

PRISTRANOST KOD SKUPLJANJA PODATAKA: KAKO JE PROMAŠENA ANKETA UNIŠTILA TJEDNIK

Tvrtko Tadić, Seattle

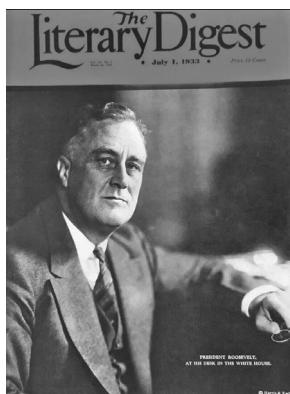
Matkači su stalno izloženi rezultatima anketa, a vjerojatno su i kao ispitanici sudjelovali u kojoj. Ono što je većina mogla zamijetiti jest da se ankete provode na relativno malom broju ljudi – **uzorku** od nekoliko stotina do nekoliko tisuća ispitanika. Na temelju tog uzorka često se donose zaključci o široj zajednici – cijeloj **populaciji**. U praksi je vrlo teško potvrditi je li anketa dala dobru procjenu. Izborne ankete su iznimka. Nakon izbora možemo reći koliko njihova predviđanja znaju biti precizna.

Kako bi anketa imala što veću vjerojatnost točno predvidjeti stanje cijele populacije, treba **dobro** odabrati uzorak (tj. ispitanike) i zabilježiti njihove odgovore.

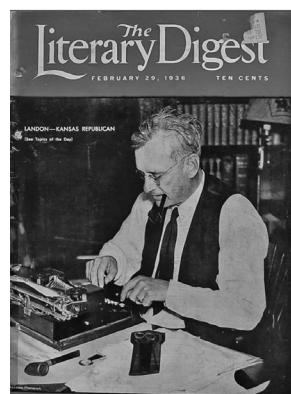
U ovom ćemo članku vidjeti da i velika količina podataka može dovesti do potpuno promašenog predviđanja. Takve greške mogu imati za posljedice gubitak povjerenja u proizvod poslovnih subjekata ili nepotrebnu potrošnju javnog novca javnih ustanova.

Slučaj tjednika *The Literary Digest*

The Literary Digest bio je američki tjednik za široku publiku osnovan 1890. godine. Imao je otprilike milijun pretplatnika i dodatne čitatelje.



Slika 1. Naslovica *Literary Digesta* sa slikom predsjednika SAD-a Roosevelta iz 1933. godine.



Slika 2. Naslovica *Literary Digesta* sa slikom guvernera Landon iz 1936.

Literary Digest provodio je anketu o ishodu predsjedničkih izbora od 1916. godine, a do 1936. godine uvijek bi točno predvidio pobjednika. Predviđanja toga tjednika u to su se vrijeme smatrала najboljima u SAD-u. Anketa provedena 1936. godine bila je jedna od najvećih i najskupljih. *Literary Digest* poslao je **10 milijuna** upitnika na adrese koje su dobivene iz popisa vlastitih pretplatnika, registra automobila i telefonskog imenika. Otprilike **2.3 milijuna** osoba vratio je anketne upitnike.

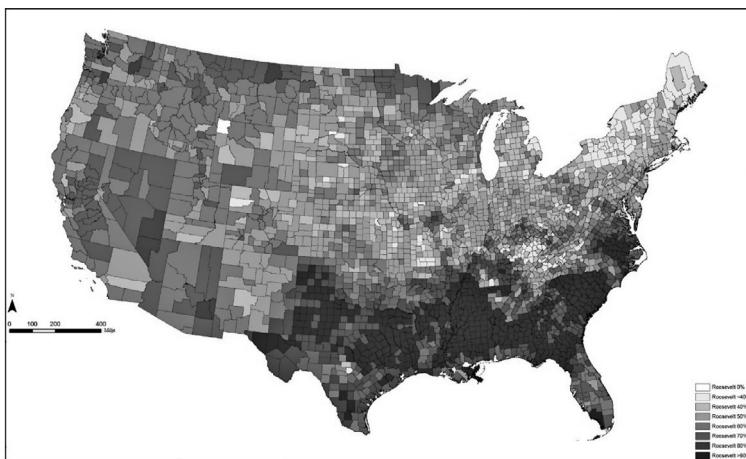


To je velik uzorak i za današnje *online* doba. Sjedinjene Američke Države 1936. godine imale su, prema procjeni Američkog ureda za popise, oko 128 milijuna stanovnika. Tjednik je anketirao nešto manje od 2 % ukupnog stanovništva i daleko više od 2 % ukupnog broja birača¹.

	Franklin Roosevelt	Alfred Landon
Predviđanje Literary Digesta	43 %	57 %
Stvarni rezultat izbora	62 %	38 %

Tablica 1. Usporedba predviđanja i stavnih rezultata

Anketa je zaključila da će republikanski kandidat **Alfred Landon**² biti uvjernjivi pobjednik protiv aktualnog predsjednika **Franklina Roosevelt**³, s 57 % naspram 43 % glasova. U stvarnosti, Roosevelt je osvojio 62 % glasova naspram 38 % za Landona, što je bio najveći postotak glasova koji je ikad osvojen u to vrijeme i drugi najviši u američkoj povijesti. Nepreciznost ankete bila je pogubna za ugled časopisa koji je prestao izlaziti 1938. godine. Cijeli slučaj poznat je kao *Literary Digest fijasko*.



Slika 3. Postotak glasova za Roosevelta diljem SAD-a – izazov je odrabiti ispitanike tako da budu pokriveni različiti dijelovi SAD-a. (Slika je preuzeta s Wikipedije.)

I drugi su promašili u procjenama, ali ne svi

Literary Digest nije bio jedini koji je pogriješio u predviđanju izbora 1936. godine. Većina drugih anketa i medija također je davala prednost Landonu ili očekivala tijesnu utrku.

Za iste izbore **George Gallup**⁴ razvio je znanstvenu metodu uzorkovanja koja je uzimala u obzir demografske i socijalne karakteristike birača, kao

¹U to vrijeme pravo glasa imale su osobe s navršenom 21 godinom.

²1887. – 1987., guverner (američke savezne države) Kansasa od 1933. do 1937. godine

³1882. – 1945., predsjednik SAD-a od 1933. do 1945. godine

⁴1901. – 1984., američki statističar, osnivač Gallup instituta za istraživanje javnog mnijenja, po obrazovanju psiholog i novinar



i njihovu vjerojatnost glasanja te dala različite težine svakoj skupini. Gallup je koristio mali uzorak na oko 50 000 ljudi, što je bilo dovoljno za dobivanje pouzdane procjene. Fijasko Literary Digesta označio je kraj ovakvih anketa i početak korištenja znanstvenih metoda u izvještavanju.

Pristrani uzorak

Pristranost prilikom skupljanja uzorka greška je koja nastaje kada uzorak koji se koristi za istraživanje nije reprezentativan za populaciju koja se proučava. To znači da neki članovi populacije imaju veću ili manju vjerojatnost da budu uključeni u uzorak, što može utjecati na valjanost i pouzdanost rezultata.

Postoje različite vrste pristranosti prilikom skupljanja uzorka, kao što su:

- **Pristranost zbog dobrovoljnosti:** kada se uzorak sastoji od dobrovoljaca koji se sami prijavljuju za sudjelovanje u istraživanju. Ovo može dovesti do toga da uzorak bude previše homogen ili da odražava samo one koji imaju jak interes ili mišljenje o temi. Primjerice, korisnici raznih proizvoda imaju mogućnost dati povratnu informaciju o proizvodu – telefonski, emailom ili ako se radi o IT proizvodu putem aplikacije. Većini tih povratnih informacija uzrok je to što proizvod ne radi prema očekivanju i uglavnom će biti negativne. Oni kojima proizvod radi prema očekivanjima uglavnom neće kontaktirati proizvođača.
- **Pristranost zbog prigodnosti:** kada se uzorak sastoji od onih koji su lako dostupni ili spremni sudjelovati u istraživanju. Ovo može dovesti do toga da uzorak bude previše ograničen ili da ne uključuje one koji su relevantni za problem. Primjerice, istraživanje o navikama korištenja mobitela koje se provodi samo među učenicima i nastavnicima u školi, a ne među općom populacijom. Uzorak će pokazati veliko korištenje edukativnih aplikacija, što općenito nije slučaj.
- **Pristranost zbog odbijanja sudjelovanja:** Ako se neki članovi populacije ne odazovu na upitnik ili odbiju sudjelovati u istraživanju, moguće je da se njihove karakteristike razlikuju od onih koji su sudjelovali. Na primjer, ako se istražuje zadovoljstvo nastavom matematike koje uključuje pitanje o ocjeni iz predmeta, moguće je da će oni koji imaju nižu ocjenu biti manje skloni odgovoriti na upitnik nego oni koji imaju višu ocjenu.
- **Pristranost preživjelih:** Fokus na uzorak koji je prošao prethodnu selekciju. Tijekom Drugog svjetskog rata istraživalo se kako poboljšati oklop na zrakoplovima, temeljem toga gdje su pogodjeni zrakoplovi koji su se vratili iz sukoba. No istaknuto je da bi možda bilo pametnije proučiti područje gdje ti zrakoplovi *nisu* pogodjeni. Oboreni zrakoplovi, koji se nisu vratili, *možda* su baš tamo pogodjeni.

- Pristranost ponuđenog izbora:** Izbor i poredak mogućih odgovora mogu imati velik utjecaj na rezultate. Primjerice, kod internetskih tražilica malo će tko ići gledati drugu stranicu ponuđenih web-stranica, a najbolja web-stranica ne mora biti ni ponuđena. Vjerojatno je da će korisnik odabrati neku više nego niže rangiranu stranicu.

Ovo su samo neki od oblika pristranosti prilikom prikupljanja podataka.

Što je pošlo po krivu u slučaju Literary Digesta?

Smatra se da je anketa imala nekoliko ključnih nedostataka koji su utjecali na njezinu valjanost i pouzdanost. Uzorak nije bio reprezentativan za cijelokupnu američku populaciju:

- Većina anketiranih mogla si je priuštiti pretplatu na tjednik, automobil i telefon za vrijeme velike depresije⁵ u SAD-u, stoga se vjerojatno radilo o bolje stojećim ljudima.
- Ljudi nezadovoljni politikom aktualnog predsjednika Roosevelt-a bili su skloniji odgovaranju na upitnik.

Možemo zaključiti da je došlo do pristranosti zbog **pogodnosti** načina dobivanja adresa na koje je poslan upitnik i **dobrovoljnosti** odgovaranja na njega.

Zaključak

U ovom članku imali smo prilike vidjeti da kod zaključivanja o općoj populaciji rezultat ne mora ovisiti o broju ispitanika, tj. veličini uzorka. Danas su razvijene metode prikupljanja i obrade koje pokušavaju smanjiti pristranost pri prikupljanju podataka⁶. Ako se prikupljanje podataka provede na pravi način, uzorak može biti relativno malen. Velik izazov u rješavanju problema pristranosti može predstavljati nepoznavanje opće populacije. Kod stanovništva imamo neku sliku jer se provode popisi stanovništva, što u nekim drugim slučajevima nećemo imati.

Uzimanje uzorka, posebice među ljudima koji mogu odbiti sudjelovati iz raznih razloga ili biti nedostupni iz drugih razloga, uvijek je izazov.

Možemo vidjeti kako specifično poznavanje populacije koja se proučava može dovesti do spoznaja koje će dovesti do napretka u metodama prikupljanja podataka. Tako je George Gallup, kao psiholog, razradio kako prikupiti podatke od ljudi i kako će oni reagirati te je uspio unaprijediti istraživanje javnog mnijenja.

⁵Svjjetska gospodarska kriza koja je trajala od 1929. do 1939. godine.

⁶Zainteresirani čitatelj više može naći o tome u članku Simulacija anketa u Matki br. 73.

