

POSLOVNA STATISTIKA

PRVO PREDAVANJE

Prikupljanje podataka

Bilješke 1A

1. PRIKUPLJANJE PODATAKA

(Autor: prof. dr. sc. Ksenija Dumičić)

Bilješke 1A

1.1. Važnost statističkih metoda u poslovanju i ekonomiji

1.2. Podaci i vrste statističkih istraživanja

1.3. Populacija i uzorak

Bilješke 1B

1.4. Tehnike statističkog uzorkovanja

1.5. Kvantitativni i kvalitativni podaci i mjerne skale

1.6. Opisne i inferencijalne metode statistike

Izvor:

- ◉ Dumičić, K. i Bahovec, V. (Ur.) (2011). Poslovna statistika. Zagreb: Element.
- ◉ Recentni izvori DZS RH i Eurostata.

1.1. VAŽNOST STATISTIČKIH METODA U POSLOVANJU I EKONOMIJI

Statističke metode široko primjenjuju menadžeri iz svih područja djelovanja u:

- ◉ poslovanju, gospodarstvu, administraciji, politici i drugdje,
- ◉ u svim granama proizvodnih i neproizvodnih djelatnosti, od prerađivačke industrije, poljoprivrede, građevinarstva, do uslužnih djelatnosti, npr. hotela, restorana, obrazovanja i drugdje, na mikro i makro razini.

U ekonomiji su značajne:

- ◉ Gospodarska statistika
- ◉ Poslovna statistika

GOSPODARSKA STATISTIKA

Gospodarska statistika kao predmet izučavanja ima makroekonomske podatke

Obuhvaća metode za njihovo prikupljanje kao i metode za izračunavanje, tumačenje i pravilno korištenje makroekonomskih indikatora pomoću kojih se mogu donositi utemeljeni zaključci, odluke i izrađivati prognoze vezane za gospodarstvo države, regije, grane djelatnosti, ...

U praćenju gospodarskih kretanja veoma je važno poznavati metodologiju svake pojedine vrste statističkog istraživanja.

Službena statistika Hrvatske harmonizira istraživanja s metodologijama Europskog statističkog sustava - ESS (*European Statistical System - ESS*).

HARMONIZIRANJE METODOLOGIJA STATISTIČKIH ISTRAŽIVANJA


Važno za gospodarsku i poslovnu statistiku:

*Državni zavod za statistiku Republike Hrvatske (DZS RH, www.dzs.hr) harmonizira istraživačke metodologije s metodologijama ESS-a, tj. Europskog statističkog ureda **EUROSTAT**-a (*Statistical Office of the European Communities*).*

- ◉ Primjena nove statističke prostorne klasifikacije NUTS Eurostata za EU i partnerske zemlje ([Nova klasifikacija za RH u 2020.!](#))
- ◉ Primjeri harmoniziranih istraživanja:
 - Anketa radne snage - ARS (*Labor Force Survey - LFS*),
 - Anketa o procjeni dohotka i životnih uvjeta privatnih kućanstva (*EU Statistics on Income and Living Conditions - EU-SILC*)
 - Standardni Eurobarometer, ...

HARMONIZIRANJE STATISTIČKIH METODOLOGIJA: NUTS METODOLOGIJA

- ◉ Statistički teritorijalni ustroj EU prema Eurostat-ovoj *Nomenklaturi statističkih prostornih jedinica* (*Nomenclature of Territorial Units for Statistics - NUTS*).
- ◉ Trenutna nomenklatura NUTS teritorij EU dijeli:
 - 92 regije na najvišoj razini NUTS 1
 - 244 regiju razine NUTS 2 i
 - 1165 na razini NUTS 3.
- ◉ Uz sustav NUTS razvijen je i sustav LAU (*Local Administrative Units*), koji predstavlja lokalne administrativne jedinice koje su osnovne sastavnice NUTS regija



U HRVATSKOJ: NOVA KLASIFIKACIJI HR_NUTS 2021.

- ◉ **Razina NUTS 1 regija:** glavne socio-ekonomske regije (cijela Hrvatska)
- ◉ **Razina NUTS 2 regija:** Osnovne za primjenu regionalne politike(i poticaja Europske unije)
- ◉ **Razina NUTS 3 regija:** male regije (u Hrvatskoj: županije)
- ◉ **LAU razinu** čine općine.

Hrvatska:

- ◉ Klasifikacija NUTS službeno je uvedena u hrvatski statistički sustav 9. prosinca 2013. godine
- ◉ od 1.1.2020. vrijedi treća revizija NUTS sustava:

Nacionalna klasifikacija statističkih regija 2021. - HR_NUTS 2021., NN 125/2019

- ◉ RH ima četiri prostorne jedinice 2. razine (HR_NUTS 2):
 - Jadranska Hrvatska,
 - Grad Zagreb,
 - Sjeverna Hrvatska i
 - Panonska Hrvatska.

HARMONIZIRANJE STATISTIČKIH METODOLOGIJA: NUTS METODOLOGIJA

Kriteriji Eurostat-a za uspostavljanje statističkih prostornih jedinica (NUTS) i broj regija u RH prema **HR_NUTS 2021.** (od 1.1.2020.)

Razina NUTS-a	Minimalni broj stanovnika	Maksimalni broj stanovnika	Broj jedinica u RH
NUTS 1	3 000 000	7 000 000	1
NUTS 2	800 000	3 000 000	4
NUTS 3	150 000	800 000	21


KODOVI NOMENKLATURE HR_NUTS 2021.

Izvor: *Statistical regions in the European Union and partner countries NUTS and statistical regions 2021, European Union, 2020.*

HRVATSKA

Code	NUTS 1	NUTS 2	NUTS 3
HR0	Hrvatska		
HR03		Jadranska Hrvatska	
HR031			Primorsko-goranska županija
HR032			Ličko-senjska županija
HR033			Zadarska županija
HR034			Šibensko-kninska županija
HR035			Splitsko-dalmatinska županija
HR036			Istarska županija
HR037			Dubrovačko-neretvanska županija
HR05		Grad Zagreb	
HR050			Grad Zagreb
HR06		Sjeverna Hrvatska	
HR061			Međimurska županija
HR062			Varaždinska županija
HR063			Koprivničko-križevačka županija
HR064			Krapinsko-zagorska županija
HR065			Zagrebačka županija
HR02		Panonska Hrvatska	
HR021			Bjelovarsko-bilogorska županija
HR022			Virovitičko-podravska županija
HR023			Požeško-slavonska županija
HR024			Brodsko-posavska županija
HR025			Osječko-baranjska županija
HR026			Vukovarsko-srijemska županija
HR027			Karlovačka županija
HR028			Sisačko-moslavačka županija
HRZ	Extra-Regio NUTS 1		
HRZZ		Extra-Regio NUTS 2	
HRZZZ			Extra-Regio NUTS 3

Nacionalna klasifikacija
statističkih regija 2021. –
Statistička regija 1. razine
(HR NUTS 1)



Legenda
HR0 Hrvatska

Nacionalna klasifikacija
statističkih regija 2021. –
Statističke regije 2. razine
(HR NUTS 2)

Legenda

HR02 Panonska Hrvatska
HR03 Jadranska Hrvatska
HR05 Grad Zagreb
HR06 Sjeverna Hrvatska



0 20 40 60 80 100
km

**Nacionalna klasifikacija
statističkih regija 2021. –
Statističke regije 3. razine
(HR NUTS 3)**

Legenda

 HR NUTS 3:

- HR021 Bjelovarsko-bilogorska županija
- HR022 Virovitičko-podravska županija
- HR023 Požeško-slavonska županija
- HR024 Brodsko-posavska županija
- HR025 Osječko-baranjska županija
- HR026 Vukovarsko-srijemska županija
- HR027 Karlovačka županija
- HR028 Sisačko-moslavačka županija
- HR031 Primorsko-goranska županija
- HR032 Ličko-senjska županija
- HR033 Zadarska županija
- HR034 Šibensko-kninska županija
- HR035 Splitsko-dalmatinska županija
- HR036 Istarska županija
- HR037 Dubrovačko-neretvanska županija
- HR050 Grad Zagreb
- HR061 Međimurska županija
- HR062 Varaždinska županija
- HR063 Koprivničko-križevačka županija
- HR064 Krapinsko-zagorska županija
- HR065 Zagrebačka županija



0 20 40 60 80 100
km

HARMONIZIRANJE STATISTIČKIH METODOLOGIJA: EUROBAROMETAR

„Eurobarometer je instrument ispitivanja koji koriste Europska komisija, Europski parlament i druge institucije i agencije EU -a za redovito praćenje **javnog mnijenja** u Europi o pitanjima vezanim za **Europsku uniju**, kao i **stavove o temama političke ili društvene prirode**. Pokriva različite teme.

Projekt Eurobarometer pokrenuo je 1974. u okviru Europske komisije Jacques-René Rabier, bivši suradnik Jeana Monneta, a prvo je zamišljen kao sredstvo za „otkrivanje Europljana samih sebi (engl. *reveal Europeans to themselves*)”.

<https://europa.eu/eurobarometer/about/eurobarometer>

Eurobarometer

Public Opinion in the European Union



Latest Surveys & Publications

10 latest surveys

PARLEMETER | September 2025 | EUROPEAN PARLIAMENT

EP Spring 2025 survey

In an increasingly unpredictable world, the European Union emerges as a place of stability in the eyes of citizens, finds survey. While approval of EU membership has reached its highest values in 2025, there are also strong expectations regarding the future role of the EU, with citizens putting the focus on security, defence, the economy, peace and democracy. Europeans call for more unity among Member States and more ... [More](#)

September 2025 | EUROPEAN COMMISSION

Attitudes towards EU Enlargement

Izvor: [Eurobarometer – Public opinion in the European Union \(europa.eu\)](https://europa.eu/eurobarometer)

POSLOVNA STATISTIKA

Definicija:

Poslovna statistika se definira kao znanost o metodama koje se koriste za pretvaranje podataka u smislene informacije u poslovnom okruženju sa svrhom stjecanja znanja za uspješnije odlučivanje i prognoziranje u uvjetima neizvjesnosti i rizika.

POSLOVNA STATISTIKA

Skup metoda za:

- prikupljanje,
- sažimanje, odnosno
- uređivanje poslovnih podataka,
- za njihovu obradu i analiziranje te
- prikazivanje i tumačenje rezultata statističke analize,

kako bi se proizvele što solidnije informacije koje su temelj učinkovitim poslovnim odlučivanju i prognoziranju.

POSLOVNA STATISTIKA

Metode primjenjive u različitim područjima poslovanja kao što su:

- ◉ **razvoj i proizvodnja** (primjerice, za razvoj proizvoda i unapređenje procesa, ...)
- ◉ **financije i upravljanje financijskim rizicima** (financijsko planiranje i analizu, za uočavanja koeficijenata koji ukazuju na probleme ili na mogućnosti investiranja ili dr., za analizu rizika ulaganja, ...)
- ◉ **računovodstvo i revizija** (za potrebe revizije na temelju uzorka ispitivanog materijala, ...)
- ◉ **marketing** (za istraživanje tržišta i provedbu marketinške kampanje, ...)
- ◉ **prodaja** (primjerice, za analizu uspješnosti prodaje po prodajnim područjima, za prognoziranje prodaje, ...)

POSLOVNA STATISTIKA

Za potrebe različitih funkcija vezanih za upravljanje, kao što su:

- ◉ **kontroling**, primjerice, za praćenje različitih financijskih pokazatelja, i dr.;
- ◉ **upravljanje kvalitetom**, npr. za statističku kontrolu procesa, izradu kontrolnih karata i plana uzorka za prihvatanje pošiljke i dr.;
- ◉ **poslovna logistika i operativni menadžment**, npr. za poboljšanja u procesa nabave, proizvodnje, upravljanja zalihama i drugo;
- ◉ **upravljanje ljudskim resursima**, npr. za ispitivanje zadovoljstva zaposlenika i unapređenja upravljanja ljudskim resursima; i dr.

ZAŠTO MENADŽER TREBA POZNAVATI STATISTIČKE METODE

- (1) da bi mogao **grafički i brojčano opisati, prikazati i protumačiti podatke** i iz njih izvedene informacije,
- (2) da bi mogao iz dijela analiziranih podataka, temeljem slučajnog **uzorka**, donijeti zaključak o cjelini iz koje je uzorak izabran, tj. da **zaključke može poopćavati**,
- (3) da bi saznao kako, kada i gdje, te s kim, sa čime u vezi i uz kolika ulaganja može **poboljšati poslovne procese i rezultate poslovanja** u smislu povećanja sveopćeg zadovoljstva i na korist svih aktera uključenih u poslovni proces u širem smislu (proizvođača, kupca, dobavljača, zaposlenika te šire društvene zajednice i okoliša),
- (4) uspješan menadžer treba **znati kako dobiti što točnije poslovne prognoze**, a to može samo osloncem na statističke metode.

1.2. PODACI I VRSTE STATISTIČKIH ISTRAŽIVANJA

Elementi ili članovi neke cjeline ili dijela su subjekti ili objekti, primjerice, osobe, poslovni subjekti, proizvodi, općine ili sl., o kojima se prikupljaju informacije.

Varijable su značajke koje se izučavaju, a koje podrazumijevaju različite vrijednosti za različite elemente. Te se vrijednosti nazivaju **podacima**.

Nasuprot varijablama, **konstante** imaju nepromjenjive vrijednosti.

Podaci su opažanja ili mjerenja vezana za jednu varijablu, koja je predmet izučavanja statistike i koja povezuju istraživane elemente.

Za svaki element izučavanja jedna varijabla će primiti određeni oblik/modelitet, tj. određenu vrijednost, odnosno podatak.

IZVORI PODATAKA I STATISTIČKA ANALIZA

Izvori podataka:

I. Sekundarni, primarni

II. Interni, eksterni,

Različiti oblici izvora podataka:

U obliku publikacija i u elektroničkom obliku, kao baze podataka i poslovni registri (Registar poslovnih subjekata RH (DZS), Registar financijskih izvještaja FINA-e, ...)

Statistička analiza može biti:

- ◉ **jednodimenzionalna analiza ili**
- ◉ **dvo-i višedimenzionalna, ako nas zanimaju odnos, povezanost, odnosno ovisnost između dviju ili više varijabli**

SEKUNDARNI IZVORI

- ◉ Državni zavod za statistiku Republike Hrvatske (DZS RH): <http://www.dzs.hr>,
- ◉ Hrvatska narodna banka: <http://www.hnb.hr>,
- ◉ Hrvatska gospodarska komora: <http://www.hgk.hr>,
- ◉ Ministarstvo financija Republike Hrvatske: <http://www.mfin.hr>,
- ◉ Hrvatska agencija za nadzor financijskih usluga-
<http://www.hanfa.hr>,
- ◉ Zagrebačka burza: <http://www.zse.hr>,
- ◉ EUROSTAT- Statistical Office of the European Communities :
<http://epp.eurostat.ec.europa.eu/portal/page/portal/eurostat/home>
- ◉ i još mnogi drugi.

SEKUNDARNI IZVORI

- ◉ World Tourism Organization (UNWTO) :
<http://www.unwto.org/index.php>
- ◉ UN Food and Agriculture Organization (FAO): <http://www.fao.org/>
- ◉
- ◉
- ◉ International Monetary Fund (IMF):
<http://www.imf.org/external/index.htm>;
- ◉ World Bank: <http://www.worldbank.org/>
- ◉ Bloomberg- <http://www.bloomberg.com/>
- ◉ Reuters - <http://www.reuters.com/>
- ◉ New York Stock Exchange - <http://www.nyse.com/>
- ◉ Tokyo Stock Exchange - www.tse.or.jp/english/ ...

PRIMARNI IZVORI

Primarni izvori podataka su originalna, empirijska kvantitativna istraživanja:

- (1) anketna istraživanja (engl. *survey research*),
- (2) istraživanja pomoću pokusa (engl. *experimental research*), ili
- (3) kontrolirana neposredna opažanja (engl. *direct controlled investigation* ili *observational research*)

VRSTE PODATAKA S OBZIROM NA DIZAJN ISTRAŽIVANJA

(1) anketni podaci dobiveni su primjenom dizajna ankete:

- telefonskim intervjuom,
- osobnim intervjuom,
- poštanskom metodom, ...

(2) eksperimentalni podaci rezultat su primjene dizajna eksperimenta

(3) opaženi podaci koji su prikupljeni dizajnom kontroliranih opažanja

(1)ANKETNI PODACI

Anketa se definira kao vrsta statističkog istraživanja koje proučava agregate jedinica, najčešće ljudi, ekonomskih ili društvenih cjelina/institucija pomoću **anketnog upitnika u popisu ili na statističkom uzorku jedinica.**

Cilj je izabrati reprezentativni uzorak jedinica i doći do što točnijih anketnih podataka sa svrhom daljnje obrade podataka.

S obzirom na način prikupljanja:

I.Anketa uz pomoć anketara: telefonskim intervjuom ili osobnim intervjuom

II.Anketa bez anketara:

poštanskom metodom:

- klasična,
- e-mail ili
- Web anketa.

VRSTE ANKETNIH PITANJA

S obzirom na zatvorenost:

- **Zatvorena pitanja** s ponuđenim odgovorima (višestruki odgovori ili dihotomni; jednostavno se obrađuju)
- **Otvorena** (teško ih je analizirati)

S obzirom na ulogu:

- **Demografska pitanja** o karakteristikama ispitanika ili jedinice analize (Dodaju se u svaki anketni upitnik)
- **Filterska pitanja** za izdvajanje kvalificiranog sugovornika s kojim se nastavlja anketni intervj

Tablica 1.2. Prednosti i nedostaci različitih načina prikupljanja anketnih podataka

	OSOBN INTERVJU	TELEFONSKI INTERVJU	POŠTANSKA ANKETA
TROŠKOVI PRIKUPLJANJA PODATAKA	visoki	srednji	niski
VRIJEME POTREBNO ZA PRIKUPLJANJE	srednje	kratko	dugo
VELIČINA UZORKA UZ DANE TROŠKOVE	mala	srednja	velika
MOGUĆ BROJ PODATAKA PO ISPITANIKU	velika	srednja	mala
DOSEŽE VRLO RASPROSTRANJENE JEDINICE	ne	možda moguće	da
DOSEŽE MJESTA OD POSEBNOG INTERSA	da	možda moguće	ne
INTERAKCIJA S ISPITANIKOM	da	da	ne
RAZINA PRISTRANOSTI ZBOG ANKETARA	visoka	srednja	nema je
OZBILJNOST PRISTRANOSTI ZBOG NEODGOVORA	mala	mala	velika
VIZUALNO POTICANJE ISPITANIKA	moguće	nemoguće	možda moguće
POTREBA ZA OBUKOM ANKETARA	da	da	ne

(2) EKSPERIMENTALNI PODACI

Eksperimentalni podaci rezultat su primjene dizajna eksperimenta.

U dizajnu eksperimenta sistematski se variraju faktori inputa koji se mogu kontrolirati te se određuju učinci koje ti faktori imaju na parametre izlaznog proizvoda.

U dizajnu eksperimenta analitičar kontrolira koji tretmani i kako se koriste.

Primjena dizajna eksperimenta:

- ◉ u fazi razvoja proizvoda
- ◉ u fazi razrade promidžbene kampanje
- ◉ pri određivanju učinkovitog načina izlaganja proizvoda u samoposluzi
- ◉ pri određivanju učinkovitog načina prodaje ili sl.

(3) OPAŽENI PODACI

Opaženi podaci dobiveni su izravnim kontroliranim opažanjem.

- ◉ Primjerice, promatranja kupaca u određenim situacijama u trgovini, banci...- to je **metoda tajnoga kupca** (engl. *mystery shopping*).
- ◉ Pritom se koristi **evidencijski obrazac**.
- ◉ Ponekad se kombiniraju dizajn eksperimenta i dizajn kontroliranih opažanja

[Datoteka](#) [Uređivanje](#) [Prikaz](#) [Favoriti](#) [Alati](#) [Pomoć](#)

Favoriti REPUBLIKA HRVATSKA - DRŽAVNI ZAVOD ZA STATIS...

REPUBLIKA HRVATSKA - DRŽAVNI ZAVOD ZA STATISTIKU

Početna stranica | Objavljeni podaci | Baze podataka | Obrasci | Prvi rezultati | Novosti | Zanimljivosti | Kutak za novinare

Publikacije

- Kalendar
- Program publiciranja
- Statističke informacije
- Zloupotreba opojnih droga
- Koruptivna kaznena djela
- Nasilje u obitelji, 2001.-2006.
- Žene i muškarci u Hrvatskoj
- Statistički ljetopis
- Mjesečno statističko izvješće
- Priopćenja i Stat. izvješća
- Kako doći do publikacija?
- Pravilnik o distribuciji publikacija

Popisi

- Probni popis stanovništva 2009.
- Popis stanovništva 2001.
- Popis poljoprivrede 2003.

Baze podataka

- PC AXIS baze podataka
 - Strukturno poslovne statistike
 - Popis poljoprivrede 2003.
 - Naselja i stanovništvo RH 1857. - 2001.

Nomenklature, standardi, metodologije

- Statistički standardi za godišnje istraživanje o utoršku sirovina, materijala i energenata u industriji - IND-21/REPRO.
PDF dokument (1,08 MB), potreban je Acrobat reader 5.0 ili noviji
- Statistički standardi za strukturno-poslovno istraživanje industrije
PDF dokument (443 KB)
objavljena u [Narodnim novinama broj 49/09](#), od 20. travnja 2009.
(otvara stranice Narodnih novina u novom prozoru)
- Nomenklatura industrijskih proizvoda - NIPUM 2009.
PDF dokument (1,09 MB)
objavljena u [Narodnim novinama broj 11/09](#), od 26. siječnja 2009.
(otvara stranice Narodnih novina u novom prozoru)
- Nomenklatura industrijskih proizvoda - NIP 2009.
PDF dokument (1,58 MB)
objavljena u [Narodnim novinama broj 6/10](#), od 12. siječnja 2010.
(otvara stranice Narodnih novina u novom prozoru)
- Nacionalna klasifikacija djelatnosti - NKD 2007
Svi prilozi su u PDF formatu
 - Novi statistički standard NKD 2007.
 - Nacionalna klasifikacija djelatnosti NKD 2007.
 - Nacionalna klasifikacija djelatnosti NKD 2007. - objašnjenja

1.3. POPULACIJA I UZORAK

Populacija

je potpuni skup svih jedinica ili svih podataka koje zanimaju istraživača. Veličina populacije označena je s N . Najčešće je populacija **konačna**, a može biti veoma velika, pa i **beskonačna**.

Pri istraživanjima dizajnom ankete i dizajnom kontroliranih opažanja populacija je **realna**, dok je kod dizajna eksperimenta ona ponekad i **hipotetična**.

POPULACIJA I UZORAK

Uzorak

je izabrani podskup populacije, a njegova je veličina označena s n . Veličina uzorka obično je značajno manja od veličine populacije te omogućava veću brzinu i manje troškove prikupljanja podataka. Ako je uzorak slučajan (statistički), on čini temelj inferencijalne statistike.

OKVIR IZBORA

Ciljana populacija (engl. *target population*) nije uvijek jednaka onoj koja je dostupna, stoga ih se i terminološki razlikuje, pa se ova druga naziva **populacijom iz koje se bira uzorak** (engl. *sampling population*). Stvarno istraživana populacija pokrivena je tzv. **okvirom izbora uzorka** (engl. *sampling frame*).

Iz slučajnog (statističkog) uzorka, koji je po pravilu izabran kao nepristran, zaključci se smiju poopćavati samo na istraživanu populaciju iz koje je uzorak zaista i izabran.

PRIMJERI POPULACIJA

- ◉ **objekti:** računi, narudžbe, poluproizvodi, konačni proizvodi, dionice, strojevi, stanovi...
- ◉ **osobe:** punoljetni građani, studenti, zaposlenici, nezaposlene osobe, menadžeri, kućanstva (to je skupina osoba u ekonomskoj zajednici), obitelj (to je skupina osoba koje su u srodstvu), razredi učenika (skupine osoba), i drugo...
- ◉ **poslovni subjekti:** obrti, mala poduzeća, srednje velika poduzeća, velika poduzeća, ili neka kombinacija, no, to mogu biti poslovne jedinice, pogoni, dućani, poslovnice i drugo,
- ◉ **pojave:** transakcije, kupovine...
- ◉ **prostorne jedinice:** naselja, općine, NUTS regije, ...

KONZISTENTNOST, HOMOGENOST I USPOREDIVOST PODATAKA

- ◉ Bitan preduvjet za opravdanost i mogućnost primjene određenih metoda statističke analize je **konzistentnost, odnosno homogenost statističkih podataka** s obzirom na **pojam, prostor, vrijeme i metodologiju prikupljanja**, jer to omogućava analize temeljene na uspoređivanju podataka,
- ◉ To je posebno značajno danas kada se Hrvatska glede istraživačkih statističkih metodologija **harmonizira** s Europskom unijom i njezinim statističkim standardima ESS-a

PARAMETAR I PROCJENA

- ◉ Kada računamo određeni pokazatelj temeljem N podataka prikupljenih iz cijele **populacije** nazivamo ga **parametar**
- ◉ Kada se isti taj pokazatelj računa temeljem n podataka prikupljenih iz **uzorka** nazivamo ga **procjena parametra** (engl. *estimate* ili *statistic*).
- ◉ **Parametar** je opisna mjera populacije, a **procjena** je opisna mjera uzorka.

INFERENCIJALNA STATISTIKA

- ◉ Statistika kao znanstvena induktivna metoda oslanja se samo na statističke, odnosno slučajne ili probabilističke uzorke, kod kojih svi elementi populacije imaju poznatu i pozitivnu vjerojatnost izbora u uzorak, te koji omogućavaju računanje procjena te izračunavanje pogreške (engl. *sampling error*) nastale zbog primjene uzorka pri procjenjivanju nepoznatog parametra populacije.
- ◉ Primjena slučajnih uzoraka temelj je inferencijalne statistike, tj. induktivnih postupaka:
 - procjenjivanja parametara i
 - testiranja statističkih hipoteza