

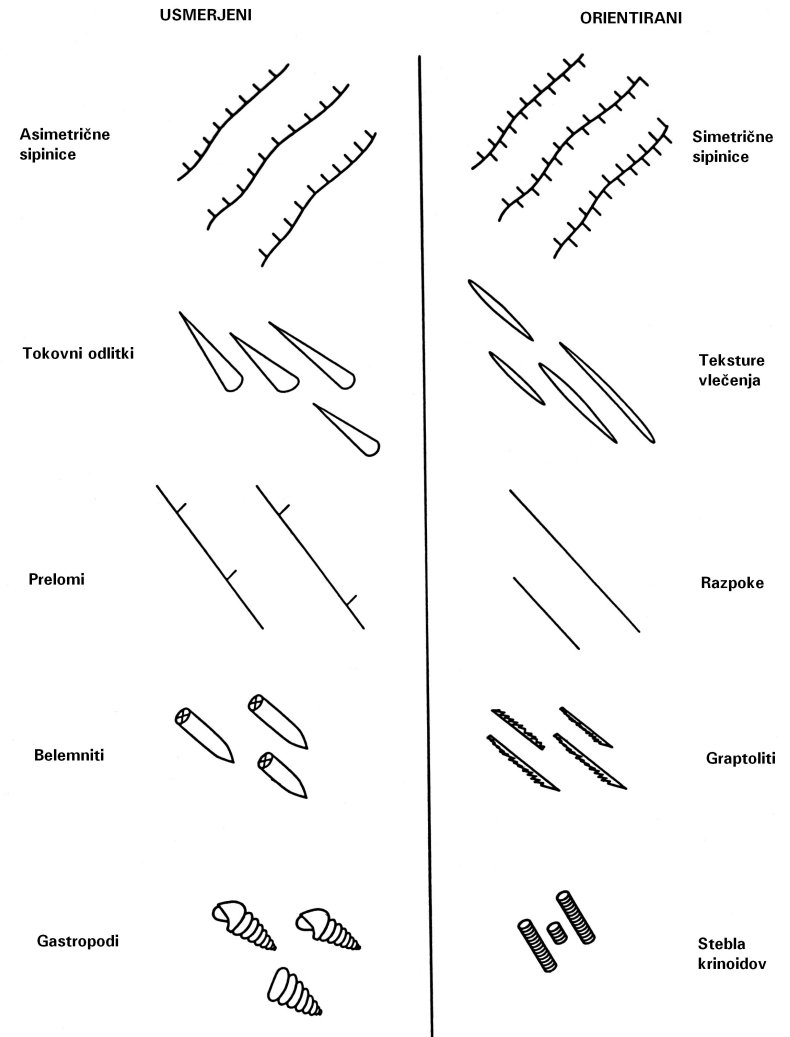
5. USMERJENI IN ORIENTIRANI PODATKI

5.1. UVOD

5.1.1. Definicije in vrste podatkov

■ Krožni podatki so dveh vrst:

- Usmerjeni
- Orientirani




5.1.1. Definicije in vrste podatkov




- Preden pričnemo analizirati krožne smeri, je pogosto bistveno, da odstranimo vpliv tektonskega nagiba.
- Prvotni položaj neke linearne oblike lahko ugotovimo, če poznamo kot in smer nagiba sistema gub.
- Nagib celotne gube zavrtimo po navpični ravnini v vodoravno lego.
- Ravnino plasti potem zavrtimo okrog osi gube v vodoraven položaj.
- Kot med linearno obliko in prvotno smerjo vpada se ohrani, nagib pa v narisu ohrani smer.

5.1.1. Definicije in vrste podatkov



- Prvoten vpad linearne oblike je enak smeri nagiba in kotu v ravnini plasti med linearno obliko in nagibom.



5.1.1. Definicije in vrste podatkov

- Če je:

- ⊖ smer nagiba linearne oblike (merjene v vodoravni ravnini)

- α kot nagiba linearne oblike (merjene v napični ravnini)

- Φ smer nagiba gube (merjene v vodoravni ravnini)

- β kot nagiba gube (merjene v napični ravnini)

- Poiščemo enotni vektor (x_1, y_1, z_1) linearne oblike iz:

$$x_1 = \cos\alpha \sin\Theta$$

$$y_1 = \cos\alpha \cos\Theta$$


$$z_1 = \sin\alpha$$

- In enotni vektor (x_p, y_p, z_p) nagnjene gube iz:

$$x_p = \cos\beta \sin\Phi$$

$$y_p = \cos\beta \cos\Phi$$

5.1.1. Definicije in vrste podatkov



- Če je kot med linearno obliko in nagnjeno gubo v ravnini plasti γ , lahko načrtamo pravokotni trikotnik s hipotenuzo z dolžino ene enote.


$$\cos\gamma = a$$

kjer je a dolžina pravokotne projekcije enega vektorja na drugega.

- Zmnožek vektorjev je dolžina projekcije:

$$\cos\gamma = \cos\alpha \sin\Theta \cos\beta \sin\Phi + \cos\alpha \cos\Theta \cos\beta \cos\Phi + \sin\alpha \sin\beta$$

5.1.1. Definicije in vrste podatkov




- Originalen vpad je torej:

$$\Phi + \cos^{-1}(\cos\alpha \cdot \sin\Theta \cdot \cos\beta \cdot \sin\Phi + \cos\alpha \cdot \cos\Theta \cdot \cos\beta \cdot \cos\Phi + \sin\alpha \cdot \sin\beta)$$

- Izračun lahko uporabimo le za linearne oblike, ki ležijo v ravnini plasti ter kadar je med gubanjem prišlo le do enostavnih rotacij.
- Kadar gre za deformacijo ob strigu, se koti v ravnini plasti ne ohranijo.
- Že najmanjša deformacija onemogoči kakršnokoli oceno originalnega vpada.



5.1.2. Grafična predstavitev

- Najpreprostejša grafična ponazoritev usmerjenih podatkov je s točkami, nanešenimi na obod kroga.
- Univariatnemu histogramu je pri krožnih podatkih enak veterni (rose) diagram, sestavljen iz delov kroga.
- Polmeri delov so sorazmerni frekvenci.




5.1.2. Grafična predstavitev

- Vizualni vtis dela je sorazmeren njegovi površini, ta pa r^2 .
- Visoke frekvence so zato vizualno preveč, nizke premalo poudarjene, kar lahko vodi do napačnega vtisa prednostne smeri popolnoma naključnih podatkov.
- Polmere zato rošemo sorazmerne kvadratnemu korenu ali uporabimo zmajasti (kite) diagram.



5.1.2. Grafična predstavitev

- Pri orientiranih podatkih so si za 180° nasprotne strani enakovredne, zato grafični prikaz omejimo na polkrog.
- Rotacijsko simetrijo lahko ohranimo tako, da imajo nasproti ležeče si smeri, enake frekvence.



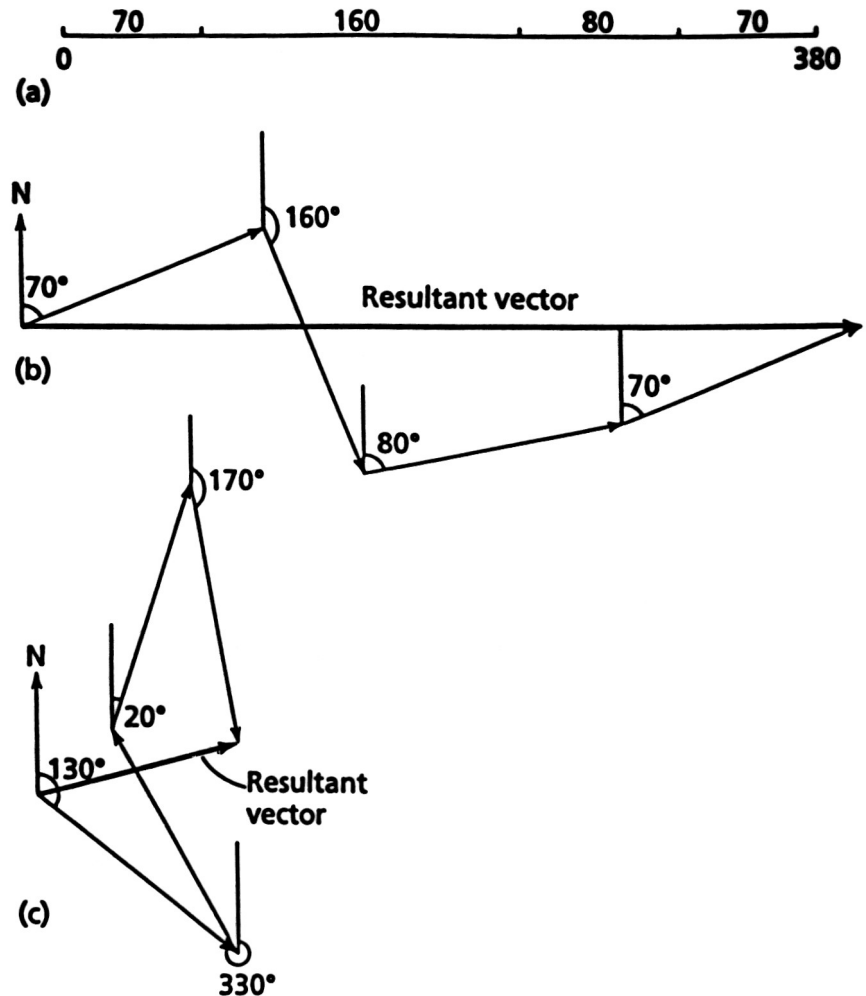
5.2. STATISTIKE Z USMERJENIMI PODATKI



- Potrebujemo postopek, ki obravnava 1 in 395 kot podobni vrednosti ter 0 in 360 kot enaki.
- Rešitev je v uporabi trigonometričnih funkcij – sinus, cosinus in tangens, ki se ponovijo vsakih 360° , kjer je $\sin(0^\circ) = \sin(360^\circ)$, ter enako cosinus in tanges.

5.2.1. Geometrijski koncept seštevanja smeri

- Usmerjene podatke predstavimo tako, da vsaka meritev določa smer vektorja in ne dolžine, ki je stalna.
- Vsoti ustreza premica, ki povezuje začetno in končno točko – rezultanta.
- Njena smer je srednja vrednost smeri.
- Dolžina rezultante pa odraža varianco.



5.2.2. Izračun povprečne smeri in mere sipanja

- Ponazorimo podatke s $\Theta_1, \Theta_2, \dots, \Theta_n$.
- Komponenti vsakega enotnega vektorja sta:

$$x_i = \sin\Theta_i$$

$$y_i = \cos\Theta_i$$


- Komponenti vektorja rezultante:

$$x_r = \sum \sin\Theta_i$$

$$y_r = \sum \cos\Theta_i$$

- Srednja vrednost smeri je smer hipotenuze:

$$\overline{\Theta} = \tan^{-1} \left(\frac{x_r}{y_r} \right)$$



5.2.2. Izračun povprečne smeri in mere sipanja



- Opozorila:
 - Upoštevajte, da večina računalnikov normalno delijo v radijanih in ne stopinjah ($1 \text{ rad} = 57,2956^\circ$).
 - Ker se funkcija tangens ponovi vsakih 180° , daje \tan^{-1} pogosto zavajajoče rezultate, če računamo z osebnim ali žepnim računalnikom – vrednost bo izračunana v obsegu -90° do 90° , dejanski rezultat pa bi moral biti v razponu 0° do 360° .

5.2.2. Izračun povprečne smeri in mere sipanja

- Pravo vrednost poiščemo tako, da dodamo 0° , 180° ali 360° obrnjeni vrednosti, glede na predznaka komponent x in y.

x	y	dodaj
+	+	0°
+	-	180°
-	-	180°
-	+	360°

5.2.2. Izračun povprečne smeri in mere sipanja

■ Dolžina rezultante je:

$$R = \sqrt{x_r^2 + y_r^2}$$

■ Sipanje podatkov je odvisno od velikosti vzorca n , zato uporabljamo srednjo vrednost dolžine rezultante:

$$\bar{R} = \frac{R}{n}$$

■ Neugodna lastnost je, da višji uporabljamo krožno varianco:

pomeni nižjo varianco, zato raje

$$\sigma_0 = 1 - \bar{R}$$

5.2.3. Frekvenčne porazdelitve



- Ničelna naključna frekvenčna porazdelitev usmerjenih podatkov je enotna porazdelitev, brez modalne najvišje vrednosti.
- Večina geoloških razmer daje usmerjene podatke s sipanjem vrednosti okrog prednostne smeri, ki morda nakazuje prevladujočo smer toka.
- Zato lahko pri statističnih izračunih uporabimo kot pomoč normalno porazdelitev.

5.2.3. Frekvenčne porazdelitve



- Če z usmerjenimi podatki uporabimo normalno porazdelitev, se bosta skrajna konca porazdelitve nujno ovijala po krožnici, tako da se bodo skrajne vrednosti začele približevati srednji vrednosti iz nasprotne smeri!
- Včasih zato uporabljamo “ovito normalno”, pogosteje pa von Misesovo porazdelitev.

5.2.3. Frekvenčne porazdelitve



- Von Mises ima dva parametra:
 - Srednjo vrednost smeri $\overline{\Theta}$
 - Parameter koncentracije κ
- Parameter koncentracije κ ocenimo iz srednje vrednosti dolžine rezultante.
- Njegove vrednosti naraščajo s padajočim sipanjem, tako da $\kappa = 0$ pomeni enotno porazdelitev.


5.2.4. Test značilnosti povprečne smeri

5.2.4.1. Test povprečne dolžine rezultante

- Rayleighov test značilnosti srednje vrednosti smeri izračunamo:

$$\bar{R} = \frac{1}{n} \sqrt{\left(\sum_{i=1}^n \sin \Theta_i \right)^2 + \left(\sum_{i=1}^n \cos \Theta_i \right)^2}$$

- H_0 , da ni značilne prevladujoče smerizavrtnemo, kadar izračunana vrednost presega kritično.



<i>n</i>	α (%)			
	10	5	2.5	1
3	0.86	0.96	1.03	1.13
4	0.75	0.84	0.91	1.03
5	0.67	0.75	0.82	0.94
6	0.62	0.69	0.76	0.87
7	0.57	0.64	0.70	0.82
8	0.53	0.60	0.66	0.77
9	0.50	0.57	0.63	0.73
10	0.48	0.54	0.59	0.70
11	0.46	0.52	0.57	0.67
12	0.44	0.49	0.54	0.64
13	0.42	0.48	0.52	0.62
14	0.40	0.46	0.51	0.60
15	0.39	0.44	0.49	0.58
16	0.38	0.43	0.47	0.56
17	0.37	0.42	0.46	0.54
18	0.36	0.41	0.45	0.53
19	0.35	0.39	0.44	0.52
20	0.34	0.38	0.42	0.50
22	0.32	0.37	0.41	0.48
24	0.31	0.35	0.39	0.46



5.2.4.2. Test enotnosti

- Pri naključni porazdelitvi, ki se ne razlikuje bistveno od enotne, je pričakovana frekvenca v vsakem razredu enaka, in sicer preprosto n/k , kjer je k število razredov.
- Testiramo jo s X^2 testom, kjer H_0 enotne porazdelitve zavrnemo, če izračunana vrednost presega kritično.

5.2.4.2. Test enotnosti

- H_0 : podatki izhajajo iz enotno porazdeljene populacije

H_1 : podatki izhajajo iz neenotno porazdeljene populacije

$$\chi^2 = \frac{\sum (O_j - E_j)^2}{E_j}$$

- Ker je pričakovani model enoten, je E_j enak za vse razrede, zato poenostavimo:

$$\chi^2 = \frac{1}{E_j} \sum (O_j - E_j)^2$$

5.2.4.3. Bimodalne in polimodalne porazdelitve

- Rayleighov test ne bo ovrigel ničelne hipoteze, kadar so podatki bi- ali polimodalni, zlasti če si ležita modusa nasproti.
- Pri dodajanju členov k dolžini rezultante se nasprotni si smeri izničita.
- Bi- ali polimodalni podatki se kljub temu značilno razlikujejo od enotnega modela v X^2 testu.

5.2.5. Testiranje hipotetične povprečne smeri

5.2.5.1. En vzorec

- Izračunamo interval zaupanja srednje vrednosti smeri in preverimo, če predpostavljena smer znotraj tega intervala.
- Pri $\alpha = 0,05$ bo dejanska srednja vrednost populacije v razponu od:

$$\bar{\kappa} \pm 1,96s_e$$

- kjer je s_e standardna napaka srednje vrednosti, n velikost vzorca, κ koncentracijski parameter (tabele) in $\bar{\kappa}$ srednja vrednost dolžine rezultante:

R

$$s_e = \frac{1}{\sqrt{nR\kappa}}$$




5.2.5.1. En vzorec

■ Opozorila:

- Enote s_e so radiani in ne stopinje, pretvorimo jih z množenjem z 57,2956.
- Podatki se morajo vsaj približno ujemati s von Misesovo porazdelitvijo.
- Najprej naredimo Rayleighov test prednostne smeri. Če je ni, bo standardna napaka velika in predpostavljena srednja vrednost bo zato verjetno padla znotraj intervala zaupanja, a bo rezultat nesmiselen.
- Ker ne poznamo verjetnosti zavrnitve H_0 , ne moremo zaupati ujemanju podatkov z določeno srednjo vrednostjo. To je ustrezno, ker je tudi pri podatkih, ki jih Rayleighov test potrdi, s_e pogosto velika in daje interval zaupanja, ki zajema velik del kroga.

5.2.5.2. Dva vzorca

- Za test enakost dveh srednjih vrednosti smeri primerjamo dolžini rezultant R_1 in R_2 , z rezultanto združenih dolžin obeh vzorcev R_T .
- Če sta si srednji vrednosti vzorcev blizu, bo vsota dolžin $R_1 + R_2$ podobna vrednosti R_T (a), če pa sta si zelo različni, bo združeni rezultirajoči vektor precej krajši (b).




5.2.5.2. Dva vzorca

- H_0 : vzorca izhajata iz populacij z enakima srednjima vrednostima smeri
- H_1 : vzorca izhajata iz populacij z različnima srednjima vrednostima smeri


$$F = \left(1 + \frac{3}{8\kappa}\right) \frac{(n-2)(R_1 + R_2 - R_T)}{(n - R_1 - R_2)}$$

- κ poiščemo v tabelah na osnovi \bar{R}_T
- Izračunani F primerjamo s kritičnim $F_{\alpha,1,n-2}$ in H_0 zavrnamo, če izračunana vrednost presega tabelirano.



\bar{R}	κ	\bar{R}	κ
0.00	0.00000	0.59	1.47543
0.02	0.04001	0.60	1.51574
0.04	0.08006	0.61	1.55738
0.06	0.12022	0.62	1.60044
0.08	0.16051	0.63	1.64506
0.10	0.20101	0.64	1.69134
0.12	0.24175	0.65	1.73945
0.14	0.28279	0.66	1.78953
0.16	0.32419	0.67	1.84177
0.18	0.36599	0.68	1.89637
0.20	0.40828	0.69	1.95357
0.22	0.45110	0.70	2.01363
0.24	0.49453	0.71	2.07685
0.26	0.53863	0.72	2.14359
0.28	0.58350	0.73	2.21425
0.30	0.62922	0.74	2.28930
0.31	0.65242	0.75	2.36930
0.32	0.67587	0.76	2.45490
0.33	0.69958	0.77	2.54686
0.34	0.72356	0.78	2.64613
0.35	0.74783	0.79	2.75382
0.36	0.77241	0.80	2.87129

5.2.5.2. Dva vzorca



■ Opozorila:

- Oba vzorca morata izhajati iz von Misesove porazdelitve.
- Zgornja enačba velja zgolj za $10 > \kappa > 2$. $\kappa > 10$ je zelo malo verjeten, in če je $\kappa < 2$, je zelo verjetno, da ni prednostne smeri, ali da sta si srednji vrednosti smeri očitno različni.



5.2.6. Nekateri hitri neparametrični testi

- Prednost neparametričnih usmerjenih metod je, da ne zahtevajo von Misesove porazdelitve, ter da jih hitro in preprosto izračunamo.
- Taki sta npr.:
 - Hodges – Ajnejev test prednostne smeri
 - Test nizov enakosti srednjih vrednosti smeri

5.2.6.1. Hodges – Ajnejev test prednostne smeri

- Podatke narišemo na obod kroga.
- Kadar obstaja prednostna smer, bodo točke zgoščene na enem delu krožnice.
- Potujemo po krožnici, dokler ne dosežemo največje razlike med številom točk na vsaki strani.
- Hodges – Ajnejeva statistika M_{\min} je najmanjše število točk na eni strani.
- Test ni zelo občutljiv.

5.2.6.2. Test nizov enakosti srednjih vrednosti smeri

- Podatke dveh vzorcev združimo in jih razvrstimo v naraščajočem vrstnem redu.
- Niz predstavlja vrsto zaporednih točk istega vzorca.
- Kadar dva vzorca izhajata iz populacij z enakima smerema pričakujemo, da bosta vzorca med seboj pomešana in bo število nizov visoko.
- Če se smeri močno razlikujeta, bodo opazovanja razvrščena le v dva niza.
- Razprševanje podatkov mora biti v obeh vzorcih približno enako, ker lahko pride do anomalno majhnega števila nizov, tudi ob enakih srednjih vrednostih smeri, če so opazovanja enega izmed vzorcev tesno skupaj.

5.2.6.2. Test nizov enakosti srednjih vrednosti smeri

- Testna statistika je :

$$Z = \frac{U - \bar{U}}{\sigma_{\bar{U}}}$$


- Pričakovano število nizov je:

$$\bar{U} = 1 + \frac{2n_1n_2}{n_1 + n_2}$$

- In pričakovana varianca:

$$\sigma_{\bar{U}}^2 = \frac{2n_1n_2(2n_1n_2 - n_1 - n_2)}{(n_1 + n_2)^2(n_1 + n_2 - 1)}$$

5.3. Statistike orientiranih podatkov



- Izračune za orientirane podatke izvajamo enako kot za usmerjene, le da so vsi koti že v naprej podvojeni.
- Vse kotne rezultate, zato razpolovimo.
- Kote podvajamo zato, da postanejo smeri, ki se razlikujejo za 180° (enaka orientacija), 360° narazen in s tem identične v trigonometričnih izračunih.
- Vsi ostali testi so veljavni s podvojenimi podatki.