Sveučilište Sjever

Preddiplomski sveučilišni studij Zaštita okoliša, recikliranje i ambalaža

ISVU šifra	Naziv predmeta	Status predmeta	Semestar
257689	Statistika	Obvezni	4

Tip predmeta	Oblici nastave (ukupan broj sati u semestru)				Samostalni rad (sati)	ECTS
	P	S	V	E-učenje		
Opći	30	0	30		60	5

Nastavnik	Bojana Harambašić predavač
Suradnik	
Cilj predmeta	Cilj kolegija je upoznati studente s osnovnim statističkim pojmovima i metodama. Osposobiti studente da mogu, odgovarajućim postupcima, provesti statističku analizu prikupljenih podataka. Razvijati kreativne sposobnosti studenata kroz primjenu znanja u području tehnike i gospodarstva.
Ishodi učenja	1. Utvrditi, razlikovati i opisati različite kombinatorne probleme te ih koristiti pri rješavanju jednostavnijih zadataka. 2. Valorizirati osnovne pojmove vjerojatnosti događaja i uvjetne vjerojatnosti te konstruirati i grafički prikazati podatke, izračunati srednje vrijednosti i mjere raspršenosti. 3. Utvrditi diskretne i neprekidne slučajne varijable te ih pravilno tumačiti i ispitati i razlikovati diskretne i neprekidne razdiobe te ih koristiti pri rješavanju jednostavnijih problema-zadataka. 4. Samoprocijeniti ideju statističkog testa i opisati statistički test te analizirati osnovne postupke pri testiranju hipoteza koje se odnose na očekivanje te pravilno interpretirati dobivene rezultate 5. Preispitati pojmove korelacije i regresije te valorizirati korelaciju i regresiju analizu
Uvjeti za upis predmeta (odslušan ili položen kolegij) te potrebna znanja i vještine	Nema
Vrste izvođenja predmeta	Auditorne vježbe Predavanja Samostalni zadaci
Komentari	
Obveze studenata	Redovito pohađanje predavanja i auditornih vježbi. Izrada domaćih zadataka. Polaganje pismenog i usmenog ispita. Pismeni ispit obuhvaća numeričko rješavanje problemskih zadataka. Na usmenom ispitu provjerava se usvojenost teorijskih sadržaja na razini zadanih ishoda učenja

Sadržaj predmeta

Nastavna cjelina	Oblici nastave (sati)			
	Predavanja	Seminari	Vježbe	E-učenje

Iz uzorka prema populaciji: Što je reprezentativan uzorak? Kako obraditi uzorak? Tablica frekvencija. Relativne frekvencije. Grafički prikaz podataka (excell). Srednja vrijednost, medijan, mod. Raspršenje podataka, odstupanja, teorem o prosječnom odstupanju, prosjek apsolutnih odstupanja i SD (excell). Iz populacije prema uzorku: Može li se iz poznavanja sustava/populacije predvidjeti kakav ćemo dobiti uzorak? (Npr. Uzorak učenika iz škole u kojoj je poznat omjer učenica vs.učenika 75:25.) Razlika između empirijske i teorijske distribucije. Bacanje novčića 10 puta, 100 puta, 1000 puta i definiranje tzv. „a posteriori“ vjerojatnosti: vjerojatnost kao limes relativne frekvencije. Apriori vjerojatnost. Mali prostori događaja (kocka, novčić, špil karata). Koncept suprotne vjerojatnosti. Vennovi dijagrami Uvod u kombinatoriku Bacanje dviju ili više kocaka: Problem određivanja velikog prostora događaja Kombinatoričko određivanje veličine prostora događaja. Teorem o uzastopnom prebrojavanju. Permutacije. Permutacije s ponavljanjem. Varijacije, varij.s ponavlj., kombinacije. Množenje i zbrajanje vjerojatnosti. Određivanje kardinalnog broja unije dvaju skupova, bez presjeka i s presjekom. Uvjetna vjerojatnost. Stablo vjerojatnosti. Teorijska distribucija i očekivana vrijednost. Binomna distribucija (ponovimo permutacije s ponavljanjem). Poissonova distribucija. Poisson kao limes Binomne distr. Rekurzivna formula za Poissonovu distribuciju. Gaussova distribucija. Galtonova daska. Distribucija uzoraka. Centralni granični teorem. Razlika između dva gausijana. T-test i Anova (excell, matlab). Korelacija i regresijski pravac (excell, matlab).	30	0	30

Obvezna literatura	1. Keček D., Modrić D., Stojić M.: Vjerojatnost i statistika, Veleučilište u Varaždinu, Varaždin, 2012. 2. P. Vranjković: Zbirka zadataka iz vjerojatnosti i statistike, Školska knjiga, Zagreb,1992.
Dopunska literatura	1. Ž. Pauše: Uvod u matematičku statistiku, Školska knjiga, Zagreb, 1993. 2. I. Pavlić: Statistička teorija i primjena, Tehnička knjiga , Zagreb,1985. 3. D. S. Moore: The Basic Practice of Statistics, W. H. Freeman and Co., N. Y., 1998.
Način provjere ishoda učenja	Provjera ishoda učenja obavlja se redovitim praćenjem rada studenata. Ishodi učenja na nivou operativnosti, tj. primjene stečenog znanja, provjeravaju se pismenim međuispitima, koji obuhvaćaju numeričko rješavanje zadataka. Ostali ishodi učenja provjeravaju se odgovorima na pitanja, iz sadržaja predviđenih programom, u obliku testa ili usmenim odgovorima studenata. Vrednovanje zadanih ishoda učenja ostvaruje se kroz dva međuispita u semestru. Ukoliko student ne postigne zadovoljavajući uspjeh kroz redovite provjere ishoda učenja, upućuje se na ponovne provjere u narednim ispitnim rokovima.
Završni / Diplomski rad	Ne