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

Agroekonometrija (296316)

Nositelj kolegija

doc. dr. sc. Petra Posedel Šimović

Opis kolegija

Predmet Agroekonometrija uvodi studente u kvantitativne metode analize podataka koje se koriste u agrarnoj ekonomiji i ruralnoj sociologiji. Naglasak je na praktičnoj primjeni kvantitativnih metoda razumijevanju agroekonomskih pojava i njihovih odnosa, poput procjene utjecaja agrotehničkih mjera na prinose, kretanja cijena poljoprivrednih proizvoda, analizi tržišta, financijske uspješnosti gospodarstva, ponašanja potrošača, marketinga poljoprivredno-prehrambenih proizvoda, ruralnih kretanja i odnosa. Nastava se izvodi u računalnoj učionici uz primjenu softvera Excel i R ili SPSS. Studenti kroz rad na stvarnim podacima uče kako interpretirati rezultate modela i donositi odluke temeljene na kvantitativnim dokazima.

ECTS: **6.00**

Engleski jezik: **R1**

E-učenje: **R1**

Sati nastave: 60
Predavanja: 30
Vježbe u praktikumu: 16
Seminar: 14

Ocjenjivanje

Dovoljan (2): 51-64%
Dobar (3): 65-75%
Vrlo dobar (4): 76-89%
Izvrstan (5): >90%

Vrsta kolegija

- Diplomski studij / Agrobiznis i ruralni razvitak (Izborni kolegij, 1. semestar, 1. godina)

Opće kompetencije

Uspješnim završetkom ovog modula student će:
- Primijeniti ekonometrijske modele u analizi ekonomskih problema u poljoprivredi te razumijevanju agronomskih pojava i njihovih odnosa
- Evaluirati i interpretirati rezultate ekonometrijskih modela i primijeniti ih u donošenju poslovnih ili razvojnih odluka
- Identificirati i primijeniti indikatore za mjerenje ruralnosti, metode za upravljanje troškovima u agrobiznisu, metode kontrole i ocjene efikasnosti projekata
- Kritički prosuđivati, procijeniti i preporučiti rješenja vezana uz menadžment i marketing u agrobiznisu te agrarnu i ruralnu politiku
- Analizirati tržišta, financijsku uspješnost gospodarstva, ponašanje potrošača i marketinga poljoprivredno-prehrambenih proizvoda
- Interpretirati podatke uz primjenu računalnih alata
- Samostalno oblikovati mini-projekt na stvarnom skupu podataka iz poljoprivredne prakse

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
  Upoznavanje studenata s kvantitativnim metodama analize podataka koje se koriste u agrarnoj ekonomiji i ruralnoj sociologiji te temeljnim znanjima i alatima potrebnim za analizu i interpretaciju istih.
- Auditorne vježbe
  Primjena znanja u programskim paketima Excel i R ili SPSS, te rad na stvarnim podacima u cilju interpretacije rezultata modela i donošenje odluka temeljenih na kvantitativnim dokazima.
- Vježbe u praktikumu
  Primjena znanja u programskim paketima Excel i R ili SPSS, te rad na stvarnim podacima u cilju interpretacije rezultata modela i donošenje odluka temeljenih na kvantitativnim dokazima.
- Seminari
  Izrada mini-projekta na temelju zadane agroekonomske ideje ili cilja te istraživanje raspoloživih podataka iz poljoprivredne prakse.

Ishodi učenja i način provjere

Ishod učenja	Način provjere
Formulirati ekonometrijski model na temelju poljoprivredne teorije (npr. funkcija proizvodnje ili potražnje).	Aktivnost na nastavi, seminarski rad (mini projekt), pismeni ispit I.
Procijeniti parametre jednostavne i višestruke regresije koristeći specijalizirani softver (Excel, JASP, R ili SPSS) na realnim agro-podacima	Aktivnost na nastavi, pismeni ispit I.
Interpretirati rezultate analize jednostavne i višestruke linearne regresije na agrarnim podacima	Aktivnost na nastavi, seminarski rad (mini projekt), pismeni ispit I.
Dijagnosticirati narušavanje pretpostavki klasičnog modela jednostavne i višestruke linearne regresije (multikolinearnost, heteroskedastičnost, autokorelacija)	Aktivnost na nastavi, pismeni ispit II.
Modelirati utjecaj kvalitativnih čimbenika te testirati razliku između skupina.	Aktivnost na nastavi, seminarski rad (mini projekt),
Izraditi kratkoročnu prognozu poljoprivrednih prinosa ili cijena primjenom metoda dekompozicije vremenskih nizova.	Aktivnost na nastavi, pismeni ispit II.
Samostalno oblikovati mini-projekt na stvarnom skupu podataka iz poljoprivredne prakse.	Seminarski rad

Način rada

Obveze nastavnika

Prenijeti studentima znanje iz područja vezanog uz cilj, ishode učenja i kompetencije ovog modula, putem predavanja, primjera za vježbu i vođenja izrade mini-projekta (seminara). Nastavnik održava stalnu komunikaciju sa studentima te im stavlja na raspolaganje nastavne materijale i važne informacije u svezi modula korištenjem suvremenih metoda učenja, uključivo i e-učenje. Također provjerava nazočnost, vrednuje stupanj usvajanja znanja i ocjenjuje studente.

Obveze studenta

Studenti su obavezni nazočiti predavanjima, vježbama i seminarskim vježbama te raditi na izradi seminarskog rada u obliku mini-projekta i pripremi za pisane provjere znanja (ispite). Studenti su također dužni redovito pratiti obavijesti vezane uz nastavu i prijaviti se na sustav e-učenja kao korisnici modula. Kod predaje seminarskih radova i prijavljivanja ispita dužni su se držati zadanih rokova.

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

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
Pohađanje nastave				30	30	1
Priprema i prezentacija mini-projekata (MP)	20%	20 40 60 80	Dovoljan (2) Dobar (3) Vrlo dobar (4) Izvrstan (5)	26	30	1
Parcijalni ispit I. (PI1)	40%	0-50% 51-64% 65-75% 76-89% 90-100%	Nedovoljan (1) Dovoljan (2) Dobar (3) Vrlo dobar (4) Izvrstan (5)	2	60	2
Parcijalni ispit II. (PI2)	40%	0-50% 51-64% 65-75% 76-89% 90-100%	Nedovoljan (1) Dovoljan (2) Dobar (3) Vrlo dobar (4) Izvrstan (5)	2	60	2
Aktivno sudjelovanje u nastavi i izrada zadaća (AKTV)	10%					
Ukupno	110%	0.4*(PI1)+0.4*(PI2)+0.2*MP+AKTV		60	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

Tjedni plan nastave

1. Uvod u agroekonometriju i ponavljanje statistike: podsjetnik na deskriptivne i inferencijalne metode, svrha i primjena ekonometrije u poljoprivredi, izvori podataka (DZS, HGK, Ministarstvo poljoprivrede)
2. Jednostavna linearna regresija: modeliranje odnosa prinosa i inputa (gnojivo, rad, trošak), interpretacija parametara. Analiza povezanosti varijabli: Pearsonova i Spearmanova korelacija.
3. Višestruka regresija: uvođenje više objašnjavajućih varijabli, procjena modela, interpretacija koeficijenata modela
4. Višestruka regresija: Multikolinearnost, heteroskedastičnost, testiranje značajnosti, transformacije podataka
5. ANOVA i dummy varijable: testiranje razlika između skupina – primjer regija, godina, sortimenta
6. Planiranje mini-projekta primjenom regresijske ili vremenske analize na stvarnom skupu podataka iz poljoprivredne prakse: značaj planiranja, vrste analize, struktura analize, upute za izradu jednostavne ekonometrijske analize.
7. 1. Međuispit: pismeni.
8. Analiza vremenskih nizova: osnovni pojmovi trenda i sezonalnosti
9. Analiza vremenskih nizova: osnovni pojam cikličnosti, vizualizacija u Excelu
10. Analiza vremenskih nizova: modeliranje trenda, sezonske korekcije, kratkoročna prognoza
11. Napredna primjena vremenskih nizova: kombiniranje trenda i regresije.
12. Analiza cijene mlijeka kroz vrijeme i faktori troškova
13. Prezentacije projekata
14. 2. Međuispit: pismeni.
15. Prezentacije projekata

Preduvjeti

- Poslovna statistika 1 (132786)

Obvezna literatura

1. P. Newbold, W. L. Carlson, B. Thorne: Statistika za poslovanje i ekonomiju, Mate d.o.o, Zagreb (2010)
2. Jeffrey M. Wooldridge, Introductory Econometrics: A Modern Approach, South-Western, Cengage Learning (2020)
3. G. van Belle: Statistical rules of Thumb, John Willey and Sons, USA, 2002.

Preporučena literatura

1. Hill, R. C., Griffiths, W. E., Lim, G. C. (2018): Principles of Econometrics, Wiley.
2. • F.M. Dekking, C. Kraaikamp, H.P. Lopuhaa, L.e. Meester: A modern introduction to probability and statistics, understanding why and how, Springer-Verlag, London, 2005

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