Sveučilište u Zagrebu Agronomski fakultet
Svetošimunska cesta 25, 10000 Zagreb
Telefon: +385 (0)1 2393 777
E-mail: dekanat@agr.hr
Web: www.agr.unizg.hr

Poslovna statistika 1 (132786)

Nositelj kolegija

doc. dr. sc. Petra Posedel Šimović

Opis kolegija

Predmet obuhvaća temelje deskriptivne i inferencijalne statistike. Pri izboru gradiva i primjera vodi se računa o specifičnom kontekstu agroekonomske struke. Dio o deskriptivnoj statistici obuhvaća sadržaje o tipovima podataka, njihovoj organizaciji, prezentaciji i interpretaciji, skalama mjerenja i numeričkim deskriptivnim pokazateljima. Posebna se pozornost poklanja razvoju statističke pismenosti i opće kulture pri interpretaciji statističkih pokazatelja. U kratkom dijelu o osnovama teorije vjerojatnosti izlažu se elementi nužni za razumijevanje složenijih koncepata. Uvode se i opisuju pojmovi diskretne i kontinuirane slučajne varijable i njihove raspodjele: binoma, geometrijska, hipergeometrijska, Poissonova, normalna, uniformna, eksponencijalna i t-raspodjela. Ostatak predmeta posvećen je inferencijalnoj statistici – intervalnim procjenama očekivanja i vjerojatnosti i testiranju hipoteza o njima.

ECTS: **6.00**

Engleski jezik: **R1**

E-učenje: **R1**

Sati nastave: 60
Predavanja: 44
Auditorne vježbe: 12
Seminar: 4

Izvođač predavanja

- doc. dr. sc. Petra Posedel Šimović

Izvođač vježbi

- doc. dr. sc. Petra Posedel Šimović

Ocjenjivanje

Dovoljan (2): 60-70%
Dobar (3): 71-80%
Vrlo dobar (4): 81-90%
Izvrstan (5): 91-100%

Uvjeti za dobivanje potpisa

Redovito pohađanje predavanja i vježbi, osvajanje barem 25% mogućih bodova na svakom ispitu znanja, izrada zadaća

Vrsta kolegija

- Prijediplomski studij / Agrarna ekonomika (Obvezni kolegij, 3. semestar, 2. godina)

Opće kompetencije

Stjecanje statističke opće kulture te statističkih znanja i vještina primjenjivih u analizi i rješavanju statističkih problema iz prakse u agroekonomskoj struci.

Developed by Superfluo d.o.o. • www.superfluo.hr

Sveučilište u Zagrebu Agronomski fakultet
Svetošimunska cesta 25, 10000 Zagreb
Telefon: +385 (0)1 2393 777
E-mail: dekanat@agr.hr
Web: www.agr.unizg.hr

Oblici nastave

- Predavanja

  Predavanja s primjerima
- Auditorne vježbe
- Seminari

  seminarski rad na projektnom zadatku

Ishodi učenja i način provjere

Ishod učenja	Način provjere
Klasificirati skale mjerenja i tipove podataka. Organizirati podatke i grafički ih prikazati. Računati osnovne numeričke deskriptivne mjere podataka	Izrada problemskih zadataka, samostalno izrađena zadaća, pismeni ispit
Primijeniti Excelove alate za deskriptivnu statistiku	Sudjelovanje u radu u praktikumu, grupni rad na zadatcima, samostalno izrađena zadaća
Utvrditi vjerojatnost događaja. Diferencirati raspodjele diskretnih i kontinuiranih slučajnih varijabli. Koristiti statističke tablice	Sudjelovanje u problemskoj nastavi i raspravi, izrada problemskih zadataka, samostalno izrađena zadaća, pismeni ispit
Identificirati i razlikovati razne vjerojatnostne raspodjele	Sudjelovanje u problemskoj nastavi i raspravi, izrada problemskih zadataka, samostalno izrađena zadaća
Komentirati izgled grafa funkcije gustoće normalne raspodjele u ovisnosti o veličini standardne devijacije	Sudjelovanje u problemskoj nastavi i raspravi, izrada problemskih zadataka, samostalno izrađena zadaća, pismeni ispit
Konstruirati interval procjene za očekivanja i udjele	Sudjelovanje u problemskoj nastavi i raspravi, izrada problemskih zadataka, samostalno izrađena zadaća, pismeni ispit
Formulirati hipotezu, testirati je i donijeti zaključak o njezinoj istinitosti na temelju testa	Izrada problemskih zadataka, samostalno izrađena zadaća, pismeni ispit

Developed by Superfluo d.o.o. • www.superfluo.hr

Sveučilište u Zagrebu Agronomski fakultet
Svetošimunska cesta 25, 10000 Zagreb
Telefon: +385 (0)1 2393 777
E-mail: dekanat@agr.hr
Web: www.agr.unizg.hr

Način rada

Obveze nastavnika

1. Ustrojiti i redovito i savjesno izvoditi nastavu i druge oblike nastavnog rada
2. Pripremati nastavne i ispitne materijale
3. Razraditi i provoditi odgovarajuće metode praćenja i vrednovanja rada studenata
4. Bodovati i ocijeniti rad studenata na ispitima znanja, zadaćama i seminarskim radovima studenata te na projektnom zadatku
5. Poticati studente na samostalan rad i razvijati njihovo zanimanje za predmet
6. Biti dostupan za pitanja studenata na nastavi, u vrijeme konzultacija i prema dogovoru u drugo vrijeme

Obveze studenta

1. Redovito prisustvovati nastavi
2. Izvršavati nastavne obveze (predavati zadaće, izraditi seminarski rad i praktični rad na računalu, pristupati ispitima znanja)
3. Aktivno sudjelovati u nastavi pitanjima, davanjem odgovora na problemska pitanja
4. Angažirano sudjelovati u radu, raditi u grupama, svladati predviđene vježbe
5. Na svakom ispitu znanja studenti trebaju skupiti minimalno 25% bodova da bi ostvarili pravo na potpis

Polaganje ispita

Elementi praćenja	Maksimalno bodova ili udio u ocjeni	Bodovna skala ocjena	Ocjena	Broj sati izravne nastave	Ukupni broj sati rada prosječnog studenta	ECTS bodovi
1.ispit znanja	40%			2	40	2
2.ispit znanja	30%			2	30	1
3.ispit znanja	30%			2	30	1
Aktivno sudjelovanje na nastavi	do 10%					
Pohađanje nastave i izrada zadaća				54	80	2
UKUPNO	100%	0-59 60-70 71-80 81-90 91-100	Nedovoljan (1) Dovoljan (2) Dobar (3) Vrlo dobar (4) Odličan (5)		180	6

Developed by Superfluo d.o.o. • www.superfluo.hr

Sveučilište u Zagrebu Agronomski fakultet
Svetošimunska cesta 25, 10000 Zagreb
Telefon: +385 (0)1 2393 777
E-mail: dekanat@agr.hr
Web: www.agr.unizg.hr

Elementi praćenja	Opis	Rok	Nadoknada
2.ispit znanja	Diskretne i kontinuirane slučajne varijeble i njihove raspodjele. Statistika uzoraka	12.tjedan	
3. ispit znanja	Inferencijalna statistika – intervalne procjene i testiranje hipoteza: udjeli i srednje vrijednosti	16. tjedan	
Pohađanje nastave i izrada zadaća	Evidencija nazočnosti studenata, samostalno izrađivanje zadaća, aktivno sudjelovanje na nastavi	Kroz semestar	
Aktivno sudjelovanje na nastavi	Studenti se potiču odgovarati na problemska pitanja, predlažu načine za rješavanje problema, vođeni su do ispravnih zaključaka vlastitim kritičkim razmišljanjem, rade u grupama na rješavanju konkretnog problema iz prakse	Kontinuirano tijekom nastave	
Pismeni ispit	Za studente koji nisu položili predmet preko ispita znanja ako imaju pravo na potpis	U ispitnim rokovima	

Developed by Superfluo d.o.o. • www.superfluo.hr

Sveučilište u Zagrebu Agronomski fakultet
Svetošimunska cesta 25, 10000 Zagreb
Telefon: +385 (0)1 2393 777
E-mail: dekanat@agr.hr
Web: www.agr.unizg.hr

Tjedni plan nastave

1. Što je i čemu služi statistika Svrha statistike. Primjeri iz deskriptivne i inferencijalne statistike. Pojmovi populacije i uzorka. Kvalitativne i kvantitativne varijable. Skale mjerenja Grafičko predočavanje kvalitativnih i kvantitativnih podataka.
2. Organizacija i prezentacija podataka Razni tipovi dijagrama. Interpretacija dijagrama. Uočavanje manipulacija podatcima i njihovog tendencioznog prikazivanja. Histogrami.
3. Numeričke deskriptivne mjere Srednja vrijednost, medijan i mod. Varijanca i standardna devijacija. Koeficijent varijacije. Kvartili, centili.
4. Primjena Excela I Unos podataka u Excel, struktura radnog prostora, tvorba i uporaba formula, statističke funkcije u Excelu
5. Primjena Excela II Primjena Excela u određivanju numeričkih deskriptivnih mjera i grafičkom prikazivanju podataka
6. Osnovni elementi teorije vjerojatnosti Slučajni pokus, ishod i prostor događaja. Primjeri. Nezavisni i zavisni događaji. Tri pristupa konceptu vjerojatnosti. Uvjetna vjerojatnost
7. Diskretne slučajne varijable i njihove raspodjele I Vjerojatnostna raspodjela diskretne slučajne varijable. Očekivanje i standardna devijacija. Primjeri. Binomna slučajna varijabla i binomna formula.
8. Diskretne slučajne varijable i njihove raspodjele II Binomna raspodjela, geometrijska raspodjela, Poissonova i hipergeometrijska raspodjela. Primjeri.
9. Kontinuirane slučajne varijable i njihove raspodjele I Normalna raspodjela. Primjeri i primjene. Računanje s tablicama standardne normalne raspodjele.
10. Kontinuirane slučajne varijable i njihove raspodjele II Aproksimacija normalne raspodjele kontinuirane slučajne varijable binomnom raspodjelom diskretne slučajne varijable. Uniformna raspodjela.
11. Populacije i uzorci Intervalne procjene očekivanja Slučajni i neslučajni uzorci. Odabir slučajnog uzorka. Pogreške. Statistike uzorka.
12. Intervalne procjene vjerojatnosti Točkovne i intervalne procjene. Intervalne procjene očekivanja za velike i male uzorke. t-raspodjela. Intervalne procjene vjerojatnosti. Određivanje veličine uzorka.
13. Testiranje hipoteza o očekivanju Testiranje hipoteza. Primjeri. Tipovi pogrešaka. Jakost testa i repovi testa.
14. Testiranje hipoteza o vjerojatnosti Testiranje hipoteza o očekivanju za velike i male uzorke. Testiranje hipoteza o vjerojatnosti.
15. Seminar i ispit Pismena i usmena provjera znanja. Seminarski rad

Obvezna literatura

1. P.S. Mann, Statistics for Bussines and Economics, J. Wiley, N.Y., 1995.
2. P. Newbold, W. L. Carlson, B. Thorne: Statistika za poslovanje i ekonomiju, Mate d.o.o, Zagreb, 2010
3. M. Silver: Business statistics, Mc Graw-Hill, 1997.
4. I. Šošić, Zbirka zadataka iz statistike, Mikrorad i Ekonomski fakultet, Zagreb, 1998.

Preporučena literatura

1. L. Kazmier, Schaum's Easy Outline of Business Statistics, McGraw-Hill, N.Y., 2003.
2. B. Petz, Statistika za nematematičare, Školska knjiga, Zagreb,
3. D. Huff, How to lie with statistics, WW Norton, N.Y. 1993

Developed by Superfluo d.o.o. • www.superfluo.hr

Sveučilište u Zagrebu Agronomski fakultet
Svetošimunska cesta 25, 10000 Zagreb
Telefon: +385 (0)1 2393 777
E-mail: dekanat@agr.hr
Web: www.agr.unizg.hr

Sličan kolegij na srodnim sveučilištima

- Matematik und Statistik, BOKU
- Statistika, Sveučilište u Osijeku Poljoprivredni fakultet
- Statistik, University of Hohenheim

Developed by Superfluo d.o.o. • www.superfluo.hr