SVEUČILIŠTE U SPLITU

FAKULTET ELEKTROTEHNIKE, STROJARSTVA I BRODOGRADNJE

IZMJENE I DOPUNE STUDIJSKOG PROGRAMA

DIPLOMSKI SVEUČILIŠNI STUDIJ ELEKTRONIKA I RAČUNALNO INŽENJERSTVO

SPLIT, travanj, 2023.

OPĆE INFORMACIJE O STUDIJSKOM PROGRAMU

Prvotni naziv studijskoga programa	ELEKTRONIKA I RAČUNALNO INŽENJERSTVO		
Novi naziv studijskoga programa	ELEKTRONIKA I RAČUNALNO INŽENJERSTVO		
Nositelj studijskoga programa	Fakultet elektrotehnike, strojarstva i brodogradnje u Splitu		
Sunositelj studijskoga programa	-		
Vrsta studijskoga programa	Stručni studijski program ☐	Sveučilišni studijski program ☒	
Razina studijskoga programa	Preddiplomski ☐	Diplomski ☒	Integrirani ☐
	Poslijediplomski sveučilišni ☐	Poslijediplomski specijalistički ☐	Diplomski specijalistički ☐
Akademski/stručni naziv koji se stječe po završetku studija	Magistar/magistra inženjer/inženjerka elektronike i računalnog inženjerstva (mag. ing. el.)		
Ukupni broj ECTS bodova	120		
Ukupni broj ECTS bodova predmeta u kojima je došlo do promjene			
Procjena postotka izmjena i dopuna studijskog programa	☒ Manje od 20% ☐ Više od 20%, manje od 40% ☐ Više od 40%		
Redni broj izmjene i dopune studijskog programa	5.		
Odluka fakultetskog vijeća o prihvaćanju izmjena i dopuna (dostaviti u prilogu)			
Preslika dopusnice za studijski program (dostaviti u prilogu)			

Popis predmeta u kojima je napravljena izmjena i/ili dopuna

Semestar	Predmet	ECTS prije	ECTS poslije	Izmjena (navesti u čemu je izmjena)
	IZBORNI PREDMETI			
1	Odabir izbornih predmeta	5	5	Izborni se predmeti mogu birati isključivo s predložene liste izbornih predmeta ovoga studija. Bira se jedan predmet.
2.	Odabir izbornih predmeta	5	5	Izborni se predmeti mogu birati isključivo s predložene liste izbornih predmeta ovoga studija. Biraju se dva predmeta.
3.	Odabir izbornih predmeta, smjer 221 (Elektronika)	5	5	Izborni se predmeti mogu birati isključivo s predložene liste izbornih predmeta ovoga smjera studija. Biraju se tri predmeta.
3.	Odabir izbornih predmeta, smjer 222 (računalno inženjerstvo)	5	5	Izborni se predmeti mogu birati isključivo s predložene liste izbornih predmeta ovoga smjera studija. Biraju se tri predmeta.
2.	Primjena računala u vođenju procesa	5	5	Izmijenjen uvjet upisa
1.	Uvod u strojno učenje	5	5	Izbrisan uvjet upisa
3.	Medicinski elektronički uređaji	5	-	Briše se kolegij
3.	Medicinski uređaji	-	5	Novi izborni kolegij
3.	Računalne 3D animacije	5	5	Izmijenjen uvjet upisa
3.	Mjerenja u bežičnim sustavima	-	5	Novi izborni kolegij
2.	Mobilne komunikacije	-	5	Novi izborni kolegij
1.	Radari	-	5	Novi izborni kolegij
1,	Geografski informacijski sustavi	-	5	Novi izborni kolegij
1.	Industrijska robotika	-	5	Novi izborni kolegij
1.	Napredne web tehnologije	-	5	Novi izborni kolegij
1.	Telemedicina i biokibernetika	-	5	Novi izborni kolegij
2.	IP komunikacije	-	6	Novi izborni kolegij
2.	Kriptografija i mrežna sigurnost	-	5	Novi izborni kolegij
2.	Modeliranje i vođenje plovila i vozila	-	5	Novi izborni kolegij
2.	Računalna forenzika	-	5	Novi izborni kolegij
2.	Računska inteligencija (NFG sustavi)	-	5	Novi izborni kolegij
2.	Skladišta podataka	-	5	Novi izborni kolegij

2.	Upravljanje projektima	-	4	Novi izborni kolegij
3.	Sustavi bežičnog prijenosa energije	-	5	Novi izborni kolegij
3.	Paralelno programiranje	-	5	Novi izborni kolegij
3.	Sigurnost bežičnih mreža	-	5	Novi izborni kolegij
3.	Vođenje procesa	-	5	Novi izborni kolegij

Popis obveznih i izbornih predmeta prema dopusnici

POPIS PREDMETA								
Godina studija: 1.								
Semestar: 1.								
STATUS	KOD	PREDMET	SATI U SEMESTRU*					ECTS
			P	S	AV	LV	KV	
Obvezni	FELH01	Algoritmi i strukture podataka	30	0	0	30	0	5
	FEMJ02	Fizika informacijske tehnologije	30	0	0	15	0	4
	FELH02	Teorija informacija i kodiranje	45	0	0	15	0	6
	FELH38	Polja i valovi u elektronici	30	0	0	30	0	5
	FELH08	Sustavi za digitalnu obradu signala	30	0	0	30	0	5
		Izborni predmet 1**						
	Ukupno obvezni		165	0	0	120	0	25
*P=predavanja, S=seminar, AV=auditorne vježbe, LV=laboratorijske vježbe, KV=konstrukcijske vježbe								
****Izborni se predmeti mogu birati s predložene liste ili s lista obveznih i izbornih predmeta zimskih semestara sveučilišnih diplomskih studija AIS, KIT i Računarstvo. Ako se obvezni predmet upiše kao izborni, postoji mogućnost da ukupni broj ECTS bodova po semestru bude veći od 30.**								
Izborni**	FELH43	Projektiranje VLSI integriranih krugova	30	0	0	30	0	5
	FELG30	Uvod u strojno učenje	30	0	0	30	0	5
	FELH21	Programiranje za Windows	30	0	0	30	0	5
	FELH23	Vremensko-frekvencijska analiza signala	30	0	0	30	0	5
	FELH24	Elektromagnetska kompatibilnost	30	0	0	30	0	5
	FELH30	Lokalne i pristupne mreže	30	0	0	30	0	5
	FELJ17	Numeričke metode u komunikacijama	30	0	0	30	0	5
	FELH39	Digitalna obrada i analiza slike	30	0	0	30	0	5
	Bira se: **1 izborni predmet**							
*P=predavanja, S=seminar, AV=auditorne vježbe, LV=laboratorijske vježbe, KV=konstrukcijske vježbe								

POPIS PREDMETA								
Godina studija: 1.								
Semestar: 2.								
STATUS	KOD	PREDMET	SATI U SEMESTRU*					ECTS
			P	S	AV	LV	KV	
Obvezni	FELH05	Napredne arhitekture računala	30	0	0	30	0	5
	FELH06	Jezici i prevoditelji	45	0	0	15	0	5
	FELH07	Projektiranje digitalnih sustava	30	0	0	30	0	5
	FELH04	Elektronička i virtualna instrumentacija	30	0	0	30	0	5
		Izborni predmet 1**						

		Izborni predmet 2**						
	Ukupno obvezni		135	0	0	105	0	20
*P=predavanja, S=seminar, AV=auditorne vježbe, LV=laboratorijske vježbe, KV=konstrukcijske vježbe								
****Izborni se predmeti mogu birati s predložene liste ili s lista obveznih i izbornih predmeta ljetnih semestara diplomskih studija AIS, KIT i Računarstvo. Ako se obvezni predmet upiše kao izborni, postoji mogućnost da ukupni broj ECTS bodova po semestru bude veći od 30.**								
	FELH32	Elektroakustika	30	0	0	30	0	5
	FELH34	Primjena računala u vođenju procesa	30	0	0	30	0	5
	FELH35	Sunčane ćelije	30	0	0	30	0	5
	FELG14	Operacijska istraživanja	30	0	0	30	0	5
	FELJ24	Bioelektromagnetizam	30	0	0	30	0	5
	FELJ09	Bežične komunikacijske mreže	30	0	15	15	0	5
	FELJ30	Radiokomunikacije u pomorstvu i zrakoplovstvu	30	0	0	30	0	5
	FELJ31	Programiranje baza podataka	30	0	0	30	0	5
	FELJ32	Trodimenzionalne simulacije	30	0	0	30	0	5
	FELK34	Programiranje računalnih videoigara	30	0	0	30	0	5
	FELG33	Optoelektroničke mjerne metode	30	0	0	30	0	5
	Bira se: - **2 izborna predmeta**							
*P=predavanja, S=seminar, AV=auditorne vježbe, LV=laboratorijske vježbe, KV=konstrukcijske vježbe								

Smjer: **ELEKTRONIKA - 221**

POPIS PREDMETA								
Godina studija: 2.								
Semestar: 3.								
STATUS	KOD	PREDMET	SATI U SEMESTRU*					ECTS
			P	S	AV	LV	KV	
Obvezni	FELH12	Bežične komunikacije	30	0	0	30	0	5
	FELH13	Elektronički praktikum	15	0	15	30	0	5
	FELH14	Optoelektronika	30	0	0	30	0	5
		Izborni predmet 1**						
		Izborni predmet 2**						
		Izborni predmet 3**						
	Ukupno obvezni		75	0	15	90	0	15
*P=predavanja, S=seminar, AV=auditorne vježbe, LV=laboratorijske vježbe, KV=konstrukcijske vježbe								
****Izborni se predmeti mogu birati s predložene liste ili s lista obveznih i izbornih predmeta zimskih semestara sveučilišnih diplomskih studija AIS, KIT i Računarstvo. Ako se obvezni predmet upiše kao izborni, postoji mogućnost da ukupni broj ECTS bodova po semestru bude veći od 30.**								
Izborni**	FELH44	Dizajn naprednih digitalnih sustava	30	0	0	30	0	5
	FELH16	Ugrađeni računalni sustavi	30	0	0	30	0	5

	FELH20	Projektiranje i korištenje računalnih mreža	30	0	0	30	0	5
	FELH37	Mikroelektronika	30	0	0	30	0	5
	FELJ20	Multimedijski sustavi	30	0	0	30	0	5
	FELG17	Bioelektrični sustavi i oprema	30	0	0	30	0	5
	FELJ38	Tehnologija radiofrekvencijske identifikacije	30	0	0	30	0	5
	FELH40	Programiranje mobilnih robota i letjelica	30	0	0	30	0	5
	FELH42	Računalne 3D animacije	30	0	0	30	0	5
	FELH41	Medicinski elektronički uređaji	30	0	0	30	0	5
	FEXX06	Stručna praksa						5
	Bira se: - **3 izborna predmeta**							
*P=predavanja, S=seminar, AV=auditorne vježbe, LV=laboratorijske vježbe, KV=konstrukcijske vježbe								

POPIS PREDMETA								
Godina studija: 2.								
Semestar: 4.								
STATUS	KOD	PREDMET	SATI U SEMESTRU*					ECTS
			P	S	AV	LV	KV	
	FEXX02	Diplomski rad						30
	Ukupno obvezni							
*P=predavanja, S=seminar, AV=auditorne vježbe, LV=laboratorijske vježbe, KV=konstrukcijske vježbe								

Smjer: **RAČUNALNO INŽENJERSTVO - 222**

POPIS PREDMETA								
Godina studija: 2.								
Semestar: 3.								
STATUS	KOD	PREDMET	SATI U SEMESTRU*					5
			P	S	AV	LV	KV	
Obvezni	FELH09	Programsko inženjerstvo	45	0	0	15	0	5
	FELH10	Distribuirani informacijski sustavi	30	0	0	30	0	5
	FELH11	Umjetna inteligencija	30	0	0	30	0	5
		Izborni predmet 1**						
		Izborni predmet 2**						
		Izborni predmet 3**						
	Ukupno obvezni		105	0	0	75	0	15
*P=predavanja, S=seminar, AV=auditorne vježbe, LV=laboratorijske vježbe, KV=konstrukcijske vježbe								
****Izborni se predmeti mogu birati s predložene liste ili s lista obveznih i izbornih predmeta zimskih semestara sveučilišnih diplomskih studija AIS, KIT i Računarstvo. Ako se obvezni predmet upiše kao izborni, postoji mogućnost da ukupni broj ECTS bodova po semestru bude veći od 30.**								
Izborni**	FELH16	Ugrađeni računalni sustavi	30	0	0	30	0	5
	FELH20	Projektiranje i korištenje računalnih mreža	30	0	0	30	0	5

	FELH37	Mikroelektronika	30	0	0	30	0	5
	FELJ20	Multimedijski sustavi	30	0	0	30	0	5
	FELG17	Bioelektrični sustavi i oprema	30	0	0	30	0	5
	FELJ38	Tehnologija radiofrekvencijske identifikacije	30	0	0	30	0	5
	FELH40	Programiranje mobilnih robota i letjelica	30	0	0	30	0	5
	FELH42	Računalne 3D animacije	30	0	0	30	0	5
	FELH41	Medicinski elektronički uređaji	30	0	0	30	0	5
	FENI51	Programiranje FPGA uređaja	30	0	0	30	0	5
	FEXX06	Stručna praksa						5
	Bira se: - **3 izborna predmeta**							
*P=predavanja, S=seminar, AV=auditorne vježbe, LV=laboratorijske vježbe, KV=konstrukcijske vježbe								

POPIS PREDMETA								
Godina studija: 2.								
Semestar: 4.								
STATUS	KOD	PREDMET	SATI U SEMESTRU*					ECTS
			P	S	AV	LV	KV	
	FEXX02	Diplomski rad						30
	Ukupno obvezni							
*P=predavanja, S=seminar, AV=auditorne vježbe, LV=laboratorijske vježbe, KV=konstrukcijske vježbe								

Popis obveznih i izbornih predmeta izmijenjenog studijskog programa

POPIS PREDMETA								
Godina studija: 1.								
Semestar: 1.								
STATUS	KOD	PREDMET	SATI U SEMESTRU*					ECTS
			P	S	AV	LV	KV	
Obvezni	FELH01	Algoritmi i strukture podataka	30	0	0	30	0	5
	FEMJ02	Fizika informacijske tehnologije	30	0	0	15	0	4
	FELH02	Teorija informacija i kodiranje	45	0	0	15	0	6
	FELH38	Polja i valovi u elektronici	30	0	0	30	0	5
	FELH08	Sustavi za digitalnu obradu signala	30	0	0	30	0	5
		Izborni predmet 1**						
	Ukupno obvezni		165	0	0	120	0	25
*P=predavanja, S=seminar, AV=auditorne vježbe, LV=laboratorijske vježbe, KV=konstrukcijske vježbe								
****Izborni se predmeti mogu birati isključivo s predložene liste izbornih predmeta ovoga studija. Bira se jedan predmet.**								
Izborni**	FELH43	Projektiranje VLSI integriranih krugova	30	0	0	30	0	5
	FELG30	Uvod u strojno učenje	30	0	0	30	0	5
	FELH21	Programiranje za Windows	30	0	0	30	0	5
	FELH23	Vremensko-frekvencijska analiza signala	30	0	0	30	0	5
	FELH24	Elektromagnetska kompatibilnost	30	0	0	30	0	5
	FELK32	Geografski informacijski sustavi	30	0	0	30	0	5
	FELG05	Industrijska robotika	30	0	0	30	0	5
	FELK33	Napredne web tehnologije	30	0	0	30	0	5
	FELG32	Telemedicina i biokibernetika	30	0	0	30	0	5
	FELH30	Lokalne i pristupne mreže	30	0	0	30	0	5
	FELJ17	Numeričke metode u komunikacijama	30	0	0	30	0	5
	FELJ28	Radari	30	0	0	30	0	5
	FELH39	Digitalna obrada i analiza slike	30	0	0	30	0	5
	Bira se: **1 izborni predmet**							
*P=predavanja, S=seminar, AV=auditorne vježbe, LV=laboratorijske vježbe, KV=konstrukcijske vježbe								

POPIS PREDMETA								
Godina studija: 1.								
Semestar: 2.								
STATUS	KOD	PREDMET	SATI U SEMESTRU*					ECTS
			P	S	AV	LV	KV	
Obvezni	FELH05	Napredne arhitekture računala	30	0	0	30	0	5

	FELH06	Jezici i prevoditelji	45	0	0	15	0	5
	FELH07	Projektiranje digitalnih sustava	30	0	0	30	0	5
	FELH04	Elektronička i virtualna instrumentacija	30	0	0	30	0	5
		Izborni predmet 1**						
		Izborni predmet 2**						
	Ukupno obvezni		135	0	0	105	0	20

*P=predavanja, S=seminar, AV=auditorne vježbe, LV=laboratorijske vježbe, KV=konstrukcijske vježbe

**** Izborni se predmeti mogu birati isključivo s predložene liste izbornih predmeta ovoga studija. Biraju se dva predmeta. Ovisno o odabiru, postoji mogućnost da ukupni broj ECTS bodova po semestru bude veći od 30.**

	FELH32	Elektroakustika	30	0	0	30	0	5
	FELH34	Primjena računala u vođenju procesa	30	0	0	30	0	5
	FELH35	Sunčane ćelije	30	0	0	30	0	5
	FELG14	Operacijska istraživanja	30	0	0	30	0	5
	FELJ24	Bioelektromagnetizam	30	0	0	30	0	5
	FELJ09	Bežične komunikacijske mreže	30	0	15	15	0	5
	FELG27	Modeliranje i vođenje plovila i vozila	30	0	0	30	0	5
	FELJ11	IP komunikacije	30	0	0	30	0	6
	FELK10	Kriptografija i mrežna sigurnost	30	0	0	30	0	5
	FELK40	Računalna forenzika	30	0	0	30	0	5
	FELK16	Skladišta podataka	30	0	0	30	0	5
	FETG01	Upravljanje projektima	30	0	0	15	0	4
	FELG18	Računarska inteligencija (NFG sustavi)	30	0	0	30	0	5
	FELJ30	Radiokomunikacije u pomorstvu i zrakoplovstvu	30	0	0	30	0	5
	FELJ31	Programiranje baza podataka	30	0	0	30	0	5
	FELJ14	Mobilne komunikacije	30	0	0	30	0	5
	FELJ32	Trodimenzionalne simulacije	30	0	0	30	0	5
	FELK34	Programiranje računalnih videoigara	30	0	0	30	0	5
	FELG33	Optoelektroničke mjerne metode	30	0	0	30	0	5
	Bira se: - **2 izborna predmeta**							

*P=predavanja, S=seminar, AV=auditorne vježbe, LV=laboratorijske vježbe, KV=konstrukcijske vježbe

Smjer: **ELEKTRONIKA - 221**

POPIS PREDMETA								
Godina studija: 2.								
Semestar: 3.								
STATUS	KOD	PREDMET	SATI U SEMESTRU*					ECTS
			P	S	AV	LV	KV	
Obvezni	FELH12	Bežične komunikacije	30	0	0	30	0	5

	FELH13	Elektronički praktikum	15	0	15	30	0	5
	FELH14	Optoelektronika	30	0	0	30	0	5
		Izborni predmet 1**						
		Izborni predmet 2**						
		Izborni predmet 3**						
	Ukupno obvezni		75	0	15	90	0	15
*P=predavanja, S=seminar, AV=auditorne vježbe, LV=laboratorijske vježbe, KV=konstrukcijske vježbe								
**** Izborni se predmeti mogu birati isključivo s predložene liste izbornih predmeta ovoga smjera studija. Biraju se tri predmeta.**								
Izborni**	FELH44	Dizajn naprednih digitalnih sustava	30	0	0	30	0	5
	FELH16	Ugrađeni računalni sustavi	30	0	0	30	0	5
	FELH20	Projektiranje i korištenje računalnih mreža	30	0	0	30	0	5
	FELH37	Mikroelektronika	30	0	0	30	0	5
	FELJ22	Mjerenja u bežičnim sustavima	30	0	0	30	0	5
	FELJ20	Multimedijski sustavi	30	0	0	30	0	5
	FELG17	Bioelektrični sustavi i oprema	30	0	0	30	0	5
	FELJ38	Tehnologija radiofrekvencijske identifikacije	30	0	0	30	0	5
	FELJ36	Sustavi bežičnog prijenosa energije	30	0	0	30	0	5
	FELH40	Programiranje mobilnih robota i letjelica	30	0	0	30	0	5
	FELH42	Računalne 3D animacije	30	0	0	30	0	5
		Medicinski uređaji	30	0	0	30	0	5
	FEXX06	Stručna praksa						5
	Bira se: - **3 izborna predmeta**							
*P=predavanja, S=seminar, AV=auditorne vježbe, LV=laboratorijske vježbe, KV=konstrukcijske vježbe								

POPIS PREDMETA								
Godina studija: 2.								
Semestar: 4.								
STATUS	KOD	PREDMET	SATI U SEMESTRU*					ECTS
			P	S	AV	LV	KV	
	FEXX02	Diplomski rad						30
	Ukupno obvezni							
*P=predavanja, S=seminar, AV=auditorne vježbe, LV=laboratorijske vježbe, KV=konstrukcijske vježbe								

Smjer: **RAČUNALNO INŽENJERSTVO - 222**

POPIS PREDMETA				
Godina studija: 2.				
Semestar: 3.				
STATUS	KOD	PREDMET	SATI U SEMESTRU*	5

			P	S	AV	LV	KV	
Obvezni	FELH09	Programsko inženjerstvo	45	0	0	15	0	5
	FELH10	Distribuirani informacijski sustavi	30	0	0	30	0	5
	FELH11	Umjetna inteligencija	30	0	0	30	0	5
		Izborni predmet 1**						
		Izborni predmet 2**						
		Izborni predmet 3**						
	Ukupno obvezni		105	0	0	75	0	15
*P=predavanja, S=seminar, AV=auditorne vježbe, LV=laboratorijske vježbe, KV=konstrukcijske vježbe								
****Izborni se predmeti mogu birati isključivo s predložene liste izbornih predmeta ovoga smjera studija. Biraju se tri predmeta.**								
Izborni**	FELH16	Ugrađeni računalni sustavi	30	0	0	30	0	5
	FELH20	Projektiranje i korištenje računalnih mreža	30	0	0	30	0	5
	FELH37	Mikroelektronika	30	0	0	30	0	5
	FELJ20	Multimedijski sustavi	30	0	0	30	0	5
	FELG17	Bioelektrični sustavi i oprema	30	0	0	30	0	5
	FELJ38	Tehnologija radiofrekvencijske identifikacije	30	0	0	30	0	5
	FELH40	Programiranje mobilnih robota i letjelica	30	0	0	30	0	5
	FELH42	Računalne 3D animacije	30	0	0	30	0	5
		Medicinski uređaji	30	0	0	30	0	5
	FENI51	Programiranje FPGA uređaja	30	0	0	30	0	5
	FELK19	Sigurnost bežičnih mreža	30	0	0	30	0	5
	FELK35	Paralelno programiranje	30	0	0	30	0	5
	FELG21	Vođenje procesa	30	0	0	30	0	5
	FEXX06	Stručna praksa						5
	Bira se: - **3 izborna predmeta**							
*P=predavanja, S=seminar, AV=auditorne vježbe, LV=laboratorijske vježbe, KV=konstrukcijske vježbe								

POPIS PREDMETA								
Godina studija: 2.								
Semestar: 4.								
STATUS	KOD	PREDMET	SATI U SEMESTRU*					ECTS
			P	S	AV	LV	KV	
	FEXX02	Diplomski rad						30
	Ukupno obvezni							
*P=predavanja, S=seminar, AV=auditorne vježbe, LV=laboratorijske vježbe, KV=konstrukcijske vježbe								

Opis novog predmeta ili predmeta koji je nadopunjen i izmijenjen

NAZIV PREDMETA	Primjena računala u vođenju procesa						
Kod	FELH34	Godina studija	2				
Nositelj/i predmeta	doc. dr. sc. Tihomir Betti dr. sc. Ivan Marasović	Bodovna vrijednost (ECTS)	5				
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	AV	LV	KV
			30	0	0	30	0
Status predmeta	Izborni	Postotak primjene e-učenja	0				

OPIS PREDMETA			
Ciljevi predmeta	Razumijevanje primjene računala u vođenju procesa. Sposobnost projektiranja tehničke i programske potpore mjernog i upravljačkog sustava. Primjena PLC-a u sustavima vođenja. Zapis i simuliranje sustava pomoću MATLAB paketa.		
Uvjeti za upis predmeta i ulazne kompetencije potrebne za predmet	Položen kolegij „Linearni regulacijski sustavi“.		
Očekivani ishodi učenja na razini predmeta (4-10 ishoda učenja)	Nakon uspješno savladanog predmeta, studenti će moći: 1. klasificirati vrste procesa i procesnih računala, 2. opisati način primjene digitalnih računala u vođenju procesa, 3. opisati komunikacijske protokole u sustavima vođenja, 4. objasniti načine povećanja pouzdanosti sustava vođenja, 5. koristiti softver za programiranje PLC-a, 6. predložiti način automatizacije jednostavnijeg sustava.		
Sadržaj predmeta detaljno razrađen prema satnici nastave	**Sadržaj**	**Sati P**	**Sati LV**
	Uvod. Definicija i vrste procesa i procesnih računala.	2	2
	Povijesni razvoj sustava za vođenje procesa.	2	2
	Digitalna računala u vođenju procesa.	2	2
	Centralizirani i decentralizirani sustavi vođenja.	2	2
	Hijerarhijski i distribuirani sustavi vođenja.	2	2
	Komunikacijske topološke strukture sustava vođenja.	2	2
	Redundantni sustavi vođenja.	2	2
	Sučelja između procesnog računala i procesa: senzori, mjerni članovi, davači, komunikacijska oprema.	2	2
	Vrste ulaznih i izlaznih signala kod upravljanja procesima.	2	2
	Komunikacijski protokoli i standardi u vođenju procesa.	2	2
	Aplikativni software u sustavima vođenja.	2	2
	Primjeri sustava vođenja u industrijskim i energetskim postrojenjima.	2	2
	Pregled mogućih smjerova razvoja sustava vođenja u budućnosti.	2	2
Vrste izvođenja nastave:	☒ predavanja ☐ seminari i radionice ☒ vježbe ☐ *on line* u cijelosti ☐ mješovito e-učenje	☒ samostalni zadaci ☒ multimedija ☒ laboratorij ☐ mentorski rad ☐ (ostalo upisati)	

	☒ terenska nastava					
Obveze studenata	Nazočnost na predavanjima u iznosu od najmanje 70% predviđene satnice. Obavljene sve predviđene laboratorijske vježbe i prezentacija završnog projekta.					
Praćenje rada studenata *(upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti predmeta):*	Pohađanje nastave	1	Istraživanje		Praktični rad	
	Eksperimentalni rad		Referat		Samostalni rad	2
	Esej		Seminarski rad		Laboratorijske vježbe	1
	Kolokviji	0,15	Usmeni ispit			
	Pismeni ispit	0,1	Projekt	0,75		
Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Tijekom semestra bit će dva međuispita (kolokvija). Prvi je međuispit nakon 7 tjedana nastave, a drugi nakon narednih 6 tjedana. Međuispiti se provode kao pisani ispit u trajanju od 90 minuta i sastoji se od teorijskih pitanja. Na završnom ispitu studenti polažu dijelove gradiva koje nisu položili na međuispitima. Uvjet za pozitivnu ocjenu je pozitivna ocjena iz završnog projekta te po 40% bodova na svakom međuispitu, a konačna se ocjena (u postocima) formira prema formuli: Ocjena(%) = 0,3(M1+M2)+0,4P gdje su: • M1, M2 – bodovi na međuispitima izraženi u postocima, • P – bodovi iz završnog projekta izraženi u postocima. Konačna se ocjena utvrđuje na sljedeći način: 50% - 60% - dovoljan (2) 61% - 74% - dobar (3) 75% - 87% - vrlo dobar (4) 88% - 100% - izvrstan (5) Studenti koji nisu položili ispit nakon dva završna ispita polažu popravni ispit u jesenskom roku. Na popravnom se ispitu polaže cjelokupno gradivo. Ispit je pisani i traje ukupno 135 minuta.					
Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	**Naslov**			**Broj primjeraka u knjižnici**	**Dostupnost putem ostalih medija**	
	N. Perić, I. Petrović: Automatizacija postrojenja i procesa, skripta, FER, Zagreb					
	G. Smiljanić: Računala i procesi, Školska knjiga, Zagreb, 1991.					
Dopunska literatura	C.A. Smith, Automated Continuous Process Control, Wiley, 2002.					
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	• Vođenje evidencije o prisutnosti na nastavi • Godišnja analiza uspješnosti polaganja ispita • Studentska anketa s ciljem evaluacije nastavnika • Samoevaluacija nastavnika • Povratna informacija od strane studenata koji su već diplomirali o relevantnosti sadržaja predmeta					
Ostalo (prema mišljenju predlagatelja)						

NAZIV PREDMETA	UVOD U STROJNO UČENJE						
Kod	FELG30	Godina studija	1				
Nositelj/i predmeta	prof. dr. sc. Tamara Grujić doc. dr. sc. Ivo Stančić	Bodovna vrijednost (ECTS)	5				
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	AV	LV	KV
			30			30	
Status predmeta	Izborni	Postotak primjene e-učenja					

OPIS PREDMETA

Ciljevi predmeta	Osposobljavanje studenata za: • Razumijevanje i primjenu temeljnih pojmova iz područja strojnog učenja • Primjenu različitih algoritama strojnog učenja na klasifikaciju i regresiju podataka • Odabir i primjenu odgovarajućeg klasifikacijskog ili regresijskog algoritma za zadani, konkretan zadatak • Evaluaciju kvalitete izvedbe pojedinih algoritama strojnog učenja pomoću evaluacijskih mjera • Izvršavanje algoritama strojnog učenja u programskim okružjima Weka, Python (s pripadajućim bibliotekama za strojno učenje) i Matlab • Izvršavanje algoritama strojnog učenja na namjenskom hardveru
Uvjeti za upis predmeta i ulazne kompetencije potrebne za predmet	Nema
Očekivani ishodi učenja na razini predmeta (4-10 ishoda učenja)	Nakon uspješno savladanog predmeta, studenti će moći: • Definirati osnovne pojmove strojnog učenja • Objasniti prednosti i nedostatke temeljnih algoritama strojnog učenja • Primijeniti razne algoritme klasifikacije i regresije • Procijeniti prikladnost pojedinačnog algoritma strojnog učenja za zadani, konkretni zadatak na temelju evaluacijskih mjera • Razumjeti princip rada različitih arhitektura umjetnih neuronskih mreža • Primijeniti razne tipove umjetnih neuronskih mreža u rješavanju konkretnih zadataka

Sadržaj predmeta detaljno razrađen prema satnici nastave	Sadržaj	Sati P
	Uvod u strojno učenje: temeljni pojmovi, primjene strojnog učenja, programski alati koji se koriste za strojno učenje, nadzirano i nenadzirano učenje, prezentacija i priprema podataka	2
	Naivni Bayes klasifikator	2
	Stabla odluka	3
	Evaluacijske mjere za evaluaciju efikasnosti algoritama strojnog učenja	2
	Linearna regresija	3
	Logistička regresija	3
	Osnove neuronskih mreža	2
	Konvolucijske neuronske mreže	3
	Treniranje i optimizacija neuronskih mreža	2
	Stroj s potpornim vektorima (SVM)	2
	Metode nenadziranog učenja, redukcija dimenzionalnosti	3
	Detekcija anomalije, primjena složenih neuronskih mreža, implementacija algoritama strojnog učenja na hardveru	3

	Popis laboratorijskih vježbi	Sati LV
	Programska okružja za provedbu algoritama strojnog učenja (Weka, Python, Tensorflow i Matlab)	3
	Naivni Bayesov klasifikator	3
	Stabla odluke	3
	Evaluacijske mjere	3
	Linearna i logistička regresija	3
	Osnove neuronskih mreža	3
	Konvolucijske neuronske mreže, prepoznavanje karaktera	3
	Stroj s potpornim vektorima	3
	K-means klasteriranje, PCA	3
	Primjena neuronskih mreža u analizi vremenski ovisnih signala, implementacija na hardveru	3

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	Prisutnost na predavanjima i auditornim vježbama u iznosu od najmanje 70% predviđene satnice. Obavljene sve predviđene laboratorijske vježbe kao i predani i pozitivno ocijenjeni izvještaji sa svih laboratorijskih vježbi.	

Praćenje rada studenata *(upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti predmeta):*	Pohađanje nastave	0.5	Istraživanje		Praktični rad	
	Eksperimentalni rad		Referat		Samostalni rad	0.25
	Esej		Seminarski rad		Laboratorijske vježbe	1
	Kolokviji	1.5	Usmeni ispit		Pripreme za laboratorijske vježbe	0.25
	Pismeni ispit	1.5	Projekt		(Ostalo upisati)	

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Tijekom semestra održat će dva međuispita (kolokvija), nakon čega slijede završni i popravni ispit. Prvi kolokvij je nakon 7 tjedana nastave i obuhvaća prvu polovicu gradiva, a drugi po završetku nastave i obuhvaća drugu polovicu gradiva. Na završnom ispitu studenti polažu dijelove gradiva koje nisu položili na međuispitima. Na popravnom ispitu polaže se cjelokupno gradivo. Uvjet za pozitivnu ocjenu jest 50% ostvarenih bodova na svakom međuispitu (ili završnom te popravnom ispitu) i pozitivna ocjena iz laboratorijskih vježbi. Uvjet za pozitivnu ocjenu iz laboratorijskih vježbi jest prisustvo i aktivan rad na svim vježbama, te predani i pozitivno ocijenjeni svi domaći radovi (izvještaji s vježbi). Svaki se međuispit provodi kao pisani ispit u trajanju od 105 min i sastoji se od ukupno 8 pitanja i zadatka. Završni ispit, u trajanju od 120 min, sastoji se od 10 pitanja i zadataka podijeljenih u dvije skupine (po 5 pitanja i zadataka iz gradiva obuhvaćenog jednim međuispitom). Popravni ispit, u trajanju od 120 min, sastoji se od 8 pitanja i zadataka. Uvjet za polaganje međuispita i ispita jest 50% ostvarenih bodova od ukupnog broja pitanja. Ukupna ocjena se formira na način: Ocjena(%)= 0,6 (M1 + M2)/2 + 0,2 LV + 0.2 (0.1) SR +0.1 PP

<table>
<tr><td></td><td colspan="3">M1, M2 - bodovi na međuispitima, izraženi u postocima.
LV – bodovi iz laboratorijskih vježbi, izraženi u postocima
SR – bodovi iz opcionalnog seminarskog rada (napomena: postotak bodova, 0.2 ili 0.1 ovisi o zahtjevnosti teme seminara)
PP – prisustvo na predavanjima veće od 70% (dodatni bodovi)

Konačna se ocjena utvrđuje na sljedeći način:

Postotak — Ocjena
50% do 61,9% — dovoljan (2)
62% do 74,9% — dobar (3)
75% do 89,9% — vrlo dobar (4)
90% do 100% — izvrstan (5)</td></tr>
<tr><td rowspan="3">Obvezna literatura (dostupna u knjižnici i putem ostalih medija)</td><td>Naslov</td><td>Broj primjeraka u knjižnici</td><td>Dostupnost putem ostalih medija</td></tr>
<tr><td>Skripta: "Uvod u strojno učenje", Tamara Grujić, Ivo Stančić, FESB</td><td></td><td>e-learning portal</td></tr>
<tr><td>"Upute za laboratorijske vježbe iz kolegija Uvod u strojno učenje", Tamara Grujić, Ivo Stančić</td><td></td><td>e-learning portal</td></tr>
<tr><td>Dopunska literatura</td><td colspan="3">• Hastie, T.; Tibshirani, R.; Friedman, J: The Elements of Statistical Learning; Springer-Verlag: New York, USA, 2008.
• D. Conway, J. M. White: “Machine Learning for Hackers”, O'Reilly Media, Inc. 2012.
• Ian H. Witten, Eibe Frank: Data Mining: Practical Machine Learning Tools and Techniques, 2nd edition, The Morgan Kaufmann, 2005.
• Christopher M. Bishop, Pattern recognition and Machine learning, Springer, 2006.
• Tom M. Mitchell, Machine Learning, McGraw – Hill, 1997.
• I. Kononenko, M. Kukar, Machine learning and Data mining: Introduction to principles and algorithms, Horwood Press, 2007.</td></tr>
<tr><td>Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja</td><td colspan="3">• Vođenje evidencije o prisutnosti na nastavi
• Vođenje evidencije o prisutnosti na laboratorijskim vježbama te pregled i ocjena predanih izvještaja
• Studentska anketa s ciljem evaluacije nastavnika
• Samoevaluacija nastavnika
• Godišnja analiza uspješnosti polaganja ispita
• Povratna informacija od strane diplomiranih studenata o relevantnosti sadržaja predmeta</td></tr>
<tr><td>Ostalo (prema mišljenju predlagatelja)</td><td colspan="3"></td></tr>
</table>

NAZIV PREDMETA	MEDICINSKI UREĐAJI						
Kod		Godina studija	2. (diplomski)				
Nositelj/i predmeta	prof. dr.sc. Antonio Šarolić	Bodovna vrijednost (ECTS)	5				
Suradnici	mr. sc. Darijo Radović, dr. med. Anđela Matković, mag. ing. el.	Način izvođenja nastave (broj sati u semestru)	P	S	AV	LV	KV
			30			30	
Status predmeta	izborni	Postotak primjene e-učenja	0				

OPIS PREDMETA

Ciljevi predmeta	- poznavanje vrsti, izvedbi i primjena elektroničke, računalne te komunikacijsko-informacijske tehnologije u medicinskim uređajima - poznavanje vrsti i izvedbi uređaja i sustava za biomedicinsko oslikavanje kao trenutno dominantnu primjenu elektroničke, računalne te komunikacijsko-informacijske tehnologije u biomedicini - razumijevanje posebnosti uvođenja elektroničkih, računalnih te komunikacijsko-informacijskih tehnologija u medicinsku primjenu, s interdisciplinarnim pristupom biomedicinskim istraživanjima, inovacijama i razvoju medicinskih uređaja - razumijevanje funkcionalnih, sigurnosnih, etičkih i regulatornih zahtjeva za medicinske uređaje, s potrebom provođenja kliničkih ispitivanja te certificiranja pripadnog hardvera i softvera
Uvjeti za upis predmeta i ulazne kompetencije potrebne za predmet	Nema.
Očekivani ishodi učenja na razini predmeta (4-10 ishoda učenja)	Nakon uspješno savladanog predmeta, studenti će biti sposobni: - interdisciplinarnim pristupom povezati znanje iz elektroničke, računalne ili komunikacijsko-informacijske tehnologije s medicinskim potrebama, za inovacije, razvoj i analizu medicinskih uređaja - osmisliti hardverska rješenja i/ili računalnu podršku za primjenu u medicinskom uređaju - opisati uređaje i sustave za biomedicinsko oslikavanje u kliničkoj praksi (RTG, CT, PET, MRI, medicinski ultrazvuk) - primijeniti načela biomedicinskih istraživanja u istraživačkim i razvojnim projektima, uz interdisciplinarni pristup, suradnjom tehničkih disciplina (elektronika, računarstvo, komunikacijsko-informacijske tehnologije) i biomedicine - osmisliti klinička ispitivanja medicinskih uređaja i kritički ih prosuđivati - vrjednovati medicinski uređaj s aspekta sigurnosnih, etičkih i regulatornih zahtjeva - kritički prosuđivati o uspješnosti inovacija i razvoja medicinskog uređaja

Sadržaj predmeta detaljno razrađen prema satnici nastave	Sadržaj	Sati P	Sati AV
	Osnove humane anatomije i fiziologije	3	0
	Načela i primjene biomedicinskog oslikavanja (prikupljanje informacija o morfologiji, sastavu, funkcionalnim značajkama tkiva)	1	0
	Uređaji i sustavi za biomedicinsko oslikavanje: RTG i CT	1	0
	Uređaji i sustavi za biomedicinsko oslikavanje: PET	1	0
	Uređaji i sustavi za biomedicinsko oslikavanje: MRI	2	0
	Uređaji i sustavi za biomedicinsko oslikavanje: medicinski ultrazvuk	1	0
	Uređaji i sustavi za snimanje električne aktivnosti: EKG, EEG,	2	0

	EMG		
	Elektronički sklopovi i komponente (hardver) u medicinskim uređajima	2	0
	Računalna podrška (softver) u medicinskim uređajima i sustavima	2	0
	Komunikacijsko-informacijske tehnologije u medicinskim uređajima, Internet medicinskih stvari (IoMT - *Internet of Medical Things*), sučelje mozga i računala (BCI - *brain-computer interface*)	2	0
	Sigurnosni, etički i regulatorni zahtjevi za hardver i softver medicinskih uređaja	1	0
	Inovativni uređaji za terapiju karcinoma (RF/mikrovalna ablacija, elektroporacija, elektromagnetska hipertermija, netermička elektromagnetska stimulacija)	2	0
	Inovativni uređaji za stimulaciju živčanog sustava (stimulacija mozga, stimulacija kralježnične moždine, stimulacija perifernih živaca)	2	0
	Ostali inovativni medicinski uređaji	2	0
	Translacijska istraživanja i razvoj medicinskih uređaja od laboratorija do uvođenja u kliničku praksu	1	0
	Kliničke studije: načela i provedba kliničkih ispitivanja medicinskih uređaja. Ocjena kliničke i ekonomske učinkovitosti medicinske tehnologije (HTA - *Health Technology Assessment*)	1	0
	Popis laboratorijskih ili konstrukcijskih vježbi		Sati LV
	Dijagnostički uređaji za medicinsko oslikavanje u kliničkom okruženju: RTG snimanje		2
	Dijagnostički uređaji za medicinsko oslikavanje u kliničkom okruženju: CT		2
	Dijagnostički uređaji za medicinsko oslikavanje u kliničkom okruženju: PET		2
	Dijagnostički uređaji za medicinsko oslikavanje u kliničkom okruženju: MRI		2
	Dijagnostički uređaji za medicinsko oslikavanje u kliničkom okruženju: medicinski ultrazvuk		2
	Računalni modeli i simulacije interakcija uređaja s biološkim tkivom		6
	Ispitivanje električne sigurnosti medicinskih uređaja		2
	Mjerenje dielektričnih svojstava tkiva		2
	Praktični istraživački pokus, individualni projekt ili problemski zadatak		6
	Napomena: Dio nastave odvija se u Poliklinici "Medikol" - nastavnoj bazi FESB-a za predmete "Medicinski elektronički uređaji" i "Bioelektromagnetizam".		

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	Nazočnost na predavanjima i vježbama u iznosu od najmanje 70% predviđene satnice.	

Praćenje rada studenata *(upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti predmeta):*	Pohađanje nastave	1	Istraživanje	0,5	Praktični rad	0,5
	Eksperimentalni rad	0,5	Referat		Laboratorijske vježbe	0,5
	Esej		Seminarski rad	1	Samostalni rad	0.5
	Kolokviji		Usmeni ispit		(Ostalo upisati)	
	Pismeni ispit		Projekt	0,5	(Ostalo upisati)	
Ocjenjivanje i vrjednovanje rada	Ispit: prezentacija i obrana seminarskog rada					

studenata tijekom nastave i na završnom ispitu			
Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	**Naslov**	**Broj primjeraka u knjižnici**	**Dostupnost putem ostalih medija**
	Paul Yock, Stefanos A. Zenios, and Todd J. Brinton: "Biodesign: The process of innovating medical technologies", Cambridge University Press, 2015.		elektroničko izdanje
	Carlo Boccato, Sergio Cerutti, Joerg Vienken: "Medical Devices: Improving Health Care Through a Multidisciplinary Approach", Springer, 2022.		elektroničko izdanje
	Nadine B. Smith, Andrew Webb: "Introduction to Medical Imaging: Physics, Engineering and Clinical Applications", Cambridge University Press, 2015.		elektroničko izdanje
	Joseph D. Bronzino, Donald R. Peterson: "The Biomedical Engineering Handbook", CRC Press, 2015.		elektroničko izdanje
Dopunska literatura	- Peter Ogrodnik: "Medical Device Design Innovation from Concept to Market", Academic Press, 2019. - Sujata Dash, Subhendu Kumar Pani, Joel Jose P. Coelho Rodrigues, Babita Majhi: "Deep Learning, Machine Learning and IoT in Biomedical and Health Informatics: Techniques and Applications", CRC Press, 2022. - Jaakko Malmivuo & Robert Plonsey: "Bioelectromagnetism - Principles and Applications of Bioelectric and Biomagnetic Fields", Oxford University Press, New York, 1995. - Ante Šantić: "Biomedicinska elektronika", Školska knjiga, Zagreb, 1995.		
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	Mišljenja studenata o kvaliteti nastave putem anketa.		
Ostalo (prema mišljenju predlagatelja)			

NAZIV PREDMETA	RAČUNALNE 3D ANIMACIJE						
Kod	FELH42	Godina studija	2.				
Nositelj/i predmeta	Izv. prof. dr.sc. Ivan Zoraja	Bodovna vrijednost (ECTS)	5				
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	AV	LV	KV
			30	0	0	30	
Status predmeta	Izborni	Postotak primjene e-učenja	0				

OPIS PREDMETA			
Ciljevi predmeta	Osposobljavanje studenata za: • Temeljna znanja o 3D modelima • Temeljna znanja o 3D animacijama • Dizajniranje 3d animacija • Implementiranje 3D animacija • Testiranje 3D animacija		
Uvjeti za upis predmeta i ulazne kompetencije potrebne za predmet	Položen kolegij „Trodimenzionalne simulacije“		
Očekivani ishodi učenja na razini predmeta (4-10 ishoda učenja)	Studenti će nakon uspješno savladanog predmeta moći: 1. Primijeniti 3D transformacijame u iscrtavanju modela u cilju kreiranja iluzije pokreta. 2. Implementirati grafičke cjevovode. 3. Implementirati ključne okvire. 4. Implementirati hierarhijske strukture. 5. Implementirati animaciju osoba. 6. Implementirati prepoznavanje pokreta		
Sadržaj predmeta detaljno razrađen prema satnici nastave	Sadržaj	Sati P	Sati AV
	Osnove 3D sustava. Cijevovodi. Aplikacijska razina. Geometrijska razina. Stvaranje fragmenata. DirectX. OpenGL. WegGL.	2	
	SUSTAVI I TRANSFORMACIJE. Skaliranje. Rotacija. Orijentacija, Translacija. Kompozicija.Transformacija. Pogledi i projekcije. Mapiranja na ekran.	2	
	MREŽE. Geometrijske informacije. Međuspremnici podskupova i značajki. Crtanja. Infromacije o okolini. Kloniranje. Stvaranje mreže.	2	
	ISCRTAVANJE. Prikaz modela. Cjevovodi iscrtavanja. Postavlanje čvorova (vertex). Međuspremnici. Rezanje. Rasterizacija. Grafički procesori.	2	
	INTERPOLACIJE. Gibanje po krivulji. Interpolacija orijentacije. Staze. Ključni okviri. Deformacije. Morfološke promjene. Animacijski jezici.	2	
	ANIMACIJE. Ključni okviri. Kože i skeletoni. Algebra kvaterniona. Interpolacija stanja. Hierarhije djelova. Transformacije.	2	
	KINEMATIKA. Hierarhijsko modeliranje. Unaprijedna kinematika. Inverzna kinematika.	2	
	HVATANJE POKRETA. Tehnologije za hvatanje pokreta. Kinect. Proc3esiranjue slika. Kalibriranje kamere. Markeri i skeletoni.	2	
	FIZIKALNE ANIMACIJE. Flexibilna i čvrsta tijela. Animacija opruga. Simulacija čvrstih tijela. Simulacija odjeće. Tekućine i plinovi.	2	

	LJUDSKE FIGURE. Modeliranje ljdskih figura. Hodanje. Dosezanje. Hvatanje. Pokrivala. Simulacija Kosa.	2	
	FACIJALNE ANIMACIJE. Modeli lica. Animacija lica. Analiza govora. Simulacija govora. Sinkronizacija pokreta usana. Modeliranje očiju. Nabori.	2	
	SUSTAVI ČESTICA. Prikaz čestica. Kretanje čestica. Randomizacija. Osvjetljavanje sustava čestica. Emiter čestica. Sustavi čestica temeljeni na grafičkim procesorima.	2	
	DETEKCIJA SUDARA. Okružujuči volumeni (kocke i sfere). Presijeci geometrijskih tijela. Odabir (picking).	2	
	ANIMACIJE PONAŠANJA. Jednostavna ponašanja. Znanja o okruženjima. Modeliranje inteligentnoga ponašanja. Gomile i gužve.	2	
	Popis laboratorijskih vježbi		Sati LV
	Implementiranje osnovne 3D matematike.		2
	Implementacija 3D motora „engine-a“		6
	Implementacija 3D mreža		3
	Implementacija osnovnih interpolacija		4
	Implementacija osnovnih animacija (ključni okviri)		3
	Implementacija animacije ljudskih figura		3
	Implementacija facijalnih animacija		2
	Implementacija intesekcija i sudara (picking)		3
	Implementacije animacije ponašanja		4

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	Nazočnost na predavanjima i auditornim vježbama u iznosu od najmanje 70% predviđene satnice. Obavljene sve predviđene laboratorijske vježbe. Seminarski rad.	

Praćenje rada studenata *(upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti predmeta):*	Pohađanje nastave	1,5	Istraživanje		Praktični rad	
	Eksperimentalni rad		Referat		Samostalni rad	1,4
	Esej		Seminarski rad	0,8	Laboratorijske vježbe	0,5
	Kolokviji	0,2	Usmeni ispit		Pripreme za laboratorijske vježbe	0,5
	Pisani ispit	0,1	Projekt		(Ostalo upisati)	

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Tijekom semestra bit će dva međuispita (kolokvija). Prvi je međuispit nakon 7 tjedana nastave, a drugi nakon narednih 6 tjedana. Na završnom ispitu studenti polažu dijelove gradiva koje nisu položili na međuispitima. Svaki se međuispit provodi kao pisani ispit u trajanju od 90 minuta i sastoji se od ukupno 4 pitanja i zadataka. Uvjet za pozitivnu ocjenu je pozitivna ocjena iz laboratorijskih vježbi te barem 40% bodova na svakom međuispitu, a konačna se ocjena (u postocima) formira prema formuli: Ocjena(%) = 0,2 LV + 0,4 (M1 + M2) gdje su aktivnosti izražene u postocima: • LV - ocjena iz laboratorijskih vježbi, • M1, M2 - bodovi na međuispitima. . Uvjet za pozitivnu ocjenu je 40% bodova na svakom međuispitu, ili iz svakog dijela gradiva na završnom ispitu, pozitivna ocjena iz laboratorijskih vježbi te napravljen seminarski rad. Uvjet za pozitivnu ocjenu na popravnom ispitu je 50% ukupnog

<table>
<tr><td></td><td colspan="3">broja bodova.

Konačna se ocjena utvrđuje na sljedeći način:
Postotak Ocjena
50% do 61% dovoljan (2)
62% do 74% dobar (3)
75% do 87% vrlo dobar (4)
88% do 100% izvrstan (5)

Međuispiti i ispiti se održavaju u terminima određenim kalendarom ispitnih rokova. Svaki međuispit se sastoji od 4 pitanja podijeljenih u dvije skupine, završni ispit sastoji se od 6 pitanja podijeljenih u dvije skupine.

Ukoliko je student iz nekog međuispita imao 40% i više bodova, na završnom ispitu pitanja iz tog područja nije nužno odgovarati. Konačnu ocjenu se i u ovom slučaju izračunava kao suma postignutih postotaka ispita (maksimalno 80%) i laboratorijskih vježbi (maksimalno 20%).</td></tr>
<tr><td rowspan="2">Obvezna literatura (dostupna u knjižnici i putem ostalih medija)</td><td>Naslov</td><td>Broj primjeraka u knjižnici</td><td>Dostupnost putem ostalih medija</td></tr>
<tr><td>Zoraja, Ivan. Račiunalane Animacije, predavanja. Interna skripta.</td><td></td><td>e-learning portal</td></tr>
<tr><td>Dopunska literatura</td><td colspan="3">Rick Parent: Computer Animation, Third Edition: Algorithms & Techniques, third edition. Elsivier Inc. 2012.
Tomas Akenine-Möller, Eric Haines, and Naty Hoffman: Real-Time Rendering.
Microsoft, DirectX 12. web.</td></tr>
<tr><td>Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja</td><td colspan="3">Vođenje evidencije o prisutnosti na nastavi
Godišnja analiza uspješnosti polaganja ispita
Studentska anketa s ciljem evaluacije nastavnika
Samoevaluacija nastavnika
Povratna informacija od strane studenata koji su već diplomirali o relevantnosti sadržaja predmeta</td></tr>
<tr><td>Ostalo (prema mišljenju predlagatelja)</td><td colspan="3"></td></tr>
</table>

NAZIV PREDMETA	MJERENJA U BEŽIČNIM SUSTAVIMA						
Kod	**FELJ22**	Godina studija	2				
Nositelj/i predmeta	prof.dr.sc. Zoran Blažević	Bodovna vrijednost (ECTS)	5				
Suradnici	doc.dr.sc. Maja Škiljo	Način izvođenja nastave (broj sati u semestru)	P	S	AV	LV	KV
			30	0	0	30	
Status predmeta	Izborni	Postotak primjene e-učenja	0				

OPIS PREDMETA		
Ciljevi predmeta	Osposobljavanje studenata za: • mjerenja parametara radijskih kanala, • statističko modeliranje radio propagacije u različitim sredinama i različitih radijskih sustava, • primjenu empirijskih i statističkih modela pri karakterizaciji radio kanala	
Uvjeti za upis predmeta i ulazne kompetencije potrebne za predmet	Nema	
Očekivani ishodi učenja na razini predmeta (4-10 ishoda učenja)	Studenti će, nakon uspješno savladanog gradiva biti sposobni: 1. definirati parametre radijskih kanala 2. vršiti osnovna mjerenja parametara fiksnih i mobilnih radijskih kanala 3. statistički karakterizirati radio propagaciju različitih radijskih sustava na osnovi mjerenja, 4. primijeniti različite modele za proračun radio propagacije	
Sadržaj predmeta detaljno razrađen prema satnici nastave	Sadržaj	Sati P
	Uvod	1
	Parametri radijskog kanala kod fiksnih radio-veza. Feding.	2
	Planiranje i mjerenja fiksnih zemaljskih radijskih veza.	2
	Feding kod mobilnih radijskih sustava.	2
	Parametri mobilnih radijskih kanala.	2
	Modeli za predviđanje gubitaka propagacije u naseljenim sredinama. Hata-Okumura model.	3
	Usporedba statističkih modela zemaljskih kanala i rezultata dobivenih Maxwellovom teorijom.	2
	Satelitski radijski kanali. Modeli za predviđanje karakteristika kanala na osnovi mjerenja (Loo model, Suzuki model).	4
	Parametri širokopojasnih radijskih sustava. Širokopojasna mjerenja kanala.	4
	Modeli širokopojasnih radijskih sustava na osnovi mjerenja.	2
	Procjena parametara radio kanala u zatvorenim sredinama na osnovi mjerenja.	3
	Širokopojasni modeli za predviđanje kvalitete signala u zatvorenim sredinama. Saleh-Valenzuela model.	3
	Popis laboratorijskih vježbi	Sati LV
	Mjerenja parametara antena vektorskim mrežnim analizatorom. Kalibracija mjernog sustava.	3
	Uskopojasna mjerenja radio veza na različitim frekvencijama.	3
	Širokopojasna mjerenja parametara radijskog kanala u unutrašnjosti	3

	zgrade.	
	Planiranje radijskih veza korištenjem mjerenih podataka i računalne podrške.	5
	Analiza mjerenih parametara kanala statističkim modelom.	4
	Mjerenje snage signala na šestom katu FESB-a.	6
	Obrada i analiza mjerenih podataka.	6

Vrste izvođenja nastave:	x predavanja ☐ seminari i radionice x vježbe ☐ *on line* u cijelosti ☐ mješovito e-učenje x terenska nastava	☐ samostalni zadaci ☐ multimedija x laboratorij ☐ mentorski rad ☐ (ostalo upisati)
Obveze studenata	Student je dužan sudjelovati u radu svih oblika nastave te prisustvovati: predavanjima najmanje 70% nastavnih sati, auditornim vježbama najmanje 70% nastavnih sati te laboratorijskim vježbama 100% nastavnih sati.	

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

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Tijekom semestra bit će dva kolokvija prema kalendaru nastave. Student može putem kolokvija položiti cjelokupni ispit ukoliko postigne pozitivnu ocjenu iz svakog od tih kolokvija. Na svakom od dvaju kolokvija student polaže jedan dio gradiva. Na dva završna ispita u veljači tekuće godine studenti polažu dijelove gradiva koje nisu položili na kolokvijima. Ako na prvom završnom ispitu student položi neki od dijelova gradiva, taj dio gradiva ne mora polagati na drugom završnom ispitu. Pod zasebnim dijelom gradiva se podrazumijeva se točno utvrđena i zaokružena cjelina gradiva obuhvaćena kolokvijem. Pritom, svaki od kolokvija sadržavat će pitanja iz teorije te zadatke, pri čemu pojedino pitanje često može sadržavati i zadatak i teoriju, odnosno teorija i zadaci tretiraju se kao nedjeljiva cjelina. Također, na ispitu student može odgovarati pojedinu cjelinu ili čitavo gradivo ukoliko nije zadovoljan postignutim uspjehom na kolokviju ili konačnom ocjenom. Uvjet za pozitivnu ocjenu je da student ima najmanje 50 % bodova iz pojedinog dijela kolokvija ili na završnom ispitu, a konačna se ocjena (u postocima) formira na temelju svih aktivnosti prema formuli: $$\text{Ocjena (\%)} = 0.1NPV + 0.1LV + 0.4(K1 + K2)\ ,$$ gdje su aktivnosti izražene u postocima: - NPV - nazočnost na predavanjima i auditornim vježbama (%), - LV – bodovi iz laboratorijskih vježbi (%), - K1, K2 - bodovi iz pojedinog kolokvija (%), Studenti koji nisu položili ispit nakon dva završna ispita mogu ispit položiti početkom rujna tekuće godine na tzv. popravnom ispitu. Samo studentima koji su prethodno položili kolokvij iz pojedinog dijela gradiva bit će priznato da su položili taj dio gradiva. Na popravnom ispitu studenti mogu položiti cjelokupni ispit ili pak prvi ili drugi dio gradiva. Zadnja prilika za polaganje ispita u tekućoj školskoj godini je tzv. komisijski ispit koji će biti održan u drugom dijelu rujna prema kalendaru nastave.

	Uvjet za pozitivnu ocjenu na popravnom i komisijskom ispitu je da student ima najmanje 50 % bodova iz pojedinog dijela gradiva. Ocjena se računa prema prethodno navedenoj formuli. Konačna se ocjena utvrđuje na sljedeći način: Postotak Ocjena 50% do 59% dovoljan (2) 60% do 74% dobar (3) 75% do 89% vrlo dobar (4) 90% do 100% izvrstan (5) Ispitni rokovi: Prema kalendaru nastave		
Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	**Naslov**	**Broj primjeraka u knjižnici**	**Dostupnost putem ostalih medija**
	Z. Blažević; Mjerenja u bežičnim sustavima, predavanja		portal e-učilice
	M. Patzold: "Mobile Fading Channels", Wiley, 2002.	1	
	Doble, J.: "Introduction to Radio Propagation for Fixed and Mobile Communications", Artech House Boston - London, GB, 1996.	1	
Dopunska literatura	G. H. Bryant: ''Principles of Microwave Measurements'', IEE Publishing, 1993. Zentner, E.: Antene i radiosustavi, Graphis Zagreb, 2001.		
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	• Vođenje evidencije o prisutnosti na nastavi • Godišnja analiza uspješnosti polaganja ispita • Studentska anketa s ciljem evaluacije nastavnika • Samoevaluacija nastavnika • Povratna informacija od strane studenata koji su već diplomirali o relevantnosti sadržaja predmeta		
Ostalo (prema mišljenju predlagatelja)			

NAZIV PREDMETA	MOBILNE KOMUNIKACIJE						
Kod	**FELJ14**	Godina studija	1				
Nositelj/i predmeta	prof.dr.sc. Zoran Blažević	Bodovna vrijednost (ECTS)	5				
Suradnici	doc.dr.sc. Maja Škiljo	Način izvođenja nastave (broj sati u semestru)	P	S	AV	LV	KV
			30	0	0	30	
Status predmeta	Izborni	Postotak primjene e-učenja	0				

OPIS PREDMETA

Ciljevi predmeta	Osposobljavanje studenata za: • projektiranje radijskih sustava, • analizu fizičkog sloja OSI ćelijskih radijskih mreža, • analizu širokopojasnih mobilnih radijskih kanala
Uvjeti za upis predmeta i ulazne kompetencije potrebne za predmet	Nema
Očekivani ishodi učenja na razini predmeta (4-10 ishoda učenja)	Studenti će, nakon uspješno savladanog gradiva moći: 1. proračunati optimalni radio-sustav u smislu odabira modulacije i kodiranja digitalnih radijskih kanala, 2. izvršiti osnovna modeliranja ćelijskih radio mreža: proračun interferencije i snage odašiljanja baznih postaja, 3. računati i analizirati parametre (uskopojasnih i širokopojasnih) radio-kanala, 4. analizirati mjerenja radijskih kanala.

Sadržaj predmeta detaljno razrađen prema satnici nastave	Sadržaj	Sati P
	Uvod	1
	Podjela radijskog kanala.	2
	Performanse digitalnih radijskih sustava.	2
	Sustavi s ograničenom širinom pojasa.	2
	Sustavi s ograničenjem snage.	2
	Sustavi s ograničenom širinom pojasa i ograničenjem snage. Kodiranje kanala.	2
	Radijski sustavi s proširenim spektrom (DS/SS).	2
	Ćelijski radijski sustavi. Interferencija unutar kanala (ISI) i intereferencija susjednih kanala (ACI).	2
	Zakon gubitaka propagacije. Proračun snage bazne postaje. Višestazni prijam.	2
	Proračun pokrivenosti ćelije.	2
	Analiza mobilnog propagacijskog kanala.	2
	Mjerenja propagacijskog kanala.	2
	Klasifikacija propagacijskog kanala. Rasipanje kašnjenja i koherentni pojas kanala.	2
	Popis laboratorijskih vježbi	Sati LV
	Testiranje i simulacija komunikacijskih sustava u Matlab-u i Simulink-u.	2
	Analogna i digitalna modulacija	3
	Kanal s višestaznim fedingom (Matlab i Simulink)	4
	RF pogoršanja kanala (Simulink)	3
	COST 207 i GSM/EDGE modeli kanala (Matlab)	4

	Susjedno- i isto-kanalna interferencija u ćelijskim sustavima (Simulink)	4
	Antene i mjerni uređaji u ćelijskim sustavima.	5
	Mjerenja signala baznih stanica.	5

Vrste izvođenja nastave:	x predavanja ☐ seminari i radionice x vježbe ☐ *on line* u cijelosti ☐ mješovito e-učenje x terenska nastava	☐ samostalni zadaci ☐ multimedija x laboratorij ☐ mentorski rad ☐ (ostalo upisati)
Obveze studenata	Student je dužan sudjelovati u radu svih oblika nastave te prisustvovati: predavanjima najmanje 70% nastavnih sati, auditornim vježbama najmanje 70% nastavnih sati te laboratorijskim vježbama 100% nastavnih sati.	

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

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Tijekom semestra bit će dva kolokvija prema kalendaru nastave. Student može putem kolokvija položiti cjelokupni ispit ukoliko postigne pozitivnu ocjenu iz svakog od tih kolokvija. Na svakom od dvaju kolokvija student polaže jedan dio gradiva. Na dva završna ispita u lipnju tekuće godine studenti polažu dijelove gradiva koje nisu položili na kolokvijima. Ako na prvom završnom ispitu student položi neki od dijelova gradiva, taj dio gradiva ne mora polagati na drugom završnom ispitu. Pod zasebnim dijelom gradiva se podrazumijeva se točno utvrđena i zaokružena cjelina gradiva obuhvaćena kolokvijem. Pritom, svaki od kolokvija sadržavat će pitanja iz teorije te zadatke, pri čemu pojedino pitanje često može sadržavati i zadatak i teoriju, odnosno teorija i zadaci tretiraju se kao nedjeljiva cjelina. Također, na ispitu student može odgovarati pojedinu cjelinu ili čitavo gradivo ukoliko nije zadovoljan postignutim uspjehom na kolokviju ili konačnom ocjenom. Uvjet za pozitivnu ocjenu je da student ima najmanje 50 % bodova iz pojedinog dijela kolokvija ili na završnom ispitu, a konačna se ocjena (u postocima) formira na temelju svih aktivnosti prema formuli: $$\text{Ocjena (\%)} = 0.1NPV + 0.1LV + 0.4(K1 + K2)\ ,$$ gdje su aktivnosti izražene u postocima: - NPV - nazočnost na predavanjima i auditornim vježbama (%), - LV – bodovi iz laboratorijskih vježbi (%), - K1, K2 - bodovi iz pojedinog kolokvija (%), Studenti koji nisu položili ispit nakon dva završna ispita mogu ispit položiti početkom rujna tekuće godine na tzv. popravnom ispitu. Samo studentima koji su prethodno položili kolokvij iz pojedinog dijela gradiva bit će priznato da su položili taj dio gradiva. Na popravnom ispitu studenti mogu položiti cjelokupni ispit ili pak prvi ili drugi dio gradiva. Zadnja prilika za polaganje ispita u tekućoj školskoj godini je tzv. komisijski ispit koji će biti održan u drugom dijelu rujna prema kalendaru nastave. Uvjet za pozitivnu ocjenu na popravnom i komisijskom ispitu je da student ima najmanje 50 % bodova iz pojedinog dijela gradiva. Ocjena se računa prema prethodno navedenoj formuli.

<table>
<tr><td></td><td colspan="3">Konačna se ocjena utvrđuje na sljedeći način:
Postotak Ocjena
50% do 59% dovoljan (2)
60% do 74% dobar (3)
75% do 89% vrlo dobar (4)
90% do 100% izvrstan (5)
Ispitni rokovi: Prema kalendaru nastave</td></tr>
<tr><td rowspan="4">Obvezna literatura (dostupna u knjižnici i putem ostalih medija)</td><td>Naslov</td><td>Broj primjeraka u knjižnici</td><td>Dostupnost putem ostalih medija</td></tr>
<tr><td>Z. Blažević; Mobilne komunikacije, predavanja</td><td></td><td>portal e-učilice</td></tr>
<tr><td>I. Zanchi, Z. Blažević: Radiokomunikacije, predavanja, FESB</td><td></td><td>portal e-učilice</td></tr>
<tr><td>David Parson.: The Mobile Radio Propagation Channel, Pentech Press Pub. London, 1992.</td><td>1</td><td></td></tr>
<tr><td>Dopunska literatura</td><td colspan="3">R. Steele: "Mobile Radio Communications", Pentech Press, London, GB and IEEE Press, Piscataway, USA, 1992.
Vijag, K. Garg, Joseph, E. Wilkes: Wireless and Personal Communications Systems, Prentice Hall PTR, NY 1996.</td></tr>
<tr><td>Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja</td><td colspan="3">• Vođenje evidencije o prisutnosti na nastavi
• Godišnja analiza uspješnosti polaganja ispita
• Studentska anketa s ciljem evaluacije nastavnika
• Samoevaluacija nastavnika
• Povratna informacija od strane studenata koji su već diplomirali o relevantnosti sadržaja predmeta</td></tr>
<tr><td>Ostalo (prema mišljenju predlagatelja)</td><td colspan="3"></td></tr>
</table>

NAZIV PREDMETA	RADARI							
Kod	**FELJ28**	Godina studija	1					
Nositelj/i predmeta	Doc. dr. sc. Maja Škiljo	Bodovna vrijednost (ECTS)	5					
Suradnici	-	Način izvođenja nastave (broj sati u semestru)	P	S	AV	LV	KV	
			30	0	0	30		
Status predmeta	Izborni	Postotak primjene e-učenja	0					

OPIS PREDMETA

Ciljevi predmeta	Osposobljavanje studenata za: • Uvod tehniku radarskih sustava, • proračun osnovnih parametara različitih radarskih sustava.
Uvjeti za upis predmeta i ulazne kompetencije potrebne za predmet	Nema
Očekivani ishodi učenja na razini predmeta (4-10 ishoda učenja)	Studenti će, nakon uspješno savladanog gradiva biti sposobni: 1. razlikovati i objasniti tehnike različitih radarskih sustava 2. vršiti proračun temeljnih parametara radarskih sustava 3. analizirati i projektirati radio propagaciju kod radara 4. primijeniti različita već stečena tehnička znanja pri proiektiranju radara

Sadržaj predmeta detaljno razrađen prema satnici nastave	Sadržaj	Sati P
	Uvod	1
	Osnove radarskih sustava.	2
	Impulsni radar.	2
	Radarska jednadžba, maksimalni domet.	3
	Refleksijska površina cilja.	3
	Mjerenje prostornih parametara cilja radarskim signalom.	2
	Radari s Dopplerovim frekvencijskim pomakom.	3
	Radari za izdvajanje pokretnih ciljeva.	2
	Impulsni Doppler radar.	3
	Radari u meterologiji	2
	Sekundarni radar.	2
	Utjecaji propagacije na radarski signal.	2
	Postupci za smanjenje neželjenih refleksija.	1
	Osnovne sklopovske cjeline radarskog sustava.	2
	Popis laboratorijskih vježbi	Sati LV
	Mjerenja refleksijskih i transmisijskih parametara uređaja.	2
	Principi radara-mjerenje udaljenosti objekta vektorskim mrežnim analizatorom..	6
	Numerička simulacija refleksijske površine cilja.	2
	Mjerenje bistatičke refleksijske površine.	2
	Koncepti SAR-radara, simulacija i mjerenja.	4
	Koncept MTI radara.	2
	Koncept UWB radara.	2
	Posjet radarskim sustavima HRM-a u Lori.	5
	Posjet Pomorskom Centru za Elektroniku-Split	5

Vrste izvođenja nastave:	x predavanja ☐ seminari i radionice	x samostalni zadaci ☐ multimedija

	☐ vježbe ☐ *on line* u cijelosti ☐ mješovito e-učenje x terenska nastava	x laboratorij ☐ mentorski rad ☐ (ostalo upisati)
Obveze studenata	Student je dužan sudjelovati u radu svih oblika nastave te prisustvovati: predavanjima najmanje 70% nastavnih sati te laboratorijskim vježbama 100% nastavnih sati.	

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

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Tijekom semestra bit će jedan kolokvij prema kalendaru nastave, dok će se ostatak gradiva položiti putom seminarskog rada. Student može putem kolokvija i seminarskog rada položiti cjelokupni ispit ukoliko postigne pozitivnu ocjenu iz kolokvija. Na dva završna ispita u veljači tekuće godine studenti polažu gradivo koje nisu položili na kolokviju, uz obvezu prezentacije seminarskog rada. Uvjet za pozitivnu ocjenu je da student ima najmanje 50 % bodova iz kolokvija ili na završnom ispitu, a konačna se ocjena (u postocima) formira na temelju svih aktivnosti prema formuli: $$\text{Ocjena (\%)} = 0.1NPV + 0.1LV + 0.4(K + SR)\ ,$$ gdje su aktivnosti izražene u postocima: - NPV - nazočnost na predavanjima i auditornim vježbama (%), - LV – bodovi iz laboratorijskih vježbi (%), - K - bodovi iz kolokvija (%), - SR – bodovi iz seminarskog rada Studenti koji nisu položili ispit nakon dva završna ispita mogu ispit položiti početkom rujna tekuće godine na tzv. popravnom ispitu. Zadnja prilika za polaganje ispita u tekućoj školskoj godini je tzv. komisijski ispit koji će biti održan u drugom dijelu rujna prema kalendaru nastave. Uvjet za pozitivnu ocjenu na popravnom i komisijskom ispitu je da student ima najmanje 50 % bodova iz čitavog gradiva. Ocjena se računa prema prethodno navedenoj formuli. Konačna se ocjena utvrđuje na sljedeći način: Postotak Ocjena 50% do 59% dovoljan (2) 60% do 74% dobar (3) 75% do 89% vrlo dobar (4) 90% do 100% izvrstan (5) Ispitni rokovi: Prema kalendaru nastave

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	**Naslov**	**Broj primjeraka u knjižnici**	**Dostupnost putem ostalih medija**
	M. Škiljo:: Radari, predavanja		portal e-učilice
	Skolnik, M: Introduction to Radar Systems, McGraw-Hill, 1990.	1	
	Peebles, P. Z: "Radar Principles", John Wiley &	1	

	Sons, 1998.		
Dopunska literatura	Tait, P: "Introduction to Radar Target Recognition", IEE, 2005. Zentner, E.: Antene i radiosustavi, Graphis Zagreb, 2001.		
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	• Vođenje evidencije o prisutnosti na nastavi • Godišnja analiza uspješnosti polaganja ispita • Studentska anketa s ciljem evaluacije nastavnika • Samoevaluacija nastavnika • Povratna informacija od strane studenata koji su već diplomirali o relevantnosti sadržaja predmeta		
Ostalo (prema mišljenju predlagatelja)			

NAZIV PREDMETA	GEOGRAFSKI INFORMACIJSKI SUSTAVI							
Kod	FELK32	Godina studija	1.					
Nositelj/i predmeta	izv. prof. dr. dc. Marjan Sikora	Bodovna vrijednost (ECTS)	5					
Suradnici	-	Način izvođenja nastave (broj sati u semestru)	P	S	AV	LV	KV	
			30			30		
Status predmeta	Izborni	Postotak primjene e-učenja	10					

OPIS PREDMETA	
Ciljevi predmeta	Student stječe temeljna znanja potrebna za razumijevanje značajki raznih vrsta prostornih podataka, za projektiranje i izradu GIS sustava, te za analizu prostornih podataka.
Uvjeti za upis predmeta i ulazne kompetencije potrebne za predmet	Nema
Očekivani ishodi učenja na razini predmeta (4-10 ishoda učenja)	Studenti će nakon uspješno savladanog predmeta moći: 1. definirati temeljne vrste prostornih podataka i njihove zakonitosti, 2. primijeniti metode i tehnike projektiranja GIS sustava, 3. izvršiti unos i georeferenciranje prostornih podataka, 4. odrediti ispravnu projekciju prostornih podataka, 5. izraditi kartu pomoću GIS-a, 6. izvršiti prostornu analizu temeljem GIS-a, 7. izraditi i postaviti distribuirani GIS.

Sadržaj predmeta detaljno razrađen prema satnici nastave	Sadržaj	Sati P
	Predstavljanje predmeta	2
	Uvod, tri primjera GIS-a	2
	Modeli prostornih podataka, generalizacija	2
	Osobine prostornih podataka	2
	Modeliranje prostornih podataka	2
	GIS softver	2
	Konzultacije u vezi projektnog zadatka	2
	Georeferenciranje	2
	Prikupljanje podataka	2
	Kartografija	2
	Analize	2
	Prostorni modeli	2
	Konzultacije u vezi projektnog zadatka	2
	Popis laboratorijskih vježbi	Sati LV
	Uvodna vježba	2
	Osnove rada u GIS pregledniku..	2
	Osnove rada s bazama prostornih podataka	2
	Načini prikazivanja prostornih podataka.	2
	Klasificiranje.	2
	Labeliranje	2
	Georeferenciranje	2
	Prostorne projekcije	2
	Stvaranje prostorne baze podataka	2

	Unos prostornih podataka u bazu	2
	Izmjene prostornih podataka	2
	Izrada karte	2
	Vršenje upita nad prostornom bazom	2

Vrste izvođenja nastave:	☒predavanja ☐seminari i radionice ☒vježbe ☐*on line* u cijelosti ☐mješovito e-učenje ☐terenska nastava	☒samostalni zadaci ☐multimedija ☒laboratorij ☒mentorski rad ☒CDIO
Obveze studenata	Obavljene sve predviđene laboratorijske vježbe. Sudjelovanje u izradi projekta.	

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		Rad u grupi	1
	Esej		Seminarski rad		(Ostalo upisati)	
	Kolokviji		Usmeni ispit		(Ostalo upisati)	
	Pismeni ispit		Projekt	2	(Ostalo upisati)	

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Predmet se ocjenjuje temeljem rada na projektu. Svaki student sudjeluje u projektnoj grupi koja prilikom izrade projekta treba napraviti/predati slijedeće: Plan projekta (PP), Izvještaj o ulaznim podacima (IUP), Kartu (K), Distibuirani GIS (DG), Završni izvještaj (ZI). Po završetku projekta student sa ostatkom projektne grupe sudjeluje u prezentaciji projekta (PR) pred nastavnikom i drugim studentima. Završna ocjena računa se kao: Ocjena (%) = 0,3 DG + 0,3 K + 0,15 PR + 0,15 ZI + 0,05 PP + 0,05 IUP

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	**Naslov**	**Broj primjeraka u knjižnici**	**Dostupnost putem ostalih medija**
	Maguire, D. J.; Goodchild, M. F.; Rhind, D. W., Geographical information systems and Science, John Wiley and Sons, Ltd., 2005.	1	-

Dopunska literatura	Galati, S.R.: Geographic Information Systems Demystified, Artec House, Inc., 2006.
	Tutić, D.; Vučetić, N.; Lapaine, M., Uvod u GIS, Sveučilište u Zagrebu, Geodetski fakultet, 2002.
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	• Vođenje evidencije o prisutnosti na nastavi • Online anonimna studentska anketa s ciljem evaluacije nastavnika i predmeta • Samo-evaluacija nastavnika • Povratna informacija od strane studenata koji su već diplomirali o relevantnosti sadržaja predmeta
Ostalo (prema mišljenju predlagatelja)	-

NAZIV PREDMETA	NAPREDNE WEB TEHNOLOGIJE							
Kod		Godina studija	1					
Nositelj/i predmeta	Prof. dr.sc. Maja Štula	Bodovna vrijednost (ECTS)	5					
Suradnici	Dr. sc. Josip Maras	Način izvođenja nastave (broj sati u semestru)	P	S	AV	LV	KV	
			30			30		
Status predmeta	izborni	Postotak primjene e-učenja	0					

OPIS PREDMETA

Ciljevi predmeta	Ciljevi predmeta su: • Razumijevanje temeljnih koncepata i trendova razvoja modernih web aplikacija. • Usvajanje dubokih znanja o programskim okruženjima i dizajnerskim predlošcima web aplikacija • Stjecanje znanja potrebnih za razvoj naprednih, suvremenih web aplikacija
Uvjeti za upis predmeta i ulazne kompetencije potrebne za predmet	Nema
Očekivani ishodi učenja na razini predmeta (4-10 ishoda učenja)	1. Posjedovati dubinsko znanje o aktualnim programskim jezicima i tehnologijama za suvremene web apliklacije 2. Razumjeti web tehnologije i arhitekture uključenih u napredne web aplikacije koje se sastoje od klijentskih komponenti i komponenti poslužiteljskih aplikacija 3. Kritički analizirati zahtjeve velikih i složenih web aplikacija za stvarne scenarije 4. Primjeniti moderne front end biblioteke i frameworke u svrhu razvoja kompleksnih korisničkih sučelja 5. Primjeniti moderne back end frameworke u svrhu razvoja suvremenih web aplikacija 6. Razumjeti koncepte skalabilnosti web aplikacije 7. Dizajnirati i razviti kompleksnu web aplikaciju s trenutno popularnim tehnologijama

Sadržaj predmeta detaljno razrađen prema satnici nastave	Sadržaj	Sati P	Sati AV
	Korištenje MVC (Model-View-Controler) predloška kod razvoja web aplikacija (primjer ASP.NET MVC)	8	
	Tehnologije za mapiranje između baza i objektnih modela (primjer Entity frameworka)	8	
	Napredna izrada responzivnih HTML sučelja korištenjem modernih CSS i JS razvojna okruženja	4	
	Napredni Javascript programski jezik	4	
	React + redux	4	
	Angular (osnove)	2	
	Popis laboratorijskih ili konstrukcijskih vježbi		Sati LV ili KV
	ASP.NET MVC		8
	Napredni CSS		2
	Napredni JS		4
	React + Redux		14
	Angular (osnove)		2

Vrste izvođenja	☒ predavanja	☒ samostalni zadaci

nastave:	☐ seminari i radionice ☒ vježbe ☐ *on line* u cijelosti ☐ mješovito e-učenje ☐ terenska nastava	☐ multimedija ☒ laboratorij ☐ mentorski rad ☐ (ostalo upisati)
Obveze studenata		

Praćenje rada studenata *(upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti predmeta):*	Pohađanje nastave	1	Istraživanje		Praktični rad	
	Eksperimentalni rad		Referat		Samostalni rad	1,7
	Esej		Seminarski rad	1	Laboratorijske vježbe	1
	Kolokviji	0,2	Usmeni ispit		(Ostalo upisati)	
	Pisani ispit	0,1	Projekt		(Ostalo upisati)	

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Tijekom semestra biti će održana dva međuispita (kolokvija) prema kalendaru nastave te će biti podijeljeni seminarski radovi. Također, tijekom cijelog semestra kontinuirano praćenje zalaganja studenata. Uvjet za uspješno položen predmet je minimalno 40% na svakom međuispitu (kolokviju), ili iz svakog dijela gradiva na završnom ispitu. Polaganje na temelju dva kolokvija ili cjelokupnog ispita. O = ((S + I) / 2) + B S – seminar I – ispit ili kolokviji B – bonus bodovi (lab. vježbe i/ili domaći radovi) Predmet je uspješno položen ako je ukupan postotak veći od 50%.

	Naslov	**Broj primjeraka u knjižnici**	**Dostupnost putem ostalih medija**
Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Secrets of the JavaScript Ninja, John Resig, Bear Bibeault,, Manning Publication, 2013.		
	Professional ASP.NET MVC 4, Jon Galloway, Phil Haack, Wrox, 2012.		
Dopunska literatura			

Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	• Vođenje evidencije o prisutnosti na nastavi • Godišnja analiza uspješnosti polaganja ispita • Studentska anketa s ciljem evaluacije nastavnika • Samoevaluacija nastavnika • Povratna informacija od strane studenata koji su već diplomirali o relevantnosti sadržaja predmeta
Ostalo (prema mišljenju predlagatelja)	

NAZIV PREDMETA	INDUSTRIJSKA ROBOTIKA						
Kod	FELG05	Godina studija	1. godina				
Nositelj/i predmeta	Prof. dr. sc. Mojmil Cecić	Bodovna vrijednost (ECTS)	5				
Suradnici	Hrvoje Jurić, mag. ing.	Način izvođenja nastave (broj sati u semestru)	P	S	AV	LV	KV
			30	0	0	30	0
Status predmeta	Izborni	Postotak primjene e-učenja	0				

OPIS PREDMETA		
Ciljevi predmeta	Osposobljavanje studenata za: 1. stjecanje temeljnih znanja o industrijskim robotima i vještini modeliranja kinematike i dinamike robota, 2. izvođenje planiranih trajektorija te primjena različitih metoda upravljanja robotima, 3. osposobljavanje studenata za samostalne simulacije pomoću programa Matlab, 4. razvijanje sposobnosti samostalnog rada i rada u manjim grupama (timski rad) i prikaza ostvarenih rezultata	
Uvjeti za upis predmeta i ulazne kompetencije potrebne za predmet	Nema.	
Očekivani ishodi učenja na razini predmeta (4-10 ishoda učenja)	Po završetku kolegija studenti bi trebali: 1. Opisati različite mehaničke konfiguracije robotskih manipulatora, 2. Razumjeti funkcionalnost i ograničenja robotskih aktuatora i senzora, 3. Napraviti kinematičku analizu robotskog manipulatora, 4. Razumjeti zašto je važna dinamika robota, 5. Znati kako primijeniti različite tehnike za rješavanje različitih problema vezanih za vođenje robota i navigaciju, 6. Programirati robota da izvede specifičan zadatak, 7. Razumjeti kako funkcioniraju simulacije, zašto su korisne i koji su im nedostaci.	
Sadržaj predmeta detaljno razrađen prema satnici nastave	**NASTAVNE JEDINICE ZA PREDAVANJA**	**BROJ SATI**
	Uvod. Povijesni pregled. Klasifikacija robota. Robotske paradigme.	1
	Komponente robota. Stupnjevi slobode. Koordinatni sustavi i konfiguracije robotskih sustava. Karakteristike robotskih sustava. Radni prostor. Primjena robota.	1
	Kinematika robota: Robot kao mehanizam. Homogena matrica transformacije. Predstavljanje transformacija.	2
	Karakteristični sustavi u robotskom radnom prostoru i njihovi odnosi. Inverzna transformacijska matrica. Koordinatni sustav kamere.	2
	Direktna kinematika robota. Primjeri za različite robotske konfiguracije.	2
	Rješenje inverzne kinematike robota.	2
	Danavit-Hartenbergov prikaz direktne kinematike robota	2
	Diferencijalni pomaci i brzine: Odnosi među diferencijalnim veličinama. Jakobijan robota. Singulariteti.	2
	Dinamička analiza i sile: Newton-Euler-ova formulacija dinamike. Lagrangian-ova formulacija dinamike manipulatora.	2
	Generiranje trajektorije: Opis trajektorije. Način predstavljanja trajektorije pomoću unutrašnjih i vanjskih koordinata robotskog sustava.	2
	Pogoni u robotici	2
	Aktuatori i senzori robotskih sustava.	2
	Linearno upravljanje robotskim sustavom.	2

	Modeliranje i vođenje robotskog sustava vidom.	2
	NASTAVNE JEDINICE ZA LAB. VJEŽBE	**BROJ SATI**
	Izračun homogene transformacijske matrice.	2
	Direktna kinematika robotskog manipulatora.	2
	Inverzna kinematika robotskog manipulatora.	2
	Jakobijan robota.	1
	Dinamika robotskog manipulatora.	2
	Projekt kinematičkog i dinamičkog opisa konkretnog robotskog manipulatora.	4
	Programiranje robota.	2
	Programiranje mobilnog robota.	4
	Izračun i simulacija trajektorije.	2
	Vođenje mobilnog robota.	1
	Izračun i simulacija robotskih koordinata pomoću koordinata slike.	2
	Projekt vođenja vidom	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	Nazočnost na predavanjima u iznosu od najmanje 70% predviđene satnice. Obavljene sve predviđene laboratorijske vježbe.	

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

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu

Tijekom semestra bit će dva međuispita (kolokvija). Prvi međuispit je nakon 7 tjedana nastave, drugi nakon 13 tjedana nastave. Na završnom ispitu studenti polažu one dijelove gradiva koje nisu položili na međuispitima. Uvjet za pozitivnu ocjenu je pozitivna ocjena iz laboratorijskih vježbi i 50% bodova međuispitima. Konačna ocjena se formira na slijedeći način:

$$\text{Ocjena}(\%)=0{,}25L + 0{,}375(M1 + M2)$$

Gdje je L ocjena iz laboratorijskih vježbi izražena u postocima, a M1 i M2 bodovi na međuispitima izraženi u postocima. Vrijedi:

- 50% do 61% dovoljan (2)
- 62% do 74% dobar (3)
- 75% do 87% vrlo dobar (4)
- 88% do 100% izvrstan (5)

Studenti koji ne polože ispit preko kolokvija polažu pismeni ispit koji sadrži do 5 pitanja i zadataka. Uvjet za polaganje ispita je 50% bodova od ukupnog broja. Ispitni rokovi održavaju se prema kalendaru nastave

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	**Naslov**	**Broj primjeraka u knjižnici**	**Dostupnost putem ostalih medija**
	• Saeed B. Niku: Introduction to Robotics: Analysis, Systems, Applications, Prentice Hall, 2001.	1	

Dopunska literatura

1. Tadej Bajd: Osnove robotike, Fakulteta za elektrotehniko, Univerza v Ljubljani, 2000.
2. Kovačić, Laci, Bogdan, Osnove robotike, Fakultet elektrotehnike i računarstva,

	Zagreb 1999.
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	• Vođenje evidencije o prisutnosti na nastavi • Godišnja analiza uspješnosti polaganja ispita • Studentska anketa s ciljem evaluacije nastavnika • Samoevaluacija nastavnika • Povratna informacija od strane studenata koji su već diplomirali o relevantnosti sadržaja predmeta
Ostalo (prema mišljenju predlagatelja)	

NAZIV PREDMETA	TELEMEDICINA I BIOKIBERNETIKA						
Kod	FELG32	Godina studija	1.				
Nositelj/i predmeta	prof. dr. sc. Mojmil Cecić doc. dr. sc. Josip Musić	Bodovna vrijednost (ECTS)	5				
Suradnici	dr. sc. Tea Marasović	Način izvođenja nastave (broj sati u semestru)	P	S	AV	LV	KV
			30	0	0	30	0
Status predmeta	Izborni	Postotak primjene e-učenja	0				

OPIS PREDMETA	
Ciljevi predmeta	Stjecanje temeljnih znanja iz područja telemedicine i biomehanike.
Uvjeti za upis predmeta i ulazne kompetencije potrebne za predmet	Nema
Očekivani ishodi učenja na razini predmeta (4-10 ishoda učenja)	Student će nakon uspješno savladanog predmeta moći: 1. objasniti računalnu i telekomunikacijsku osnovu telemedicine 2. ocijeniti karakteristike algoritama za obradu slikovnih zapisa za potrebe telemedicine 3. komentirati kliničku primjenu telemedicine 4. upotrijebiti izvore medicinskih informacija u smislu učenja na daljinu 5. komentirati sustave za mjerenje biomehaničkih parametara čovjeka 6. analizirati sile i momente u zglobovima u korelaciji s mišićnom aktivnosti 7. koristiti mjerne sustave bazirane na EMG uređajima, inercijskim senzorima i optoelektroničkim sustavima u biokibernetici 8. kritički prosuđivati rezultate mjerenja u smislu mogućnosti daljnje primjene i ograničenja pojedinih sustava

Sadržaj predmeta detaljno razrađen prema satnici nastave	**Sadržaj**	Sati P
	Uvod u telemedicine, razvoj telemedicine.	2
	Računalna i telekomunikacijska osnovica telemedicine.	2
	Telemedicinska oprema i telemedicinske usluge.	2
	Učenje na daljinu, pretraživanje izvora medicinskih informacija.	2
	Obrada slikovnih zapisa za potrebe telemedicine	2
	Etika i telemedicina	2
	Klinička primjena	2
	Uvod u biomehaniku; Pregled tehničkih sustava za mjerenje biomehaničkih parametara čovjeka; Mjerne metode u biomehanici.	2
	Identifikacija antropometrijskih parametara čovjeka ; Analiza hoda: terminologija i mjerenja.	2
	Mjerenja parametara hoda; Kinematika i Kinetika; Položaj i ravnoteža tijela tijekom hoda; Sile reakcije podloge pri hodu.	2
	Elektromiografija, mjerenje mišićne aktivnosti tijekom čovjekovog pokreta.	2
	Inverzna kinematika u identifikaciji mišićnih sila.	2
	Primjena računalnog vida u biokibernetici.	2
	Popis laboratorijskih vježbi	Sati LV
	Uvodno predavanje o načinu izvršavanja vježbi, mjernim sustavima u laboratoriju i mjernim zadacima na vježbama	2
	Mjerenje antropometrijskih parametara čovjeka metodom konačnih elemenata.	3
	Mjerenje kinematičkih parametara ljudskog hoda upotrebom brzih kamera.	4
	Mjerenje sila reakcije podloge pri hodu pomoću platforme sila.	3

	Mjerenje EMG signala mišića pri hodu.	4
	Određivanje mišićnih sila i momenata pri hodu na temelju izmjerenih kinematičkih parametara hoda i sila reakcije podloge pri hodu, te usporedba s izmjerenim EMG signalima.	4
	Mjerenje opsega pokreta vratne kralježnice upotrebom inercijskih senzora pokreta.	3
	Primjena računalnog vida na prepoznavanje i automatsko prevođenje znakovne abecede gestikulacijskog jezika.	4
	Algoritmi za obradu slikovnih zapisa za potrebe telemedicine.	3

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	Nazočnost na predavanjima u iznosu od najmanje 70% predviđene satnice. Obavljene sve predviđene laboratorijske vježbe i predani izvještaji sa svih vježbi.	

Praćenje rada studenata *(upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti predmeta):*	Pohađanje nastave	1	Istraživanje		Praktični rad	
	Eksperimentalni rad		Referat		Samostalni rad	2
	Esej		Seminarski rad		Laboratorijske vježbe	1,5
	Kolokviji	0,1	Usmeni ispit		Pripreme za laboratorijske vježbe	0,3
	Pismeni ispit	0,1	Projekt			

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Tijekom semestra bit će dva međuispita (kolokvija). Prvi međuispit je nakon 7 tjedana (iz područja biokibernetike), a drugi nakon 13 tjedana nastave (iz područja telemedicine u vidu obrane projektnog zadatka). Na završnom ispitu studenti polažu dijelove gradiva koje nisu položili na međuispitima. Svaki se međuispit (i završni ispit) provodi kao pisani ispit u trajanju od 90 minuta. Studenti koji ne polože ispit preko međuispita polažu pismeni ispit koji sadrži 8 pitanja i zadataka. Uvjet za polaganje ispita je 50% bodova od ukupnog broja. Uvjet za pozitivnu ocjenu je pozitivna ocjena iz laboratorijskih vježbi, te srednja vrijednost dva međuispita ((M1 + M2)/2) od najmanje 50%. Pri tome student na svakom od međuispita mora imati najmanje 45% bodova. Konačna se ocjena (u postocima) formira prema formuli: Ocjena(%)=0,25L + 0,25M1 + 0,5M2 L - ocjena iz laboratorijskih vježbi izražena u postocima, M1, M2 - bodovi na međuispitima izraženi u postocima. Konačna se ocjena utvrđuje na sljedeći način: Postotak Ocjena 50% do 62% dovoljan(2) 63% do 74% dobar (3) 75% do 86% vrlo dobar (4) 87% do 100% izvrstan (5) Prema Članku 65. Statuta Fakulteta, student je dužan sudjelovati u radu svih oblika nastave te prisustvovati: predavanjima najmanje 70 % nastavnih sati, laboratorijskim vježbama 100% nastavnih sati. Shodno tome student treba izraditi i predati 100 % zadataka koje dobije u okviru laboratorijskih vježbi. Ako ne ispuni navedene uvjete, student neće moći pristupiti, te će kolegij morati ponovo upisati.

	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	I. Klapan, I. Čikeš:; Telemedicina u Hrvatskoj, Medika, Zagreb, 2001.	3	predmetni nastavnik
	R. J. Jagacinski, J. M. Flach: Control Theory for Humans: Quantitative Approaches to Modeling Performance, Lawrence Erlbaum Associates Inc., 2003		predmetni nastavnik
	T. Marasović, Upute za laboratorijske vježbe, FESB		e-learning portal
	M. Cecić, J. Musić: Autorizirana predavanja, FESB		e-learning portal
Dopunska literatura	1. Winter D.A.: The Biomechanics and Motor Control of Human Gait, University of Waterloo Press, Waterloo, 1991. 2. Zanchi V., Cecić M., Grujić T., Kuzmanić A., Papić V. : Laboratory for Identification of Human Movement with LaBACS Software Support, International Congress on Computational Bioengineering, ICCB'03, 24-26 September 2003., Zaragoza, Spain, p.p. 155-161 3. I. Kaplan, I Čikeš (editori): "Telemedicine", Telemedicine Assodication, Zagreb, 2005. 4. V. Štambuk: "Kibernetika s informatikom", 1989. 5. V. R. Milačić : "Tehnička kibernetika", 1981. 6. N. Wiener: "Kibernetika ili upravljanje i komunikacija kod živih bića i mašina", 1972.		
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	1. vođenje evidencije o prisutnosti na nastavi 2. godišnja analiza uspješnosti polaganja ispita 3. studentska anketa s ciljem evaluacije kvalitete nastavnika i kolegija 4. samoevulacija nastavnika 5. povratna informacija od strane studenata koji su već diplomirali (ili su na višim godinama studija) o relevantnosti sadržaja kolegija 6. povremeno promatranje i evaluacija nastava od strane šefa katedre		
Ostalo (prema mišljenju predlagatelja)			

NAZIV PREDMETA	MODELIRANJE I VOĐENJE PLOVILA I VOZILA						
Kod	FELG27	Godina studija	1				
Nositelj/i predmeta	prof.dr.sc.Darko Stipaničev doc.dr.sc.Damir Krstinić	ECTS	5				
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	AV	LV	KV
			30	0	0	30	
Status predmeta	Izborni	Postotak primjene e-učenja	80				

OPIS PREDMETA

Ciljevi predmeta	Cilj je kolegija usvajanje osnovnih znanja iz modeliranja plovila (brodova, plovećih platformi, ronilica) i kopnenih vozila s posebnim naglaskom na sustave automatskog vođenja (auto pilote).
Uvjeti za upis predmeta i ulazne kompetencije potrebne za predmet	
Očekivani ishodi učenja na razini predmeta (4-10 ishoda učenja)	Studenti će nakon uspješno savladanog predmeta moći: 1. Razumjeti sustavni pristup automatskom vođenju prijevoznih sredstava i podjelu prijevoznih sredstava u odnosu na medije u kojima se gibaju. 2. Razumjeti i primijeniti postupke matematičkog modeliranje gibanja prijevoznih sredstava (lokalni i globalni koordinatni sustavi, kinematičke i dinamičke jednadžbe, linearizacija jednadžbi gibanja, stabilnost). 3. Razumjeti i primijeniti matematičke modele plovila (brod, platforma) promatrane kao objekt vođenja (upravljive i neupravljive slobode gibanja plovila, postavljanje matematičkog modela gibanja plovila, hidrodinamički koeficijenti, propulzija i kormilarski sustav, linearni i nelinearni model gibanja broda). 4. Razumjeti zadatke kormilarenja i automatskog kormilarenja, stabilizacije plovila i automatske stabilizacije, značaj navigacija i navigacijskih sustava u vođenju broda. Razumjeti i primijeniti postuke projektiranja auto-pilota. 5. Razumjeti osnovne pojmove vezane uz bespilotna plovila: daljinski upravljana vozila (ROV – Remotely Operated Vehicles) i autonomna površinska vozila (ASV – Autonomous Surface Vehicles) i principi njihovog vođenje. 6. Razumjeti i primijeniti matematičke postupke modeliranja kopnenih vozila promatranih kao objekt vođenja (postavljanje matematičkog modela gibanja kopnenog vozila, pogonski sustavi i upravljačke strukture). 7. Razumjeti osnovne pojmove vezane uz bespilotna vozila: daljinski upravljana vozila i samostalna samohodna vozila. 8. Razumjeti primjenu umjetne inteligencije i inteligentnih tehnologija u sustavima automatskog vođenju plovila i vozila.

	Sadržaj	Sati P	Sati AV
Sadržaj predmeta detaljno razrađen prema satnici nastave	Sustavni pristup automatskom vođenju prijevoznih sredstava (prometala). Podjela prijevoznih sredstava u odnosu na medije u kojima se gibaju. Matematičko modeliranje gibanja plovila i vozila: lokalni i globalni koordinatni sustavi, kinematičke i dinamičke jednadžbe gibanja, stabilnost.	4	0
	Plovilo (brod, platforma) kao objekt vođenja. Upravljive i neupravljive slobode gibanja plovila. Postavljanje matematičkog modela gibanja plovila. Hidrodinamički koeficijenti. Propulzija i kormilarski sustav. Linearni i nelinearni matematički modeli gibanja plovila.	6	0

	Navigacija i navigacijski sustavi u vođenju broda (terestička, astronomska, radio i satelitska (GPS) navigacija). NMEA komunikacijski protokoli. Kormilarenje i automatsko kormilarenje. Standardni i inteligentni auto-pilot. Projektiranje auto-pilota za režim plovidbe stabilizacija kursa i režim plovidbe skretanja. Stabilizacija plovila i automatska stabilizacija. Bespilotna plovila: daljinski upravljana vozila (ROV – Remotely Operated Vehicles) i autonomna površinska vozila (ASV – Autonomous Surface Vehicles) i principi njihovog vođenje.	8	0
	Kopneno vozilo kao objekt vođenja. Postavljanje matematičkog modela gibanja kopnenog vozila. Vozila s tri, četiri i više kotača. Pogonski sustav i toplinski strojevi. Upravljačke strukture i sustavi automatskog vođenja kopnenih vozila. CAN komunikacijski protokoli. Daljinski upravljana vozila i samostalna samohodna vozila.	6	0
	Primjena umjetne inteligencije u sustavima automatskog vođenju plovila i vozila.	2	
	Matematičko modeliranje plovila linearnim i nelinearnim modelima. Identifikacija matematičkog modela broda.	0	6
	Automatizacija plovidbe i autonomna plovila (auto-pilot, održavanje kursa, automatsko manevriranje, autonomna plovidba)	0	6
	Brod kao objekt vođenja, komandni most, upravljanje brodskim strojevima (terenski rad – posjet suvremenom pomorskom simulatoru na jednom od pomorskih učilišta)	0	4
	Matematičko modeliranje kopnenih vozila.	0	6
	Autonomna vozila – primjeri različitih algoritama koji se koriste kod autonomnih vozila (održavanje konstantne brzine – tempomat, održavanje razmaka između vozila – konvojska vožnja, automatsko parkiranje)	0	4

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	Nazočnost na predavanjima u iznosu od najmanje 70% predviđene satnice. Napravljene sve laboratorijske vježbe.	

Praćenje rada studenata *(upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti predmeta):*	Pohađanje nastave	1,5	Istraživanje		Praktični rad	
	Eksperimentalni rad		Referat		Samostalni rad	
	Esej		Seminarski rad	1,5	Laboratorijske vježbe	
	Kolokviji		Usmeni ispit		Pripreme za laboratorijske vježbe	
	Pisani ispit	2	Projekt		(Ostalo upisati)	

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Ispit se sastoji od pismenog dijela i ukoliko je potrebno dodatne usmene provjere. Tijekom semestra biti će dva kolokvija. Prvi kolokvij je u 8 tjedanu nastave, drugi u 18 tjednu. Student može putem kolokvija položiti gradivo kolegija. Na dva završna ispita u lipnju i srpnju, studenti koji nisu sakupili prolazan broj bodova na kolokvijima polažu cjelokupno gradivo obuhvaćeno sa dva kolokvija. Uvjet za izlazak na završni ispit je uspješno odrađen praktični dio laboratorijskih vježbi, te predani svi izvještaji.

	Ispit je cjelovit te uključuje i teorijski dio gradiva i zadatke. Uvjet za pozitivnu ocjenu je da student ima ukupno najmanje 50 % bodova na ispitu ali pri tome mora imati minimalno 25% položenog teorijskog dijela gradiva i 25% položenih zadataka. Ukoliko student ima manje od 25% bodova na zadacima i/ili manje od 25% bodova iz teorijskog dijela gradiva ponovo polaže cijeli ispit. Studenti koji nisu položili ispit nakon dva završna ispita mogu ispit položiti u jesenskim rokovima. Sva ispitna pitanja studentima će biti poznata prije ispita. Ova se pravila podjednako odnose na studente koji su ovaj kolegij upisali prvi put i na one studente koji su kolegij upisali po drugi put. Konačna se ocjena utvrđuje na sljedeći način: Postotak Ocjena 50% do 61% dovoljan (2) 62% do 74% dobar (3) 75% do 87% vrlo dobar (4) 88% do 100% izvrstan (5) Na prvom kolokviju će se polagati gradivo prema nastavnim jedinicama do sedmog tjedna uključivo, a na drugom ostatak gradiva tjedna uključivo. Ispitni rokovi održavaju se u terminima predviđenim kalendarom nastave. Prema Članku 65. Statuta Fakulteta, student je dužan sudjelovati u radu svih oblika nastave te prisustvovati: predavanjima najmanje 70 % nastavnih sati. Ako ne ispuni navedene uvjete, student neće moći pristupiti ispitu i dobiti potpis, te će ispit morati ponovo upisati.

	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	D.Stipaničev, Uvod u modeliranje i vođenje plovila, radni udžbenik u digitalnom formatu, FESB, 2021.		e-learning portal
	Jecić, S.: Mehanika II - kinematika i dinamika, Tehnička knjiga Zagreb, 1989.		
	Babić, E.; Karmelić, A.: Numeričko modeliranje složenih gibanja, Školska knjiga Zagreb, 1988.		
	Fossen, T.I.: Guidance and Control of Ocean Wehicles, J.Wiley, Chicester, 1994		

Dopunska literatura	- Ship Dynamics - https://www.scribd.com/document/53761891/Ship-Dynamics - International Network for Autonomous Ships - http://www.autonomous-ship.org - Autonomous Vehicles International - https://www.autonomousvehicleinternational.com
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	• Vođenje evidencije o prisutnosti na nastavi • Godišnja analiza uspješnosti polaganja ispita • Studentska anketa s ciljem evaluacije nastavnika • Samoevaluacija nastavnika • Povratna informacija od strane studenata koji su već diplomirali o relevantnosti sadržaja predmeta
Ostalo (prema	

mišljenju predlagatelja)	

NAZIV PREDMETA	IP KOMUNIKACIJE						
Kod	FELJ11	Godina studija	1.				
Nositelj/i predmeta	Izv. prof. dr. sc. Mladen Russo	Bodovna vrijednost (ECTS)	6				
Suradnici	Matija Pauković, mag.ing.,	Način izvođenja nastave (broj sati u semestru)	P	S	AV	LV	KV
			30	0	0	30	0
Status predmeta	Izborni	Postotak primjene e-učenja	0				

OPIS PREDMETA

Ciljevi predmeta	Osposobljavanje studenata za: • razumijevanje i poznavanje arhitekture i protokola mreža temeljenih na ISO-OSI referentnom modelu i kodiranoj (paketskoj) komutaciji, • poznavanje TCP/IP protokolnog sloga, protokola i funkcija po slojevima, • razumijevanje metoda adresiranja u IPv4 i IPv6 mrežama, • razumijevanje mehanizama usmjeravanja, protokolima za multimedijski promet te metodama upravljanja kvalitetom QoS, • poznavanje najvažnijih primjena TCP/IP mreže, elektroničke pošte, www i http komunikacija, prijenosa datoteka (ftp), daljinskog rada (telnet), IP govora (VoIP) i IP televizije (IPTV)
Uvjeti za upis predmeta i ulazne kompetencije potrebne za predmet	Nema
Očekivani ishodi učenja na razini predmeta (4-10 ishoda učenja)	Studenti će nakon uspješno savladanog predmeta moći: 1. usporediti ISO-OSI model i TCP/IP protokolni stog 2. opisati mehanizme usmjeravanja paketa 3. usporediti IPv4 i IPv6 protokole 4. kreirati računalnu mrežu 5. uspostaviti VoIP komunikaciju

Sadržaj predmeta detaljno razrađen prema satnici nastave	Sadržaj	Sati P	Sati AV
	Mrežne arhitekture, tehnologije i usluge, ISO-OSI model i TCP/IP mreže i protokoli	2	1
	IP protokol, adresiranje i usmjeravanje (rutiranje)	2	1
	Upravljanje podmrežama, ARP protokol, upravljanje i koordiniranje internet porukama (ICMP)	2	1
	IP protokol v6	2	1
	Sloj transporta TCP, nepouzdana i pouzdana isporuka paketa	2	1
	Upravljanje prometom i kontrola zagušenja	2	1
	Statičko i dinamičko usmjeravanje, RIP i OSPF protokoli usmjeravanja	2	1
	Dial-up pristup, SLIP i PPP protokoli	2	1
	Multimedijski protokoli u IP mrežama, usmjeravanje prometa real-time aplikacija (RIP), pričuva resursa za real-time aplikacije (RVSP)	2	1
	Upravljanje u mrežama (SNMP)	2	1
	WWW, HTTP, HTML, e-mail, FTP, Telnet	2	1
	Govor putem IP (VoIP), H.323 i SIP protokoli, mobilne IP komunikacije	2	1
	IP televizija i video	2	1
	Popis laboratorijskih vježbi		Sati LV
	Umrežavanje računala		2

	Konfiguracija mrežnog preklopnika (engl. switch)	2
	ARP protokol	2
	IP protokol – analiza zaglavlja	2
	Subnetiranje	2
	TCP postupak trostrukog rukovanja	2
	ICMP protokol	2
	VoIP komunikacija	2
	Konfiguriranje bežičnog usmjernika i mreže	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	Nazočnost na predavanjima i auditornim vježbama u iznosu od najmanje 70% predviđene satnice. Obavljene sve predviđene laboratorijske vježbe.	

Praćenje rada studenata *(upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti predmeta):*	Pohađanje nastave	3	Istraživanje		Praktični rad	
	Eksperimentalni rad		Referat		Samostalni rad	2,7
	Esej		Seminarski rad		(Ostalo upisati)	
	Kolokviji	0,2	Usmeni ispit		(Ostalo upisati)	
	Pismeni ispit	0,1	Projekt		(Ostalo upisati)	

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Tijekom semestra održat će se dva međuispita (kolokvija) i završni ispit. Završni ispit i međuispiti se održavaju prema kalendaru nastave. Na završnom ispitu studenti polažu cjelovito gradivo ako nemaju pozitivnih ocjena na međuispitima, ili polažu gradivo međuispita koje(ga) nisu položili. Na popravnom i komisijskom ispitu se polaže cjelovito gradivo. Uvjet za pozitivnu ocjenu je 50% bodova na svakom međuispitu. Ocjena(%)= 0,5*M1+0,5*M2; M1, M2 - bodovi na međuispitima izraženi u postotcima. Konačna se ocjena utvrđuje na sljedeći način: Postotak Ocjena 50% do 61% dovoljan (2) 62% do 74% dobar (3) 75% do 87% vrlo dobar (4) 88% do 100% izvrstan (5) Studenti koji ne polože ispit preko kolokvija polažu pismeni završni ispit. Uvjet za pozitivnu ocjenu je ostvarenih barem 50% bodova. Ispitni rokovi se održavaju u terminima predviđenim kalendarom nastave.

	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Casad, J.: TCP/IP in 24 hours, Sams Publ. 2012.	1	e-learning portal
Dopunska literatura	W. Stallings: High Speed Networks: TCP/IP Design Principles, Prentice Hall B. Khasnabish: Implementing Voice over IP, Wiley Interscience, 2003.		
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	• Vođenje evidencije o prisutnosti na nastavi • Studentska anketa s ciljem evaluacije nastavnika • Samoevaluacija nastavnika • Povratna informacija od strane studenata koji su već diplomirali o		

	relevantnosti sadržaja predmeta
Ostalo (prema mišljenju predlagatelja)	

NAZIV PREDMETA	KRIPTOGRAFIJA I MREŽNA SIGURNOST						
Kod	FELK10	Godina studija	1.				
Nositelj/i predmeta	izv. prof. dr. sc. Mario Čagalj	Bodovna vrijednost (ECTS)	5				
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	AV	LV	KV
			30	0	0	30	
Status predmeta	Izborni	Postotak primjene e-učenja	0				

OPIS PREDMETA	
Ciljevi predmeta	Osnovni ciljevi predmeta su: • pružiti studentima uvid u osnovne značajke i aspekte zaštite digitalnih informacija primjenom kriptografskih mehanizama • predstaviti studentima dokazane alate i mehanizme za zaštitu sigurnosti digitalnih informacija • osposobiti studenate za implementaciju i primjenu kriptografskih mehanizama u dizajnu komunikacijsko-informacijskih sustava
Uvjeti za upis predmeta i ulazne kompetencije potrebne za predmet	Nema
Očekivani ishodi učenja na razini predmeta (4-10 ishoda učenja)	Nakon uspješno savladanog predmeta, studenti će moći: • objasniti ključne koncepte informacijske sigurnosti (povjerljivost, integritet i dostupnost) • objasniti suštinsku razliku između osiguravanja integriteta i povjerljivosti poruka • odabrati primjerene/sigurne mehanizme za zaštitu digitalnih informacija • karakterizirati razinu zaštite koju pružaju IPsec i TLS protokoli za danu konfiguraciju • uspostaviti virtualnu privatnu mrežu (VPN) primjenom kriptografske zaštite na mrežnoj i transportnoj razini • preporučiti kriptografske mehanizme za zaštitu povjerljivosti i integriteta na aplikacijskoj razini • integrirati i koristiti kriptografske biblioteke u vlastitim softverskim rješenjima • generirati i upravljati digitalnim certifikatima • osmisliti sustave za autentifikaciju korisnika temeljene na digitalnim certifikatima • kritički prosuditi sigurnost informacijskih sustava baziranih na osnovnim kriptografskim primitivima (AES, HMAC, CBC-MAC, DH, RSA i sl.)

Sadržaj predmeta detaljno razrađen prema satnici nastave	Nastavne jedinice	Sati P
	Uvod u informacijsku sigurnost (sigurnosne prijetnje, osnovni sigurnosni ciljevi)	2
	Kriptografija bazirana na simetričnom (tajnom) ključu (*secret-key cryptography*)	2
	Osnovni modovi rada modernih šifri (ECB, CBC, CFB, OFB, CTR mode)	2
	Kriptografija bazirana na asimetričnom (javnom) ključu (*public-key cryptography*)	4
	Autentifikacijske funkcije (*hash* i MAC algoritmi, digitalni potpisi i digitalni certifikati javnih ključeva)	4
	1. kolokvij	2

	Internet Security Protocol (IPsec)	2
	IPsec: *Internet Key Exchange* (IKE) protocol	2
	Web sigurnost: *Secure Socket Layer* (SSL) i *Transport Layer Security* (TLS)	4
	Mrežni vatrozidi (*network firewalls*)	2
	2. kolokvij	2
	Laboratorijske vježbe	Sati LV
	Ranjivost računalnih mreža (MitM, DoS, ARP *spoofing* napadi)	4
	Simetrična kriptografija (DES, 3DES, CBC)	4
	Asimetrična kriptografija (RSA, Diffie-Hellman)	4
	Autentifikacijske funkcije (*hash* i MAC algoritmi, digitalni potpisi i digitalni certifikati javnih ključeva)	6
	IPsec i IKE protokoli	5
	Web sigurnost: *Secure Socket Layer* (SSL) i *Transport Layer Security* (TLS)	4
	Mrežni vatrozidi (*network firewalls*)	3

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	Prisustsvo na predavanjima – najmanje 70% predviđene satnice. Izvršene sve laboratorijske vježbe.	

Praćenje rada studenata *(upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti predmeta):*	Pohađanje nastave	0.7	Istraživanje		Praktični rad	
	Eksperimentalni rad		Referat		Samostalan rad	2
	Esej		Seminarski rad		Laboratorijske vježbe	2
	Kolokviji	0.2	Usmeni ispit		(Ostalo upisati)	
	Pismeni ispit	0.1	Projekt		(Ostalo upisati)	

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Tijekom semestra održat će se dva kolokvija (nakon 7. odnosno 13. tjedna neposredne nastave). U okviru kolegija organizirat će se praktične (*hands-on*) laboratorijske vježbe. Student je dužan prisustovati svim vježbama te izraditi i predati odgovarajuća izvješća (predana izvješća s laboratorijskih vježbi su preduvjet za upis ocjene). Ocjenjivanje: P - Prisustvo na predavanjima i rad u laboratoriju LV - Izvješća s laboratorijskih vježbi K1 - 1. kolokvij K2 - 2. kolokvij (cijelo gradivo) Ocjena = zaokruži [0.05 P + 0.10 LV + 0.35 K1 + 0.50 K2] (NAPOMENA: Ukoliko student ne zadovolji pojedinu aktivnost, ista se postavlja na 0 pri izračunu konačne ocjene.)

Obvezna literatura (dostupna u knjižnici	**Naslov**	**Broj primjeraka**	**Dostupnost putem ostalih**

i putem ostalih medija)		**u knjižnici**	**medija**
	• Prezentacije s predavanja		e-learning portal
	• Menezes J., van Oorschot P. C., Vanstone S. A.: Handbook of AppliedCryptography, CRC Press, 1996.		dostupna online
Dopunska literatura	• Stallings W.: Cryptography and Network Security, Principles and Practice, Prentice Hall, 2005.		
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	• Mišljenja studenata o kvaliteti nastave putem anketa • Samoevaluacija nastavnika • Redovito usklađivanje sadržaja predavanja sa sličnim kolegijima na prestižnim svjetskim institucijama		
Ostalo (prema mišljenju predlagatelja)			

NAZIV PREDMETA	RAČUNALNA FORENZIKA						
Kod	FELK40	Godina studija	2				
Nositelj/i predmeta	Izv. prof. dr. sc. Toni Perković	Bodovna vrijednost (ECTS)	5				
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	AV	LV	KV
			30			30	
Status predmeta	izborni	Postotak primjene e-učenja	0				

OPIS PREDMETA	
Ciljevi predmeta	Razumijevanje uloge računalne forenzike u ICT okruženju; razumijevanje i poznavanje pojmova i metoda sigurnosti računalnih sustava; osposobljenost za primjenu metoda i tehnika računalne forenzike; poznavanje i primjena softverskih i hardverskih forenzičkih alata.
Uvjeti za upis predmeta i ulazne kompetencije potrebne za predmet	Nema
Očekivani ishodi učenja na razini predmeta (4-10 ishoda učenja)	1. Utvrditi i predvidjeti zlouporabu ICT tehnologija. 2. Prepoznati, klasificirati i analizirati relevantne podatke u slučajevima zlouporabe ICT tehnologija. 3. Preporučiti softverske i hardverske forenzičke alate. 4. Utvrditi i preporučiti sigurnosne aspekte informacijskih i telekomunikacijskih sustava. 5. Predložiti metode prikupljanja relevantnih podataka u slučajevima ugroze sigurnosti i zlouporabe informacijskih i komunikacijskih mreža 6. Voditi forenzičku analizu u slučajevima ugroze sigurnosti i zlouporabe informacijskih i komunikacijskih mreža 7. Primijeniti suvremenu metodologiju i tehnologiju forenzičnih znanosti 8. Objasniti i primijeniti programske i računalne forenzične alate

Sadržaj predmeta detaljno razrađen prema satnici nastave	Sadržaj	Sati P	Sati AV
	Uvod u računalnu forenziku	2	
	Osnovni pojmovi računalne forenzike. definicije. Faze istrage mjesta događaja. dokazi u računalnoj forenzici	4	
	Alati računalne forenzike	2	
	Analiza nositelja podataka, slojevi, volumen	2	
	Alati za analizu nositelja podataka. Tehnologija tvrdog diska, adresiranje	2	
	Datotečni sustav, kategorije podataka, boot sektor	2	
	Windows i linux forenzika	2	
	Forenzika fotografija, steganografija	2	

	Prikupljanje nestalnih podataka (RAM). Mrežna forenzika	3	
	Forenzika smartphone uređaja	3	
	Forenzika mikrokontrolera	2	
	Forenzika bežičnih mrežnih sustava	2	
	Budućnost razvoja računalne forenzike	2	
	Popis laboratorijskih ili konstrukcijskih vježbi		Sati LV ili KV
	Rad s diskovima, particijama, datotekama		2
	Razumijevanje hash funkcija, hexadecimalne notacije, metapodataka		2
	Provjera integriteta slike i kreiranje Live USB-a		2
	Restauracija izbrisanih podataka, kreiranje slike medija i sigurno brisanje medija		2
	Forenzika fotografija, steganografija i metapodaci		2
	Windows Registry, event logovi i USB forenzika		2
	Mrežna forenzika		2
	Forenzika smartphone uređaja		2
	Pronalaženje tragova korištenja e-maila		2
	Forenzika memorijskih sadržaja na mikrokontrolerima		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		

Praćenje rada studenata *(upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti predmeta):*	Pohađanje nastave	1	Istraživanje		Praktični rad	
	Eksperimentalni rad		Referat		Samostalni rad	1,7
	Esej		Seminarski rad	1	Laboratorijske vježbe	1
	Kolokviji	0,2	Usmeni ispit		(Ostalo upisati)	
	Pisani ispit	**0,1**	Projekt		(Ostalo upisati)	

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Tijekom semestra biti će održana dva međuispita (kolokvija) prema kalendaru nastave ili će biti podijeljeni seminarski radovi a ovisno o dogovoru sa studentima. Uvjet za pozitivnu ocjenu je 45% bodova na svakom međuispitu (seminaru), ili iz svakog dijela gradiva na završnom ispitu te pozitivna ocjena iz laboratorijskih vježbi. Uvjet za pozitivnu ocjenu na popravnom ispitu je 50% ukupnog broja bodova. Svaki međuispit se sastoji od 4 pitanja , završni ispit sastoji se od 6 pitanja podijeljenih u dvije skupine. Uvjet za polaganje ispita je 50% bodova od ukupnog broja pitanja. U konačnoj ocjeni, svaki kolokvij sudjeluje s maksimalno 30% (seminar 60%), a laboratorijske vježbe s maksimalno 40% od ukupno maksimalno mogućeg broja bodova (30%+30%+40%). Konačna ocjena slijedi iz na taj način dobivenog postotka i to: Za postotak Ocjena 50% do 62% dovoljan (2) 63% do 75% dobar (3) 76% do 88% vrlo dobar (4)

	89% do 100% izvrstan (5) Studenti koji ne polože ispit preko kolokvija polažu cjeloviti ispit pod istim uvjetima, a konačnu ocjenu se i u ovom slučaju izračunava kao suma postignutih postotaka ispita (maksimalno 60%) i laboratorijskih vježbi (40%).		
Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	**Naslov**	**Broj primjeraka u knjižnici**	**Dostupnost putem ostalih medija**
	Nastavni tekst Računalna forenzika		DA
	Internet		DA
Dopunska literatura	- Criss Posise, Kevin Mandia, Matt Pepe: "Incident Response and Computer Forensics", Second Edition, McGraw-Hill, Inc. New York, USA, 2001. - Waren G. Kruse, Jay H. Heiser: "Computer Forensics: Incident Response Essentials" - "Security Engineering", Ross Anderson - E. Eugene Schultz, Russell Shumway: "Incident Response: A Strategic Guide to Handling System and Network Security", Sums Publishing, 2001.		
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	• Vođenje evidencije o prisutnosti na nastavi • Godišnja analiza uspješnosti polaganja ispita • Studentska anketa s ciljem evaluacije nastavnika • Samoevaluacija nastavnika • Povratna informacija od strane studenata koji su već diplomirali o relevantnosti sadržaja predmeta		
Ostalo (prema mišljenju predlagatelja)	/		

NAZIV PREDMETA	SKLADIŠTA PODATAKA						
Kod	FELK16	Godina studija	1.				
Nositelj/i predmeta	prof. dr. sc. Stipe Čelar	Bodovna vrijednost (ECTS)	5				
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	AV	LV	KV
			30	0	0	30	
Status predmeta	Izborni	Postotak primjene e-učenja	0				

OPIS PREDMETA			
Ciljevi predmeta	Osposobljavanje studenata za: • razumijevanje arhitekture skladišta podataka • razumijevanje koncepata dimenzijskog modela podataka • analizu poslovnih procesa i izradu jednostavnijih dimenzijskih modela podataka • primjenu alata i tehnologija za izradu i korištenje skladišta podataka • sudjelovanje u svim fazama projekta skladištenja podataka		
Uvjeti za upis predmeta i ulazne kompetencije potrebne za predmet	-		
Očekivani ishodi učenja na razini predmeta (4-10 ishoda učenja)	Studenti će nakon uspješno savladanog predmeta moći: razumjeti arhitekturu skladišta podataka • opisati alate i tehnologije koje se koriste za izradu skladišta podataka • napraviti osnovni dimenzijski model poslovnog područja (s 5-10 dimenzija) u izabranoj tehnologiji i alatu • projektirati skladište podataka za manje opsežan poslovni proces (proces s 5-10 dimenzija) • realizirati funkcionalno skladište s testnim podatcima prema definiranom konceptualnom, logičkom i fizičkom modelu • moći sudjelovati u većim projektima skladištenja podataka		
Sadržaj predmeta detaljno razrađen prema satnici nastave	Sadržaj	Sati P	Sati AV
	Uvodno predavanje o skladištenju podataka (DW)	2	
	Upoznavanje s tehnologijama i okruženjem DW-a	2	
	Arhitektura DW-a. Principi skladištenja. Kocka. OLAP. Data Mart	2	
	Povijest DW-a. Karakteristike DW-a	2	
	Uvod u poslovne procese	2	
	ETL proces	2	
	Koncepti dimenzijskog modela (zvijezda vs. pahuljica)	2	
	Tablica činjenica. Primjeri	2	
	Dimenzijska tablica. Surogate Keys. Primjeri	2	
	Aktivnosti i metodologije projekata skladištenja podataka	2	
	OLAP alati i analize (CubePlayer)	2	
	Poslovna inteligencija. Rudarenje nad podatcima	2	

	Primjeri projekata skladištenja podataka	2	
	Popis laboratorijskih vježbi		Sati LV
	Odabir tehnologije i pripremanje vlastitog okruženja za rad Definiranje projektnih timova		2
	Instaliranje i konfiguriranje testnog skladišta podataka Odabir poslovnog procesa		4
	Definiranje željenih dimenzija budućeg modela – ***prezentacija***		2
	Definiranje arhitekture skladišta podataka		2
	Dizajniranje dimenzijskog modela skladišta (dimenzije i činjenice) – ***prezentacija logičkog dizajna***		4
	Fizički dizajn modela skladišta		2
	Fizička izvedba skladišta podataka (testni podatci)		4
	Izvedba OLAP sustava		4
	Analize podataka – ***prezentacija***		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	Nazočnost na predavanjima (i vježbama) u iznosu od najmanje 70% (i 100%) predviđene satnice. Obavljene sve predviđene laboratorijske vježbe i izrađen dogovoreni projektni zadatak.	

Praćenje rada studenata *(upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti predmeta):*	Pohađanje nastave	1	Istraživanje	0,8	Praktični rad	1
	Eksperimentalni rad		Referat		Samostalni rad	1
	Esej		Seminarski rad		Laboratorijske vježbe	0,2
	Kolokviji		Usmeni ispit	0,5	Pripreme za laboratorijske vježbe	
	Pisani ispit		Projekt	0,5	(Ostalo upisati)	

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Tijekom semestra nema međuispita (kolokvija) nego studenti tijekom cijelog semestra rade na praktičnom zadatku – ***izradi vlastitog skladišta podataka***. Rad se odvija u malim projektnim timovima, uz mentorstvo profesora, pisane upute i testna skladišta podataka. Tijekom semestra timovi nekoliko puta prezentiraju svoj rad u okviru grupe (koncept, model, izvedbu). Konačna se ocjena utvrđuje na završnom ispitu primjenjujući apsolutni ECTS sustav ocjenjivanja u skladu s Pravilnikom o studijima i sustavu studiranja Sveučilišta u Splitu. Na završnom ispitu (ili već na predroku, u terminu 2. kolokvija) studenti polažu cjelovito gradivo kolegija prezentirajući svoj projekt (prilažu i pisani projektni materijal). Završni ispit Ispit studenti polažu praktično (na svom skladištu podataka), na računalu na kojem su radili tijekom semestra i odgovarajući usmeno. Ispit se polaže pojedinačno ili u manjima grupama, projektnim timovima (ali su ocjene individualne). Završni ispit je javan i mogu mu nazočiti svi studenti s godine koji su ga položili tog dana ili ranije.

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	**Naslov**	**Broj primjeraka u knjižnici**	**Dostupnost putem ostalih medija**
	S. Čelar: Autorizirana predavanja, FESB		e-learning portal
	J. Stark: Product Lifecycle Management- 21st Century Paradigm for Product Realisation, 2nd edition, Springer, ISBN 978-0-85729-545-3, London, 2011		
	Kimball, R. i Ross, M.: The Data Warehouse Toolkit, The Definitive Guide to Dimensional Modeling, Third Edition, John Wiley & Suohns, 2013		
	S. Čelar: Autorizirane upute za laboratorijske vježbe, FESB		e-learning portal
Dopunska literatura	Kimball, R. i Ross, M.: The Data Warehouse Toolkit, The Complete Guide to Dimensional Modeling, Second Edition, Wiley Computer Publishing, 2002		
	Todman, C., Designing a Data Warehouse: Supporting Customer Relationship Management , 1st Edition, Prentice Hall PTR, ISBN: 0-13-089712-4, 2000		
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	• Vođenje evidencije o prisutnosti na nastavi • Vođenje dnevnika projekata tijekom vježbi • Godišnja analiza uspješnosti polaganja ispita • Studentska anketa s ciljem evaluacije nastavnika • Samoevaluacija nastavnika • Povratna informacija od strane studenata koji su već diplomirali o relevantnosti sadržaja predmeta		
Ostalo (prema mišljenju predlagatelja)			

NAZIV PREDMETA	**UPRAVLJANJE PROJEKTIMA**						
Kod	FETG01	Godina studija	1.				
Nositelj/i predmeta	Prof. dr. sc. Ivica Veža	Bodovna vrijednost (ECTS)	4				
Suradnici	Dr. sc. Marko Mladineo	Način izvođenja nastave (broj sati u semestru)	P	S	AV	LV	KV
			30	0	0	15	0
Status predmeta	Izborni	Postotak primjene e-učenja	0				

OPIS PREDMETA	
Ciljevi predmeta	Osposobljavanje studenata za: • naučiti studente planiranje i upravljanje projektima • znati izračunati rentabilnost projekta i vraćanje uloženih sredstava (ROI)
Uvjeti za upis predmeta i ulazne kompetencije potrebne za predmet	Nema
Očekivani ishodi učenja na razini predmeta (4-10 ishoda učenja)	Studenti će nakon uspješno savladanog predmeta moći: • Analizirati zahtjeve kupca (VOC) • Formulirati glavne ciljeve projekta i rangirati ih • Razviti glavne aktivnosti projekta i strukturu raspodjele rada – (Work Breakdown Structure) • Planirati vrijeme (odrediti kritični put) • Planirati kapacitete (odrediti uska grla i balansirati aktivnosti) • Planirati troškove i rizike • Primijeniti usvojena znanja i vještine iz sadržaja odslušanih predmeta na rješavanje konkretnog zadatka • Kombinirati i primijeniti stečena znanja i vještine u timskom radu

Sadržaj predmeta detaljno razrađen prema satnici nastave	Sadržaj	Sati P	Sati AV
	Uvod i osnovni pojmovi	2	
	Pojam i definiranje projekata, te projektnog anagementa	2	
	Projekti – vizija, strategija, ciljevi (primjeri - automobilska i brodogradilišna industrija).	2	
	Strategija i projekt management. Višeprojektni management.	2	
	Osnove organizacije. Projektna organizacijska struktura.	2	
	Faze rada na projektu (iniciranje projekata, selekcija projekta, planiranje projekta, upravljanje projektom, završetak projekta)	2	
	Metode za planiranje projekata.	2	
	Upravljanje kvalitetom (planiranje, poboljšanje i kontrola kvalitete)	2	
	Upravljanjem troškovima. Kontinuirano poboljšanje – Kaizen.	2	
	Upravljanjem rizicima.	2	
	Psihološko-socijalna komponenta upravljanja projektima. Projektni manager.	2	
	Timski rad.	2	

	Komunikacija i motivacija u timu. Metode za poticanje kreativnosti.	2	
	Popis laboratorijskih vježbi		Sati LV
	Uvod u Tehniku mrežnog planiranja		1
	Osnovni pojmovi iz tehnike mrežnog planiranja		1
	Analiza vremena		1
	CPM metoda		1
	PERT metoda		1
	PRECEDENCE metoda		1
	Analiza troškova		1
	Analiza resursa		1
	Uvod u softver Microsoft Project		1
	Uvod u upravljanje poslovnim procesima		1
	Osnove procesnih dijagrama		1
	Mapiranje procesa		1
	Usporedba različitih procesnih dijagrama		1

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	Nazočnost na predavanjima i auditornim vježbama u iznosu od najmanje 70% predviđene satnice. Obavljene sve predviđene laboratorijske vježbe.	

Praćenje rada studenata *(upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti predmeta):*	Pohađanje nastave	1,0	Istraživanje		Praktični rad	
	Eksperimentalni rad		Referat		Samostalni rad	1,0
	Esej		Seminarski rad		Laboratorijske vježbe	0,5
	Kolokviji	0	Usmeni ispit		Pripreme za laboratorijske vježbe	
	Pisani ispit		Projekt	1,5	(Ostalo upisati)	

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Tijekom semestra student se upoznaje s fazama upravljanja projektom, te paralelno s pohađanjem predavanja i laboratorijskih vježbi razvija svoj projekt. Na projektu se radi timski, minimalan broj studenata je dvoje a maksimalno troje. Tijekom nastave oni zajednički određuju sadržaj projekta, te glavne ciljeve. Nakon toga razvijaju glavne aktivnosti na projektu i strukturu raspodjele rada (WBS). Planiraju vrijeme za svaku pojedinu kativnost i određuju kritičan put. Planiraju kapacitete, te određuju uska grla i vrše balansiranje kapaciteta. Na kraju određuju troškove, izračunavaju rentabilnost projekta (ROI) i analiziraju rizike. Na kolikoviju i ispitu studenti izlažu svoje radove, koji se ocjenjuju (ocjena M). S druge strane, studenti kolokviraju područje Tehnike mrežnog planiranja (LV) kroz 1 pisani kolokvij na kraju semestra. • LV - ocjena iz laboratorijskih vježbi,

	• M - bodovi na projektu. Konačna se ocjena (u postocima) formira prema formuli: Ocjena(%) = 0,30 LV + 0,70 M		
Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	**Naslov**	**Broj primjeraka u knjižnici**	**Dostupnost putem ostalih medija**
	• Veža, I., Bilić, B., Gjeldum, N., Mladineo, M., "Upravljanje projektima", Fakultet elektrotehnike, strojarstva i brodogradnje, Split, 2011.		e-learning portal
	• Majstorović, V. Projektni menadžment, Sveučilište u Mostaru, Mostar, 2010.	5	
	• Omazić, M.A. Projektni menadžment, Sinergija, Zagreb, 2005.	5	
Dopunska literatura	• "A Guide to the Project Management Body of Knowledge, PMBOK Guide", Project Management Institute, Newtown Square, 2004. • Wysocki, R. K., McGary, R., "Effective Project Management: Traditional, Adaptive, Extreme", John Wiley & Sons, 2003,		
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	• Vođenje evidencije o prisutnosti na nastavi • Godišnja analiza uspješnosti polaganja ispita • Studentska anketa s ciljem evaluacije nastavnika • Samoevaluacija nastavnika • Povratna informacija od strane studenata koji su već diplomirali o relevantnosti sadržaja predmeta		
Ostalo (prema mišljenju predlagatelja)			

NAZIV PREDMETA	SUSTAVI BEŽIČNOG PRIJENOSA ENERGIJE						
Kod	**FELJ36**	Godina studija	2.				
Nositelj/i predmeta	Prof. dr. sc. Zoran Blažević Doc. dr. sc. Maja Škiljo	Bodovna vrijednost (ECTS)	5				
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	AV	LV	KV
			30	0	0	30	
Status predmeta	Izborni	Postotak primjene e-učenja	0				

OPIS PREDMETA		
Ciljevi predmeta	Osposobljavanje studenata za: • uvod tehničke osnove radijskih sustava za prijenos energije • projektiranje sustava za bežični prijenos energije u bliskom polju • projektiranje sustava za bežični prijenos energije u dalekom polju • proračun i analizu parametara bežični prijenos energije.	
Uvjeti za upis predmeta i ulazne kompetencije potrebne za predmet	Nema	
Očekivani ishodi učenja na razini predmeta (4-10 ishoda učenja)	Studenti će, nakon uspješno savladanog gradiva biti sposobni: • objasniti tehnike pozicioniranja putom satelita, • vršiti proračun i analizirati temeljne parametre sustava za pozicioniranje, • analizirati i projektirati radio propagaciju kod pozicioniranja putom satelita, • primijeniti standarde pri projektiranju satelitske mreže za pozicioniranje	
Sadržaj predmeta detaljno razrađen prema satnici nastave	Sadržaj	Sati P
	Uvod. Povijest radija.	2
	Tehnike i principi radio-prijenosa energije. Transformatori, rezonantni transformatori (Teslina zavojnica) i električki male antene.	4
	S-matrica antene. Model prijenosa između dviju i više antena na osnovi teorije strujih krugova (Z i Y matrice).	4
	Rektene.	2
	Prijenos energije u bliskom polju. Rezonantni transformator.	4
	Prijenos energije u dalekom polju.	4
	Koncept zemaljskih sustava za prijenos energije u dalekom polju antena.	3
	Koncepcija satelitskih sustava za bežični prijenos energije radio-valovima	3
	Standardi i norme za sustave bežičnog prijenosa energije. Qi standard	2
	Procjene utjecaja na okoliš i zdravlje	2
	Problem interferencije radijskih komunikacijskih sustava i sustava za bežični prijenos energije.	2
	Popis laboratoriskih vježbi	Sati LV
	Mjerenja i podešavanja induktivno napajanih antena za prijenos energije	8
	Mjerenja performansi prijenosa analizatorom spektra i osciloskopom..	6
	Mjerenja kvalitete prijenosa energije vektorskim mrežnim analizatorom.	8

	Mjerenja Tesline zavojnice.					8
Vrste izvođenja nastave:	x predavanja ☐ seminari i radionice ☐ vježbe ☐ *on line* u cijelosti ☐ mješovito e-učenje x terenska nastava		x samostalni zadaci ☐ multimedija x laboratorij ☐ mentorski rad ☐ (ostalo upisati)			
Obveze studenata	Student je dužan sudjelovati u radu svih oblika nastave te prisustvovati: predavanjima najmanje 70% nastavnih sati te laboratorijskim vježbama 100% nastavnih sati.					
Praćenje rada studenata *(upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti predmeta):*	Pohađanje nastave	1,5	Istraživanje		Praktični rad	
	Eksperimentalni rad		Referat		Samostalni rad	2
	Esej		Seminarski rad		Laboratorijske vježbe	0,8
	Kolokviji	0,5	Usmeni ispit		Priprema za laboratorijske vježbe	0,2
	Pismeni ispit		Projekt		(Ostalo upisati)	
Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Tijekom semestra bit će jedan kolokvij prema kalendaru nastave, dok će se ostatak gradiva položiti putom seminarskog rada. Student može putem kolokvija i seminarskog rada položiti cjelokupni ispit ukoliko postigne pozitivnu ocjenu iz kolokvija. Na dva završna ispita u veljači tekuće godine studenti polažu gradivo koje nisu položili na kolokviju, uz obvezu prezentacije seminarskog rada. Uvjet za pozitivnu ocjenu je da student ima najmanje 50 % bodova iz kolokvija ili na završnom ispitu, a konačna se ocjena (u postocima) formira na temelju svih aktivnosti prema formuli: Ocjena (%) = 0.1NPV + 0.1LV + 0.4(K + SR) , gdje su aktivnosti izražene u postocima: - NPV - nazočnost na predavanjima i auditornim vježbama (%), - LV – bodovi iz laboratorijskih vježbi (%), - K - bodovi iz kolokvija (%), - SR – bodovi iz seminarskog rada Studenti koji nisu položili ispit nakon dva završna ispita mogu ispit položiti početkom rujna tekuće godine na tzv. popravnom ispitu. Zadnja prilika za polaganje ispita u tekućoj školskoj godini je tzv. komisijski ispit koji će biti održan u drugom dijelu rujna prema kalendaru nastave. Uvjet za pozitivnu ocjenu na popravnom i komisijskom ispitu je da student ima najmanje 50 % bodova iz čitavog gradiva. Ocjena se računa prema prethodno navedenoj formuli. Konačna se ocjena utvrđuje na sljedeći način: Postotak Ocjena 50% do 59% dovoljan (2) 60% do 74% dobar (3) 75% do 89% vrlo dobar (4) 90% do 100% izvrstan (5) Ispitni rokovi: Prema kalendaru nastave					

	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	• Ki Young Kim (editor), "Wireless Power Transfer-Principles and Engineering Explorations", InTech, January 2012.		portal e-učilice WEB
	• Volakis J., C. C. Chen and K. Fujimoto, "Small antennas: miniaturization techniques and applications", New York, McGraw-Hill, 2010.		portal e-učilice WEB
	• Special issue „Solar Power Satellite and Wireless Power Transmission", IEEE Microwave Magazine, Vol. 3, No. 4, December 2002.	1	
Dopunska literatura	• Lee J. and S. Nam, "Fundamental aspects of near-field coupling small antennas for wireless power transfer", IEEE Trans. Antennas Propag., Vol. 58, No. 12, 3442-3449, 2010. • P. Sample, D. T. Meyer, J. R. Smith: Analysis, experimental results, and range adaptation of magnetsically coupled resonators for wireless power transfer, IEEE Transactions on Industrial Electronics, Vol. 58, No. 2, 2010, p.p 544-554. • N. Tesla, A. Marinčić: Colorado Springs Notes, Nolit, Beograd, 1978. • Carol Gray Montgomery, Robert Henry Dicke and Edward M. Purcell, "Principles of microwave circuits", McGraw-Hill Book Company, Inc., USA, 1948.		
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	• Vođenje evidencije o prisutnosti na nastavi • Godišnja analiza uspješnosti polaganja ispita • Studentska anketa s ciljem evaluacije nastavnika • Samoevaluacija nastavnika • Povratna informacija od strane studenata koji su već diplomirali o relevantnosti sadržaja predmeta		
Ostalo (prema mišljenju predlagatelja)			

NAZIV PREDMETA	**RAČUNSKA INTELIGENCIJA (NEURO-FUZZY-GENETSKI SUSTAVI)**						
Kod		Godina studija	1				
Nositelj/i predmeta	Prof. dr. sc. Darko Stipaničev	ECTS	5				
Suradnici	dr. sc. Marin Bugarić	Način izvođenja nastave (broj sati u semestru)	P	S	AV	LV	KV
			30	0	0	30	
Status predmeta	Izborni	Postotak primjene e-učenja	80				

OPIS PREDMETA			
Ciljevi predmeta	Cilj je kolegija naučiti studente osnovna znanja iz područja računalne inteligencije, i to prije svega iz teorije i primjene neizrazitih (fuzzy) skupova, umjetnih neuronskih mreža i genetskih algoritama.		
Uvjeti za upis predmeta i ulazne kompetencije potrebne za predmet	Nema		
Očekivani ishodi učenja na razini predmeta (4-10 ishoda učenja)	Studenti će nakon uspješno savladanog predmeta moći: 1. Razumijevanje što je to biološka inteligencija, računska inteligencija, umjetna inteligencija i distribuirana inteligencija. 2. Razumjeti i primijeniti **teoriju neizrazitih (fuzzy) skupova**. Osnovne definicije i matematičke operacije. Neizraziti skup, neizrazita relacija, kompozicije neizrazitih relacija. Neizraziti produkcijski sustavi. Lingvističko modeliranje temeljeno na neizrazitim skupovima. Primjena neizrazitih skupova u modeliranju, vođenju, predviđanju, donošenju odluka. 3. Razumjeti i primijeniti **teoriju umjetnih neuronskih mreža** (ANN): Tipovi neuronskih mreža i njihova podjela. Podešavanje težina. Aktivacijske funkcije. Perceptron. Hebbove mreže i konvolucijske mreže. Povratna propagacija i kompetitivno učenje. Primjena ANN-a u obradi signala, vođenju, prepoznavanju oblika, poslovanju. 4. Razumjeti i primijeniti **teoriju evolucijskih procese** u prirodi (genetski kod, križanje i mutacija). Razumjeti i primijeniti **genetske algoritme** kao primjer umjetnih evolucijskih procesa: Jednostavni genetski algoritmi (funkcija dobrote, postupci selekcije, genetski operatori). Prilagodljivi genetski algoritmi. Paralelni genetski algoritmi. Postupci selekcije (proporcionalne selekcije, rangirajuće selekcije, eliminacijske turnirske selekcije). Primjena genetskih algoritama.		
Sadržaj predmeta detaljno razrađen prema satnici nastave	Sadržaj	Sati P	Sati AV
	Inteligencija, računska inteligencija, umjetna inteligencija i distribuirana inteligencija.	2	0
	Uvod u **teoriju neizrazitih (fuzzy) skupova**. Osnovne definicije i matematičke operacije. Neizraziti skup, neizrazita relacija, kompozicije neizrazitih relacija. Neizraziti produkcijski sustavi. Lingvističko modeliranje temeljeno na neizrazitim skupovima. Primjena neizrazitih skupova u modeliranju, vođenju, predviđanju, donošenju odluka.	8	8
	Uvod u **umjetne neuralne mreže** (ANN). Tipovi mreža i njihova podjela. Podešavanje težina. Aktivacijske funkcije. Peerceptron. Hebbove mreže. Konvolucijske mreže. Povratna propagacija i kompetitivno učenje. Primjena ANN-a u obradi signala, vođenju, prepoznavanju oblika, poslovanju.	8	9
	Uvod u evolucijske procese u prirodi (genetski kod, križanje i mutacija). **Genetski algoritmi** kao primjer umjetnih evolucijskih	6	9

	procesa. Jednostavni genetski algoritmi (funkcija dobrote, postupci selekcije, genetski operatori). Prilagodljivi genetski algoritmi. Paralelni genetski algoritmi. Postupci selekcije (proporcionalne selekcije, rangirajuće selekcije, eliminacijske turnirske selekcije). Primjena genetskih algoritama.		
		0	0

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	Nazočnost na predavanjima u iznosu od najmanje 70% predviđene satnice. Napravljene sve laboratorijske vježbe.	

Praćenje rada studenata *(upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti predmeta):*	Pohađanje nastave	1,5	Istraživanje		Praktični rad	
	Eksperimentalni rad		Referat		Samostalni rad	
	Esej		Seminarski rad	1,5	Laboratorijske vježbe	
	Kolokviji		Usmeni ispit		Pripreme za laboratorijske vježbe	
	Pisani ispit	2	Projekt		(Ostalo upisati)	

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Ispit se sastoji od pismenog dijela i ukoliko je potrebno dodatne usmene provjere. Tijekom semestra biti će dva kolokvija. Prvi kolokvij je u 8 tjedanu nastave, drugi u 18 tjednu. Student može putem kolokvija položiti gradivo kolegija. Na dva završna ispita u lipnju i srpnju, studenti koji nisu sakupili prolazan broj bodova na kolokvijima polažu cjelokupno gradivo obuhvaćeno sa dva kolokvija. Uvjet za izlazak na završni ispit je uspješno odrađen praktični dio laboratorijskih vježbi, te predani svi izvještaji. Ispit je cjelovit te uključuje i teorijski dio gradiva i zadatke. Uvjet za pozitivnu ocjenu je da student ima ukupno najmanje 50 % bodova na ispitu ali pri tome mora imati minimalno 25% položenog teorijskog dijela gradiva i 25% položenih zadataka. Ukoliko student ima manje od 25% bodova na zadacima i/ili manje od 25% bodova iz teorijskog dijela gradiva ponovo polaže cijeli ispit. Studenti koji nisu položili ispit nakon dva završna ispita mogu ispit položiti u jesenskim rokovima. Sva ispitna pitanja studentima će biti poznata prije ispita. Ova se pravila podjednako odnose na studente koji su ovaj kolegij upisali prvi put i na one studente koji su kolegij upisali po drugi put. Konačna se ocjena utvrđuje na sljedeći način: Postotak Ocjena 50% do 61% dovoljan (2) 62% do 74% dobar (3) 75% do 87% vrlo dobar (4) 88% do 100% izvrstan (5) Na prvom kolokviju će se polagati gradivo prema nastavnim jedinicama do sedmog tjedna uključivo, a na drugom ostatak gradiva tjedna uključivo. Ispitni rokovi održavaju se u terminima predviđenim kalendarom nastave. Prema Članku 65. Statuta Fakulteta, student je dužan sudjelovati u radu svih oblika nastave te prisustvovati: predavanjima najmanje 70 % nastavnih sati. Ako ne ispuni navedene uvjete, student neće moći pristupiti ispitu i dobiti potpis, te će ispit morati

	ponovo upisati.		
Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	**Naslov**	**Broj primjeraka u knjižnici**	**Dostupnost putem ostalih medija**
	Stranice kolegija na e-learning portalu		e-learning portal
	W.Pedrycz, Fuzzy Control and Fuzzy Systems, J.Wiley & Sons Inc. New York 1989.		
	Laurene V. Fausett, Fundamentals of Neural Networks, Prentice Hall, 1994.		
	D.E.Goldberg, Genetic Algorithms in Search, Optimisation and Machine Learning, Addison-Wesley Pub. Co., Inc., Reading, Mass., 1989.		
Dopunska literatura	Computational Intelligence – the logical approach (http://www.cs.ubc.ca/spider/poole/ci.html)		
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	• Vođenje evidencije o prisutnosti na nastavi • Godišnja analiza uspješnosti polaganja ispita • Studentska anketa s ciljem evaluacije nastavnika • Samoevaluacija nastavnika • Povratna informacija od strane studenata koji su već diplomirali o relevantnosti sadržaja predmeta		
Ostalo (prema mišljenju predlagatelja)			

NAZIV PREDMETA	SIGURNOST BEŽIČNIH MREŽA						
Kod	FELK19	Godina studija	2.				
Nositelj/i predmeta	Izv. prof. dr. sc. Mario Čagalj	Bodovna vrijednost (ECTS)	5				
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	AV	LV	KV
			30	0	0	30	0
Status predmeta	Izborni	Postotak primjene e-učenja	0				

OPIS PREDMETA		
Ciljevi predmeta	Osnovni ciljevi predmeta su: • pružiti studentima uvid u osnovne značajke i aspekte zaštite bežičnih komunikacijskih kanala • predstaviti studentima dokazane mehanizme za zaštitu bežičnih komunikacijskih kanala • osposobiti studente za implementaciju odgovarajućih sigurnosnih mehanizama za zaštitu bežičnih komunikacijskih kanala	
Uvjeti za upis predmeta i ulazne kompetencije potrebne za predmet	Nema	
Očekivani ishodi učenja na razini predmeta (4-10 ishoda učenja)	Nakon uspješno savladanog predmeta, studenti će moći: • Poznavati suštinsku razliku između ranjivosti klasičnih žičanih i bežičnih kanala • Posjedovati kritičko razumijevanje dizajna, sigurnosti i upravljanja bežičnim mrežama • Analizirati standarde, protokole i arhitekture bežičnih sustava radi utvrđivanja ranjivosti • Kritički procijeniti potencijalne sigurnosne rizike određene bežične komunikacijske tehnologije i sustava • Primijeniti odgovarajuće sigurnosne alate i revizijske tehnike za zaštitu bežičnih mreža i sustava • Preporučiti i ispravno konfigurirati odgovarajuće mehanizme zašite bežičnih mreža • Planirati sigurnu implementaciju bežične mreže uzimajući u obzir moguće prijetnje	
Sadržaj predmeta detaljno razrađen prema satnici nastave	Nastavne jedinice	Sati P
	Uvod u sigurnost bežičnih komunikacijskih i navigacijskih sustava	1
	Radio komunikacijski kanal	2
	Napadi ometanjem signala (*radio jamming*)	2
	Prisluškivanje i napadi prijenosom komunikacije (*relay attacks*)	1
	Zaštita od ometanja signala: tehnike raspršenog spektra (FHSS i DSSS)	2
	Pregled osnovnih kriptografskih primitiva	2
	Sigurnost WiFi mreža (802.11 arhitekture, WEP, WPA, WPA2, 802.11i, anomalije, sebično ponašanje)	4
	1. kolokvij	2
	Sigurnost celularnih mreža (GSM and UMTS, ometanje, privatnost,	2

	man-in-the-middle napadi)	
	Ranjivost bežičnih navigacijskih sustava (GPS, Gallileo)	2
	Sigurnost bežičnih senzorskih mreža (inicijalizacija, uspostava enkripcijskih ključeva, ometanje)	4
	User-friendly autentifikacija poruka preko radio kanala (I-*codes* i uparivanje uređaja)	2
	Lokacijska privatnost u mobilnim mrežama	2
	2. kolokvij	2
	Laboratorijske vježbe	Sati LV
	Ranjivost radio kanala (DoS ometanjem signala, MitM putem ARP *spoofing* napada, prisluškivanje i analiza podataka)	6
	Osnovni kriptografski primitivi (Cryptool2)	4
	Sigurnost WiFi mreža (probijanje WEP i WPA/WPA2, lažne AP, SSL *stripping* napad, propusti u konfiguraciji EAP-TTLS autentifikacijske metode)	10
	Anomalija u performansama kod IEEE 802.11 norme	2
	Sigurnost bežičnih senzorskih mreža (Xbee i Arduino platforme)	4
	Lokacijska privatnost u celularnim mrežama	4

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	Prisustvo na predavanjima – najmanje 70% predviđene satnice. Izvršene sve laboratorijske vježbe.	

Praćenje rada studenata *(upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti predmeta):*	Pohađanje nastave	0.7	Istraživanje		Praktični rad	
	Eksperimentalni rad		Referat		Samostalan rad	2
	Esej		Seminarski rad		Laboratorijske vježbe	2
	Kolokviji	0.2	Usmeni ispit		(Ostalo upisati)	
	Pismeni ispit	0.1	Projekt		(Ostalo upisati)	

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Tijekom semestra održat će se dva kolokvija (nakon 7. odnosno 13. tjedna neposredne nastave). U okviru kolegija organizirat će se praktične (*hands-on*) laboratorijske vježbe. Student je dužan prisustvovati svim vježbama te izraditi i predati odgovarajuća izvješća (predana izvješća s laboratorijskih vježbi su preduvjet za upis ocjene). Ocjenjivanje: P - Prisustvo na predavanjima i rad u laboratoriju LV - Izvješća s laboratorijskih vježbi K1 - 1. kolokvij K2 - 2. kolokvij (cijelo gradivo) Ocjena = zaokruži [0.05 P + 0.15 LV + 0.30 K1 + 0.50 K2] (NAPOMENA: Ukoliko student ne zadovolji pojedinu aktivnost, ista se postavlja na 0 pri izračunu konačne ocjene.)

Obvezna literatura	**Naslov**	**Broj**	**Dostupnost**

(dostupna u knjižnici i putem ostalih medija)		**primjeraka u knjižnici**	**putem ostalih medija**
	Prezentacije s predavanja		e-learning portal
	Buttyan L., Hubaux J.-P.: Security and Cooperation in Wireless Networks: Thwarting Malicious and Selfish Behavior in the Age of Ubiquitous Computing, Cambridge University Press, 2007.		dostupna online
Dopunska literatura	• Stallings W.: Cryptography and Network Security, Principles and Practice, Prentice Hall, 2005. • Menezes J., van Oorschot P. C., Vanstone S. A.: Handbook of AppliedCryptography, CRC Press, 1996.		
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	• Mišljenja studenata o kvaliteti nastave putem anketa • Samoevaluacija nastavnika • Redovito usklađivanje sadržaja predavanja sa sličnim kolegijima na prestižnim svjetskim institucijama		
Ostalo (prema mišljenju predlagatelja)			

NAZIV PREDMETA	PARALELNO PROGRAMIRANJE							
Kod	FELK35	Godina studija	2.					
Nositelj/i predmeta	Izv. prof. dr. sc. Tamara Grujić	Bodovna vrijednost (ECTS)	5					
Suradnici	Dr. sc. Ana Kuzmanić Skelin	Način izvođenja nastave (broj sati u semestru)	P	S	AV	LV	KV
			30			30	
Status predmeta	Izborni	Postotak primjene e-učenja					

OPIS PREDMETA		
Ciljevi predmeta	Osposobljavanje studenata za: • razumijevanje temeljnih načela i metodologije paralelnog programiranja paralelnih računalnih arhitektura • primjenu programskog jezika za paralelno računanje i sposobnost implementacije u razvoju aplikacija	
Uvjeti za upis predmeta i ulazne kompetencije potrebne za predmet	Nema	
Očekivani ishodi učenja na razini predmeta (4-10 ishoda učenja)	Student će nakon uspješno svladanog predmeta moći: • navesti primjere paralelnih algoritama i često korištenih programskih struktura • objasniti paralelizam algoritma i prepoznati to svojstvo kod konkretnih algoritama • implementirati jednostavnije paralelne algoritme • primijeniti stečena znanja kod implementacije paralelnih algoritama	
Sadržaj predmeta detaljno razrađen prema satnici nastave	**Sadržaj**	**Sati P**
	Uvod u paralelno programiranje. Osnovne tehnike i temeljne značajke	2
	Tipovi paralelizma	2
	Razvojna okruženja za paralelno programiranje. Ekstenzije programskih jezika za paralelno programiranje.	4
	Osnovne programske strukture, tipovi podataka, operatori i funkcije. Programi opće namjene za grafički procesor.	4
	Pisanje programa opće namjene za GPU. GPU nasuprot CPU. Obrada toka podataka. Programski koncepti. GPU tehnike.	4
	Analiza izvedbe koda. Implementacija programskog jezika za paralelno programiranje na CPU i GPU.	4
	Analiza primjera: redukcija i sortiranje, algoritmi na matricama, obrada slika, konvolucija, obrada videa, histogrami	4
	Implementiranje vlastitih algoritama.	2
	Popis laboratorijskih vježbi:	**Sati LV**
	Primjeri Open Multiprocessing (OpenMP)	4
	MPI model. Primjeri MPI programa.	6
	GPU programiranje sa NVIDIA CUDA programskom ekstenzijom u Cu.	6
	Realizacija projektnih zadataka	14
Vrste izvođenja	☐ predavanja	☒ samostalni zadaci

nastave:	☐ seminari i radionice ☒ vježbe ☐ *on line* u cijelosti ☐ mješovito e-učenje ☐ terenska nastava	☒ multimedija ☒ laboratorij ☒ mentorski rad ☐ (ostalo upisati)
Obveze studenata	Prisutnost na predavanjima iznosu od najmanje 70% predviđene satnice, te prisutnost na laboratorijskim vježbama 100% predviđene satnice. Obavljene sve predviđene laboratorijske vježbe. Izrada i izlaganje projektnih zadataka.	

Praćenje rada studenata *(upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti predmeta):*	Pohađanje nastave	1	Istraživanje		Praktični rad	
	Eksperimentalni rad		Referat		Laboratorijske vježbe	2
	Esej		Seminarski rad	1.5	(Ostalo upisati)	
	Kolokviji	0.25	Usmeni ispit		(Ostalo upisati)	
	Pismeni ispit	0.25	Projekt		(Ostalo upisati)	

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu

Tijekom semestra biti će održana dva međuispita (kolokvija). Prvi međuispit je nakon 7 tjedana, a drugi međuispit po završetku nastave. Na završnom ispitu studenti polažu dijelove gradiva koje nisu položili na međuispitima. Prvi međuispit se i završni ispit provodi kao pisani ispit u trajanju od 90 minuta.

Uvjet za polaganje ispita je 50% bodova od ukupnog broja bodova. Uvjet za pozitivnu ocjenu je pozitivna ocjena iz laboratorijskih vježbi, te srednja vrijednost dva međuispita ((M1 + M2)/2) od najmanje 50%. Pri tome student na svakom od međuispita mora imati najmanje 45%.

Konačna ocjena formira se prema formuli:
Ocjena(%)= 0,4M1 + 0,4M2 + 0,2L
M1, M2 - bodovi na međuispitima, izraženo u postocima
L - bodovi iz laboratorijskih vježbi i projektnih zadataka, izraženo u postocima

Konačna se ocjena utvrđuje na sljedeći način:

Postotak	Ocjena
50% do 61,9%	dovoljan (2)
62% do 74,9%	dobar (3)
75% do 89,9%	vrlo dobar (4)
90% do 100%	izvrstan (5)

Prema Članku 65. Statuta Fakulteta, student je dužan sudjelovati u radu svih oblika nastave te prisustvovati: predavanjima najmanje 70 % nastavnih sati, laboratorijskim vježbama 100% nastavnih sati. Ukoliko ne ispuni navedene uvjete, student mora kolegij ponovo upisati.

	Naslov	**Broj primjeraka u knjižnici**	**Dostupnost putem ostalih medija**
Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	A. Grama, G. Karypis, V. Kumar, A. Gupta: Introduction to Parallel Computing, 2nd Edition. Addison-Wesley, 2003.		predmetni nastavnik/Internet
	David B. Kirk and Wen-mei W. Hwu: Programming Massively Parallel Processors: A Hands-on Approach. Morgan Kaufmann, 2nd Edition, Elsevier, 2012.		predmetni nastavnik/Internet
Dopunska literatura	• J. Sanders, E. Kandrot: CUDA by example. Addison-Wesley, 2011.		

Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	• vođenje evidencije o prisutnosti na nastavi • godišnja analiza uspješnosti polaganja ispita • studentska anketa s ciljem evaluacije kvalitete nastavnika i kolegija • samoevulacija nastavnika • povratna informacija od strane studenata koji su već diplomirali (ili su na višim godinama studija) o relevantnosti sadržaja kolegija
Ostalo (prema mišljenju predlagatelja)	

NAZIV PREDMETA	**VOĐENJE PROCESA**						
Kod	FELG21	Godina studija	2				
Nositelj/i predmeta	Prof.dr.Darko Stipaničev	Bodovna vrijednost (ECTS)	6				
Suradnici	Prof. dr. sc. Jadranka Marasović	Način izvođenja nastave (broj sati u semestru)	P	S	AV	LV	KV
			45	0	30	0	
Status predmeta	Izborni	Postotak primjene e-učenja	80				

OPIS PREDMETA

Ciljevi predmeta	Usvajanje osnovnih znanja o postupcima matematičkog modeliranja procesa i načina njihove analiza, kao i usvajanje znanja o osnovnim postupcima vođenja procesa.
Uvjeti za upis predmeta i ulazne kompetencije potrebne za predmet	Nema
Očekivani ishodi učenja na razini predmeta (4-10 ishoda učenja)	Studenti će nakon uspješno savladanog predmeta moći: 1. Razumjeti i opisati procese kroz sustavni prikaz, zamisao vođenja, značaj matematičkog modela i principe automatskog vođenja. 2. Nabrojiti i opisati temeljne procese i njihove modele: procese prijenosa, procese prijelaza, procese pretvorbe. 3. Razumjeti postupke izvođenja modele procesa na temelju jednadžbe ravnoteže materije i energije. 4. Primijeniti znanje o modeliranju procesa na fluidičke procese, toplinske procese, procese miješanja, te složenih procesi (procese destilacije, jednostavnije procese u kemijskom reaktoru). 5. Razumjeti načine djelovanja procesnih mjernih osjetila, pretvornika i izvršnih sprave za mjerenje i upravljanje temperaturom, protjecanjem, tlakom, razinom i gustoćom. 6. Razumjeti i primijeniti različite načine vođenje procesa, od osnovnih sheme vođenja (ON-OFF, P, PI, PD, PID vođenje, programsko vođenje), do naprednih sheme vođenja (vremenski - optimalno, omjerno, kaskadno, unaprijedno, optimalno, adaptivno i inteligentno vođenje). 7. Razumjeti ideje distribuiranog vođenja procesa i značaj SCADA (Scan, Control, Alarm Data Acquisitions) platformi. 8. Primijeniti znanje o modeliranju i vođenju procesa na osnovne postupke vođenja temeljnih procesnih varijabli (protok, tlak, razina i temperatura). 9. Razumjeti osnovne pojmove vezane uz procesnu industriju: optimiranje proizvodnje, nadzor i održavanje.

	Sadržaj	Sati P	Sati AV
Sadržaj predmeta detaljno razrađen prema satnici nastave	Uvod. Procesi i objekti. Sustavni pristup vođenju procesa. Povratno vođenje (regulacija), unaprijedno vođenje i upravljanje. Ulazno – izlazne veličine.	3	0
	Procesi i procesni uređaji. Operacije i tehnološke operacije. Podjela tehnoloških operacija: Operacije prijenosa, prijelaza i pretvorbe.	3	0
	Fluidički sustavi – osnovni zakoni mehanike fluida, osnovne fluidičke komponente, modeliranje fluidičkih sustava. Toplinski sustavi – osnovni zakoni termodinamike, osnovne toplinske komponente, modeliranje toplinskih sustava. Složeniji procesi i procesni uređaji – miješanje, destilacija, jednostavniji procesi u kemijskom reaktoru.	9	12

	Mjerna osjetila (senzori) i izvršne sprave (aktuatori) – ulazne, izlazne i prijenosne značajke. Mjerenje temperature, protoka, razine, tlaka i ostalih procesnih veličina. Izvršne sprave (aktuatori) – ventili, pumpe, grijači i ventilatori	9	2
	Osnovne sheme vođenja procesa: četverodjelni statički dijagrami, on-off i P vođenje.	3	4
	Osnovne sheme vođenja: PD, PI i PID vođenje	3	4
	Napredne sheme vođenja: izborno vođenje, omjerno vođenje, unaprijedno vođenje	3	2
	Složene sheme vođenja: Optimalno vođenje, adaptivno vođenje, inteligentno vođenje.	3	2
	Procesna industrija i automatsko vođenje, primjeri.	3	0

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	Nazočnost na predavanjima i vježbana u iznosu od najmanje 70% predviđene satnice.	

Praćenje rada studenata *(upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti predmeta):*	Pohađanje nastave	2,5	Istraživanje		Praktični rad	
	Eksperimentalni rad		Referat		Samostalni rad	
	Esej		Seminarski rad	1,5	Laboratorijske vježbe	
	Kolokviji		Usmeni ispit		Pripreme za laboratorijske vježbe	
	Pisani ispit	2	Projekt		(Ostalo upisati)	

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Ispit se sastoji od pismenog dijela i ukoliko je potrebno dodatne usmene provjere. Tijekom semestra biti će dva kolokvija. Prvi kolokvij je u 8 tjedanu nastave, drugi u 18 tjednu. Student može putem kolokvija položiti gradivo kolegija. Na dva završna ispita u lipnju i srpnju, studenti koji nisu sakupili prolazan broj bodova na kolokvijima polažu cjelokupno gradivo obuhvaćeno sa dva kolokvija. Uvjet za izlazak na završni ispit je uspješno odrađen praktični dio laboratorijskih vježbi, te predani svi izvještaji. Ispit je cjelovit te uključuje i teorijski dio gradiva i zadatke s auditornih vježbi. Uvjet za pozitivnu ocjenu je da student ima ukupno najmanje 50 % bodova na ispitu ali pri tome mora imati minimalno 25% položenog teorijskog dijela gradiva i 25% položenih zadataka. Ukoliko student ima manje od 25% bodova na zadacima i/ili manje od 25% bodova iz teorijskog dijela gradiva ponovo polaže cijeli ispit. Studenti koji nisu položili ispit nakon dva završna ispita mogu ispit položiti u jesenskim rokovima. Sva ispitna pitanja studentima će biti poznata prije ispita. Ova se pravila podjednako odnose na studente koji su ovaj kolegij upisali prvi put i na one studente koji su kolegij upisali po drugi put. Konačna se ocjena utvrđuje na sljedeći način: Postotak Ocjena 50% do 61% dovoljan (2) 62% do 74% dobar (3) 75% do 87% vrlo dobar (4) 88% do 100% izvrstan (5)

	Na prvom kolokviju će se polagati gradivo prema nastavnim jedinicama do sedmog tjedna uključivo, a na drugom ostatak gradiva tjedna uključivo. Ispitni rokovi održavaju se u terminima predviđenim kalendarom nastave. Prema Članku 65. Statuta Fakulteta, student je dužan sudjelovati u radu svih oblika nastave te prisustvovati: predavanjima najmanje 70 % nastavnih sati. Ako ne ispuni navedene uvjete, student neće moći pristupiti ispitu i dobiti potpis, te će ispit morati ponovo upisati.		
Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	**Naslov**	**Broj primjeraka u knjižnici**	**Dostupnost putem ostalih medija**
	D.Stipaničev, Uvod u modeliranje i vođenje procesa, radni udžbenik u digitalnom formatu, FESB, 2021.		e-learning portal
	D.Stipaničev, J.Marasović, Digitalno vođenje on-line, on-line (Web) udžbenik, MZT – Informatički projekt, 2004. http://laris.fesb.hr/digitalno_vodjenje		e-learning portal
Dopunska literatura	- Marlin, T.E.: Process Control, McGraw Hill, New York, 1995. - Patranabis, D.: Principles of Process Control, McGraw Hill, New Delchi, 1981. - Process Control Education Web Site - http://www.pc-education.mcmaster.ca/default.htm - Process Control Tutorial - http://www.pc-education.mcmaster.ca/Lecture_Slides/Lecture_SLides_Contents.htm		
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	• Vođenje evidencije o prisutnosti na nastavi • Godišnja analiza uspješnosti polaganja ispita • Studentska anketa s ciljem evaluacije nastavnika • Samoevaluacija nastavnika • Povratna informacija od strane studenata koji su već diplomirali o relevantnosti sadržaja predmeta		
Ostalo (prema mišljenju predlagatelja)			