NAZIV PREDMETA	**Kvantitativne metode u menadžmentu**					
Kod	EUB201	Godina studija	3.			
Nositelj/i predmeta	Prof. dr.sc. Branka Marasović, prof. dr. sc. Zdravka Aljinović, prof. dr. sc. Blanka Škrabić Perić	Bodovna vrijednost (ECTS)	5			
Suradnici	Dr. sc. Tea Kalinić Milićević, Ivana Mravak, mag. math.	Način izvođenja nastave (broj sati u semestru)	P	S	V	T
			26		26	
Status predmeta	Obvezni	Postotak primjene e-učenja	35			

OPIS PREDMETA

Ciljevi predmeta	Stjecanje znanja i vještina za identificiranjem i kvantificiranjem različitih kvantitativnih metoda za rješavanje problema poslovnog upravljanja s posebnim naglaskom na probleme koji se mogu prikazati kao problemi linearnog programiranja.
Uvjeti za upis predmeta i ulazne kompetencije potrebne za predmet	Preduvjeti za upis propisani su Statutom Ekonomskog fakulteta, te Pravilnikom o studiju i studiranju.
Očekivani ishodi učenja na razini predmeta (4-10 ishoda učenja)	Ishod učenja predmeta: Matematički modelirati različite situacije i procese iz područja poslovnog upravljanja koji se mogu svesti na probleme linearnog programiranja i riješiti dobiveni problem linearnog programiranja. Pojedinačni ishodi učenja: 1. Riješiti problemske zadatke iz vektorskih prostora 2. Matematički formulirati (modelirati) različite situacije i procese iz područja poslovnog upravljanja koji se mogu svesti na probleme linearnog programiranja 3. Riješiti grafičkom i simpleks metodom problema linearnog programiranja i prezentirati rezultate originalnog i dualnog problema 4. Analizirati osjetljivost optimalnog rješenje problema linearnog programiranja na promjene ulaznih parametara (provesti analizu osjetljivosti) 5. Analizirati probleme transporta i distribucije
Sadržaj predmeta detaljno razrađen prema satnici nastave	

Predavanja		Vježbe	
Tema	Sati	Tema	Sati
Osnovni pojmovi vektorskih prostora	1	Matrični račun i sustavi linearnih jednadžbi (ponavljanje)	1
Skalarni produkt, norma udaljenost. Linearna zavisnost i nezavisnost	1	Skalarni produkt, norma udaljenost. Linearna zavisnost i nezavisnost	1
Baza vektorskog prostora, bazična rješenja. Konveksni skupovi	2	Baza vektorskog prostora, bazična rješenja. Konveksni skupovi	2
Osnovni pojmovi linearnog programiranja i grafičko rješavanje	2	Grafička metoda rješavanja problema linearnog programiranja	2
Osnovni teoremi linearnog programiranja	2	Grafička metoda rješavanja problema linearnog programiranja	2
Primjena modela linearnog programiranja u poslovnom upravljanju	2	Primjena modela linearnog programiranja u poslovnom upravljanju i njihovo rješavanje	2

	Simpleks metoda rješavanja problema linearnog programiranja	2	Priprema za kolokvij	2
	Simpleks metoda problem maksimuma	2	Simpleks metoda problem maksimuma	2
	Problem minimuma linearnog programiranja i Charnesov M-procedura	2	Problem minimuma linearnog programiranja i Charnesov M-procedura	2
	Opći problem linearnog programiranja i njegovo rješavanje simpleks metodom	2	Opći problem linearnog programiranja i njegovo rješavanje simpleks metodom	2
	Problemi linearnog programiranja u praksi	2	Rješavanje problema linearnog programiranja na računalu - program WINQSB i Excela	2
	Problem transporta kao problem linearnog programiranja	2	Rješavanje problema linearnog programiranja na računalu - program WINQSB i Excelu	2
	Metode za rješavanje problema transporta	2	Metode za rješavanje problema transporta	2
	Problem optimalne asignacije i problem trgovačkog putnika	2	Problem optimalne asignacije i problem trgovačkog putnika	2

Vrste izvođenja nastave:	☑ predavanja ☐ seminari i radionice ☑ vježbe ☐ *on line* u cijelosti ☑ mješovito e-učenje ☐ terenska nastava	☐ samostalni zadaci ☑ multimedija ☐ laboratorij ☐ mentorski rad ☑ (ostalo upisati)
Obveze studenata	Studenti su obvezni prisustvovati nastavi i aktivno u njoj sudjelovati. Tijekom semestra se vodi evidencija o prisustvovanju nastavi. Aktivnost studenta pratit će se kroz samoevaluacijske kvizove koji će studentima biti dostupni na web stranicama predmeta unutar platforme Moodle. Uvjeti za potpis su 1). pohađanje minimalno 50% ukupne nastave 2) rješavanje najmanja dva samoevaluacijska kviza. Uvjet za pristupanje ispitu je potpis.	

Praćenje rada studenata *(upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti predmeta):*	Pohađanje nastave	2	Istraživanje		Praktični rad	
	Eksperimentalni rad		Referat		Samoevaluacijski kvizovi	0,5
	Esej		Seminarski rad		(Ostalo upisati)	
	Testovi	1,5*	Usmeni ispit	1	(Ostalo upisati)	
	Pismeni ispit	1,5*	Projekt		(Ostalo upisati)	

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	1. Ispit se sastoji od pismenog ispita iz praktičnog dijela (dio ispita sa zadacima) i pismenog/usmenog ispita iz teorije. Pisani dio ispita iz praktičnog dijela provodi se na računalu budući da se i vježbe održavaju na računalu gdje se kompletno gradivo uvježbava pomoću softverskih alata za probleme linearnog programiranja.. Pozitivno ocijenjen pisani ispit iz praktičnog dijela uvjet je za pristupanje ispitu iz teorije. 2. * U toku semestra održat će se 2 testa iz praktičnog dijela koji se provode na računalu. Uvjet za izlazak na test je da je student pristupio svim samoevaluacijskim kvizovima iz dijela gradiva koji se vrednuje testom. Dio ispita, položen preko testova ili u redovitim ispitnim rokovima, vrijedi cijelu akademsku godinu. Svaki test nosi 50 bodova. Studenti koji od mogućih 100 bodova ostvare 50 bodova (uz uvjet da u svakom od 2 testa imaju minimalno 20 bodova) oslobođeni su u tekućoj

	akademskoj godini polaganja pisanog ispita iz praktičnog dijela te mogu direktno izaći na ispit iz teorije u redovitim ispitnim rokovima. Bodovni pragovi i odgovarajuće ocjene za pisane provjere znanja praktičnog dijela gradiva: 0-49 nedovoljan (1) 50-64 dovoljan (2) 65-74 dobar (3) 75-89 vrlo dobar (4) 90-100 izvrstan (5)		
Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	**Naslov**	**Broj primjeraka u knjižnici**	**Dostupnost putem ostalih medija**
	Z. Babić: Linearno programiranje, Ekonomski fakultet Split, 2010.	10	
Dopunska literatura	Knjige: Robert J. Vanderbei: Linear Programming: Foundations and Extensions, 5th edition, Springer 2020. L. Neralić: Uvod u matematičko programiranje 1, Element, Zagreb, 2004. Z. Lukač, L. Neralić: Operacijska istraživanja, Ekonomski fakultet Sveučilišta u Zagrebu, Zagreb, 2012. C. P. Bonini, W.H. Hausman, H. Bierman: Quantitative analysis for management, McGraw-Hill, 1997. Lj. Martić: Matematičke metode za ekonomske analize II, Narodne novine, Zagreb, 1979. Članci: Babić, Z., T Perić, B. Marasović (2017): Production Planing in the bakery Via De Novo programming Approach, Proceedings of the 14th International Symposium on OPERATIONAL RESEARCH SOR'17, Bled, Slovenia, pp. 481-486 Perić, T., Z. Babić, B. Marasović (2010): Multiobjective Optimization in Production Planning Problem, Proceedings of the 12th International Conference on Operational Research - KOI'08, Pula, Croatia, pp. 213-225 Marasović, B., Z. Babić (2011): Two-step multi-criteria model for selecting optimal portfolio. International Journal of Production Economics, Vol. 134, pp. 58-66		
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	• Praćenje i uspješnosti izvršenja obveza studenata (nastavnik) • Nadzor izvođenja nastave (prodekan za nastavu i studentska pitanja) • Analiza uspješnosti studiranja po svim predmetima studija (prodekan za nastavu i studentska pitanja) • Studentska anketa o kvaliteti nastavnika i nastave za svaki predmet studija (UNIST, Centar za unaprjeđenje kvalitete) • Ispitom koji provodi predmetni nastavnik provjeravaju se svi ishodi učenja predmeta. Periodično se vrši provjera sadržaja ispita, temeljem koje se utvrđuje primjerenost načina provjeravanja ishoda učenja (prodekan za nastavu i studentska pitanja)		
Ostalo (prema mišljenju predlagatelja)			