


Narodna in univerzitetna knjižnica  
v Ljubljani

2  
1199202



UNIVERZA V LJUBLJANI  
EKONOMSKA FAKULTETA

Blejec Marijan:

STATISTIKA I. LETNIK

Nadaljevanje.

Izdala Strokovna sekcija LE Ekonomske fakultete  
v Ljubljani  
1950.

+ II 99202

II 99202



g 1347/1951

## K a z a l o :

### Časovne serije

1. Opredelitev in naloga analize	1
2. Analiza časovnih serij v kapitalističnem gospodarstvu - konjunkturna statistika	1
3. Pomen analize časovnih serij v socializmu in planskem gospodarstvu	2
4. Vrste gibanj gospodarskih pojavov	2
5. Metode analize časovnih serij	4

### Korelacija

22

### Osnovne metode izbora

27

1. Zakon velikih števil	
2. Verjetnost	28
3. Nadomestne metode statističnega opazovanja	33
31. Splošno	33
32. O nadomeščanju z eno samo vrednostjo	34
33. Normiran odklon	35
34. Celokupna statistična masa, delna masa ali vzorec	38
35. Ocenjevanje	39
36. Načini slučajnega izbiranja	49
37. Uporaba metode izbora	51
38. Po metodi izbora izvršene statistične akcije v LRS	52

Popravki glej str. 54



## Časovne serije.

### 1. Opredelitev in naloga analize.

Časovna-dimazična serija je serija individualnih, zbirnih, srednjih ali relativnih vrednosti, splošno torej serija vseh vrst statističnih količin, od katerih se vsaka nanaša na poedine sukcesivne časovne dele, oziroma momente. Členi časovne serije, katerih vsak zase da sliko samo za določen krajši razmak ali celo za moment, daje postavljeni v časovnem zaporedju kot kompleks členov, sliko v časovnem spreminjanju določenega pojava (primerjaj filmsko kamero - zaporedje v času si sledečih momentnih slik da sliko gibanja).

Analiza gospodarskih pojavov predpostavlja njih stalno časovno spreminjanje, ker stacionarnih gospodarskih pojavov v stvarnosti ni. Ustvarjanje fiktivnih stacionarnih pojavov problem le poenostavlja radi najenostavnejše možnosti analize.

Na spremembo določenega ekonomskega - družbenega pojava v času vplivajo najrazličnejši drugi pojavi in drugi vzroki. Naloga analize časovnih serij je, da ugotovi zvezo med posameznimi pojavi (korelacije) na eni strani, na drugi strani pa da analizira in razstavi rezultate vseh vplivov na posamezna komponenta, kar omogoča, da moremo bolj ali manj prodreti v zakonitosti socialno-ekonomskih pojavov.

### 2. Analiza časovnih serij v kapitalističnem gospodarstvu - konjunkturna statistika.

Kapitalističnemu gospodarstvu so lastne zakonitosti stihijskega odvijanja gospodarskih pojavov. Ker bi poznavanje teh zakonitosti moglo služiti onemu, ki bi jih poznal v njih lastno izkoriščanje je jasno, da je zanimanje za analizo časovnih serij v kapitalizmu veliko in se je pojavilo razmeroma zgodaj (že v 19. stoletju "nauk o krizah") in kasneje doseglo neverjeten napredek in se je v sklopu nauka o konjunkturah razvila specialna statistična metoda, konjunkturna statistika. Nauk o konjunkturi išče pravilnosti in zakonitosti v gibanju gospodarskih pojavov in so njeno področje vsi gospodarski pojavi. Nauk o konjunkturi je nastal v kapitalizmu in

s svojimi predpostavkami tak red tudi predstavlja, t.j. da je narodno gospodarstvo sestavljeno iz individualnih gospodarstev, in pomeni napredek za celotno gospodarstvo, ako bo vsak gospodaril tako, da zase pridobi čim več koristi). Na podlagi izsledkov o zakonitosti pojavov skuša sklepati na gospodarsko dogajanje v bodoče ( prognoza ). Vendar se je izkazalo, da se vendar ne da gospodarsko življenje zajeti suho v matematično-formalistične kalupe, ko je leta 1929 izbruhnila svetovna gospodarska kriza, po napovedih Harvardskega instituta pa je bila napovedana gospodarska prosperiteta. S tem je formalistična smer analiziranja doživela svoj prelom.

### 3. Pomen analize časovnih serij v socializmu in planskem gospodarstvu.

Za razliko od kapitalističnega sistema stopa v socializmu mesto zakona stihije plansko gospodarstvo.

Po členu 15.ustave FLRJ usmerja radibzaščite življenskih koristi ljudstva, dviga ljudske blaginje in pravnega izkoriščanja vseh gospodarskih možnosti in sil, država gospodarsko življenje in razvoj s pomočjo splošnega gospodarskega plana; pri tem se opira na državni in združni gospodarski sektor ter izvaja splošno kontrolo med zasebnim sektorjem gospodarstva.

Radi tega nauk o konjunkturi za preučevanje našega gospodarstva dejansko ne pride v poštev, pač pa moramo koristiti mnoge statistične metode časovnih serij, ker je v našem gospodarstvu nebroj pojavov, ki bi jih mogli formalno analizirati s temi metodami. (vpliv naravnih pojavov, privatna gospodarstva).

### 4. Vrste gibanj gospodarskih pojavov.

Videli bomo, da bomo vse vrste gibanj pojavov, znane iz konjunkturke statistike, našli tudi v našem gospodarstvu.

4.1. Trendi. Vsak pojav sledi v svojem časovnem razvoju, kljub odklonom za posamezne momente, neki osnovni smeri razvoja. To smer časovnega razvoja imenujemo "trend". Ta smer razvoja je lahko naraščajoča ali padajoča, ali tudi niha na daljše razdol-



je ( sekularna gibanja ). Plansko gospodarstvo predpostavlja stalen napredek in razvoj. Osnovna linija razvoja je postavljena z gospodarskim planom, to pa ni nič drugega kot trend. Seveda je možno, da različni vplivi odklanjajo stvarnost od te linije, vendar je osnovna smer več ali manj stalna. Trend moremo opazovati tudi pri vseh časovnih serijah socialno-ekonomskih pojavov, kjer osnovna smer ni podana s planom, ker absolutne konstante pojavov skoro da ne poznamo ( specialno v meteorologiji ).

42. Sezonske oscilacije pomenijo periodično odklanjanje pojava od trenda. Plansko gospodarstvo stremi za tem, da čim bolj eliminira sezonske vplive na gospodarske pojave (n.pr. gradbena dela). Vendar to v velikih primerih ni možno (n.pr. poljska dela). V takih primerih skuša sezonska oscilacija ublažiti (n.pr. turizem, kjer je perioda leto, periodični vplivi izostanki po dnevih). Iz tega je razvidno, da je važnost poznavanja sezonskih oscilacij veliko.

43. Konjunkturke oscilacije. Konjunkturke oscilacije (prosperitet - napetost - kriza - depresija) so značilne za kapitalistični red. Plansko gospodarstvo jih ne pozna, oziroma mora skrbeti, da jih eliminira. Popolna eliminacija v današnji fazi ni možna, ker imamo opravka še s privatnim sektorjem, ki je v gotovih panogah še močan (kmetijstvo). Vendar ima država možnost vplivati tudi tu z ustavo postavljeno pod kontrolo privatnega sektorja. Na drugi strani pa eliminacija konjunkturkih oscilacij ni možna radi konjunkturkih oscilacij v ostalem svetu, ki ima nujen odmev čeprav šibak tudi v državah socializma.

44. Enkratne spremembe ali enkratni vpliv. Enkratne spremembe so one, katere povzročajo enkratni vpliv. Take spremembe morejo biti trajne, t.j. take, ki trenutno spremene tek, in se po spremembi nadaljuje in druge vrednosti. Vpliv spremembe je trajen (n.pr. nov izum dvigne proizvodnjo, prehod nekaj podjetij iz ene smeri v drugo v eni zveča nivo števila delavstva v drugi pa zmanjša). Trenutne spremembe so take, ki poderejo reden tok, vendar se po prenehanju tega vzroka tek pojava nadaljuje iz prejšnjega nivoja (n.pr. vpliv štrajka na vrednost proizvodnje). Poleg te vrste trenutnih sprememb poznamo še drugo, kjer sprememba v nekem trenutku izzove v naslednjem trenutku reakcijo v obliki spremembe v obratni smeri. (n.pr. ako je tovorni transport nekega podjetja en dan prekinjen je radi tega naslednji

dan dvojen).

45. Slučajne spremembe. Vse ostale spremembe, ki so rezultat delovanja stihije oz. faktorjalnih znakov, kateri so izven možnosti uravnavanja in eliminiranja imenujemo slučajne spremembe.

## 5. Metode analize časovnih serij.

50. Splošno. Težišče analize časovnih serij je na proučevanju jakosti posameznih vrst vplivov, ki vplivajo na opazovani pojav. Ena izmed tipičnih metod proučevanja časovnih serij je indeksna metoda, katere pa ne bomo na tem mestu obdelovali, ker je bila podana pri relativnih številih. V ostalem pa se poslužujemo metod, ki pomagajo, razstavljati časovno vrsto na komponente trend, sezonske oscilacije, enkratne vplive, in rezidualne slučajne spremembe. Medsebojni vpliv posameznih pojavov bomo proučevali s korelacijo, ki pa bo predmet posobnega poglavja.
51. TREND. Tehnično se izračunava trend kot osnovna smer razvoja na več načinov, od katerih ima vsak svoje dobre in slabe strani, odvisne bodisi od lažjega ali težjega konstruiranja, bodisi po večji ali manjši teoretični dognanosti, ker zavisi sama oblika iskanega trenda v bistveni meri od metode, ki smo jo uporabljali. Predno gremo metode izračunavanja si moramo biti na jasnem, da bo trend dal sliko osnovne linije razvoja, da bo tekel med realnimi empiričnimi vrednostmi, da predstavlja torej neke vrste dinamično srednjo vrednost, okrog katere kolobirajo empirični vrednosti in se mu več ali manj priklanjajo.
511. Prostorčno črtanje trenda. Najenostavnejši način določanja trenda je, da v diagramu, v katerega smo vrtali časovno serijo med empiričnimi vrednostmi prostorčno potegnemo črto, ki naj po občutku predstavlja osnovno smer gibanja. Ta način je najlažji, obenem pa tudi najmanj točen = natančen.
512. Polzeče povprečje. Povprečje izračunano iz členov statistične serije izraža tipično vrednost serije, ker se slučajni odkloni individualnih vrednosti kompenzirajo. Enako izraža aritmetična sredina samo nekaj zaporednih členov tipično vrednost teh členov, oziroma razdobja. Serijo povprečnih vrednosti moremo določiti na ta način, da tvorimo povprečja iz vseh možnih zaporednih skupin členov po toliko členov, za kolikor smo se odločili, da bomo tvorili povprečja. Praktično nastane vsaka nova skupina

iz členov predidóče skupine tako, da prvi člen v tej skupini izpustimo, dodamo pa naslednji člen, ki pride v celotni seriji za zadnjim členom v skupini. Ker dobimo na ta način celo serijo povprečij in te skupine nekako polze po osnovni seriji, imenujemo to serijo serijo polzečih povprečij. Ako vzamemo n.pr. skupine po tri člene, bomo polzeča povprečja tvorili po naslednji shemi.

Osnovna serija

$$x_1 \quad x_2 \quad x_3 \quad x_4 \quad x_5 \quad x_6 \text{-----}$$

$$p_2 = \frac{x_1 + x_2 + x_3}{3} \quad p_3 = \frac{x_2 + x_3 + x_4}{3} \quad p_4 = \frac{x_3 + x_4 + x_5}{3} \text{ v splošnem}$$

$$p_k = \frac{x_{k-1} + x_k + x_{k+1}}{3}$$

Splošen obrazec za preračunavanje pa je:

$$p_{k+1} = p_k + \frac{x_{k-2} - x_{k-1}}{3}$$

Primer:

$$\begin{array}{cccccc} x_1 & x_2 & x_3 & x_4 & x_5 & \\ 6 & 8 & 10 & 9 & 8 & \text{-----} \end{array}$$

$$p_2 = \frac{6 + 8 + 10}{3} = \frac{24}{3} = 8$$

$$p_3 = 8 + \frac{9 - 6}{3} = 9$$

$$p_4 = 9 + \frac{8 - 9}{3} = 8$$

Če vzamemo v skupine toliko členov, da dobimo obseg periode, če gre za periodičen pojav, bo polzeča povprečja eliminirala poleg slučajnih odklonov v seriji tudi sezonske variacije, radi tega, ker se go v vsaki skupini nahajal en hrib in en dolina sezonske variacije. V tem primeru bo serija polzečega povprečja služila kot trend, ker bo v glavnem vsebovala samo osnovno smer gibanja, ker je očiščena vsaj v glavnem tako slučajnih, kot periodičnih variacij. Ker pride v gospodarskih problemih

največkrat v poštav lētna sezonska variacija, bomo izvedli tak primer: Izračunamo povprečje pripišemo srednjemu členu skupine. Ker je število mesecev sodo število, torej ni srednjega meseca, uporabljamo tehtano aritmetično sredino skupine trinajstih členov, da vzamemo za končna meseca 1/2 vrednosti, kjer pa so vseeno posamezni meseci enako zastopani.

$$T_{jul} = \frac{1}{12} \left( \frac{1}{2} \text{ jan} + \text{feb} + \dots + \text{jul} + \dots + \text{dec} + \frac{1}{2} \text{ ja} \right)$$

ali v splošnem:

$$T_m = \frac{1}{12} \left( \frac{1}{2} y_{m-6} + y_{m-5} + \dots + y_m + \dots + y_m + 5 + \frac{1}{2} y_{m+6} \right)$$

Za praktično računanje je važen postopek, kako iz izračunane povprečja za eno skupino pridemo do povprečja za poslednjo skupino.

$$T_m = \frac{1}{2} \left( \frac{1}{2} y_{m-6} + y_{m-5} + \dots + y_m + \dots + y_{m+5} + y_{m+6} \right)$$

$$T_{m+1} = \frac{1}{12} \left( \frac{1}{2} y_{m-5} + y_{m-4} + \dots + y_{m+1} + \dots + y_{m+6} + \frac{1}{2} y_{m+7} \right)$$

$$T_m - T_{m+1} = \frac{1}{12} \left( \frac{1}{2} y_{m-6} + \frac{1}{2} y_{m-5} - \frac{1}{2} y_{m+6} - \frac{1}{2} y_{m+7} \right)$$

(  $y_{m+6} - y_{m-6}$  ) oz. (  $y_{m+7} - y_{m-5}$  ) so v stvari difference vrednosti za odgovarjajoče mesece dveh sledečih let.

Kot primer vzemimo število natovorjenih vagonov v b. Jugoslaviji po mesecih (glej primer na strani ).

$$T_{avg} = T_{jul} + \frac{1}{24} ( d_{jan} + d_{feb} )$$

$$T_{sept} = T_{avg} + \frac{1}{24} ( d_{feb} + d_{jan} )$$

$$T_{okt} = T_{sept} + \frac{1}{24} ( d_{mar} + d_{apr.} )$$

**$T_{jul} = 115,3$**

$$T_{\text{avg}} = 115,3 + \frac{1}{24} (9,9 + 7,8) = 116,0$$

$$T_{\text{sept}} = 116,0 + \frac{1}{24} (7,8 + 8,2) = 116,7$$

Postopek bo dal pričakovane rezultate v slučaju, da ima osnovno gibanje konstanten porast oz. padec, in ako ima periodično gibanje stalne amplitude. Čim bolj se empirična krivulja približuje temu idealnemu stanju, tembolj bo metoda sama zadovoljiva.

Hiba postopka je tudi ta, da ne moremo izračunati vrednosti polzečega povprečja prvih in zadnjih šest mesecev časovne serije.

### 513. DOLOČANJE TRENTA S POMOČJO MATEMATIČNIH KRIVULJ.

Vrednosti členov statistične serije se s časom (neposredno) spreminjajo, so torej odvisne spremenljivke, oziroma funkcije časa. Radi tega se postavlja vprašanje, dali bi mogli izraziti empirično dano statistično serijo z matematično funkcijo. E funkcija na eni strani ne sme biti prekoamplificirana, da je konitost jasna, na drugi strani pa moramo stremeti za to, da bodo razlike med empiričnimi in vrednostmi funkcije čim manjše. Ako hočemo z matematičnimi funkcijami določiti trend, ne bomo iskali takih, katere bi se skladale v vseh vrednostih z empiričnimi, kar bi bilo običajno interpoliranje skozi dane točke, temveč bomo iskali razmeroma enostavno funkcije (parabole tega reda, logaritmične krivulje in eventualno eksponencialne funkcije) katerih vrednosti se bodo čim bolj prilegale empiričnim vrednostim. Pri izbiri tipa krivulje bomo izmed teh izbrali tisto, pri kateri bodo razlike med empiričnimi vrednostmi in vrednostmi izravnanе funkcije čim manjše. Ta izbira bo izvedena na ta način, da bomo izbrali primerne parametre, ki konkretno določajo funkcijo. Problem se v statistiki postavlja na ta način, da iščemo pri izbranem tipu funkcije tisto, za katero je vsota kvadratov odklonsv empiričnih vrednosti od funkcijskih najmanjša. (Gaussova metoda najmanjših kvadratov). Ako zaznamujemo z  $y_K$  empirično vrednost  $K$  tega člana serije, z  $f_K$  vrednost funkcije, prilagoditve za  $K$ , mora

biti izpolnjen pogoj.

$$\sum_{k=1}^N (y_k - f(x_k))^2 = \text{Min} \quad K = 1, 2, \dots, N$$

S tem so  $K=1$  parametri funkcije. Običajno izbiramo kot funkcije, ki izražajo trend:

premico  $y = a + bx$

parabolo 2 reda  $y = a + bx + cx^2$

parabolo 3 reda  $y = a + bx + cx^2 + dx^3$

v splošnem parabolo  $l$ -tega reda

$$y = a + bx + cx^2 + \dots + rx^n$$

eksponentialno funkcijo

$$y = ab^x$$

logaritmično funkcijo

$$y = a + blgx$$

$a, b, c, \dots$  so parametri, katere je treba šele od primera do primera izračunati:

Kot primer vzemimo najenostavnejši primer, da iščemo trend v obliki premice:

$y_1 \ y_2 \ y_3 \ y_4 \ y_5 \ \dots$  časovna serija za vrednosti členov  
 $x_1 \ x_2 \ x_3 \ x_4 \ x_5 \ \dots$  vrednosti časa, za katerega velja  
 $y_i$ .

Funkcija s katero hočemo izraziti trend časovne serije  $y$  je:

$$f\left(\frac{x}{K}\right) = a + bx_K$$

Izbrati je treba primerne parametre. Ti parametri so določeni s pogojem:

$$\sum_{k=1}^N (y_k - a - bx_k)^2 = \text{Min}$$

Če kvadrate izračunamo, dobimo:

$$y_1^2 + a^2 + b^2 x_1^2 - 2ay_1 - 2bx_1 y_1 + 2abx_1 +$$

$$y_2^2 + a^2 + b^2 x_2^2 - 2ay_2 - 2bx_2 y_2 + 2abx_2 +$$

$$y_k^2 + a^2 + b^2 x_k^2 - 2ay_k - 2bx_k y_k + 2abx_k +$$

$$y_N^2 + a^2 + b^2 x_N^2 - 2ay_N - 2bx_N y_N + 2abx_N$$

$$\sum_K^N y_k^2 + Na^2 + b^2 \sum_K^N x_k^2 - 2a \sum_K^N y_k - 2b \sum_K^N x_k y_k + 2ab \sum_K^N x_k = \text{Min}$$

Ako vzamemo izhodišče koordinantnega sistema sredi serije, je

$\sum_K x_k = 0$ , ker imamo iste vrednosti enkrat pozitivne, drugič negativne. Z to okrajšavo moremo gornji izraz

pisati v obliki:

pisati v obliki:

$$\sum_K^N y_k^2 + N \left( a - \frac{\sum_K y_k}{N} \right)^2 + \sum_K x_k^2 \left( b - \frac{\sum_K x_k y_k}{\sum_K x_k^2} \right)^2 - \frac{\left( \sum_K x_k y_k \right)^2}{\sum_K x_k^2} = \text{Min}$$

V tem izrazu moremo spreminjati parametra a in b. Cel izraz bo manjši (najmanjši), ako bosta drugi in tretji člen, katera s pomočjo a in b moremo še spremeniti, čim manjša. Ker ne moreta zavzeti negativne vrednosti, je njih najmanjša vrednost 0. torej je:

$$a = \frac{\sum_K y_k}{N} = 0 \quad b = \frac{\sum_K x_k y_k}{\sum_K x_k^2} = 0$$

S tem sta oba parametra določena.

Primer: Povprečno mesečno število natovirjenih vagonov v bivši Jugoslaviji po letih.

Povp. mes. Prenos  
e 000 vag. koord.  
sist.

l	$y_k$	$x_k$	$x_k^2$	$y_k \cdot x_k$	$f(x_k)$
1932	119,0	-3	9	-357,0	111,1
1933	114,0	-2	4	-229,0	116,2
1936	126,3	-1	1	-116,3	121,3
1935	121,5	0	0	0	126,4
1936	126,0	+1	1	126,0	131,5
1937	140,4	+2	4	280,8	136,6
1938	146,4	+3	9	439,2	141,7
	885,0	0	28	142,4	

N = 7

$$a = \frac{885,0}{7} = 126,4 \quad b = \frac{142,4}{28} = 5,1$$

$$f(x) = 126,4 + 5,1 \cdot x$$

Z vstavljanjem  $x = -3, -2, \dots, +3$  v  $f(x)$  dobimo izračunane vrednosti za posamezna leta.

Postopek je podoben pri drugih tipih funkcij, le da se račun znatno komplicira. Vendar so izdelane metode, ki tudi za komplicirane tipe funkcij omogočajo razmeroma hitro rešitev problema (ortogonalni polinomi, tabele itd.).

#### 514. ELIMINIRANJE TRENDNA IZ ČASOVNE VRSTE

Trend in sezonske variacije, dve glavni komponenti gibanja v časovni vrsti, moreta vplivati na vrednost na dva načina: ali aditivno ali faktorialno. Izraženo v funkciji bi imeli za aditivno veza ako je  $T(x)$  trend,  $S(x)$  pa periodično oscilacijo,  $O(x)$  pa ostali vplivi (slučajni itd.).

$$f(x) = T(x) + P(x) + O(x)$$

v slučaju faktorialne zveze pa:

$$f(x) = T(x) \cdot P(x) \cdot O(x)$$



Aditivno zvezo bomo imeli takrat, kadar bo jakost periodičnih oscilacij enaka ne glede na absolutni nivo pojava, factorialna pa v primeru, da bo vplivala sprememba nivoja pojava tudi na jakost oscilacij.

V primeru aditivnih zvez bomo trend eliminirali z odštevanjem vrednosti trenda od vrednosti členov časovne serije,

$$(f(x) - T(x)) = P(x) + O(x)$$

v drugem pa z deljenjem z vrednostjo trenda

$$\frac{f(x)}{T(x)} = P(x) \cdot O(x)$$

Iz factorialne povezave moremo priti do aditivne, ako vzamemo mesto vrednosti členov logaritme teh vrednosti.

$$\lg f(x) = \lg T(x) + \lg P(x) + \lg O(x)$$

V ekonomskih pojavih so med trendom in periodičnimi oscilacijami običajnejše factorialne kot aditivne zveze.

N.pr. jakost sezonske variacije, števila gradbenega delavstva je enkrat, dvakrat večja, če se nivo števila gradenj enkrat, dvakrat poveča.

515. ELIMINIRANJE TRENDNA. Kot primer vzemimo število natovorjenih vagonov v b. Jugoslaviji in eliminirajmo trend z odštevanjem polzečega povprečja od empirične serije. Rezultati morejo biti pozitivni ali negativni, ker so sezonske variacije pozitivne ali negativne (glej stran )

## 52. PERIODIČNE SPREMEMBE.

520. SPLOŠNO. Poleg trenda so glavne komponente gibanj periodične variacije. Periode morejo imeti najrazličnejše dolžine na primer teden, dekada, mesec, leto itd. Največji periodični vpliv na gospodarske pojave ima običajno leto. Letne variacije imenujemo tudi sezonske variacije. Periodične variacije vplivajo na gibanje pojavov tako, da se pojav na določenem mestu periode giblje po eni strani trenda. Učinki periodičnih variacij se v toku ene periode po pravilu izenačujejo in je zato vsota vseh periodičnih učinkov ene periode enaka 0.

Na podlagi tega sta obe metodi izračunavanja sezonskih variacij izdelani po naslednjih predpostavkah. Z uzraču-

navanjem povprečij iz večjih členov časovne serije se kompenzirajo slučajne variacije. Z vsoto ali z izračunavanjem povprečij členov ene periode pa se poleg slučajnih variacij kompenzirajo tudi periodične (sezonske variacije). S to predpostavko smo pri metodi polzečih povprečij eliminirali slučajne in sezonske variacije, da smo dobili čisti trend.

Konkretna vrednost člana časovne serije je v glavnem sestavljena iz naslednjih komponent: trenda, periodičnih variacij in slučajnih variacij. V simbolih dobimo

$$y_{\mu\lambda} = T_{\mu\lambda} + P_{\mu} + S_{\mu\lambda}$$

Pri Bowley-Smithovi metodi najprej eliminiramo trend s tem, da ga na kateri koli način izračunamo (polzeča povprečja, metoda najmanjših kvadratov), in ga od konkretnih vrednosti časovne serije odštejemo. Tako vstaneta samo periodična komponenta in slučajna variacija. Te pa razdružimo s tem, da v seštevanju vrednosti za določen čas periode izračunamo povprečje iz vseh period in s tem odstranimo slučajne variacije. Druga metoda takozvana Personova metoda je izdelana pod predpostavko, da je trend linearne oblike torej dan z :

$$T_{\mu\lambda} = a + bt_{\mu\lambda}$$

Z odštevanjem dveh zaporednih členov serije se komponenta trenda pojavlja v diferenci v naslednji obliki

$$T_{\mu\lambda+1} - T_{\mu\lambda} = a + bt_{\mu\lambda+1} - a - bt_{\mu\lambda} = b,$$

torej kot konstanta, ki jo moremo določiti kot kaže izpeljava metode pod 522.

521. Bowley-Smithova metoda. Po eliminaciji trenda ostanejo v časovni vrsti v glavnem sezonske oz. periodične oscilacije in slučajne oscilacije. Ako pogledamo konkretno za naš primer, (problem razdružitve obeh oscilacij) iz prometne statistike bivše Jugoslavije vrednosti za vsa leta za določen mesec, bomo videli, da te vrednosti več ali manj varirajo vendar je nivo vrednosti za vsak mesec drugo. Po podrobnejšem pregledu vidimo, da gornja variacija izhaja iz slučajnih vplivov, spreminjanje nivoja pa od periodičnih oscilacij, ki so rezultat periodičnih vplivov. Nivo gornjih vrednosti bomo dolo-

čili s tem, da bomo izračunali srednjo vrednost, ki bo podala tipično vrednost sezonskega odklona, za določen mesec in s tem merilo odklona. Ker predpostavlja, da je vsota vseh periodičnih oscilacij tekom ene periode 0 (vsota čnega hriba in čnega dola je 0), bomo eventuelno od 0 različno vsoto razdelili enakomerno na posamezne člene s tem dosegli gornji pogoj.

Shema računanja je naslednja:

$\lambda = \lambda$  - to leto

$n = n$  -ti mesec  $y_{\lambda\mu}$  = empirična vrednost za  $\lambda$ -to leto

$\lambda$  = število let,  $m$  = štev. mesecev = 12  $\mu$  -ti mesec

Potek periode  $T_{\lambda\mu}$  = vrednost trenda za  $\lambda\mu$

$Y_{\lambda\mu} = T_{\lambda\mu} =$

$Y_{\lambda\mu}$  = empirične vrednosti očiščene trenda

$$p_{\mu} = \frac{\sum_{\lambda=1}^m Y_{\lambda\mu}}{\sum_{\mu=1}^m p_{\mu}}$$

$p_{\mu}$  = sezonska variacija (nekorigirana)

$$p = \frac{\sum_{\mu=1}^m p_{\mu}}{m}$$

$p$  = korektura

$$P_{\mu} = p_{\mu} - p$$

$P_{\mu}$  = sezonska variacija (korigirana)

$$\sum_{\mu=1}^m P_{\mu} = 0$$

Gornji način uporabljamo, kadar so posamezne komponente povezane aditivno. V primeru faktorialne povezave pa bomo prešli na računanje z logaritmi ali na računске operacije, ki so stopnjo višji od seštevanja in odštevanja, t.j. množenje in deljenje.

Pri prvem primeru je bila sezonska oscilacija dana absolutno, medtem ko je v drugem dana z indeksom in moramo za eliminacijo empirične vrednosti s temi vrednostmi deliti. Navedeni metodi se imenujeta Bowley-Smithova metoda in predpostavljata, da je v seriji trend že eliminiran.

522. Personova metoda verižnih diferenc oz. verižnih indeksov.

Ako nimamo trenda eliminiranega in pri predpostavki enakomernega porasta osnovne smeri moremo uporabiti Personovo metodo verižnih diferenc pri aditivnih zvezah, oziroma verižnih in-

deksov pri faktorskih zvezah.

Metoda obstoja v tem, da izračunamo serijo verižnih diferenc in poiščemo povprečne verižne diference za posamezne mesece. Kumulativna serija povprečij verižnih diferenc da nekorigirane sezonske razlike. Korrektura bo obstojala v tem, da bomo verižne diference zmanjšali ali povečali za  $\frac{1}{12}$

vsote verižnih diferenc, tako, da bo vsota vseh verižnih diferenc enako 0. Ker vsota sezonskih diferenc izračunanih na ta način ne bo enaka 0, iščemo pa take sezonske diference, kjer je vsota vseh članov ~~mnaha~~ periode enaka 0, bomo od vsakega člana odšteli  $\frac{1}{12}$  vrednosti vsote vseh členov.

Z simboli je postopek naslednji:

$$Y_{\lambda, \mu}$$

individualna vrednost časovne serije za  $\lambda$  leto in  $\mu$ -ti mesec

$$Y_{\lambda, u+1} - Y_{\lambda, u} = v_{\lambda, u+1}$$

individualna verižna diferenca

$$\sum_{\lambda=1}^l v_{\lambda, \mu}$$

$$\frac{\sum_{\lambda=1}^l v_{\lambda, \mu}}{l} = V_{\mu}$$

povprečna verižna diferenca

$$d_m = \sum_{\mu=1}^{12} V_{\mu}$$

nekorigirana sezonska diferenca

$$\sum_{\mu=1}^{12} V_{\mu}$$

$$\frac{\sum_{\mu=1}^{12} V_{\mu}}{12} = \frac{d}{12} = v$$

korekturna konstanta

$$v_{\mu} - v = v'_{\mu}$$

korigirana sezonska diferenca

$$\sum_{\mu=1}^{12} v'_{\mu} = d'_m$$

$$\sum_{m=1}^{12} d'_m$$

$$\frac{\sum_{m=1}^{12} d'_m}{12} = d'_m - d = \delta_m$$

sezonska diferenca reducirana na vsoto 0  $[\sum \delta_m = 0]$

Analogen je postopek verižnih indeksov le da so operacije za eno računsko stopnjo višje; t.j. mesto verižne difference - verižni indeksi, mesto vsote produkti, mesto razlike kvoci-enti itd. razen pri izračunavanju povprečnih verižnih indeksov kjer ostane izračunavanje aritmetične sredine ( ako ne računamo z logaritmi ).

Postopek v simbolih je naslednji:

$$\frac{Y_{\lambda, \mu+1}}{Y_{\lambda, \mu}} = V_{\lambda, \mu}; \quad \frac{\prod_{\lambda=1}^q V_{\lambda, \mu}}{1} = V_{\mu}; \quad P_{\mu} = \prod_{\mu=1}^m V_{\mu};$$

$$V = \frac{12}{\sqrt{12}} \sqrt{\prod_{\mu=1}^{12} V_{\mu}} = \frac{12}{\sqrt{12}} \sqrt{V_{12}}; \quad P'_{12} = \frac{P_{12}}{V}; \quad P = \frac{\sum_{\mu=1}^{12} P_{\mu}}{12}$$

$$P'_{12} - P = \sum_{\mu=1}^{12} \dots$$

53. Enkratne izpremembe: Trajne enkratne izpremembe se očitujejo s spremembo splošnega nivoja časovne serije. Vpliv je viden iz višine pronosa nivoja. Vpliv enkratnih trenutnih sprememb eliminiramo s tem, da z običajno metodo interpolacije za trenotek take enkratne spremembe interpoliramo vrednost, ki bi nastopila, če te izpremembe ne bi bilo. Razlika med empirično vrednostjo in interpolirano vrednostjo je jakost vpliva enkratne spremembe. xxx

54. o s t a l e ( r e z i d u a l n e ) k o m p o n e n t e .

Po eliminaciji trenda, periodičnih oscilacij enkratnih sprememb, ostanejo v časovni seriji še izvestne komponente, ki pa so po svoji izmeri navadno manjše, kn ki so večinoma rezultat slučajnih vplivov.

xxx Glede enkratnih sprememb naj omenimo še, da pri analizi trenotne spremembe eliminiramo na ta način, da na tisto mesto vključimo interpolirano vrednost, pri trajnih spremembah pa moramo na mestu prekinitve rednega toka razdeliti časovno serijo na dva dela in za vsak del posebno določati trend.

Izračunavanje trenda po metodi polzećih povprečih

Število natovorjenih vagonov v b. Jugoslaviji.

A: Absolutni podatki  
v  $\lambda \mu$

	1933	1934	1935	1936	1937	1938
jan.	89,0	98,9	90,5	96,5	107,1	114,6
feb.	86,6	94,4	90,0	92,5	103,4	120,1
mar.	109,7	110,1	104,3	111,6	122,2	148,0
apr.	97,1	101,1	103,0	102,4	128,4	134,3
maj	110,8	113,3	116,0	114,0	129,9	143,2
jun.	106,7	113,2	110,5	116,1	136,3	139,9
jul.	109,5	111,3	125,7	129,5	152,5	148,5
avg.	127,6	125,3	137,4	145,0	163,4	168,8
sept.	152,6	136,7	152,7	155,0	169,2	171,9
okt.	152,2	153,4	169,9	171,0	132,3	178,1
nov.	130,6	132,5	147,4	150,8	151,1	156,1
dec.	106,0	110,8	110,4	129,4	133,3	132,5

B: diferencna med leti:

a  $\lambda \mu$

leto  $\lambda$

mes.  $\mu$

	1933	1934	1935	1936	1937	1938
jan.		+ 9,9	- 8,4	+ 6,1	+ 10,5	+ 7,5
feb.		+ 7,8	- 4,4	+ 2,5	+15,9	+11,7
mar.		+ 0,4	- 5,8	+ 7,3	+10,6	+25,0
apr.		+ 4,0	+ 2,7	- 1,4	+26,0	+ 6,4
maj		+ 2,5	+ 2,7	- 2,0	+15,9	+13,3
jun.		+ 6,5	- 2,7	+ 5,6	+20,2	+ 3,6
jul.		+ 1,8	+14,4	+ 3,8	+23,0	- 4,0
avg.		- 1,7	+11,5	+ 7,6	+18,4	+ 5,4
sept.		-15,9	+16,0	+ 2,3	+14,2	+ 2,7
okt.		+ 1,2	+16,5	+ 1,1	+11,3	- 4,2
nov.		+ 1,9	+14,9	+ 3,4	+ 0,3	+ 5,0
dec.		+ 4,8	- 0,4	+19,0	+ 4,4	- 1,3

C: polzeče vsote

24xTλu	1933	1934	1935	1936	1937	1938
jan.		2820,8	2785,8	2957,2	3249,0	3501,2
feb.		2820,9	2811,7	2968,6	3290,4	3503,2
mar.		2803,3	2839,2	2978,5	3323,0	3511,2
apr.		2788,6	2871,7	2981,9	3348,5	3509,2
maj		2791,7	2903,1	2986,4	3360,1	3510,2
jun.		2793,4	2917,6	3008,8	3364,8	3514,2
jul.	2766,7	2794,8	2923,3	3038,3	3376,7	
avg.	2784,4	2782,0	2931,9	3064,7	3395,9	
sep.	2792,6	2771,7	2941,7	3091,2	3433,4	
okt.	2797,0	2768,7	2947,6	3127,8	3465,6	
nov.	2803,5	2774,1	2944,2	3169,7	3485,3	
dec.	2812,5	2774,1	2947,8	3205,8	3502,2	

D: Trend izračunan s pomočjo polzečih povprečij.

Tλμ

	1933	1934	1935	1936	1937	1938
jan.		117,5	116,1	123,2	135,4	145,7
feb.		117,6	117,3	123,6	137,1	145,9
mar.		116,3	118,3	124,0	138,4	146,3
apr.		116,2	119,7	124,3	139,4	145,9
maj		116,4	121,1	124,4	139,9	146,0
jun.		116,6	121,5	125,2	140,1	146,3
jul.	115,3	116,5	121,8	126,5	140,6	
avg.	116,0	116,0	122,2	127,6	141,4	
sept.	116,4	115,5	122,6	128,7	142,9	
okt.	116,5	115,3	122,8	130,2	144,2	
nov.	116,8	116,6	122,7	132,0	145,2	
dec.	117,2	115,6	122,8	133,4	145,7	

Izračunavanje sezonskih cariacij po Bowley - Smithovi metodi odklonov od trendsa


( Število natovorjenih vagonov v mlj.v bivši Jugoslaviji)



Leto $\lambda$ mesec $\mu$	Odklon od trendsa $y_{\lambda\mu} - y_{T\lambda\mu}$						I $\sum y_{\lambda\mu}$	Py	Pu
	1933	1934	1935	1936	1937	1938			
januar	-	-10,6	-25,6	-26,6	-23,3	-31,1	-130,2	-26,0	-25,3
februar	"	-23,2	-27,0	-31,1	-23,7	-25,3	-135,8	-27,2	-26,9
marec	"	-6,7	-14,0	-12,4	-16,2	+1,7	-47,6	-9,5	-9,3
april	"	-15,1	-15,9	-21,9	-11,0	-11,1	-75,0	-15,0	-14,7
maj	"	-3,1	-5,1	-20,4	-10,0	-2,8	-41,4	-8,3	-8,1
junij	"	-3,4	-11,0	-9,1	-3,3	-16,4	-43,7	-8,7	-8,4
julij	-5,3	-5,2	+3,9	+3,0	+11,3	+7,3	+1,6	+1,6	+1,3
avgust	+11,6	+9,3	+15,2	+17,4	+22,0	+76,1	+15,2	+15,2	+15,5
september	+36,2	+21,2	+30,1	+26,3	+26,3	+140,1	+28,0	+28,0	+28,2
oktobar	+35,7	+33,1	+47,1	+40,3	+38,1	+199,3	+40,0	+40,0	+40,3
november	+13,8	+15,9	+24,7	+13,8	+5,9	+79,1	+15,3	+15,3	+16,0
december	-11,2	-4,3	-12,4	-4,0	-11,9	-44,3	-3,9	-3,9	-8,6
Vsota								-3,0	0
Vsota :12 = povprečje								-0,25	
Oznaka konstante								P	



Izračunavanje sezonskih varijacij po Personovi metodi verižnih diferenc  
 (Število natovrjenih vagonov v mlj. v bivši Jugoslaviji)

Leto $\lambda$ mesec $\mu$	Verižna diferenc $V_{\lambda\mu}$						$\sum_{\mu=1}^12 V_{\lambda\mu}$	$v_{\mu}$	$t_{\mu}$	$v'_{\mu}$	$t'_{\mu}$	$S_{\mu}$
	1933	1934	1935	1946	1937	1939						
januar	-7,1	-20,3	-13,3	-22,3	-19,2	-32,7	-16,5	-16,5	-16,9	-16,9	-25,1	
februar	-2,4	-4,5	-0,5	-4,1	+5,5	-4,7	-0,9	-17,3	-1,2	-18,1	-27,3	
marec	+23,1	+15,7	+14,3	+13,3	+27,9	+113,9	+19,0	+1,7	+13,6	+0,5	-8,7	
april	-12,6	-3,0	-0,5	-9,2	-13,2	-38,3	-6,4	-4,7	-6,8	-6,3	-15,5	
maj	+13,7	+12,2	+12,1	+11,6	+8,4	+59,5	+10,0	+5,3	+9,6	+3,3	-5,9	
junij	-4,1	-0,1	-5,5	+2,1	-3,3	-4,5	-0,7	+4,6	-1,1	+2,2	-7,0	
julij	+2,3	-1,9	+15,2	+13,4	+8,5	+54,3	+9,1	+13,7	+8,7	+10,9	+1,7	
avgust	+18,1	+14,6	+11,7	+15,5	+20,3	+91,1	+15,2	+28,3	+14,3	+25,7	+16,5	
september	+25,0	+10,8	+15,3	+10,0	+3,1	+70,0	+11,7	+40,6	+11,3	+37,0	+27,8	
oktobar	-0,4	+16,7	+17,2	+16,7	+6,2	+68,3	+11,5	+52,1	+11,1	+48,1	+38,3	
november	-21,6	-20,3	-22,5	-20,2	-22,0	-139,4	-23,1	+29,0	-23,5	+24,5	+15,4	
december	-24,6	-21,7	-37,0	-21,4	-23,6	-145,6	-24,3	+4,7	-24,7	-0,1	-9,3	
<b>Vsota</b>							+4,7			+110,7	+0,5	
<b>Vsota: 12 = povprečje</b>							+0,4			+9,2		
<b>Označba konstante</b>							v			d		





## K O R E L A C I J A .

Ekonomski pojavi ne nastopajo neodvisno eden od drugega, temveč je vsak zase rezultat medsebojnih vplivov. Videli smo že do sedaj, da je vrednost rezultativnega znaka odvisna od vrednosti faktorijelnih znakov in da se s spremembo vrednosti faktorijelnih znakov spremeni tudi vrednost rezultativnega znaka. Vendar ta odvisnost ni funkcionalnega značaja. Pri funkcionalni zvezi odgovarja vsakemu argumentu ena ali nekaj točno določenih vrednosti. V statistiki pa po pravilu odgovarja eni in isti vrednosti faktorijelnega znaka več in ne točno določenih vrednosti rezultativnega znaka. Ta variacija nastane radi nemožne opredelitve določenih faktorijelnih znakov. Take vrste zveze imenujemo za razliko od funkcionalnih, korelacijske ( correlation - odnos - razmerje ).

Razlika med funkcionalno in korelacijsko zvezo je v tem, da funkcionalna zveza velja za vsak kompleks spremenljivk, medtem ko korelacijska zveza v posameznih primerih opazovanja ne velja, temveč velja samo v povprečju za zelo statistično maso. S spremembo vrednosti faktorijelnega znaka ni nujno, da se spremeni vrednost rezultativnega znaka posameznega primera, temveč se spremeni nivo vrednosti rezultativnega znaka.

Korelacijska odvisnost rezultativnega znaka od faktorijelnega je lepo razvidna iz tabelarne analize, kjer imamo po grupah izračunana povprečja, katerih vrednost se spreminja od grupe do grupe. Ta povprečja so seveda samo izraz tipičnosti vrednosti rezultativnega znaka. Individualne vrednosti varirajo okrog teh sredin.

Ker velja korelacijska odvisnost le v povprečju ne pa za individualne primere, bomo skušali to odvisnost izraziti s krivuljo povprečij ( če gre za en faktorijelni in za en rezultativni znak). Ta krivulja bo tembolj reprezentant odvisnosti med faktorijelnim in rezultativnim znakom, čim manjši bodo odkloni individualnih vrednosti od vrednosti te krivulje. Tip krivulje mora biti izbran tako, da bo odgovarjal zvezi med faktorijelnim in rezultativnim znakom. Izbrali bomo radi enostavnosti premico, ki bo pokazala linearno odvisnost med faktorijelnim in rezultativnim znakom in se bo najbolj prilegala stvarnim vrednostim.

Povprečen kvadratičen odklon ( varianca ) od aritmetične sredine je merilo dispersije okrog aritmetične sredine. Povprečen kvadratičen odklon individualnih vrednosti od premice linearne odvisnosti je merilo dispersije okrog preme. Varianca okrog premice je manjša, kvečjemu enaka varianci okrog aritmetične sredine. Tem manjša je, čim bolj se odvisnosti prilaga stvarnim vrednostim. Na vsak način opisuje prema odvisnosti vrednosti rezultativnega znaka, boljša kot aritmetična sredina. To sledi iz tega, ker se varianca zmanjša. V koliko ga opisuje boljše, pa je razvidno iz zmanjšanja variance. Povezanost med faktorjelnim in rezultativnim znakom je tem večja, čim večje je rezultativno zmanjšanje variance. Relativna diferenca med variancama napram premi in aritmetični sredini more služiti kot merilo povezanosti vrednosti obeh znakov in jo imenujemo, ker določa jakost zveze, determinacijski koeficient  $r^2$ .

$S_y^2$  = rezultativnega znaka  
varianca od aritmetične sredine

$S_p^2$  = rezultativnega znaka  
varianca od preme odvisnosti

$r^2$  = determinacijski koeficient

$$r^2 = \frac{S_y^2 - S_p^2}{S_y^2} = 1 - \frac{S_p^2}{S_y^2}$$

Ako je  $S_p^2 = S_y^2$  kar pomeni, da se varianca ni nič spremenila, moremo reči, da premica odvisnosti ne opiše vrednosti rezultativnega znaka boljše kot aritmetična sredina. V tem primeru povezanosti ni  $r^2 = 0$ .

Ako je  $S_p^2 = 0$ , pomeni, da je varianca empiričnih vrednosti od premice odvisnosti 0, kar pomeni strogo linearne odvisnost rezultativnega znaka. V tem primeru je  $r^2 = 1$ .

Ker je  $S_p^2 \leq S_A^2$  je vrednost determinacijskega koeficienta omejena in sicer  $0 \leq r^2 \leq 1$ .

Čim večji je determinacijski koeficient, tem tesnejša je povezanost oziroma odvisnost med obema znakoma.

Ako pomnožimo  $r^2$  z 100, dobimo odstotno determinacijo, ki pove, koliko odstotkov variacije je pojasnjene z linearno povezavo.

$\frac{S_p^2}{S_A^2}$  to je  $1-r^2$  pa pove, kakšen del variacije je ostal še nepojasnen ( $1-r^2$ ) imenujemo koeficient nedeterminacije.

$\sqrt{1 - \frac{S_p^2}{S_A^2}} = r$  pa imenujemo korelacijski koeficient.

$r$  more biti pozitiven ali negativen. Pozitiven je v primeru premo odvisnosti (če se večja  $X$ , se večja tudi  $Y$ ), negativen pa v primeru obratne odvisnosti (če se večja  $x$ ,  $y$  pada). Kredno preidemo k izračunavanju koeficienta determinacije, si moramo biti na jasnem, da bomo vzeli kot premo odvisnosti tisto katera najboljše opisuje individualne vrednosti, za katere je torej srednji kvadratični odklon (varianca) najmanjša.

$(x_k, y_k)$  je  $k$ -ta dvojica vrednosti faktorjelnega znaka ( $x$ ) in rezultativnega znaka ( $y$ ).

$f = a + bx$  premo odvisnosti

$(y_k - a - bx_k)$  odklon vrednosti rezultativnega znaka od preme vrednosti

$$S_p^2 = \frac{\sum_{k=1}^N (y_k - a - bx_k)^2}{N} = \text{Min}_{a \text{ in } b} \quad \text{Pogoj za določitev parametrov}$$

Z metodo najmanjšega kvadrata je možno določiti parametra  $a$  in  $b$  in s tem korelacijski koeficient. Pri vpoštevanju gornjih predpostavk se obrazec za izračunavanje korelacijskega koeficienta glasi:

$$\frac{\sum_{k=1}^N x_k y_k - \bar{x} \bar{y}}{N} = r$$

$\bar{x} \quad \bar{y}$

Korelacijski koeficient  $r$  leži v mejah:

$-1 < r < +1$ , Korelacija more torej biti ali negativna ali pozitivna.

Pozitivna korelacija obstoji npr. med velikostjo posestva in številom živine tega posestva, med uvozom in izvozom v zunanji trgovini ( primer bivša Jugoslavija ) med starostjo in težo živine itd. negativna pa npr. med količino in ceno na kapitalističnem trgu, kjer vlada zakon ponudbe in povpraševanja, med skupno površino posestva in % njiv od skupne površine itd.

Korelacijski koeficient je zelo prikladen, ker z enim številom izraža stopnjo povezanosti dveh pojavov.

Primer izračunavanja korelacijskega koeficienta

uvoz in izvoz v bivši Jugoslaviji.

	x	y	$x^2$	$y^2$	xy
					x = uvoz y = izvoz
1921	2,5	4,1	6,25	16,81	10,25
1922	3,7	6,4	13,69	40,96	23,68
1923	8,0	8,3	64,00	68,89	66,40
1924	9,5	8,2	90,25	67,24	77,90
1925	8,9	8,8	79,21	77,44	78,32
1926	7,8	7,6	60,84	57,76	59,28
1927	6,4	7,3	40,96	53,29	46,72
1928	6,4	7,8	40,96	60,84	49,92
1929	7,5	7,6	62,41	57,76	60,04
1930	6,8	7,0	46,24	49,00	47,60
1931	4,8	4,8	23,04	23,04	23,04
1932	3,1	2,9	9,61	8,41	8,99
1933	3,4	2,9	11,56	8,41	9,86
1934	3,9	3,6	15,21	12,96	14,04
1935	4,0	3,7	16,00	13,69	14,80
$\Sigma$	87,1	91,1	580,23	616,50	590,84
: 15	5,81	6,07	38,68	41,10	39,39

$$r^2 = \frac{(\frac{\sum xy}{N} - \frac{\sum x}{N} \cdot \frac{\sum y}{N})^2}{[\frac{\sum x^2}{N} - (\frac{\sum x}{N})^2][\frac{\sum y^2}{N} - (\frac{\sum y}{N})^2]} = \frac{(39,39 - 35,27)^2}{(38,68 - 33,76)(41,10 - 36,84)}$$

$$\sigma_x = 2,22 \quad \frac{(4,12)^2}{16,9744} = 0,81$$

$$\sigma_y = 2,06 \quad 4,92 \cdot 4,26 \quad 20,9592$$

$$r = 0,9$$

$$y - 6,07 = 0,834 (x - 5,81)$$

$$y = 0,834x + 1,22$$

$y - \bar{y} = \frac{\sigma_y}{\sigma_x} r (x - \bar{x})$  pokaže linearno odvisnost znaka in ga imenujemo regresijsko enačbo. Ako zamenjamo v tej enačbi  $y$  z  $x$ ,  $x$  pa z  $y$ , dobimo

$$x - \bar{x} = \frac{\sigma_x}{\sigma_y} r (y - \bar{y})$$

$r$  ostane isti radi tega, ker je glade  $x$  in  $y$  simetričen. Ta veza kaže odvisnost  $x - a$  od  $y - a$

Te premici se ne skladata, ker koeficienta

$\frac{\sigma_y}{\sigma_x} r$  in  $\frac{\sigma_x}{\sigma_y} r$  nista recipročni vrednosti.

Imamo torej 2 regresijski premii, ki gresta preko točke  $\bar{x}$ ,  $\bar{y}$ , to je skozi aritmetično sredino.

Za prejšnji primer dobimo naslednji regresijski enačbi:

$$1. y - 6,07 = \frac{2,06}{2,22} \cdot 0,9 (x - 5,81) \quad y = 0,834x + 0,69$$

$$2. x - 5,81 = \frac{2,22}{2,06} \cdot 0,9 (y - 6,07) \quad x = 0,97y - 0,73$$

Korelacijska teorija razvija svoje izvajanje tudi na večje število pojavov, ki se med seboj povezujejo. V teh primerih gre za tkz. multiple in partielne korelacije.



O S N O V N E M E T O D E I Z B O R A .

1. ZAKON VELIKIH ŠTEVIL.

Naloga statistike ni samo opazovanje o obsegu in notranji sestavi statističnih mas, temveč tudi iskanje zvez in zakonitosti odnosov, ki se pojavljajo v socialno-ekonomskih pojavih. Že v prejšnjih odstavkih smo videli, da je vrednost rezultativnih znakov plov vplivov faktorialnih znakov, ki se razdele v dve grupi: prva grupa tkzv. opredeljujočih znakov, katerih vrednosti moremo v vsakem konkretnem primeru določiti (n.pr. pri hektarskem odnosu vrsta žita, način gnojenja itd.) in druga grupa vplivov in pogojev, ki jih radi svoje narave ne moremo opredeliti (konkretno pogoji rasti, mikro sestav zemlje itd.) in ki jih združimo v grupo slučajnih vzrokov. Vendar moremo opazovati, da se vplivi slučajnih vzrokov, ki niso dosegljivi našemu evidentiranju in reguliranju med seboj kompenzirajo in uničujejo in izbije iz rezultata tembolj značilnost tipičnosti in zakonitosti vrednosti ali odnosov, čim večje smo vzeli število opazovanj oz. enot v statistični masi, iz katere smo dognali rezultat. N.pr. primer: Opazujemo shematični primer metanja novca, kjer je statistična enota posamezen met novca, statistična masa vsi izvršeni meti, vrednosti znaka ena ali druga stran novca (številka ali grb). Pogoji metanja niso enostranski, tako da bi bila tendenca za met ene ali druge strani, in novac je simetričen. Ako pogledamo posamezen met, oddvojeno, more pasti ali cifra ali grb. Razmerje med obema je torej pri posameznem metu  $1 : 0$ , ali torej  $0 : 1$  brez zakonitosti. Ako vzamemo celo vrsto metov in pogledamo, kolikokrat je bila vržena cifra, kolikokrat grb, bomo videli, da se razmerje tembolj izenačuje in bliža vrednosti  $1 : 1$ , čim večje število smo izvršili. Čim večje število metov izvršimo, tem bolj se očituje zakonitost, da je met tako cifra kot grba enakoverjeten, in da je razmerje med njima  $1 : 1$ .

2. primer: Ako opazujemo spol otrok ima neka družina lahko samo sinove, druga same hčere. Ako pa opazujemo odnose v velikem številu rojstev, bomo dobili vedno bolj stalno razmerje 106 moških na 100 ženskih rojstev. Drugačno razmerje pri malo pri-

merih izhaja radi vpliva slučajnih vzrokov.

Gornja lastnost, da se tipične vrednosti ( srednje vrednosti ) in odnosi oz. lastnosti v homogenih statističnih masah z izvestnim povečanjem števila opazovanih enot bližja neki stalni vrednosti in da se ta vrednost z dodajanjem nadaljnjih vrednosti enot ne spremeni bistveno, imenujemo v statistiki zakon o velikih številih. Ta zakon je za iskanje zakonitosti masovnih pojavov osnovne važnosti in je bil radi tega predmet tako teoretikov, ki so izvedli njegov matematičen dokaz ( Laplace, Gauss, Poisson, Čebišev ) tako empirikov, ki so dokazali, da zakon v celoti velja v praksi ( Buffon, ki je z 4040 meti novca dobil razmerje 49, 31 : 50, 69. Karl Pearson, ki je z 24.000 poskusi dosegel razmerje 50,05 : 49,95 ). Vendar si moramo biti na jasnem, da je problematika v socialno-ekonomskih pojavih bolj zapletena, kot v teoretičnih poskusih z novci, kockami itd.

Gornja zakonitost je napotila statistike do vprašanja, ali ne bi bilo mogoče, ako velja zakon velikih števil, priti do statističnih zaključkov že na podlagi samo delnega opazovanja statistične mase. Iz tega se je razvila celotna veja matematične statistike, ki je do podrobnosti razvila možnosti izrabe teh metod in ki se v statistiki imenuje metoda vzorca. Predno preidemo na opis same metode vzorca ( izbora ), moramo prej razčistiti še par pojmov, ki bodo za nadaljnja razmotravanja potrebni.

## 2. VERJETNOST:

### SPLOŠEN POJEM.

Ako imamo določen pojav, bodisi shematičen ali socialno ekonomski, ima vsaka enota za določen znak realizirano eno izmed možnih vrednosti. Čeprav za posamezne enote te mase ne moremo naprej vedeti kakšno vrednost ima, moremo pri ložnavanju zasedenosti z vrednostmi predvidevati kakšno vrednost znaka bo imela določena enota. To predvidevanje moremo določiti pojma verjetnosti. Čim več enot mase ima neko določeno vrednost znaka, temvečja je verjetnost, da ima posamezna enota to vrednost znaka. Število enot z določeno vrednostjo v statistični masi se v tem primeru meri z relativno zasedenostjo, ki jo dobimo, da število enot z določeno vrednostjo delimo z celotnim številom enot mase.

Matematično je verjetnost limita ulomka število ugodnih primerov napram skupnemu številu primerov.

$$\lim_{n \rightarrow \infty} \frac{nk}{n} = pk = \text{verjetnost.}$$

V teoriji verjetnosti imamo običajno opravka z verjetnostjo "a priori", to pomeni, da operiramo s pojavi in shemami, za katere je možno že vnaprej določiti verjetnost ponavljanja. N.p.r. metanje kocke; verjetnost da vržemo številko 3 je  $1/6$ , ker imamo 6 številke, od 1-6, od katerih za nobeno ni razloga, da bi bila verjetnost za nastop manjša, pri vsakem metu pa mora pasti ena izmed šestih številke, verjetnost za nastop katerekoli številke je 1, za eno samo številko torej  $1/6$ . Ta verjetnost se da določiti, ne da bi predhodno izvršili eksperiment in število ugodnih slučajev delili s številom možnih slučajev in iskali limito tega ulomka.

V statistiki je prinosialno - ekonomskih pojavih nemogoča ne enak način, kot v zgornji shemi določati verjetnost za nastop nekega dogodka ali pojava. V statistiki izvedemo najprej opazovanje poedinih pojavov in šele naknadno določimo, kolik je odnos ugodnih do možnih slučajev. Na ta način dobimo verjetnost nastopa določenega pojava šele naknadno po poiskus, zato imenujemo tako verjetnost "a posteriori". Ako imamo v neki statistični masi  $N$  enot, od teh pa jih ima  $n$  vrednost znaka  $A$ , je verjetnost za nastop vrednosti  $P(A) = \frac{n}{N}$ .

(Ako sestoji statistična masa iz 800 gospodinjstev od katerih jih je 200 z 3 člani, pravimo, da je statistična verjetnost ali relativna frekvenca (ker je v stvari to frekvenca v odnosu na celoto)  $P(3) = \frac{200}{800} = 0,25$ .

800

Verjetnost 0,25 pomeni, da bi, ako bi napravili poiskus in iz 800 gospodinjstev slučajno izbrali posamezna gospodinjstva, v limiti, to je z velikim številom ponavljanj tega postopka v 0,25 slučajih od celotnega števila naleteli na gospodinjstvo z 3 člani.

Ako izračunamo relativne frekvence za celo serijo dobimo serijo relativnih frekvenc. Vsota vseh relativnih frekvenc je enaka 1, kar pomeni, da ima vsaka statistična enota mase realizirane eno izmed vrednosti znaka.

Primer diskontinuirane serije:

Razdelitev družin po številu otrok

Število otrok	Število družin	Relativna frekvence
1	12.788	0,34226
2	11,630	0,31126
3	6,399	0,17126
4	3,721	0,09959
5	1,838	0,05053
6	710	0,01900
7	177	0,00484
8	40	0,00107
9	9	0,00024
10	2	0,00005
Skupno	37.364	1,00000

V statistiki se je utrdila terminologija, da govorimo v primeru majhne statistične mase o relativnih frekvencah, v primeru velikih mas pa o verjetnostih.

Kadar je osnovni znak statistične serije zvezen, ne moremo navesti frekvenc za vsako vrednost znaka, temveč tvorimo razrede, poiščemo frekvence v teh razredih, in iz teh frekvenc izračunamo relativne frekvence.

Trajanje gorenja žarnic

Ure gorenja	štev. žar.	relativ. frekvence
-600	3	0,0333
nad 600-800	10	0,1111
nad 1000-1200	32	0,3556
nad 800-1000	33	0,3667
nad 1200-1400	9	0,1000
nad 1400-1600	3	0,0333
	90	1,0000

ako vzamemo iz tega kolektiva 90 žarnic na slepo eno žarnico, je verjetnost 0,3667, da bo gorela od 800-1000 ur. Grafično se da relativna frekvence pokazati z histogramom. Vsota ploščin vseh stolpcev je enaka 1. Ploščina posameznega stolpa pa je direktno enaka relativni frekvenci oz.

verjetnosti za nastop pripadajoče vrednosti.

Ako bi povečali število preizkušenih žarnic, za katere smo izvršili merjenje od 90 n.pr. na 10.000, razrede pa zožili na razrede z širino 10 ur, izračunali relativne frekvence in narisali frekvenčni poligon, bi dobili sliko, ki bi bila sicer

prvi podobna vendar bolj precizna, ker bi pokazala relativne frekvence za manjše intervale. V tej sliki bi dobili boljši vpogled v razdelitev posameznih vrednosti. Teoretično bi prišli z večanjem števila žarnic, ki jih vključujemo v statistično maso in manjšanje širine razreda v limiti do zvezne slike razporeditve verjetnosti. Stopničasto sliko bi zamenjala krivulja.

## 22. SEŠTEVANJE VERJETNOSTI oz. relativnih frekvenc.

Ako pogledamo primer razdelitve družin po številu otrok in se vprašamo po relativni frekvenci družin z 3 ali 4 otroci, moramo po gornjem pravilu deliti število družin z 3 ali 4 člani t.j.  $6.399 + 3721$  z skupnim številom vseh družin  $37.364$  torej  $\frac{6399 + 3.721}{37.364} = 0,27085$ .

$$\frac{6399 + 3.721}{37.364}$$

Vidimo torej, da pridemo do istega rezultata, ako relativna frekvence oz. verjetnosti seštejemo.

Verjetnost, da bi imela slučajno izbrana družina iz kolektiva  $37.364$  družin 3 ali 4 otroke je torej  $0,27085$ . Vidimo, da se v primeru, da gre za verjetnost nastopa ene ali druge vrednosti znaka, verjetnosti enostavno seštevajo. N.pr. verjetnost, da ima slučajna izbrana družina manj od 5 otrok, bo enaka verjetnost, da ima družina ali enega ali dva, ali tri, ali štiri otroke, torej  $( 1 \text{ ali } 2 \text{ ali } 3 \text{ ali } 4 ) = 0,34226 + 0,31126 + 0,17126 + 0,99959 = 0,92437$ .

Paziti moramo seveda, da gornji stavek velja samo v primeru, da gre za vrednosti znaka, ki se izključujejo. Ne velja n.pr. v naslednjem primeru.

Verjetnost družine z 1 ali 2 otroci je  $0,65352$

Verjetnost družine z 2 ali 3 otroci je  $0,49252$

Verjetnost družin z (ali 2) ali (2 ali 3) otroci ni enaka  $1,13604$  kot bi veljalo po gornjem stavku, kar pa je popoln nesmisel, ker verjetnost ne more biti večja od 1, temveč manjša, ker se gornja dva pojavi ne izključujeta (število otrok 2 imamo v prvi in drugi skupini). Vendar tega stavka ne bomo naprej razvijali, ker bomo v nadaljnjem imeli opravka samo z verjetnostmi, ki se izključujejo. V primeru kontinuiranega znaka se bo gornji stavek izkazal v tem. Verjetnost, da bo gorela žarnica od 600-1.000 ur je enaka vsoti verjetnosti, da bo gorela od 600-800 ur in verjetnosti, da bo gorela od 800-1.000 ur. Torej

$P(600 - 1.000 n) = P(600 - 800) + P(800 - 1.000) =$   
 $0,1111 + 0,3667 = 0,4778$ . Na sliki bo ta verjetnost dana  
z vsoto ploščin obeh stolpcev med mejama 600 - 1.000 ur.  
Ako smo frekvenčno distribucijo izdelali do podrobnosti (ve-  
lika masa, majhna širina razredov) smo v limiti prišli iz  
stopnjčaste distribucijske krivulje. V tem primeru je ver-  
jetnost za vrednost v poljubnem intervalu dana z vsoto plošč-  
čin stolpcev med tema mejama ali v limitiranem procesu s  
ploščino, omejeno z delom abscise med mejama, z ordinatama  
nad mejama in delom krivulje verjetnostne distribucije. Po-  
vršina med celotno absciso in krivuljo verjetnostne distri-  
bucije je v vseh primerih enaka 1. Geometrijskega oz. grafič-  
nega podajanja verjetnosti se bomo posluževali v vseh nadalj-  
njih izvajanjih, ker je najlažje razumljivo.

Ostalih stavkov verjetnostnega računa se ne bomo  
dotikali, ker za elementarno razumevanje vsebine teorije  
vzorca niso potrebni.

### 3. NADOMEŠTNE METODE STATISTIČNEGA OPAZOVANJA.

31. Splošno. Statistična opazovanja so običajno v praksi akcije ogromnega obsega. Radi velikega števila enot (popis prebivalstva milijone, kmetijski popisi stotisoče) zahtevajo velika materialna sredstva, široko razpredeno organizacijo, ogromno armado kadrov, ki jih je treba šele učiti izvajati konkreten popis in obdelavo na eni strani, na drugi strani pa razmeroma dolgo dobo, predno pridemo do rezultatov. Velika finančna sredstva, nezanesljivost velikega števila kadrov in prekasna možnost koriščenja podatkov je dala že zgodaj nisliti, ali bi se mogla najti metoda, ki bi gornje hibe odpravila.

S statističnimi akcijami hočemo dobiti uvid v tranji sestav statistične mase, ugotoviti zakonitosti, ki vladajo v socialno-ekonomskih pojavih s tvorjenjem grup, z izračunavanjem karakterističnih veličin (srednjih vrednosti, disperzije, korelacijskih koeficientov, relativnih števil itd.). Pod vplivom veljave zakona o velikih številih, po katerem se z večanjem števila opazovanih enot vedno bolj razkrivajo zakonitosti masovnih pojavov, se pojavlja vprašanje, dali je mogoče z opazovanjem samo dela enot statistične mase napraviti zaključke o statistični masi, oz. o socialno-ekonomskem pojavu.

Ena izmed teh nadomestnih metod je anketa, ki predstavlja deloma številčni, deloma deskriptivni opis pojava.

V statistični praksi je bila dolga časa zelo uporabljena metoda, da se je z izbiro tipičnih pojavov oz. enot sklepalo na dogajanja v celoti. Iz te se je razvila monografska metoda. Bistvo monografske metode je bilo, da se je podrobno proučilo za določeni pojav nekaj tipičnih objektov oz. pojavov. Rezultate iz teh raziskovanj se je na to posplošilo na celoto. N.pr. z monografskim opisom tipične vasi se je osvetilo življenje kmetov, z študijo budžetov tipičnih družin sklepalo na budžete v splošnem. Ta metoda tipičnih pojavov se je v statistiki dolgo časa

obdržala. Vendar jo je v novejšem času radi tega, ker je izbira tipičnih enot oz. pojavov preveč subjektivna, popolnoma izpodrinila druga metoda t. j. metoda slučajnega izbora. Izbira enot, ki jih bomo izbrali iz celote, ni več odvisna od osebe, ki izbor vrši, temveč je izbor popolnoma objektivno, ker je vsaka enota izbrana slučajno. To dejstvo omogoča, da moremo postaviti temu izboru objektivne znanstvene temelje, ki slone na verjetnostnem računu. Ker je ta metoda izmed vseh nadomestnih metod najobjektivnejša in je njena uporaba vedno večja, se bomo z njo podrobneje pobavili. Ta metoda je matematično zelo izdelana in tvori doberšen del zanimanja matematičnih statistikov.

32. O nadomeščanju kolektiva z eno samo vrednostjo. Vzemimo na splošno neko statistično maso, v tej statistični masi opazujemo nek znak. Vrednosti tega znaka varirajo od enote do enote, za določen znak oz. maso manj za drug znak oz. maso bolj. Kot nam je že znano, označimo to variabilnost z varianco  $\sigma^2$  oz. z standardno deviacijo  $\sigma$ . Tipična vrednost, ki najboljšje reprezentira vrednost vseh enot, pa je aritmetična sredina  $A$ .
- Postavlja se vprašanje, v koliko mora biti vrednost katere koli enote ( slučajno izbrane ), reprezentant vseh vrednosti oz. aritmetične sredine. V ekstremnem primeru, kjer bi bile vrednosti za vse enote iste, bi bila vrednost vsake poljubne enote direktni reprezentant, ker bi bile vse vrednosti enake, in bi bilo potrebno pogledati samo vrednost ene same enote in bi s tem poznali vse ostale vrednosti z aritmetično sredino vred. V tem primeru bi bila varianca 0. Takih ekstremnih primerov pa v statistiki nimamo. V realnih statističnih masah nastopa vedno variabilnost vrednosti znakov. V tem primeru pa bo vrednost posameznega člana statistične mase temboljša reprezentirala vrednosti vseh odn. aritmetično sredino, čim manjši bo odklon od aritmetične sredine, ki je najboljši možen reprezentant. Možni odkloni poljubnega člana pa bodo tem manjši, čim manjša bo variabilnost vrednosti znaka. Vzemimo dva kolektiva ljudi, in za vsake kolektiv opazujemo višino. V prvem smo ugotovili, da je 95% višin vseh ljudi v intervalu 163 - 172 cm. in da aritmetična sredina enaka 170 cm. Ako se poslužimo stavka o verjetnosti, moremo reči, da je 95% verjetnosti, da bo višina povprečnega človeka tega kolektiva med 168 -



172 cm, oz. da je 95% verjetnosti, da odklon višine poljubne enote od aritmetične sredine ne bo večji od 2 cm.

V drugem kolektivu pa smo ugotovili, da je 95% višin vseh ljudi tega kolektiva v mejah 124 - 176 cm in da je aritmetična sredina 150 cm. Poleg tega pa smo ugotovili, da smo 30% vseh enot v intervalu 148 - 152, torej z odklonom od aritmetične sredine, ki je manjši ali enaka 2 cm.

Na prvi pogled je vidno, da je variabilnost v prvem primeru znatno manjša kot v drugem, in da je radi tega vrednost znaka poljubne enote, boljša ocena vrednosti drugih členov in aritmetične sredine kot pa kolektiv drugega primera. Čim manjša je variacija, tem več posameznih vrednosti je v neposredni aritmetične sredine.

### 33. NORMIRAN ODKLON.

Ako iz neke statistične mase, ki ima za določen znak povprečno vrednost  $\bar{x}$ , vzamemo neko enoto  $i$ , bo ta enota imela vrednost znaka  $x_i$ . Odklon  $x_i - \bar{x}$  od aritmetične sredine je odklon individualne vrednosti od aritmetične sredine. Ta odklon imenujemo "konkretni odklon". Ta odklon, čeprav absolutno enak, je, odvisno od mase lahko relativno velik ali majhen, glede na to, ali ima večje ali manjše število vrednosti mase večje konkretne odklone. Za določeno vrednost  $x_i$ , za katero je absolutna vrednost konkretni odklon ( $x_i - \bar{x}$ ), moremo vse enote razdeliti na dva dela, v one, za katere je konkretni odklon večji in v one, za katere je konkretni odklon manjši od tega odklona.

Ta odklon je relativno majhen, ako je odklon za veliko število enot večji ali relativno velik, ako se konkretni odkloni za veliko število vrednosti manjši. To je odvisno od variabilnosti pojave. Zato običajno odklone merimo v relativnih tkzv. normiranih odklonih, kjer so odkloni merjeni v enotah standardne deviacije celotne mase.

Ako zaznamujemo normirani odklon z  $t$  je:

$$t = \frac{x_i - \bar{x}}{\sigma_x}$$

to je neimenovano število, ker imata konkretni odklon in standardna deviacija isto enoto mere, enoto opazovanega znaka.

Ako je distribucija normalna, je verjetnost, da bo normiran odklon manjši od določenega  $t$ , za vse normalne distribucije, neglede na velikost standardne devijacije distribucije vedno enaka.

Za normalno distribucijo, ki ena osnovnih distribucij teoretične statistike veljajo naslednje vrednosti:

$t$	$P \left( \frac{ x_i - \bar{x} }{\sigma_x} \leq t \right)$
0,6745	0,5000
1,0000	0,6827
1,9600	0,9500
2,0000	0,9545
3,0000	0,9973

kar pomeni, da je verjetnost  $P$ , da velja za  $x_i$  neenačba

$$\bar{x} - t\sigma_x < x_i < \bar{x} + t\sigma_x$$

Ako imamo normalno distribucijo, v kateri je  $\bar{x} = 10$   $\sigma = 2$  je 95% verjetnosti, da leži individualen primer v razmaku

$$10 - 1,96 \cdot 2 < x_i < 10 + 1,96 \cdot 2$$

$$6,08 < x_i < 13,92$$

Tudi pri ostalih teoretičnih distribucijah je verjetnost za določene normirane odklone stalno neodvisna od standardne devijacije. Običajno pa nas zanima obratni problem:

Kolika verjetnost je, da se v dani okolici individualnega podatka nahaja aritmetična sredina, ker na podlagi tega ocenimo interval, v katerem se z določeno verjetnostjo nahaja aritmetična sredina.

Za določen del, ki ga predstavlja  $P \left( \frac{|x_i - \bar{x}|}{\sigma_x} \leq t \right)$  vseh  $x_i$  velja po prejšnjem,

$$\bar{x} - t\sigma_x < x_i < \bar{x} + t\sigma_x$$

Ako od te neenačbe odštejemo  $x_i + \bar{x}$  bom še vedno veljala za iste  $x_i$ . Na ta način dobimo:

$$-x_i - t\sigma_x < -\bar{x} < -x_i + t\sigma_x$$

Ako neenačbi spremenimo predznak, moramo obrniti tudi znake neenačbe in dobimo:

$$x_i + t\sigma_x > \bar{x} > x_i - t\sigma_x$$

Na ta način vidimo, da je možno z poznavanjem standardne devijacije

vijacije, z določitvijo verjetnosti, za koliko enot naj ta neenačba verjetno velja ( s tem dobimo t ) izračunati, v katerem intervalu okrog individualne vrednosti leži aritmetična sredina.


Ako ponovimo gornji primer, in vzamemo iz statistične mase za katero je distribucija normalna, poljubno enoto, za katero je vrednost opazovanega znaka  $x_i$ , je 95% verjetnosti, da smo izbrali tak  $x_i$ , da bo aritmetična sredina  $\bar{x}$  ležala v intervalu

$$x_i - 1,96 \cdot s \leq \bar{x} \leq x_i + 1,96 \cdot s$$

$$x_i - 3,92 \cdot s \leq \bar{x} \leq x_i + 3,92 \cdot s$$

Ako narišemo relativne distribucije grafično, bo verjetnost nastopa individualne vrednosti v določenem intervalu dana z ploščino lika, ki je omejen z

1. danim intervalom abscisne osi,
2. obema ordinantama nad mejama intervala,
3. z delom distribucijske krivulje nad intervalom.



Pri simetričnih distribucijah je

$$S(c) = \frac{1}{2} \quad S(+t) + S(-t) = 1$$

in velja med  $S(t)$  naslednja zveza

$$2 S(-t) + F(t) = 1 \quad 2 S(+t) + F(t) = 1$$

$$F(t) + 1 = 2 S(+t)$$

Iz tega prejšnjega odstavka je razvidno, da je pri znanem tipu distribucije za določen normiran odklon možno določiti verjetnost, s katero lahko pričakujemo, da bo za poljubno izbrani člen distribucije  $x_i$  ležal  $\bar{x}$  v intervalu.

$$x_i - t\sigma < \bar{x} < x_i + t\sigma$$

obratno moramo trditi, kar delamo pogosteje, da je pri dani distribuciji za določeno verjetnost  $F(t)$ , možno najti normiran odklon  $t$  tak, da bo z verjetnostjo  $F(t)$  izbran poljuben  $x_i$ , tak, da bo  $\bar{x}$  ležal v intervalu.

$$x_i - t\sigma < \bar{x} < x_i + t\sigma$$

Na ta način je z intervalom, dana ocena za  $\bar{x}$ , z dano verjetnostjo  $F(t)$ , da ta ocena velja.

Te stavke smo v nadalnjem zelo pogosto uporabljali.

### 34. CELOKUPNA STATISTIČNA MASA, DELNA MASA ALI VZOREC.

Skupnost vseh enot opazovane statistične mase imenujemo celokupno statistično maso. Število enot v celokupni statistični masi bodo vselej zaznamovali z  $V$ . Vsaka izmed enot ima različne vrednosti znakov. Da inamo vpogled v celotno maso iz teh vrednosti izračunamo za celoto strukture, srednje vrednosti, standardne devijacije, itd. splošno količine, s katerimi je opisana statistična masa. Vse te vrednosti za celokupno maso bodo zaznamovali z grškimi črkami n. pr.  $\bar{x}$  pomeni aritmetična sredina za celokupno maso  $x$  itd.

Iz celokupne statistične mase moremo izbrati  $n$  enot, ki tvorijo delno maso celotne. Tako delno maso imenujemo vzorec z obsegom  $n$  iz celotne mase. Vzorec ga imenujemo radi tega, ker skušamo sklepati iz razmer v tem vzorcu na razmere v celotni masi.

Takih različnih delnih mas, oz. vzorcev z obsegom  $n$  moremo iz celotne mase z obsegom  $V$  več, v splošnem toliko, kolikor je možnih kombinacij z  $n$  členi iz kompleksa z  $V$  členi, t. j.  $\binom{V}{n}$ . Ako je  $V = 6$ ,  $n = 3$ , je možnih  $\binom{6}{3} = 20$  vzorcev, t. j.  $6.5.4 = 20$  Število vseh možnih vzorcev z danim obsegom pri 1.2.3

dani masi je kot vidimo veliko. Radi tega moremo smatrati celokupnost vseh možnih vzorcev kot samostojno maso vzorcev. Enota je posamezen vzorec. Kakšni so opredeljujoči znaki take enote? Da je določena statistična masa enota kolektiva vseh vzorcev, mora imeti določen obseg  $n$ , in mora biti vzeta iz iste

osnovne mase.

Vedeti moramo seveda, da po vsakem "vzorcu", ki ga vzamemo iz statistične mase, enote, ki so bile izbrane, ponovno vložimo v celokupno maso.

Vsak vzorec, če naj bo statistična enota mora imeti svoje znake in vrednosti teh znakov. Znak posamezne enote vzorca je lahko aritmetična sredina določenega znaka osnovne enote v tem vzorcu, ki jo zaznamujemo z  $a$ , ali standardna deviacija  $s$ , strukturni procent določenega znaka  $p$ , korelacijski koeficient izračunan iz tega vzorca  $r$  itd. Ker so enote posameznih vzorcev različne, se od vzorca do vzorca spreminjajo tudi gornje vrednosti. Vidimo, da imajo znaki vzorcev prav lastnosti statističnih znakov, variranje. Vsak tak znak mase vzorcev (ker je tu masa vseh možnih vzorcev jo imenujemo statistično skupnost) ima svojo aritmetično sredino  $A$  ( $a$ ) izračunano iz vrednosti vseh vzorcev, svojo standardno deviacijo  $S$  ( $a$ ) in druge.

V našem odtayku o metodi izbora, bomo uporabljali naslednje enake. Karakteristične količine v osnovni skupnosti zaznamujemo z grškimi črkami, karakteristične količine posameznega vzorca z malimi latinskimi črkami, karakteristične količine skupnosti vseh vzorcev z velikimi latinskimi črkami.

	Osnovna skupnost	Vzorec	Skupnost vzorcev
Število enot	$V$	$n$	$N$
Aritmetična sred.	$\bar{x}$	$a$	$A$
Varianca	$\sigma^2$	$a^2$	$S^2$
Štev. dev.	$\sigma$	$s$	$a$

351. Zakonitosti med količinami celokupne mase, delne mase in mase vzorca.

Teorija vzorcev gre za to, da skuša dobiti zveze, v koliko bi mogli razmere v vzorcu posplošiti kot razmere v celoti. To je možno radi tega, ker veljajo med karakterističnimi količinami osnovne celokupnosti vzorcev določene zakonitosti in zveze. Mi bomo našteali od zvez samo one količine, ki se najpogosteje uporabljajo t. j. aritmetična sredina in standardna deviacija.

na devijacija.

1. Število vseh možnih vzorcev  $N$  je enako številu kombinacij.

$\binom{V}{n} = N$  ako ima osnovna skupnost 10 enot je iz te mase možnih  $\binom{10}{5}$  različnih vzorcev po 5 enot.

$$N = \binom{10}{5} = \frac{10 \cdot 3}{1} = 210$$

V splošnem je  $N$  t.j. število vseh možnih vzorcev zelo veliko, kar se z večanjem  $V$  - ja  $N$  zelo večja.

2.  $A(a) = \alpha(x)$  Aritmetična sredina aritmetičnih sredin določenega znaka vseh možnih vzorcev je enaka aritmetični sredini znaka v osnovni celokupnosti,

3.  $S^2(a) = \frac{\sigma^2(x)}{n} \cdot \frac{V-n}{V-1}$  Varianca aritmetične sredine

a vseh možnih vzorcev  $S^2(a)$ , je z varianco znaka osnovne skupnosti  $(\sigma^2(x))$  z številom enot v vzorcu ( $n$ ) in številom enot osnovne skupnosti ( $V$ ) v zvezi, kot kaže enačba pod (3).

Z večanjem velikosti vzorcev, t.j. z večanjem  $n$  se varianca skupnosti vseh aritmetičnih sredin vzorcev manjša.

Ako je število enot osnovne skupnosti veliko, se zveza v limiti približa enačbi:

$$\lim S^2(a) = \frac{\sigma^2(x)}{n}$$

4. Aritmetična sredina varianc vseh možnih vzorcev je v naslednji zvezi z varianco v celokupnosti in številom enot in  $n$ .

$$A(s^2) = \sigma^2(x) \frac{n-1}{n} \cdot \frac{V}{V-1}$$

Ako je število enot osnovne skupnosti veliko, kar običajno je, limitira  $A(s^2)$

$$\lim A(s^2) = \sigma^2(x) \frac{n-1}{n}$$

5. Za velik je varianca varianc ( $s^2$ ) vseh možnih vzorcev znaka

$$S^2(s) = \frac{\sigma^2(x)}{2n}$$

Za preizkus veljavnosti zgorajjih zakonitosti izvršimo v celoti računski primer z majhnimi števili enot:

Vzemimo osnovno celokupnost 6 enot.

$$V = 6$$

1 2 3 4 5 6 R.št.enote

1 1 4 4 4 4 vrednost znake xi

Iz te skupnosti vzemimo vse možne vzorce z 3 enotami

Možni vzorci Vrednosti n = 3

xi v vzorcih

123	114	
124	114	V celoti so možni vzorci
125	114	4 krat 114
126	<u>114</u>	12 krat 144
134	144	4 krat 444
135	144	
136	144	
145	144	Že na prvi pogled je vidno, da
146	144	ima največ vzorcev sličen no-
156	144	tranji sestav kot celota t.j.
234	144	vrednosti 1 in 4 v razmerju
235	144	1 : 2
236	144	
245	144	
246	144	
256	<u>144</u>	
345	444	
346	444	
356	444	
456	444	

	frek- venca	vzorec	arit. sredina	Varianca
1 vzorec	4	114	2	2
2 vzorec	12	144	3	2
3 vzorec	4	444	4	0
skupnost vseh vzorcev	20	-	3	8/5

$$N = \binom{V}{n} = \binom{6}{3} = \frac{6 \cdot 5 \cdot 4}{1 \cdot 2 \cdot 3} = 20$$

$$\sigma(x) = \frac{1+1+4+4+4+4}{6} = 3$$

$$\sigma^2(x) = \frac{4+4+1+1+1+1}{6} = 2$$

$$A(a) = \frac{4x^2+12x^3+4x^4}{20} = \frac{8+36+16}{20} = \frac{60}{20} = 3$$

$$s^2(a) = \frac{4 \cdot (2-3)^2 + 12x(3-3)^2 + 4x(4-3)^2}{20} = \frac{4+0+4}{20} = 2/5$$

$$A(s^2) = \frac{4x^2+12 \cdot 2+4 \cdot 0}{20} = \frac{8+24}{20} = \frac{32}{20} = 8/5$$

$$s^2(a) = \frac{A(a) = \sigma(x)}{n} \cdot \frac{V-n}{V-1} \quad 3=3 \quad 2/5 = \frac{2}{3} \cdot \frac{6-3}{6-1} = \frac{2}{3} \cdot \frac{3}{5} = 2/5$$

$$A(s^2) = \frac{\sigma^2(x)}{n} \cdot \frac{n-1}{V-1} \quad 8/5 = 2 \cdot \frac{3-1}{3} \cdot \frac{6}{6-1} = 2 \cdot \frac{2}{3} \cdot \frac{6}{5} = 8/5$$

352. Ocenjevanje aritmetičnih sredin.

Poleg gornjih vez veljajo pa še naslednje zakonitosti:

a) Normirani odkloni aritmetičnih sredin vseh možnih vzorcev danega obsega  $n$ , se distribuirajo v tkz. "Studentove  $t$  - distribucije. Enačba za gostoto Studentove - distribucije je:

$$f(n,t) = C \cdot \left( 1 + \frac{t^2}{n-1} \right)^{-\frac{n}{2}}$$

$C$  je konstanta,  $n$  je parameter (število enot v vzorcu),  $t$  je spremenljivka (normiran odklon)

Kot smo navedli v prejšnjih odstavkih, pomeni ploščina omejena od intervala dela abscisne osi, končni ordinant tega intervala in dela pripadajoče krivulje verjetnost s katero pričakujemo, da bo imel individualen normiran odklon vrednost med spodnjo in gornjo mejo intervala.

Kot vidimo je Studentova  $t$  distribucija simetrična  $f(n_1, t) = f(n_1, -t)$  in ima modus za vrednost  $t = 0$   
 $f(n, 0) = \text{Maks.}$

Za naša nadaljnja razmotrivanja ni važna podrobna obrav-



nava te distribucije, temveč potrebujemo samo podatke o tem, kolike so verjetnosti, da bo normiran odklon ležal v intervalu od  $-t$  do  $+t$ . Vprašanje običajno postavljamo obratno, da izberemo verjetnosti in na podlagi teh določimo pripadajoče vrednosti  $t$ -ja.

Običajno postavljamo te verjetnosti enake:

50 %, 90 %, 95 %, 99 %, 99,9 %

Na ta način dobimo interval, v katerem se z določeno verjetnostjo nahaja normiran odklon, za individualen vzorec

$$-t < \frac{a - A(a)}{S(a)} < +t \quad \text{xx}$$

Vendar ta ocena ne more služiti za oceno aritmetične sredine  $\bar{x}$  osnovne skupnosti, ker pove odklon od aritmetične sredine vseh sredin vzorcev.

Ker pa je po (2)  $\bar{x} = A(a)$

moremo gornjo neenačbo pisati v obliki:  $-t < \frac{a - \bar{x}}{S(a)} < +t$

Poleg tega je nemogoče izračunati standardno deviacijo aritmetičnih sredin vseh vzorcev  $S(a)$ .

Po stavku (3) je  $S(a) = \frac{S(x)}{\sqrt{n}} \sqrt{\frac{v-n}{v-1}}$

Vendar je tudi  $S(x)$  t.j. standardno deviacijo osnovne skupnosti nemogoče izračunati.

Radi tega jo moramo skušati oceniti na kak drug način. Po stavku 4 je aritmetična sredina vseh vzorcev  $S^2$ , t.j. varianca vseh vzorcev, če je osnovna skupnost velika, enaka

$$A(s^2) = \sigma^2(x) \frac{n-1}{n}$$

V tej enačbi ocenimo  $A(s^2)$  z vrednostjo  $s^2$  enega samega vzorca lahko radi tega, kar je varianca od  $s: S^2(s)$  že pri razmeroma majhnem  $n$  zelo majhna in sicer  $1/2$   $n$ -ti del variance celote, na ta način dobimo oceno da je  $s^2 \approx \sigma^2(x) \frac{n-1}{n}$  ali

$$\sqrt{\frac{n}{n-1}} s \approx \sigma(x) \quad s \approx \sigma(x) \sqrt{\frac{n-1}{n}} \quad \text{ali}$$

Standardno deviacijo aritmetičnih sredin vseh vzorcev imenujemo standardno pogreško. Ako vstavimo ta izraz v neenačbo (xx) dobimo:  $-t < \frac{a - \bar{x}}{s} \sqrt{\frac{n-1}{n}} < +t$

Ker je  $t$  dan z izbero verjetnost  $a$  in  $s$  pa izračunamo iz enega samega vzorca je ta neenačba ocena aritmetične sredine celote, velja

Ako vstavimo ta približek v enačbo za S(a) dobimo

$$S(a) = \frac{\sqrt{\frac{n-1}{n-1}} \cdot s}{\sqrt{\frac{n-1}{n-1}}} = \frac{s}{\sqrt{\frac{n-1}{n-1}}} = \sqrt{\frac{v^2 n}{v-1}}$$

Pri velikem V limitira za S(a) (x)

$$\lim_{V \rightarrow \infty} S(a) = \frac{s}{\sqrt{n-1}}$$

Standardno deviacijo aritmetičnih sredin vseh vzorcev imenujemo standardno pogreško. Ako vstavimo ta izraz v neenačbo (xx) dobimo:

$$a - \frac{t s}{\sqrt{n-1}} < \alpha < a + \frac{t s}{\sqrt{n-1}}$$

$$-a - \frac{t s}{\sqrt{n-1}} < -\alpha < -a + \frac{t s}{\sqrt{n-1}} \quad \text{spremenimo preznak}$$

$$a + \frac{t s}{\sqrt{n-1}} > \alpha > a - \frac{t s}{\sqrt{n-1}}$$

Ta neenačbe podaja oceno za  $\alpha$  na ta način, da kaže interval, v katerem leži  $\alpha$ , pri verjetnosti F(t), da izberemo tak vzorec. Primer: Iz produkcije žarnic smo izbrali po slučajnem izboru 10 žarnic. Čele trajanje gorjenja so naslednje:

Primer Trajanje:  $x_i - U \quad (x_i - U)^2$

nje ur	$x_i$	$x_i - U$	$(x_i - U)^2$	
1	1.100	0	0	
2	1.150	-50	2500	$1.121 + \frac{t \cdot 52.5}{3}$
3	1.200	-20	400	$1.121 + 17,5$
4	1.200	+100	10.000	$1.121 - \frac{t \cdot 52.5}{3}$
5	1.150	+50	2.500	
6	1.170	+70	4.900	
7	1.030	-70	4.900	
8	1.140	-40	1.600	
9	1.120	+20	400	
10	1.170	+70	4.900	
$\Sigma$		+210	32.100	

$$a = 1.121 \quad s^2 = 3210 - 21^2 = 2760$$

$$s = 52.5$$



Ocena z... produkcije je z 95 % verjetnostjo

V naslednjem podajamo tabelo verjetnosti:

Verjetnosti veljajo za nastop vzorca, za katerega leži  $\alpha$  izven gornjega intervala.

Studentova t - distribucija

n-1	P=0,05	P=0,01	P=0,001	n-1	P=0,05	P=0,01	P=0,0001
1	12,706	63,657	636,619	26	2,056	2,779	3,707
2	4,303	9,925	31,598	27	2,052	2,771	3,690
3	3,182	5,841	12,941	28	2,048	2,763	3,674
4	2,776	4,604	8,610	29	2,045	2,756	3,659
5	2,571	4,032	6,059	30	2,042	2,750	3,646
6	2,447	3,707	5,959	35	2,030	2,724	3,592
7	2,365	3,499	5,405	40	2,021	2,704	3,551
8	2,306	3,355	5,041	45	2,014	2,689	3,521
9	2,262	3,250	4,781	50	2,008	2,678	3,496
10	2,228	3,169	4,587	60	2,000	2,660	3,460
				70	1,994	2,648	3,435
11	2,201	3,106	4,337	80	1,990	2,638	3,416
12	2,179	3,055	4,318				
13	2,160	3,012	4,221	90	1,987	2,631	3,402
14	2,145	2,977	4,140	100	1,984	2,626	3,390
15	2,131	2,947	4,073	120	1,980	2,617	3,372
16	2,120	2,921	4,015	140	1,977	2,611	3,361
17	2,110	2,898	3,965	160	1,975	2,607	3,352
18	2,101	2,878	3,922	180	1,973	2,603	3,346
19	2,093	2,861	3,883				
20	2,086	2,845	3,850	200	1,972	2,601	3,340
				300	1,968	2,592	3,324
21	2,080	2,831	3,819	400	1,966	2,588	3,315
22	2,074	2,819	3,792	500	1,965	2,586	3,310
23	2,069	2,807	3,767				
24	2,064	2,797	3,745	1000	1,962	2,581	3,300
25	2,060	2,787	3,725		1,960	2,576	3,291

Pri velikih vzorcih ( n velik ) Studentova t - distribucija limitira proti normalni krivulji gostota normalne distribucije je dana s formulo

$$f(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}$$

Ocena aritmetične sredine nekega pojava moremo uporabiti za ocenjevanje vrednosti določenega znaka za celoto na ta način, da pomnožimo vrednost ocene aritmetične sredine s številom enot celotne osnovne skupnosti z standardno pogreško.

Kot primer ocenjevanja celotne vrednosti vzemimo naslednji problem:

Za statistično maso 20,550 delavcev je treba oceniti plačilni fond na 1 uro z 2 % vzorcem. 2 % od 20.550 je 411. V vzorec bomo torej vzeli 411 slučajno izbranih delavcev. Za vsakega smo poizvedovali za višino urne plače in dobili naslednjo distribucijo:

Urna plača din	Štev. del.	$n_i$	$n_i f_i$	$n_i^2 f_i$
18-	19	-3	-57	171
19-	20	-2	-40	80
20-	69	-1	-69	69
21-	170	0	0	0
22-	94	+1	+94	94
23-	34	+2	+68	136
24-	5	+3	+15	45
	411		+11	595

$$a = 21,5 + \frac{11}{411} = 21,527$$

$$s = \frac{595}{411} - \left(\frac{11}{411}\right)^2 = 1,205$$

Ako gre za 95 % verjetnost je  $t = 1,966$  (po tabeli)

Standardna pogreška torej enaka

$$\xi = \frac{s \cdot t}{\sqrt{n-1}} \cdot \sqrt{\frac{V-n}{V-1}} = \frac{1,205 \cdot 1,966}{\sqrt{410}} \sqrt{0,98} = 0,116$$

Aritmetična sredina celote leži med  $a - \xi$  in  $a + \xi$ , torej med  $21,527 - 0,116$  in  $21,527 + 0,116$ . Skupni plačilni fond je:

$$Na = 20,550 \times 21,527 = 442.380 \text{ din}$$

Verjetni odklon plačilnega fonda pa je  $N\xi =$

$$20,550 \times 0,116 = 2.383,8 \text{ din.}$$

Možen odklon je kakor vidimo relativno majhen, ker znaša samo

$$\frac{2.383,8 \times 100 \%}{442.380} = 0,54 \%$$

Metoda izbora omogoča v naprej določiti dopusten odklon oz. natančnost rezultatov vzorca. Na podlagi določenega odklona moremo izračunati število enot v vzorcu po formuli za realen odklon

$$\xi = \frac{t \cdot s}{\sqrt{n-1}}$$

iz tega obrazca moremo izračunati pri danem  $\xi$ , določenem  $t$  in ocenjenem

$s, n$

$$n = 1 + \frac{t^2 \cdot s^2}{\xi^2}$$

Število potrebnih enot je temvečje čim večja je variabilnost proučevanega znaka, in čim manjši je določen dopusten odklon.

### 353. OCENJEVANJE STRUKTUR:

Ker nas pri statističnem opazovanju skoro vedno zanima struktura statistične mase, je potrebno, da si ogledamo še ocenjevanje struktur po metodi slučajnega izbora. Problem je vsebinsko popolnoma analogen kot za ocenjevanje aritmetične sredine. Poiškati moramo meje zanesljivosti za posamezne verjetnosti.

Ako zaznamujemo z  $V$  število členov z določeno vrednostjo znaka v celotni statistični masi, je  $V/n = \pi$  i relativna frekvenca v celoti.

Analogno temu imamo v vzorcu z  $n$  enotami  $\frac{n_1}{n} = p_1$

Ker te relativne frekvence v stvari niso druge, kot aritmetična sredine, ako vzamemo za  $n_1$  členov vrednost 1, za ostale pa 0

x	f <sub>i</sub>	fx	fx <sup>2</sup>
1	n <sub>1</sub>	n <sub>1</sub>	n <sub>1</sub>
0	n-n <sub>1</sub>	0	0
	n	n <sub>1</sub>	n <sub>1</sub>

$$s = \frac{\sum fx}{n} = \frac{n_1}{n} \quad s^2 = \frac{\sum fx^2}{n} - \left(\frac{\sum fx}{n}\right)^2 = \frac{n_1(n_1)}{n} - \left(\frac{n_1}{n}\right)^2 = p_1(1-p_1)$$

Zato v teh primerih veljajo vse zakonitosti, ki smo jih opazovali pri cenitvah aritmetičnih sredin s to izjemo, da relativna frekvenčna distribucija ni  $\frac{n_1}{n}$  vseh možnih vzorcev ni Studentova  $t$  - distribucija, temveč  $\frac{n_1}{n}$  tkzv. binomialna - Bernoullijeva distribucija. Relativna frekvenca za  $\left(\frac{n_1}{n}\right)$  je dana za binomialne distribucijo po obrazcu

$$P\left(\frac{n_1}{n}\right) = \binom{n}{n_1} \pi^{n_1} (1-\pi)^{n-n_1}$$

distribucija ima dva parametra  $n$  in  $\pi$ , t.j. velikost vzorca in verjetnost za nastop vrednosti  $x_1$ .

Ta distribucija v splošnem ni simetrična razen kadar je  $\pi_i = \frac{1}{2}$

V limiti preide binomialna distribucija z  $n \rightarrow \infty$  pri  $\frac{v_i}{v} = \frac{1}{2}$  v normalno distribucijo.

Običajno uporabljamo normalno distribucijo kot približek že za končne  $n$  in pri  $\pi_i \approx 1/2$ , ker napaka ni velika, pač pa se zelo olajša računsko operacija.

Meja zanesljivosti ocene so pri predpisani verjetnosti  $F(x)$  dane za aritmetično sredino v tem primeru za

$$\frac{n_i}{n} - \frac{x \cdot s}{\sqrt{n-1}} < \pi_i < \frac{n_i}{n} + \frac{x \cdot s}{\sqrt{n-1}} \quad \text{ali}$$

ker je  $s = \sqrt{p_1(1-p_1)}$

$$\frac{n_i}{n} - x \sqrt{\frac{p_1(1-p_1)}{n-1}} < \pi_i < \frac{n_i}{n} + x \sqrt{\frac{p_1(1-p_1)}{n-1}}$$

$F(x)$  za normalno distribucijo

x	f(x)	x	F(x)	x	F(x)	x	F(x)
0,0	0,000	1,0	0,683	2,0	0,955	3,0	0,9973
0,1	0,080	1,1	0,729	2,1	0,964	3,5	0,99953
0,2	0,159	1,2	0,770	2,2	0,972	4,00	0,99993
0,3	0,236	1,3	0,806	2,3	0,979		
0,4	0,311	1,4	0,838	2,4	0,984		
0,5	0,383	1,5	0,866	2,5	0,986		
0,6	0,451	1,6	0,890	2,6	0,991		
0,7	0,516	1,7	0,911	2,7	0,993		
0,8	0,576	1,8	0,928	2,8	0,995		
0,9	0,632	1,9	0,943	2,9	0,996		

Primer:

V nekem okraju je bilo rojenih v določenem razdobju 1.352 otrok. Iz te statistične mase izberemo 5 % enot tj. 67 otrok in ugotovimo, da je od teh 37 dečkov. Določiti interval v katerem predvidoma leži odstotek dečkov celote z 95 % verjetnostjo.

$$n_i = 37$$

$$n = 67 \quad \epsilon = 196 \cdot \sqrt{\frac{0,552 \cdot 0,448}{66} + \frac{1352 - 67}{1351}} =$$

$$p_i = 0,552 \quad = 196 \cdot 0,091 \cdot 0,97 =$$

$$1 - p_i = 0,048 \quad = 0,173$$

$$0,552 - 0,173 < \Pi_i < 0,552 + 0,173$$

$$0,379 < \Pi_i < 0,725$$

Kot vidimo, je rezultat radi premajhnega števila primerov zelo nezanesljiv, verjetno je z 95 % verjetnosti vrednost odstotka dečkov v celoti od 37,9 % do 72,5 %.

36. NAČINI SLUČAJNEGA IZBIRANJA. Že uvodoma o metodi izbora smo naglasili, da je slučajen izbor edina nadomestna metoda, ki ima teoretično izgrajeno osnovo, to je verjetnostni račun. Shematično dobimo slučajen izbor, da iz žare z raznobarvnimi kroglicami vlečemo na slepo kroglice. Pri stvarnem statističnem opazovanju pa je treba iz danega materiala, spisikov itd. izbrati slučajno določeno število enot. Ker je to v gotovih primerih težko, ne da bi vnesli subjektiven moment v sam izbor, se postopki izbora že v naprej izdelani. Najenostavnejši način izbora je mehanični izbor. Pri mehaničnem izboru izberemo posamezne enote na ta način, da v spisku enot celote, kjer imamo oštevilčene posamezne note z tekočimi številkami izberemo n. pr. pri 95 % izboru vsako 20. enoto n. pr. Z redno štev. 1, 21, 41, 61 itd. Ta način je zelo enostaven, treba pa je paziti, da ta delna masa ni enostranska, t. j. da se enota z določenimi značilnostmi ne kopičijo ravno v teh številkah, kar more vplivati na kakovost rezultatov.

Mehanični izbor v regionalnem smislu pa pomeni, da se enote, vzete v izbor v naravi krajevno enako oddaljene druga od druge (n. pr. pri metraži).

Ta način ni čisti slučajni izbor in more imeti radi tega pod nepravimi pogoji škodljive vplivne rezultate. Radi tega je treba pri uporabi mehaničnega izbora predhodno preštudirati ako kima sistematičnega odklona.

Pravi slučajni izbor bi imeli, ako bi iz žare z dobro premešanimi oštevilčenimi listki z vsemi tekočimi številkami celote izvlekli na slopo število enot odgovarjajoče število listkov in bi iz spiska enot vzeli enote z tistimi tekočimi številkami, ki so napisane na izvlečenih listkih. Da ni treba od primera do primera konstruirati takih pomožnih žar, so izdelane tabele "slučajnih števil". To su nanizane številke, ki bi jih z vlečenjem listkov dobili iz žar. Radi nazornosti prinašamo izrez iz tabele "slučajnih števil" iz "Romancvskega" dela "Uporaba matematične statistike v poskusih.

## Tablica slučajnih števil

8574	5490	4069 <sub>x</sub>	0163 <sup>x</sup>	1241 <sup>2</sup>	1270 <sup>2</sup>
4575	6276	2709 <sup>x</sup>	4732 <sub>x</sub>	0301 <sup>x</sup>	8730
4999	8826	0291 <sup>x</sup>	0258 <sup>x</sup>	9430	
7627	6090	9572 <sub>x</sub>			
4315	5770	1500 <sup>x</sup>			
6987	8055				
0387 <sup>x</sup>					

Ako je število vseh enot trištevilično vzamemo v obzir v vsakem štirišteviličnem številu samo prve ali zadnje tri številke. Ako je število vseh enot 378, bodo prišla v poštev samo ona števila, ki so manjša od 378 (v tabeli zaznamovane z x). V izbor bi iz teh števil prišle v poštev redne številke

38, 270, 29, 150, 16, 25, 124, 30, 127.

Slučajni izbor v splošnem ni reprezentativen, vendar je verjetno reprezentativen, t.j. obstoja večja možnost da je, kot da ni.

Pogreško v izboru, ki jih povzroči lahko slučajen vzorec, če ni reprezentativen, so lahko velike in povzročajo lahko velike motnje v uporabnosti vzorca. Raziskovalci so spoznali, da se napake morejo zelo zmanjšati, če inamo možnost, da izberemo tak vzorec, da je podoben celotni t.j. da ima slične značilnosti kot celota. Izvedba tega zahteva nekaj predhodnih informacij o celoti, da raziskovalec vsaj približno ve, kaj naj bi predstavljal reprezentativen vzorec.

Reprezentativen vzorec dosežemo z izborom v legah (stratificiran vzorec). Zanesljivost ocene v odločilni meri zavisi od velikosti variacije znakov. Če celotno maso razdelimo na homogene dele, bo variacija homogenih delov znatno padla. Variacija v grupi bo majhna, variacija med grupami pa velika. Ako bomo jemali iz posameznih homogenih delov celote slučajne vzorce, bodo ocene za te delne mase radi manjših variacij bolj zanesljive. Iz teh ocen se naknadno sestavi rezultat za celoto. Moremp pa vzeti samo izbiranje enot po legah, obdelavo podatkov pa napravimo skupno.

Primer za stratificiran izbor je predhodna razdelitev na okraje, ako ima regionalna razlika vpliv na pojav. (n.pr. pri vzorčenju zemljiških gospodarstev). Pri vzorcu zemljiških gospodarstev je dobro kot lega vzeti poljedelske rajone, ali razdeli-



~~tev na nižinsko in višinska gospodarstva, na najhna, srednja, velika.~~

Ako je število grup - leg veliko, moremo izvor vršiti tako, da ne izbiramo iz vseh leg, temveč samo iz nekaterih, ki jih pa zopet izberemo slučajno. V teh slučajno izbranih grupah pa nato izvršimo slučajno izbiranje. Ta način je zelo priporočljiv v aplikaciji na regionalno razdelitev in ga imenujemo stratificiran podizbor. Pri dosedanjih vzorcih, ki jih je vršil zvezni statistični urad FLRJ n.pr. o vezanih cenah ali katerah z več kot 5 otroci, je bila kot lega KLO (v LRS jih je 1266). Iz teh KLO-jev je bilo po slučajnem izboru izbranih določeno število. Nadaljnji izbor se je vršil samo v teh KLO-jih. Podizbor uporabljamo v glavnem radi administrativnih razlogov. Popisovanje šno v nekaterih KLO-jih je zvezano z manjšo organizacijo, manjšimi finančnimi stroški in manjšo obremenitvijo terena. Kajti ni vseeno, ako imamo popisati 10.000 enot, katere so raztresene v 1.300 KLO-jih in je v vsakem KLO-ju 5 - 10 enot, ali so vse te enote v 50 KLO-jih in je v vsaki povprečno 200 enot. V praksi se tudi mnogo uporablja dvojni izbor. Določene podatke posebno iz ekonomskega področja posameznikov je zelo težko zbrati, ker naletimo na upor in tendenco utaje in neresničnih podatkov. V takih primerih najprej podrobno opazujemo drug pojav, ki je z iskanim v korelacijski zvezi. Korelacije med obema pa poiščemo z manjšim vzorcem, tako da o kočljivih vprašanjih vprašujemo zelo malo oseb.

Večji izbor dvojnega izbora moremo uporabljati tudi za določevanje tehtanega izbora v legah, ker z njim dobimo relativno razmerje velikosti posameznih grup.

Tako moremo pri zemljiških popisih z velikim vzorcem ugotoviti razmerje med številom posestnikov po velikostnih skupinah, z manjšim vzorcem znotraj vsake skupine za medsebojne odnose ostalih znakov.

37. UPORABA METODE IZBORA Uporaba metode izbora je vsestranska. Povsod kjer imamo opravka z statističnim opazovanjem, moremo s pravilno izpeljanimi postopki metode vzorca priti do rezultatov, ki imajo predpisano natančnost. Posebej se je metoda slučajnega izbora utrla pot v tista področja, v katerih ne moremo izvajati kompletne opazovanja kot je n.pr. kontrola kvalitete proizvodnje. Statistična kontrola kvalitete proizvodnje je po-

stala posebna statistična disciplina in je v nekaterih državah vedno bolj uveljavlja. ( ZDA, SSSR itd.).

Poleg tega se metoda izbora uporablja s pridom tudi v poljedelski statistiki, ravno radi tega, ker imamo opravka z velikimi številnimi pojavi. Zanesljivo ugotavljanje hektarskega donosa posameznih kultur za večja področja, kjer ne more priti v poštev popolno opazovanje je možno le s pomočjo na metodi slučajnega izbora bazirani metodi metraže. S pomočjo vzorcev izbranih z mehaničnim izborom, se more s poljubno natančnostjo oceniti hektarski donos določene kulture. Za žita sestoji enota vzorca iz poskusne parcele v izmeri 1 m<sup>2</sup>. Na tej parceli preštejemo število klasov, iz določenega števila klasov znotraj tega kvadratnega metra (običajno ca 25) preštejemo zrna posameznih klasov in tehtamo težo 1.000 zrn. Iz skupnosti vseh enot vzorca (poskusnih parcel vzamemo več) napravimo oceno hektarskega donosa celote. Oceno moremo napraviti poljubno natančno s tem da izvedemo število enot vzorca. Za homogena področja zadošča že razmeroma majhno število poskusnih parcelic za dosego zanesljivega rezultata za nehomogena pa ni običajno pomagamo z stratificiranimi izbori.

38. PO METODI IZBORA IZVRŠENE STATISTIČNE AKCIJE V LRS. Do sedaj je statistični urad LR Slovenije bodisi v zveznem merilu, bodisi samostojno izvedel s pomočjo metode izbora naslednje statistične akcije:

10 % vzorec popisa zemljiških gospodarstev v letu 1947.

Ker bi razmeroma komplicirana obdelava podatkov popisa zemljiških gospodarstev z leta 1947 po velikostnih skupinah zahtevala preveč časa in finančnih sredstev je bil popis sumarno obdelan popolno, po velikostnih skupinah pa z 10 % izborom. Izbor je bil mehaničen in se je vzelo v obzir vsako deseto gospodarstvo po obstoječem spisku. Na ta način je bila obdelana struktura po kategorijah kultur po velikostnih skupinah.

Anketa o vezanih cenah. Akcija je bila zveznega merila in izvršena v letu 1948. Izbor je bil izvršen na podlagi stratificiranega podizbora s tem, da je bil popis izvršen v omejenem številu KLO-jev, kar je znatno pocenilo in skrajšalo celotno delo. Akcija je bila uspešno izvršena (glej govor maršala Tita na novo leto 1949), hitro in z razmeroma majhnim številom kvalificiranih kadrov.

Vzorec popisa živine leta 1948. Poleg rednega popisa živine, ki se vrši vsako leto decembra meseca je bil izveden leta 1948 vzorec popisa živine ob času najvišjega stanja živine. Izbor je bil stratificiran podizbor in sicer 5%. Izbor KLO-jev je bil slučajen v okviru OLO-ja in sicer na ta način, da ni bilo vzorčen 5 % KLO-jev temveč toliko KLO-jev, da je skupnomštevilo zneslo 5%. Poskusna metraža v LRS jeseni leta 1948. Izvršena je bila po vseh OLO-jih Slovenije. Material služi za študij za uvedbo znanstveno osnovane metraže v LRS. Proučeval se je hektarski donos pšenice.

Anketa o materah z nad 5 živimi otroci v letu 1949. Akcija je bila zveznega obsega in sicer po metodi stratificiranega podizbora. Obdelava je bila izvršena v zveznem obsegu. Rezultati so služili za osnutek vladne uredb.

2 % vzorec popisa prebivalstva v LRS. Kar bo kompletana obdelava popisa prebivalstva z dne 15. marca 1948 trajala še vse leto 1949, je statistični urad Slovenije za hiter pregled na podlagi osnovnega materiala izvedel 2 % izbor. Kot enota izbora je bilo vzeto gospodinjstvo, obdelane pa vse osebe, ki so spadale v to gospodinjstvo. Gradivo je bilo obdelano na Powers strojih in je dal zadovoljive rezultate. Izbor je bil regionalno stratificiran, ker so bila gospodinjstva izbrana tako, da so bila enakomerno razdeljena po vseh KLO-jih, na vsakih 100 gospodinjstev 2. primera.

Ocena socialne strukture iz popisa prebivalstva. Med obdelavo popisa prebivalstva je bila na hitro obdelana po metodi vzorca socialna struktura in sicer na podlagi mehničnega izbora (vsak 61 slučaj iz kontrolnika).

Anketa o živalski proizvodnji. Istočasno s popisom živine, ki je bil kompletana statistična akcija je bil izvršen vzorec o živalski proizvodnji za vsako dvajseto posestvo. Izbor je bil mehničen in so bila gospodarstva izbrana na podlagi obstoječih spiskov. Za ta gospodarstva so bila izbrana potrebna vprašanja o živalski proizvodnji. Obdelava je bila izvršena v zveznem obsegu.

Kontrola popisa živine leta 1949. Za ocenitev zanesljivosti podatkov popisa živine je bila tik za popisom izvedena za vsaki 54 gospodarstvo kontrola glavnih podatkov. Na podlagi podatkov te kontrole je bil za posamezne vrste živine po metodi vzorca izračunan % pravilnosti popisa.



Popravki.

stran	vrsta	namesto	vstavi									
5	10	$p_0 = \frac{x_1 + x_2 + x_3}{3}$	$p_2 = \frac{x_1 + x_2 + x_3}{3}$									
5	18	$p_3 = \frac{8 + 9 - 6}{3}$	$p_3 = \frac{8 + 9 - 6}{3} = 9$									
6	7	$T_{jul} = \frac{1}{1} (\frac{1}{1} \text{jan} + \text{feb} + \dots)$	$T_{jul} = \frac{1}{12} (\frac{1}{2} \text{jan} + \text{feb} + \dots)$									
6	13	$T_m = \frac{1}{2} (\frac{1}{2} y_{m-6} + \dots)$	$T_m = \frac{1}{12} (\frac{1}{2} y_{m-6} + \dots)$									
8	2	$N \sum_{k=1}^N (K - f(x_k))^2 = \text{Min}$	$N \sum_{k=1}^N [y_k - f(x_k)]^2 = \text{Min}$									
8	3	parametri	parametri									
povsod dalje paramenter			parameter									
8	8	8 parabolo 12-tega	parabolo n-tega									
8	25	$N \sum_{k=1}^N (y_k - bx_k)^2 = \text{Min}$	$N \sum_{k=1}^N (y_k - a - bx_k)^2 = \text{Min}$									
13	13	$Y_{\lambda \mu} = T_{\lambda \mu} =$	$Y_{\lambda \mu} \cdot T_{\lambda \mu} = Y_{\lambda \mu}$									
14	18	$v_{\mu} - v = v_{\mu}$	$v_{\mu} - v = v'_{\mu}$									
14	20	$\sum_{m=1}^{12} d_m$ $\frac{\sum_{m=1}^{12} d'_m - d = S_m}{12}$	$\sum_{m=1}^{12} d_m$ $\frac{\sum_{m=1}^{12} d'_m - d = S_m}{12}$									
19	3	<table border="1" style="display: inline-table; vertical-align: middle;"> <tr> <td>n</td> <td>v</td> <td>u</td> <td>d'm</td> <td>du</td> </tr> </table>	n	v	u	d'm	du	<table border="1" style="display: inline-table; vertical-align: middle;"> <tr> <td>d_m</td> <td>u</td> <td>d'm</td> <td>S_m</td> </tr> </table>	d_m	u	d'm	S_m
n	v	u	d'm	du								
d_m	u	d'm	S_m									
24	22	$N \sum_{k=1}^N x_k y_k - XY$ $\frac{\quad}{N} = v$ $G = G$	$N \sum_{k=1}^N x_k y_k$ $\frac{\quad}{N} - \bar{x} \bar{y}$ $G \times G_y = v$									

stran	vrsta	namesto	vstavi
26	3	$(4,12)^2$ <u>16,9744</u> 4,92.4,26 20,9502	$(4,12)^2=16,9744$ <u>4,92.4,26 20,9592</u>
26	7	$x-\bar{x} = \frac{\sum x}{\sum y} r(x-\bar{x})$	$(x-\bar{x}) = \frac{\sum x}{\sum y} r(y-\bar{y})$
39	5	mora	more
39	19	enake	znake
40	31	za velik je	za velik $\checkmark$ je
42	6	<u><math>4x^2+12x+4.0</math></u>	<u><math>4.2+12.2+4.0</math></u> 20
45	29	<u><math>1960 \quad 2,576</math></u> 2	<u><math>1,960 \quad 2,576</math></u> 2
45	34	$f(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}$	$f(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}$
47	7	$n = 1 + \frac{t^2 s^2}{2}$	$n = 1 + \frac{t^2 s^2}{E^2}$
47	29	$P\left(\frac{n_i}{n}\right) = \binom{n}{n_i} \prod_1^{n_i} p_i (1-p_i)^{n-n_i}$	$P\left(\frac{n_i}{n}\right) = \binom{n}{n_i} \prod_1^{n_i} p_i (1-p_i)^{n-n_i}$

Pravilna razmestitev koncev strani 43, in v začetku 44 je naslednja:

Namesto predzadnjega odstavka na strani 43 zašni na strani 44 zgoraj!:

"Alo vstavimo..... do stavka :Ako vstavimo ta izraz v neenačbo (xx) dobimo:" (Ta odstavek je že na strani 43, kjer nadaljuješ.)

Zadnjemu odstavku na strani 44 sledijo neenačbe na strani 44. (po odstavku, ki se prične: "Standard...")



