .

Vom nota prin $q = q_{n,p,d}$ probabilitatea ca valorile $p^{(k)}$, $1 \leq k \leq n$, să aparțină intervalului $[p - d, p + d]$, d fiind un număr real, ales arbitrar.

EŞANTIONARE ŞI REPREZENTATIVITATE

Este cunoscut faptul că cei n „indivizi” e_1, e_2, \dots, e_n ai unui eșantion E , $E \subset W$, pot fi „aleși” în diferite moduri din cei m indivizi w_1, w_2, \dots, w_m ai populației W (a se vedea monografia lui Kish, 1963). În acest sens vom reaminti mai multe tehnici de eșantionare. Astfel, membrii e_j ai eșantionului E pot fi selectați din întreaga populație W după un algoritm determinist sau în mod aleator. În cazul unei selecții aleatoare evidențiem două posibile variante de obținere a eșantionului E : toate elementele din populația W au aceeași sansă de a fi alese, sau vom accepta probabilități diferite de selectare ce depind efectiv de fiecare element w_i , $1 \leq i \leq m$.

În funcție de tipurile de analize ce urmează a se desfășura, „indivizii” populației sunt grupați după anumite criterii (de exemplu, integrarea indivizilor pe gospodării). În acest context, elementele eșantionului pot fi astfel de grupe.

Din motive de eficiență, în practică se utilizează adesea divizarea populației pe „straturi”, caz în care eșantionarea se va desfășura diferențiat, separat pentru fiecare strat în parte. Rezultatele finale vor fi însă obținute prin ponderarea corespunzătoare a rezultatelor parțiale ce au fost inițial deduse pe straturi.

Pe lângă aceste proceduri, există și posibilitatea desfășurării gradate, pe etape, a procesului de eșantionare. Astfel, eșantionul inițial E_1 , de volum n_1 relativ mare, este obținut cu intenția depistării unei eventuale structurări în populația W (dacă se urmărește, de exemplu, repartizarea geografică a unor categorii). Intenționându-se utilizarea eșantionului E_1 într-o operațiune de „tatonare”, la selectarea elementelor sale nu vor fi alocate prea multe resurse. Ulterior vor fi obținute eșantioanele E_2, E_3, \dots de volume n_2, n_3 , respectiv n_3 , de regulă cu mult mai mici. Aceste eșantioane sunt însă „mai specializate”, alegerea elementelor lor fiind „direcționată” în raport cu scopul urmărit în cercetare.

Din categoria eșantioanelor nealeatoare remarcăm eșantioanele fixe (tip panel) sau acelea obținute prin procedura cotelor (a se vedea: Kish, 1963; Raj, 1968; Rotariu, Iluț, 1997).

În practică, în vederea asigurării unei eficiențe sporite a procedurii de selectare, la construcția unui eșantion se folosesc simultan mai multe tehnici de

eşantionare. Astfel, metodele aleatoare de selectare se vor îmbina cu procedee deterministe. Menţionăm în acest context eşantionarea aleatoare multistratificată folosită în studiul „Dimensiuni ale sărăciei” (Cătălin Zamfir, 1995, p. 12-14), caz în care sunt însă utilizate şi procedee nealeatoare. O asemenea modalitate este adesea întrebuinţată la construirea unui eşantion naţional (Rotariu, Iluţ, 1997, p. 148-152).

Eşantioanele E sunt construite în vederea studierii, cu un efort minim şi în timp util, a unei populaţii numeroase W , greu de inventariat în totalitate. Eşantionul E , ca submulţime a populaţiei W , $E \subset W$, va conţine însă o informaţie trunchiată în raport cu populaţia W . Aşadar, aprecierea comportamentului întregii populaţii W pe baza informaţiei prezente în eşantionul E va fi supusă unor erori mai mari sau mai mici.

În această situaţie, problema principală constă în a aprecia, cât mai exact posibil, mărimea acestor erori. Erorile depind, în mod evident, de algoritmul concret folosit la selectarea elementelor eşantionului, ca şi de volumul acestuia. Dimensiunea erorilor defineşte gradul de reprezentativitate al eşantionului respectiv.

Pentru a putea fi măsurat, gradul de reprezentativitate al eşantionului E se stabileşte în raport cu o caracteristică aleasă X (sau un grup de caracteristici) a populaţiei W . Exprimarea riguroasă, prin formule, a gradului de reprezentativitate al lui E este soluţionată din punct de vedere teoretic pentru principalele procedee de alegere a eşantionului. De multe ori însă, sunt precizate formule aproximative ce au rezultat prin impunerea unor condiţii suplimentare, adesea simplificatoare. Chiar şi în această ultimă situaţie se poate ajunge la expresii complicate, impuse în fond de complexitatea algoritmilor stocastici şi determiniştici ce intervin la selectarea elementelor eşantionului în cauză. În plus, evaluarea efectivă a formulelor deduse este greoai din punct de vedere tehnic datorită multiplelor relaţii de natură combinatorială, cât şi datorită termenilor aleatori ce intervin în respectiva formulă.

În cazul în care la obţinerea unui eşantion E sunt folosite combinat mai multe procedee de selecţie, practic este imposibil de a stabili din punct de vedere teoretic formule exacte care să măsoare gradul de reprezentativitate al lui E .

În cele ce urmează vom estima gradul de reprezentativitate al eşantionului E de volum n utilizând pentru aceasta o tehnică de simulare stocastică. O astfel de procedură este deosebit de flexibilă, putând fi adaptată cu uşurinţă diverselor metode concrete, unele sofisticate, de selectare a eşantionului E .

Numai cu un simplu efort de programare pe calculator, fără a se interveni efectiv „în teren”, pot fi făcute analize utile privind tehnica de eşantionare ce trebuie adoptată. În plus, pentru orice metodă de selectare fixată, comparând rezultatele simulărilor efectuate cu eşantioane de diferite volume, se

va putea stabili în final dimensiunea optimă a eșantionului ce va trebui construit într-o situație concretă.

SOLUȚIONAREA UNEI PROBLEME CONCRETE

Vom ilustra aspectele amintite pe un exemplu ce apare adesea în practică, anume eșantionul simplu aleator.

Așadar vom accepta :

Ipoteza 1. Cele n elemente e_1, e_2, \dots, e_n ale eșantionului E sunt n „indivizi” din populația W (și nu „grupuri” de indivizi). Elementele lui E sunt alese în mod aleator din populația $W \equiv \{w_1, w_2, \dots, w_m\}$, fiecare dintre acestea având aceeași sansă de a fi selectate (nici un individ w_i , $1 \leq i \leq m$, nu este privilegiat).

În final, va trebui să stabilim reprezentativitatea eșantionului E în raport cu o caracteristică X a populației W . Pentru simplificarea expunerii vom presupune:

Ipoteza 2. Variabila X este o variabilă dihotomică (binomială) ce ia valorile 1 („da”) sau 0 („nu”). În plus, volumul m al populației este considerat finit, eventual foarte mare.

Vom nota prin p probabilitatea de a obține un răspuns afirmativ la întrebarea X presupunând ca au fost intervievați toți membrii populației W .

Cu notațiile anterioare, știind răspunsul x_i dat de individul w_i la „întrebarea” X avem

$$p = [x_1 + x_2 + x_3 + \dots + x_{m-1} + x_m] / m \quad (1)$$

În practică suntem în imposibilitate de a trece în revistă răspunsurile la întrebarea X a tuturor membrilor populației W . Așadar, evaluarea numărului de răspunsuri affirmative 1 din populația W nu poate fi realizată prin intermediul formulei (1).

De fapt, populația W depinde de parametrul p ce trebuie însă estimat utilizându-se numai informația deținută în eșantionul E . Acest aspect ar putea fi generalizat, în locul parametrului p considerându-se o mulțime de astfel de parametri.

Având răspunsurile $x_1^{(E)}, x_2^{(E)}, \dots, x_n^{(E)}$ la întrebarea X pentru cei n membri ai eșantionului E , atunci parametrul p va fi estimat de valoarea

$$p^{(E)} = [x_1^{(E)} + x_2^{(E)} + x_3^{(E)} + \dots + x_{n-1}^{(E)} + x_n^{(E)}] / n \quad (2)$$

Prezența în eșantionul E a unei informații „trunchiate” în raport cu răspunsul efectiv al tuturor membrilor populației W la întrebarea X , va antrena în mod obligatoriu apariția unei erori ε măsurată prin „diferența de răspuns” dintre populația W și eșantionul E , adică

$$\varepsilon^{(E)} = | p - p^{(E)} | \quad (3)$$

Gradul de „reprezentativitate” al eșantionului E de volum n ar putea fi stabilit în raport cu mărimea erorii ε .

Problema nu poate fi însă abordată în această manieră deoarece practic cantitatea p nu este cunoscută, efectiv fiind dedusă numai valoarea $p^{(E)}$.

În plus, considerând un alt eșantion $E^{(k)}$ de același volum n , cu răspunsurile $x_1^{(k)}, x_2^{(k)}, \dots$, respectiv $x_n^{(k)}$, la întrebarea X , vom obține o alta estimăție $p^{(k)}$ a parametrului necunoscut p , unde evident

$$p^{(k)} = [x_1^{(k)} + x_2^{(k)} + x_3^{(k)} + \dots + x_{n-1}^{(k)} + x_n^{(k)}] / n \quad (4)$$

eroarea estimării fiind de această dată $\varepsilon^{(k)}$,

$$\varepsilon^{(k)} = |p - p^{(k)}| \quad (5)$$

Presupunând că avem posibilitatea de a enumera efectiv toate cele v eșantioane $E^{(k)}$ de volum n , $1 \leq k \leq v$, ce se pot construi cu cei m indivizi ai populației W , prin procedura descrisă vom obține v estimății (diferite) $p^{(k)}$, $1 \leq k \leq v$, fiecare dintre acestea sugerând o posibilă valoare pentru parametrul p .

Așadar vom aprecia gradul de reprezentativitate al eșantioanelor E de volum n prin repartitia valorilor $e^{(k)}$, $1 \leq k \leq v$.

Precizarea repartitiei valorilor $e^{(k)}$, $1 \leq k \leq v$, este imposibil de realizat în realitate, fiind mult mai ușor de a se opera cu probabilitățile $q = q_{n,p,d}$ determinate astfel ca valorile $p^{(k)}$, $1 \leq k \leq v$, să aparțină unui interval $[p - d, p + d]$ precizat anterior. Capetele acestui interval sunt alese arbitrar prin specificarea numărului real d .

Formalizând, dacă vom desemna prin Λ_E variabila (aleatoare) ale cărei realizări sunt cele n estimății $p^{(k)}$ rezultate prin luarea în considerare a tuturor eșantioanelor $E^{(k)}$, $1 \leq k \leq v$, de volum n ce se pot alcătui cu cei m membri ai populației W , atunci.

$$q = q_{n,p,d} = \Pr(\Lambda_E \in [p - d, p + d]) \quad (6)$$

Prin urmare, reprezentativitatea eșantioanelor E de volum n va fi dictată de sirul de probabilități $q_{n,p,d}$, sir indexat după indicii p și d (volumul n este presupus fix).

În literatura de specialitate probabilitățile $q_{n,p,d}$ au fost efectiv calculate în cazul unor proceduri simple de alegere a membrilor eșantionului. În situația combinării diverselor proceduri de selectare (metode aleatoare utilizate împreună cu metode deterministe), nu au fost deduse formule exacte ce dau valorile probabilităților $q_{n,p,d}$. În plus, determinarea valorilor $q_{n,p,d}$ presupune utilizarea unui aparat matematic sofisticat.

Toate aceste neajunsuri pot fi înlăturate prin aplicarea unei tehnici de simulare stocastică pe calculator, fapt ce va fi explicitat în continuare.

Menționăm că analiza prezentată poate fi preluată fără modificări în cazul unei populații infinite.

PROCEDURA DE SIMULARE

Pentru înțelegerea detaliată a problematicii simulării stocastice recomandăm parcursarea cărții „Stochastic modelling” (Nelson, 1995), unde tratarea multiplelor aspecte se face mai mult din punct de vedere practic, cu multe exemple.

În prezenta lucrare nu vom intra în detalii tehnice. Vom urmări să sugerăm modul intuitiv în care se realizează efectiv algoritmul de simulare. În final vom face o analiză a rezultatelor simulărilor și vom trage anumite concluzii ce sunt valabile și pentru alte tipuri de eșantioane.

În cazul unei populații W numeroase este practic imposibilă enumerarea tuturor celor n eșantioane $E^{(k)}$, $1 \leq k \leq v$, de volum n , aceasta în vederea estimării probabilităților $q_{n,p,d}$. De regulă, valoarea v este „astronomică” (v reprezintă combinări de m obiecte luate câte n).

Această dificultate va fi înălțatată luând în considerare numai s astfel de eșantioane, unde s este de regulă ales mult mai mic decât v . În noua situație, probabilitatea reală $q_{n,p,d}$ va fi estimată prin valoarea $q^{(s)} = q_{n,p,d}^{(s)}$ considerându-se numai cele s realizări $p^{(1)}, p^{(2)}, \dots, p^{(s)}$ ale variabilei Λ_E , adică

$$q^{(s)} = q_{n,p,d}^{(s)} = \mu / s \quad (7)$$

unde μ este numărul de cazuri în care valorile $p^{(1)}, p^{(2)}, \dots, p^{(s)}$ aparțin intervalului $[p - d, p + d]$.

Formula (7) s-a obținut aproximând probabilitatea $q_{n,p,d} = \Pr(p - d \leq \Lambda_E \leq p + d)$ prin raportul $q^{(s)} = \mu / s$ dintre numărul m de „cazuri favorabile” și numărul s de „cazuri posibile” (rezultat clasic ce apare în următoarele lucrări: Iosifescu, s.a., 1985; Klimov, 1986; Koroliouk, s.a., 1983; Popoulis, 1990).

În concluzie, algoritmul AS de obținere a estimării $q^{(s)}$ (formula (7)) a probabilității q (formula (6)) și care utilizează s pași de simulare, are următoarea structură :

Algoritmul AS (simulare stocastică).

Pas 0. Precizează valorile parametrilor : m, n, p, d, s .

Pas 1. Luând în considerare populația W se generează s eșantioane $E^{(1)}, E^{(2)}, \dots, E^{(s)}$ (simplu)

aleatoare, toate având același volum n .

Pas 2. Se calculează estimările $p^{(1)}, p^{(2)}, \dots, p^{(s)}$ după formula (4).

Pas 3. Evaluează numărul μ , adică, câte valori $p^{(1)}, p^{(2)}, \dots, p^{(s)}$ aparțin intervalului $[p - d, p + d]$.

Pas 4. Se estimează $q^{(s)}$ utilizându-se relația $q^{(s)} = \mu / s$ (formula (7)).

Pas 5. Se editează valoarea estimată $q^{(s)}$.

Valorile $q^{(s)}$ astfel obținute vor caracteriza gradul de reprezentativitate al eșantioanelor E de volum n (ce sunt selectate simplu aleator dintr-o populație W cu m „indivizi”).

Remarcă. Pentru generarea eșantioanelor (simplu) aleatoare (Pasul 1 al algoritmului AS), ca și pentru obținerea estimației $q^{(s)}$ se poate folosi produsul soft SPSS sau se poate scrie algoritmul AS folosind orice alt limbaj de programare (de exemplu limbajul BASIC). Pentru această lucrare am preferat scrierea algoritmului AS în limbajul PASCAL .

Menționăm faptul că limbajele de programare (ca și SPSS-ul) au subroutines specializate în generarea de valori aleatoare (uniform repartizate pe intervalul $[0, 1]$).

ANALIZA REZULTATELOR SIMULĂRII

Formula (7) poate fi rescrisă și interpretată în sensul

$$q = q_{n,p,d} = \Pr(p^{(E)} - d \leq p \leq p^{(E)} + d) \quad (8)$$

unde $p^{(E)}$ este o estimare a răspunsurilor populației W considerându-se eșantioane E de volum n (a se vedea formula (2)).

Pentru orice eșantion E de volum n din populația W putem calcula exact modul de răspuns $p^{(E)}$ al indivizilor eșantionului la întrebarea X. Aproximând probabilitatea q prin valoarea $q^{(s)}$ dată de algoritmul AS, din formula (8) rezultă

$$q^{(s)} \approx \Pr(p^{(E)} - d \leq p \leq p^{(E)} + d) \quad (9)$$

Așadar, cu o șansă de (aproximativ) $q^{(s)}$ procente, indicatorul p al răspunsurilor affirmative la întrebarea X la nivelul întregii populații W se încadrează în intervalul $[p^{(E)} - d, p^{(E)} + d]$, interval ce este de această dată cunoscut.

Cum X este o variabilă dihotomică a cărei medie Med (X) este chiar p, reinterpretăm formula (9) în sensul

$$q^{(s)} \approx \Pr(p^{(E)} - d \leq \text{Med}(X) \leq p^{(E)} + d) \quad (10)$$

estimația $q^{(s)}$ fiind produsă de algoritmul AS .

În plus, valoarea $p^{(E)}$ poate fi privită ca medie a răspunsurilor la întrebarea X, răspunsuri colectate numai de la indivizii eșantionului E. Deci $p^{(E)}$ este „media pe eșantion” în raport cu caracteristica X.

Prin rularea algoritmului AS s-au obținut rezultatele precizate în Tabelele 1-4. În acest context s-au efectuat 30.000 de simulări pentru eșantioane de diverse volume n, $n \in \{100, 400, 700, 1000, 1300, 1600\}$, și diferite caracteristici X, $p \in \{0,05, 0,1, 0,2, \dots, 0,9, 0,95\}$. Intervalul de încredere are lungimea 2 d, variabila $d \in \{0,005, 0,025\}$, fapt ce semnifică „precizii” diferite atribuite rezultatelor.

Studiul a fost făcut pentru populații cu un număr variabil de indivizi, $m \in \{50.000, 1.000.000\}$.

Comparând Tabelele 1 și 2, respectiv Tabelele 3 și 4, concludem că o mărire semnificativă a populației (de 20 de ori, adică o creștere de la 50.000 de persoane la 1.000.000 de persoane) nu antrenează o creștere palpabilă a gradului de reprezentativitate a diverselor eșantioane (ale căror volume variază). Eșantioanele studiate se raportează la caracteristici X distincte (diferite valori ale parametrului p).

Cum era și de așteptat, o mărire a preciziei estimării (micșorarea intervalului de încredere $[p - d, p + d]$) se realizează printr-o micșorare a șansei de apartenență la intervalul respectiv (adică o creștere a riscului de neapartenență la intervalul de încredere). Acest lucru reiese experimental comparând Tabelele 1 cu 3, respectiv din analizarea concomitenta a Tabelelor 2 și 4.

În plus, mărirea volumului eșantionului E antrenează în mod obligatoriu o creștere a reprezentativității sale.

Astfel, pentru fiecare linie a oricărui Tabel 1-4, sirul probabilităților $q^{(s)} = q_{n,p,d}^{(s)}$ este crescător în raport cu n . Trebuie precizat faptul că valorile estimării $q_{n,p,d}^{(s)}$ ce se regăsesc pe aceeași linie a unuia dintre Tabelele 1-4 au parametrii p și d menținuți constanți. Poziționarea elementelor $q_{n,p,d}^{(s)}$ în cadrul unei linii fixate din Tabelele 1-4 este dictată de indicele n (ce reprezintă volumul eșantionului E).

Tabelul nr.1

Estimăția experimentală $q_{n,p,d}^{(s)}$ a probabilității ca media pe eșantion în raport cu caracteristica X să aparțină intervalului $[p - 0,025, p + 0,025]$, pentru eșantioane de diferite volume n ($s = 30000$, $m = 1000000$, $d = 0,025$)

p	$n = 100$	$n = 400$	$n = 700$	$n = 1000$	$n = 1300$	$n = 1600$
0,050	0,7533	0,9786	0,9972	0,9996	0,9999	1,0000
0,100	0,5945	0,9036	0,9724	0,9917	0,9974	0,9991
0,200	0,4659	0,7833	0,9010	0,9511	0,9752	0,9859
0,300	0,4200	0,7293	0,8523	0,9171	0,9521	0,9723
0,400	0,3870	0,6927	0,8251	0,8947	0,9345	0,9587
0,500	0,3835	0,6986	0,8124	0,8896	0,9272	0,9560
0,600	0,3899	0,6886	0,8210	0,8906	0,9319	0,9571
0,700	0,4156	0,7213	0,8490	0,9150	0,9506	0,9701
0,800	0,4671	0,7918	0,9047	0,9522	0,9751	0,9871
0,900	0,5899	0,9034	0,9723	0,9917	0,9972	0,9992
0,950	0,7536	0,9778	0,9975	0,9997	1,0000	1,0000

Tabelul nr. 2

Estimația experimentală $q_{n,p,d}^{(s)}$ a probabilității ca media pe eșantion în raport cu caracteristica X să aparțină intervalului $[p - 0,025, p + 0,025]$ pentru eșantioane de diferite volume n ($s = 30000$, $m = 50000$, $d = 0,025$).

p	n = 100	n = 400	n = 700	n = 1000	n = 1300	n = 1600
0,050	0,7521	0,9778	0,9972	0,9997	0,9999	1,0000
0,100	0,5993	0,9033	0,9732	0,9926	0,9977	0,9994
0,200	0,4721	0,7860	0,9014	0,9523	0,9760	0,9875
0,300	0,4143	0,7288	0,8505	0,9151	0,9502	0,9699
0,400	0,3908	0,6888	0,8220	0,8953	0,9351	0,9592
0,500	0,3853	0,7085	0,8177	0,8918	0,9284	0,9574
0,600	0,3879	0,6886	0,8228	0,8935	0,9341	0,9582
0,700	0,4194	0,7229	0,8501	0,9174	0,9503	0,9702
0,800	0,4666	0,7875	0,8992	0,9512	0,9761	0,9883
0,900	0,5922	0,8996	0,9722	0,9920	0,9976	0,9994
0,950	0,7568	0,9799	0,9974	0,9998	0,9999	1,0000

Tabelul nr.3

Estimația experimentală $q_{n,p,d}^{(s)}$ a probabilității ca media pe eșantion în raport cu caracteristica X să aparțină intervalului $[p - 0,005, p + 0,005]$ pentru eșantioane de diferite volume n ($s = 30000$, $m = 1000000$, $d = 0,005$).

p	n = 100	n = 400	n = 700	n = 1000	n = 1300	n = 1600
0,050	0,1816	0,3486	0,4490	0,5285	0,5909	0,6336
0,100	0,1301	0,2594	0,3398	0,3951	0,4493	0,4957
0,200	0,0997	0,1959	0,2562	0,3072	0,3451	0,3845
0,300	0,0880	0,1755	0,2285	0,2724	0,3077	0,3403
0,400	0,0823	0,1598	0,2153	0,2553	0,2892	0,3210
0,500	0,0785	0,1942	0,2054	0,2725	0,2877	0,3323
0,600	0,0812	0,1635	0,2127	0,2478	0,2870	0,3215
0,700	0,0879	0,1726	0,2310	0,2691	0,3083	0,3405
0,800	0,1021	0,1975	0,2629	0,3089	0,3450	0,3855
0,900	0,1292	0,2562	0,3389	0,4000	0,4540	0,4920
0,950	0,1780	0,3457	0,4538	0,5266	0,5897	0,6377

Tabelul nr.4

Estimația experimentală $q_{n,p,d}^{(s)}$ a probabilității ca media pe eșantion în raport cu caracteristica X să aparțină intervalului $[p - 0,005, p + 0,005]$ pentru eșantioane de diferite volume n ($s = 30000, m = 50000, d = 0,005$).

p	n = 100	n = 400	n = 700	n = 1000	n = 1300	n = 1600
0,050	0,1831	0,3502	0,4600	0,5310	0,5886	0,6369
0,100	0,1303	0,2614	0,3418	0,4006	0,4527	0,4958
0,200	0,0969	0,1941	0,2609	0,3078	0,3486	0,3897
0,300	0,0854	0,1717	0,2242	0,2658	0,3039	0,3365
0,400	0,0855	0,1625	0,2096	0,2532	0,2843	0,3123
0,500	0,0796	0,1975	0,2036	0,2698	0,2816	0,3280
0,600	0,0778	0,1621	0,2150	0,2542	0,2881	0,3165
0,700	0,0887	0,1709	0,2280	0,2684	0,3027	0,3395
0,800	0,0971	0,1964	0,2610	0,3017	0,3502	0,3853
0,900	0,1339	0,2604	0,3372	0,4008	0,4524	0,4953
0,950	0,1802	0,3454	0,4528	0,5252	0,5894	0,6350

Remarcă. Datorită dihotomiei caracteristicii X avem o „simetrie” a rezultatelor în raport cu valorile luate de parametrul p. Astfel, răspunsurile affirmative la întrebarea X sintetizate prin valoarea p pot fi interpretate ca răspunsuri negative la aceeași întrebarea X unde, de această dată, s-a considerat $1 - p$ drept parametru. Această observație poate fi validată urmărind efectiv rezultatele din Tabelele 1-4. Astfel se constată că $q_{n,p,d}^{(s)} \approx q_{n,1-p,d}^{(s)}$.

Utilizarea algoritmului AS permite obținerea unor tabele cu estimările probabilităților $q_{n,p,d}$ în raport cu orice valori ale parametrilor n, p, d, fapt ilustrat prin Tabelele 5 și 6. Asemenea tabele definesc de fapt gradul de reprezentativitate al unui eșantion E în raport cu cei trei parametri n, p, d.

Tabelele 5 și 6 permit stabilirea volumului n al eșantionului E pentru o probabilitate $q_{n,p,d}$ data, valorile parametrilor p și d fiind presupuse cunoscute.

Prin urmare, utilizarea unor tabele de tipul Tabelelor 5 și 6 conduce la o dimensionare optimă a volumului unui eșantion E, în ipoteza unui grad de reprezentativitate acceptat.

Tabelul nr.5

Listarea perechilor de valori $q_{n,p,d}^{(s)}(n)$, unde la calculul valorii $q_{n,p,dS(s)}$ s-au utilizat $s = 100.000$ eșantioane E de volum n (eșantioanele E sunt extrase aleator dintr-o populație cu $m = 2.000.000$ indivizi; $p = 0,05$, $d = 0,01$).

0,2181 (50); 0,3294 (100); 0,4077 (150); 0,4690 (200); 0,5206 (250); 0,5637 (300); 0,6004 (350); 0,6345 (400); 0,6628 (450); 0,6868 (500); 0,7120 (550); 0,7345 (600); 0,7544 (650); 0,7734 (700); 0,7896 (750); 0,8049 (800); 0,8183 (850); 0,8291 (900); 0,8413 (950); 0,8517 (1000); 0,8624 (1050); 0,8722 (1100); 0,8809 (1150); 0,8890 (1200); 0,8960 (1250); 0,9031 (1300); 0,9088 (1350); 0,9155 (1400); 0,9210 (1450); 0,9262 (1500); 0,9307 (1550); 0,9349 (1600); 0,9392 (1650); 0,9427 (1700); 0,9458 (1750); 0,9492 (1800); 0,9520 (1850); 0,9556 (1900); 0,9587 (1950); 0,9607 (2000); 0,9616 (2050); 0,9641 (2100); 0,9661 (2150); 0,9674 (2200); 0,9698 (2250); 0,9715 (2300); 0,9735 (2350); 0,9752 (2400); 0,9769 (2450); 0,9779 (2500); 0,9793 (2550); 0,9804 (2600); 0,9815 (2650); 0,9826 (2700); 0,9837 (2750); 0,9848 (2800); 0,9857 (2850); 0,9864 (2900); 0,9873 (2950); 0,9876 (3000); 0,9885 (3050); 0,9890 (3100); 0,9897 (3150); 0,9901 (3200); 0,9903 (3250); 0,9909 (3300); 0,9915 (3350); 0,9923 (3400); 0,9928 (3450); 0,9931 (3500); 0,9934 (3550); 0,9937 (3600); 0,9942 (3650); 0,9946 (3700); 0,9947 (3750); 0,9950 (3800); 0,9953 (3850); 0,9955 (3900); 0,9958 (3950); 0,9961 (4000); 0,9968 (4050); 0,9971 (4100); 0,9972 (4150); 0,9974 (4200); 0,9975 (4250); 0,9975 (4300); 0,9977 (4350); 0,9978 (4400); 0,9978 (4450); 0,9980 (4500); 0,9982 (4550); 0,9983 (4600); 0,9984 (4650); 0,9985 (4700); 0,9986 (4750); 0,9986 (4800); 0,9986 (4850); 0,9987 (4900); 0,9987 (4950); 0,9988 (5000); 0,9993 (5500); 0,9997 (6000);
--

Tabelul nr.6

Listarea perechilor de valori $q_{n,p,d}^{(s)}(n)$, unde la calculul valorii $q_{n,p,d}^{(s)}$ s-au utilizat $s = 100.000$ eșantioane E de volum n (eșantioanele E sunt extrase aleator dintr-o populație cu $m = 2.000.000$ indivizi; $p \in \{0,05, 0,10, 0,15, \dots, 0,45, 0,50\}$, $d = 0,02$).

6.a p = 0,05

0,6153 (100); 0,7994 (200); 0,8875 (300); 0,9349 (400); 0,9610 (500); 0,9767 (600); 0,9855 (700); 0,9907 (800); 0,9943 (900); 0,9963 (1000); 0,9977 (1100); 0,9983 (1200); 0,9990 (1300); 0,9993 (1400); 0,9997 (1500); 0,9998 (1600); 0,9999 (1700); 0,9999 (1800); 0,9999 (1900); 1,0000 (2000); 1,0000 (2100); 1,0000 (2200); 1,0000 (2300);

6.b p = 0,10

0,4771 (100); 0,6460 (200); 0,7474 (300); 0,8133 (400); 0,8606 (500); 0,8960 (600); 0,9227 (700); 0,9408 (800); 0,9556 (900); 0,9649 (1000); 0,9730 (1100); 0,9799 (1200); 0,9840 (1300); 0,9876 (1400); 0,9902 (1500); 0,9925 (1600); 0,9941 (1700); 0,9956 (1800); 0,9960 (1900); 0,9969 (2000); 0,9977 (2100); 0,9979 (2200); 0,9984 (2300); 0,9986 (2400); 0,9989 (2500); 0,9992 (2600); 0,9994 (2700); 0,9995 (2800); 0,9995 (2900); 0,9997 (3000); 0,9998 (3100); 0,9998 (3200); 0,9999 (3300); 0,9999 (3400); 0,9999 (3500); 0,9999 (3600); 0,9999 (3700); 0,9999 (3800); 0,9999 (3900); 1,0000 (4000); 1,0000 (4100); 1,0000 (4200); 1,0000 (4300);

6.c p = 0,15

0,4202 (100); 0,5671 (200); 0,6637 (300); 0,7332 (400); 0,7889 (500);
 0,8297 (600); 0,8610 (700); 0,8864 (800); 0,9058 (900); 0,9217 (1000);
 0,9367 (1100); 0,9478 (1200); 0,9571 (1300); 0,9644 (1400); 0,9698 (1500); 0,9752 (1600);
 0,9789 (1700); 0,9826 (1800); 0,9858 (1900); 0,9882 (2000); 0,9898 (2100); 0,9914 (2200);
 0,9928 (2300); 0,9940 (2400); 0,9952 (2500); 0,9959 (2600); 0,9969 (2700); 0,9972 (2800);
 0,9979 (2900); 0,9981 (3000);
 0,9981 (3100); 0,9985 (3200); 0,9987 (3300); 0,9989 (3400); 0,9991 (3500);
 0,9992 (3600); 0,9993 (3700); 0,9993 (3800); 0,9995 (3900); 0,9995 (4000);
 0,9997 (4100); 0,9997 (4200); 0,9998 (4300); 0,9998 (4400); 0,9998 (4500);

6.d p = 0,20

0,3762 (100); 0,5156 (200); 0,6114 (300); 0,6815 (400); 0,7349 (500);
 0,7780 (600); 0,8134 (700); 0,8403 (800); 0,8655 (900); 0,8864 (1000);
 0,9024 (1100); 0,9149 (1200); 0,9281 (1300); 0,9377 (1400); 0,9465 (1500); 0,9536 (1600);
 0,9603 (1700); 0,9650 (1800); 0,9696 (1900); 0,9739 (2000); 0,9776 (2100); 0,9802 (2200);
 0,9832 (2300); 0,9852 (2400); 0,9873 (2500); 0,9891 (2600); 0,9907 (2700); 0,9920 (2800);
 0,9930 (2900); 0,9940 (3000);
 0,9946 (3100); 0,9952 (3200); 0,9959 (3300); 0,9964 (3400); 0,9968 (3500);
 0,9974 (3600); 0,9978 (3700); 0,9980 (3800); 0,9983 (3900); 0,9986 (4000);
 0,9985 (4100); 0,9987 (4200); 0,9990 (4300); 0,9991 (4400); 0,9992 (4500);

6.e p = 0,25

0,4357 (100); 0,5365 (200); 0,6128 (300); 0,6740 (400); 0,7227 (500);
 0,7606 (600); 0,7935 (700); 0,8228 (800); 0,8470 (900); 0,8649 (1000);
 0,8822 (1100); 0,8977 (1200); 0,9106 (1300); 0,9213 (1400); 0,9305 (1500); 0,9379 (1600);
 0,9459 (1700); 0,9528 (1800); 0,9575 (1900); 0,9624 (2000); 0,9667 (2100); 0,9702 (2200);
 0,9739 (2300); 0,9774 (2400); 0,9798 (2500); 0,9825 (2600); 0,9843 (2700); 0,9860 (2800);
 0,9875 (2900); 0,9891 (3000);
 0,9902 (3100); 0,9913 (3200); 0,9922 (3300); 0,9928 (3400); 0,9940 (3500);
 0,9944 (3600); 0,9950 (3700); 0,9956 (3800); 0,9960 (3900); 0,9964 (4000);
 0,9970 (4100); 0,9974 (4200); 0,9977 (4300); 0,9980 (4400); 0,9982 (4500);

6.f p = 0,30

0,3339 (100); 0,4576 (200); 0,5467 (300); 0,6144 (400); 0,6677 (500);
 0,7140 (600); 0,7504 (700); 0,7826 (800); 0,8088 (900); 0,8319 (1000);
 0,8511 (1100); 0,8685 (1200); 0,8835 (1300); 0,8967 (1400); 0,9086 (1500); 0,9197 (1600);
 0,9281 (1700); 0,9359 (1800); 0,9433 (1900); 0,9496 (2000); 0,9548 (2100); 0,9600 (2200);
 0,9636 (2300); 0,9671 (2400); 0,9709 (2500); 0,9739 (2600); 0,9767 (2700); 0,9793 (2800);
 0,9814 (2900); 0,9832 (3000);
 0,9847 (3100); 0,9861 (3200); 0,9875 (3300); 0,9889 (3400); 0,9902 (3500);
 0,9913 (3600); 0,9922 (3700); 0,9931 (3800); 0,9937 (3900); 0,9946 (4000);
 0,9950 (4100); 0,9954 (4200); 0,9958 (4300); 0,9962 (4400); 0,9966 (4500);

6.g p = 0,35

0,3256 (100); 0,4458 (200); 0,5320 (300); 0,6003 (400); 0,6505 (500);
0,6969 (600); 0,7320 (700); 0,7630 (800); 0,7911 (900); 0,8130 (1000);
0,8352 (1100); 0,8531 (1200); 0,8697 (1300); 0,8841 (1400); 0,8971 (1500); 0,9070 (1600);
0,9177 (1700); 0,9256 (1800); 0,9334 (1900); 0,9402 (2000); 0,9461 (2100); 0,9513 (2200);
0,9566 (2300); 0,9610 (2400); 0,9643 (2500); 0,9678 (2600); 0,9714 (2700); 0,9741 (2800);
0,9763 (2900); 0,9788 (3000);
0,9809 (3100); 0,9829 (3200); 0,9846 (3300); 0,9861 (3400); 0,9876 (3500);
0,9882 (3600); 0,9895 (3700); 0,9904 (3800); 0,9915 (3900); 0,9920 (4000);
0,9928 (4100); 0,9936 (4200); 0,9942 (4300); 0,9947 (4400); 0,9951 (4500);

6.h p = 0,40

0,3145 (100); 0,4364 (200); 0,5201 (300); 0,5867 (400); 0,6390 (500);
0,6825 (600); 0,7172 (700); 0,7510 (800); 0,7789 (900); 0,8034 (1000);
0,8243 (1100); 0,8433 (1200); 0,8594 (1300); 0,8737 (1400); 0,8873 (1500); 0,8983 (1600);
0,9084 (1700); 0,9182 (1800); 0,9262 (1900); 0,9327 (2000); 0,9392 (2100); 0,9441 (2200);
0,9495 (2300); 0,9537 (2400); 0,9584 (2500); 0,9622 (2600); 0,9654 (2700); 0,9689 (2800);
0,9717 (2900); 0,9744 (3000);
0,9772 (3100); 0,9790 (3200); 0,9806 (3300); 0,9826 (3400); 0,9842 (3500);
0,9852 (3600); 0,9867 (3700); 0,9877 (3800); 0,9888 (3900); 0,9896 (4000);
0,9908 (4100); 0,9916 (4200); 0,9926 (4300); 0,9932 (4400); 0,9939 (4500);

6.i p = 0,45

0,3120 (100); 0,4286 (200); 0,5107 (300); 0,5747 (400); 0,6287 (500);
0,6736 (600); 0,7122 (700); 0,7436 (800); 0,7723 (900); 0,7947 (1000);
0,8174 (1100); 0,8353 (1200); 0,8517 (1300); 0,8668 (1400); 0,8806 (1500); 0,8925 (1600);
0,9022 (1700); 0,9114 (1800); 0,9205 (1900); 0,9274 (2000); 0,9341 (2100); 0,9411 (2200);
0,9466 (2300); 0,9515 (2400); 0,9558 (2500); 0,9598 (2600); 0,9634 (2700); 0,9666 (2800);
0,9693 (2900); 0,9722 (3000);
0,9756 (3100); 0,9775 (3200); 0,9798 (3300); 0,9814 (3400); 0,9833 (3500);
0,9843 (3600); 0,9859 (3700); 0,9868 (3800); 0,9881 (3900); 0,9889 (4000);
0,9898 (4100); 0,9908 (4200); 0,9916 (4300); 0,9923 (4400); 0,9929 (4500);

6.j p = 0,50

0,3816 (100); 0,4771 (200); 0,5480 (300); 0,6087 (400); 0,6533 (500);
0,6944 (600); 0,7294 (700); 0,7567 (800); 0,7819 (900); 0,8051 (1000);
0,8249 (1100); 0,8427 (1200); 0,8596 (1300); 0,8735 (1400); 0,8857 (1500); 0,8966 (1600);
0,9073 (1700); 0,9162 (1800); 0,9241 (1900); 0,9322 (2000); 0,9376 (2100); 0,9433 (2200);
0,9475 (2300); 0,9525 (2400); 0,9574 (2500); 0,9622 (2600); 0,9646 (2700); 0,9678 (2800);
0,9707 (2900); 0,9733 (3000);
0,9758 (3100); 0,9775 (3200); 0,9794 (3300); 0,9812 (3400); 0,9828 (3500);
0,9853 (3600); 0,9864 (3700); 0,9874 (3800); 0,9889 (3900); 0,9898 (4000);
0,9898 (4100); 0,9908 (4200); 0,9916 (4300); 0,9924 (4400); 0,9931 (4500);

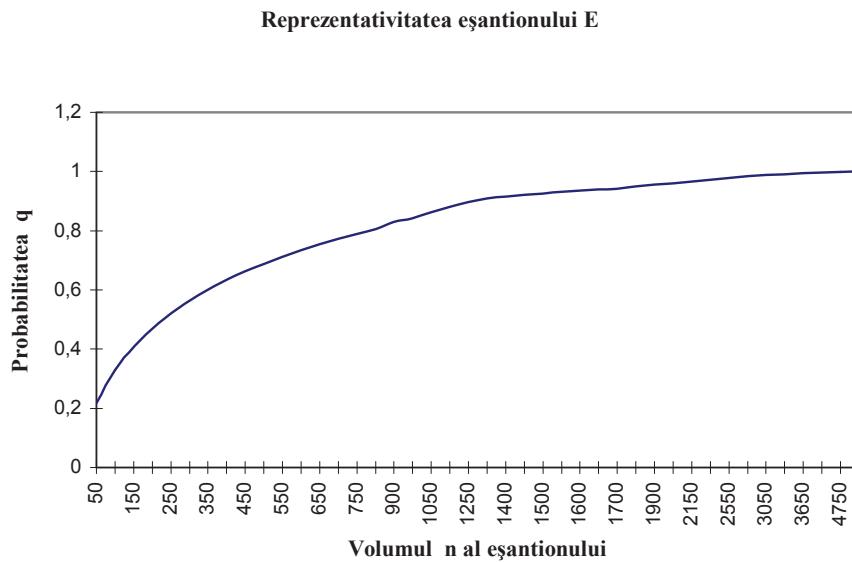
Analizând Tabelele 5 și 6 constatăm că la o creștere liniară a volumului n al eșantionului E nu corespunde tot o creștere liniară a indicatorului $q_{n,p,d}$ ce exprimă gradul de reprezentativitate al lui E.

Astfel se observă că indicatorul $q_{n,p,d}$ are mai întâi o creștere foarte bruscă, după care creșterea sa devine cu mult mai lentă, aceasta începând cu o

valoare n_0 atribuită volumului eșantionului. În fapt, valoarea n_0 definește „volumul optim” al eșantionului E deoarece o creștere a volumului lui E peste pragul n_0 nu aduce modificări semnificative ale probabilităților $q_{n,p,d}$.

Aspectul menționat este sugerat sugestiv de Figura 1 unde este reprezentat graficul funcției $q_{n,p,d}^{(s)}$ al cărei argument este volumul n al eșantionului E. În reprezentarea grafică amintită, parametrii p, d, s sunt fixați. Precizăm faptul că în acest caz valorile $q_{n,p,d}^{(s)}$ au fost preluate din Tabelul 5, pentru $p = 0,05$, $d = 0,01$, $s = 100.000$, $m = 2.000.000$.

Figura 1. Graficul estimației $q_{n,p,d}^{(s)}$ în raport cu volumul n al eșantionului
 $(p = 0,05, d = 0,01, s = 100000, m = 2000000; datele preluate din Tabelul 5).$



Menționăm că o reorientare spre o altă caracteristică X a populației W (de exemplu, modificarea valorii parametrului p), caracteristică în raport cu care s-a stabilit de fapt gradul de reprezentativitate al eșantionului E, conduce inevitabil la un alt volum optim n_0 pentru E.

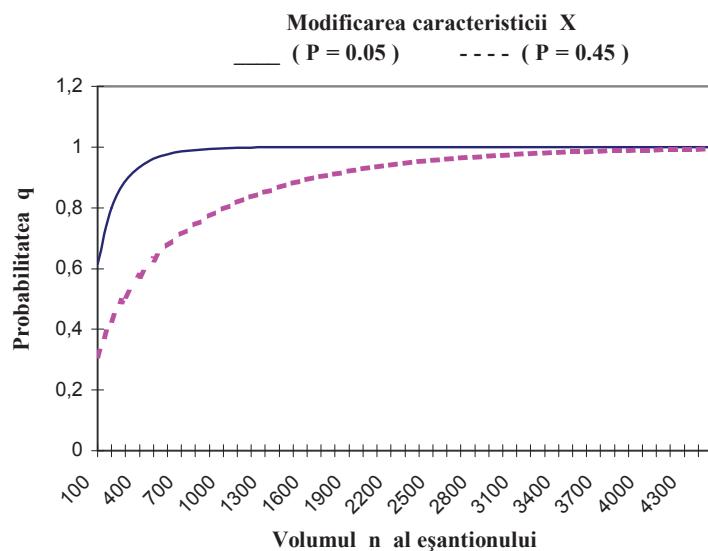
Această afirmație este justificată clar prin studierea comparativă a datelor din Tabelele 6.a - 6.j. Astfel, trecerea la o nouă valoare a parametrului

$p, 0 \leq p \leq 1$, păstrează alura curbei din Figura 1 (mai întâi o creștere rapidă urmată de o plafonare), fără însă ca noua curbă să se suprapună peste cea veche.

Un exemplu concludent este prezentat în Figura 2 unde sunt reprezentate simultan graficele funcțiilor $f_1(n) = q_{n, 0,05, 0,02}^{(100000)}$ și $f_2(n) = q_{n, 0,45, 0,02}^{(100000)}$, selectarea simplu aleatoare a eșantionului E făcându-se dintr-o populație de două milioane de indivizi.

Figura 2. Graficul estimației $q_{n,p,d}^{(s)}$ în funcție de volumul n al eșantionului atunci când caracteristica X se modifică; variante : $p = 0.05$, $p = 0.45$ (cazul $m = 2000000$, $s = 100000$,

$d = 0.02$; datele preluate din Tabelele 6.a și 6.i).



ÎMBUNĂTĂȚIREA ESTIMAȚIILOR $Q_{N,P,D}^{(s)}$ ALE PROBABILITĂȚII $Q_{N,P,D}$

Algoritmul **AS** ar putea fi apelat de un număr r de ori, la fiecare apelare t , $1 \leq t \leq r$, listându-se valorile estimațiilor $q_{n,p,d}^{(s)}$. Vom desemna prin $q_{n,p,d,t}^{(s)}$ valoarea $q_{n,p,d}^{(s)}$ obținută la a t -a rulare a algoritmului **AS**. Bineînțeles,

estimațiile $q_{n,p,d,t}^{(s)}$ vor fi diferite de la o apelare la alta a algoritmului **AS**, fapt ilustrat în Tabelul 7 (valorile $q_{n,p,d,t}^{(s)}$ se modifică în raport cu indicele t ce dă numărul apelării).

Vom nota prin $\alpha_{n,p,d,r}$, $\beta_{n,p,d,r}$ media, respectiv abaterea standard, a celor r valori $q_{n,p,d,t}^{(s)}$, $1 \leq t \leq r$, obținute succesiv după r rulări (apelări) ale algoritmului **AS**. Vom putea evalua mărimea fluctuațiile estimațiilor $q_{n,p,d,t}^{(s)}$ în raport cu diversele apelări t ale algoritmului **AS** prin determinarea abaterii standard $\beta_{n,p,d,r}$ a sirului de valori $q_{n,p,d,t}^{(s)}$, $1 \leq t \leq r$. Aceste aspecte sunt subliniate și de rezultatele prezentate în Tabelele 7 și 8 (pentru care s-au efectuat $s = 10000$, respectiv $s = 90000$ de simulări).

Tabelul nr.7

Apelarea de $r = 10$ ori a algoritmului de simulare **AS** în vederea comparării diverselor estimații $q_{n,p,d,t}^{(s)}$, $1 \leq t \leq r$, ale probabilității $q_n = \Pr(\Lambda_E \in [0,045, 0,055])$ pentru eșantioane de diferite volume n ($s = 10000$, $m = 1000000$, $p = 0,05$, $d = 0,005$) .

t	$n = 100$	$n = 400$	$n = 700$	$n = 1000$	$n = 1300$	$n = 1600$
1	0,1832	0,3452	0,4598	0,5248	0,5988	0,6391
2	0,1813	0,3436	0,4567	0,5213	0,5867	0,6346
3	0,1848	0,3462	0,4551	0,5349	0,5968	0,6427
4	0,1783	0,3500	0,4647	0,5343	0,5885	0,6335
5	0,1791	0,3472	0,4494	0,5225	0,5938	0,6393
6	0,1740	0,3556	0,4567	0,5307	0,5974	0,6428
7	0,1852	0,3479	0,4630	0,5339	0,6003	0,6495
8	0,1849	0,3453	0,4582	0,5337	0,5919	0,6348
9	0,1809	0,3451	0,4523	0,5187	0,5872	0,6295
10	0,1827	0,3551	0,4547	0,5305	0,5870	0,6368
$a_{n,p,d,r}$	0,18144	0,34812	0,45706	0,52853	0,59284	0,63826
$b_{n,p,d,r}$	0,003362796	0,003985173	0,004398454	0,005806901	0,005019004	0,005434556

Prin mărirea numărului s de simulări va crește acuratețea estimațiilor $q_{n,p,d}^{(s)}$ privind probabilitatea ca media pe eșantion $p^{(E)}$, la caracteristica X , să aparțină intervalului $[p - d, p + d]$.

Acest lucru este justificat și de faptul că valorile $q_{n,p,d}^{(s)}$ sunt determinate ca raport dintre numărul μ al „cazurilor favorabile” și numărul s al „cazurilor posibile” (formula (7)). Avem egalitatea $q_{n,p,d} = \mu / s$ dacă $s = v$, adică în situația în care se iau în considerare toate eșantioanele E de același volum n ce pot fi construite cu cei m indivizi din populația W .

Ilustrarea acestor aspecte reiese clar prin compararea Tabelelor 7 și 8 . O mărire a numărului s de simulări de la $s = 10.000$ la $s = 90.000$ conduce la o

micșorare (de aproximativ 3 ori) a abaterilor standard $\beta_{n,p,d,r}$ față de media $\alpha_{n,p,d,r}$ ale celor r estimații $q_{n,p,d,t}^{(s)}$, $1 \leq t \leq r$.

Tabelul nr.8

Apelarea de $r = 10$ ori a algoritmului de simulare **AS** în vederea comparării diverselor estimații $q_{n,p,d,t}^{(s)}$, $1 \leq t \leq r$, ale probabilității $q_n = \Pr(\Lambda_E \in [0,045, 0,055])$ pentru eșantioane de diferite volume n ($s = 90000$, $m = 1000000$, $p = 0,05$, $d = 0,005$)

t	n = 100	n = 400	n = 700	n = 1000	n = 1300	n = 1600
1	0,1802	0,3488	0,4545	0,5298	0,5942	0,6409
2	0,1794	0,3459	0,4587	0,5284	0,5915	0,6407
3	0,1786	0,3506	0,4595	0,5315	0,5924	0,6397
4	0,1803	0,3468	0,4562	0,5296	0,5901	0,6387
5	0,1818	0,3443	0,4548	0,5250	0,5892	0,6374
6	0,1806	0,3478	0,4566	0,5306	0,5934	0,6404
7	0,1804	0,3470	0,4575	0,5272	0,5918	0,6369
8	0,1821	0,3466	0,4585	0,5290	0,5920	0,6374
9	0,1817	0,3472	0,4565	0,5298	0,5939	0,6397
10	0,1794	0,3492	0,4549	0,5268	0,5887	0,6375
$\alpha_{n,p,d,r}$	0,18045	0,34742	0,45677	0,52877	0,59172	0,63893
$\beta_{n,p,d,r}$	0,001088347	0,001692808	0,00166316	0,001853672	0,001800444	0,001458115

Remarcă. Este cunoscut următorul rezultat teoretic (Gentle, 1998; Nelson, 1995): o mărire a numărului de simulări (independente) de un număr de λ^2 ori antrenează o creștere a acurateții rezultatelor simulării de numai λ ori (abaterea standard a rezultatelor se micșorează de λ ori).

Această observație a fost deja confirmată experimental prin rezultatele prezentate în Tabelele 7-8 (a se compara abaterile standard $\beta_{n,p,d,10}$ listate în aceste tabele).

O mărire a numărului r de apelări ale Algoritmului **AS** va conduce în mod evident la rezultate mai precise. În Tabelele 7 - 8 analiza era făcută pentru $r = 10$ apelări ale algoritmului de simulare **AS**. Cu aceleași valori ale parametrilor n, p, d, s reluăm această analiză, de această dată utilizându-se rezultatele obținute din $r = 50$ de rulări ale procedurii **AS**. Editarea sintetică a rezultatelor astfel obținute este prezentate în Tabelul 9 (9.a și 9.b). O trecere de la $s = 10.000$ de simulări (Tabelul 9.a) la $s = 90.000$ simulări (de 9 ori mai mult; Tabelul 9.b) va antrena, din punct de vedere teoretic, o reducere a abaterii standard de $\lambda = 9^{1/2} = 3$ ori. Rezultatul teoretic menționat este validat experimental prin compararea valorilor $\beta_{n,p,d,50}$ din Tabelele 9.a și 9.b.

Tabelul nr.9

Mediile $\alpha_{n,p,d,r}$ și abaterile standard $\beta_{n,p,d,r}$ ale rezultatelor obținute din $r = 50$ de rulări ale Algoritmului AS (în varianta: $m = 1000000$, $p = 0,05$, $d = 0,005$).

9.a Varianta $s = 10.000$ simulări

α, β	n = 100	n = 400	n = 700	n = 1000	n = 1300	n = 1600
$\alpha_{n,p,d,50}$	0,17993	0,34806	0,45624	0,52901	0,59159	0,64014
$\beta_{n,p,d,50}$	0,00407	0,00526	0,00486	0,00515	0,00516	0,00526

9.b Varianta $s = 90.000$ simulări

α, β	n = 100	n = 400	n = 700	n = 1000	n = 1300	n = 1600
$\alpha_{n,p,d,50}$	0,17991	0,34772	0,45604	0,52906	0,59170	0,63970
$\beta_{n,p,d,50}$	0,00155	0,00158	0,00157	0,00208	0,00159	0,00161

CONCLUZII ȘI POSIBILE EXTENSHII

Alternativa simulării stocastice

Procedura simulării stocastice poate fi adaptată cu ușurință și în cazul unor metode complexe de selectare a eșantionului E. Numai printr-un simplu efort de programare pe calculator, fără a se face investigații efective „în teren”, pot fi determinate eficiența și dezavantajele unei tehnici de eșantionare ce se intenționează a fi folosită.

Fixându-ne asupra unei proceduri de selectare a eșantionului, prin compararea rezultatelor simulărilor stocastice, se va putea aprecia în final dimensiunea optimă a eșantionului în raport cu resursele existente într-o situație concretă.

Concluziile analizei prezentate sunt, în general, valabile și pentru alte tipuri de eșantioane.

În acest context, sintetizăm unele dintre rezultatele calitative ce au fost justificate experimental:

- În cadrul procesului de eșantionare, creșterea volumului eșantionului E afectează în mod direct gradul de reprezentativitate al acestuia. Trebuie însă precizat că mărirea numărului indivizilor populației W nu modifică semnificativ acest grad de reprezentativitate. Înțându-se seamă de acest ultim aspect, cu erori neglijabile, populații infinite pot fi assimilate cu populații finite ce au un număr relativ mare de indivizi.

- La o creștere liniară a volumului eșantionului, creșterea reprezentativității sale nu mai este liniară. În această situație asistăm la o creștere a reprezentativității, mai întâi după o „pantă abruptă”, urmând apoi o „pantă deosebit de lină”. Aparent paradoxal, acest fapt ne conduce la eșantioane de volum relativ mic (de ordinul miilor) ce sunt însă reprezentative pentru

populații deosebit de numeroase (de ordinul miliardelor), aspect ce a fost validat experimental în prezentul studiu.

- Tehnica simulării stocastice nu presupune cunoștințe matematice deosebite sau efectuarea de raționamente sofisticate ce conduc la calcule complexe. În plus, algoritmul de simulare poate fi adaptat ușor diverselor variante de lucru.

- Mărirea numărului de „simulări” afectează direct, dar nu proporțional, acuratețea rezultatelor.

- Dintre rezultatele menționate în această lucrare, multe au deja o justificare teoretică. Avantajul simulării stocastice îl constituie însă ilustrarea cantitativă a aspectelor respective.

O observație generală

Dacă se urmăresc comparativ rezultatele simulărilor, acestea vor fi mereu altele datorită utilizării în simulările respective a unor șiruri diferite de numere aleatoare. Eroarea poate fi însă controlată, ea având o interpretare statistică.

Menționăm faptul că rezultatele simulărilor pot fi afectate și de erori datorate imperfecțiunilor generatorilor de numere aleatoare ce sunt folosiți de diversele produse soft prezente pe piață.

În cazul în care se cer precizii foarte mari privind rezultatele, pe lângă mărirea numărului de simulări, este obligatorie efectuarea unei analize calitative a șirului de valori aleatoare produse de generatorul de numere întâmplătoare ce va fi întrebuițat. De regulă, un astfel de generator produce (prin metode matematice, și nu numai) valori pseudoaleatoare, ce sunt uniform repartizate într-un interval (de obicei în intervalul [0, 1]; a se vedea, de exemplu, Gentle, 1998).

Menționăm faptul că există o mare varietate de proceduri pentru generarea șirurilor de valori întâmplătoare ce sunt uniform repartizate pe un interval. În acest sens, recomandăm lucrările lui Niederreiter (1995), Yarmolik și Demidenko (1988) în care sunt prezentate analize aprofundate privind calitățile statistice ale numerelor pseudoaleatoare produse de diverse tipuri de algoritmi matematici de generare a șirurilor de numere întâmplătoare.

Sugestii

Remarcăm câteva posibile extinderi ce urmează a fi abordate prin tehnica simulării stocastice: caracteristica X nu este neapărat dihotomică și poate fi chiar și o variabilă continuă, operarea simulată cu mai multe caracteristici, influența unor caracteristici corelate, stabilirea gradului de eroare impus de diferite proceduri de selectare și precizarea eșantionului optim, determinarea intervalelor de încredere $[d_1, d_2]$ pentru o probabilitate $q_{n,X}$ fixată.

BIBLIOGRAFIE

- Septimiu Chelcea, *Cunoașterea vieții sociale - Cuestionarul și interviul în ancheta sociologică*, Editura Institutului Național de Informații, București, 1996.
- Floyd J. Fowler Jr., *Survey research methods*, Applied Social Research Methods Series, vol. 1, SAGE Publications, London, 1993.
- Victor E. McGee, *Principles of statistics - Traditional and bayesian*, The Century Psychology Series, New York.
- James E. Gentle, *Random number generation and Monte Carlo methods*, Statistics and Computing, Springer Verlag, New York, 1998.
- Christian Gourieroux, *Theorie des sondages*, Collection „Economie et statistiques avancées”, Economica, Paris, 1981.
- Harry Joe, *Multivariate dependence measures and data analysis*, Computational statistics & Data analysis, vol. 16, Nr.3, 1993.
- Marius Iosifescu, Costache Moineagu, Vladimir Trebici, Emiliana Ursianu, *Mică enciclopedie de statistică*, Editura Științifică și Enciclopedică, București, 1985.
- Leslie Kish, *Survey sampling*, John Wiley & Sons, New York, 1963, (prima ediție).
- G. Klimov, *Probability theory and mathematical statistics*, MIR Publishers, Moscova, 1986.
- V. Koroliouk, N. Portenko, A. Skorokhod, A. Tourbine, *Aide-mémoire des théorie des probabilités et de statistique mathématique*, MIR, Moscova, 1983.
- Barry L. Nelson, *Stochastic modeling*, McGraw Hill, New York, 1995.
- Harald Niederreiter, *Pseudorandom vector generation by the multiple-recursive matrix method*, Mathematics of Computation, 64 (1995).
- Andrei Novak, *Sondarea opiniei publice*, Editura Studențească, București, 1996.
- Athanasios Papoulis, *Probability & Statistics*, Prentice Hall, Englewood Cliffs, 1990.
- Traian Rotariu, Petre Iluț, *Ancheta sociologică și sondajul de opinie*, Editura POLIROM, Iași, 1997.
- Des Raj, *Sampling theory*, TATA McGraw-Hill, Bombay, 1968.
- V.N. Yarmolik, S.N. Demidenko, *Generation and application of pseudorandom sequences for random testing*, John Wiley and Sons, New York, 1988.
- Cătălin Zamfir (coordonator), *Dimensiuni ale sărăciei*, Editura Expert, București, 1995.
- *** SPSS Base 7,5 for Windows, User's guide, 1997.