

OPĆE INFORMACIJE		
Naziv kolegija	Simboličko programiranje	
Studijski program	Sveučilišni PRIJEDIPLOMSKI STUDIJ FIZIKA	
Status kolegija	Izborni	
Semestar	6.	
Bodovna vrijednost i način izvođenja nastave	ECTS bodovi	3
	Broj sati (P+V+S)	15+15+0
Nositelj kolegija	doc. dr. sc. Arash Ranjbar	
Kontakt	aranjbar@phy.uniri.hr	
Vrijeme i mjesto konzultacija	Po dogovoru	
Suradnik na kolegiju	/	
Kontakt	/	
Vrijeme i mjesto konzultacija	/	
Jezik izvođenje nastave	Engleski	
Web stranica kolegija	Portal sustava Merlin (srce.hr)	
Vrijeme i mjesto izvođenja nastave	Prema rasporedu sati objavljenom na mrežnoj stranici Fakulteta za fiziku.	
Izravna (učionička) nastava	15P+15V+0S, 100 %	
Virtualna nastava	0%	
Ispitni rokovi	29.06.2027.	
	14.07.2027.	
	03.09.2027.	

OPIS KOLEGIJA
1.1. Ciljevi kolegija
Cilj predmeta je upoznati studente s osnovama rada programskih paketa za simboličko programiranje (različite Python biblioteke ili slično) te ih uputiti kako da primijenjuju simboličko programiranje kod rješavanja problema vezanih za matematičku analizu i linearnu algebru. Na taj će način studenti dobiti osnovna znanja o korištenju programskih paketa za simboličko programiranje u svrhu analitičkih i numeričkih izračuna u fizici. Studenti će se upoznati s osnovnim operacijama s brojevima, matematičkim izrazima i funkcijama. Naučit će kako koristiti Python za računanje s brojevima i ugrađenim funkcijama, crtanje grafova, rješavanje jednadžbi i sustava jednadžbi, računanje s matricama i vektorima, određivanje limesa, diferenciranje, integriranje, razvoj funkcija u redove, računanje diferencijalnih jednadžbi i sustava diferencijalnih jednadžbi.
1.2. Uvjeti za upis kolegija
Kolegij pretpostavlja osnovno znanje iz informatike na srednjoškolskoj razini i korištenje operativnog sustava Microsoft Windows ili nekih distribucija Linuxa. Preporuča se da studenti polože ispite iz kolegija prve godine Matematička analiza I, II i Linearna algebra I, II prije pohađanja ovog kolegija.

1.3. Očekivani ishodi učenja za kolegij		
1. Koristiti određeni programski paket za simboličko programiranje kod jednostavnih simboličkih i numeričkih izračunavanja 2. Crtati grafove funkcija u 2D i 3D te pri tom mijenjati opcije (na primjer, crtati grafove u bojama,...). 3. Računati derivacije i neodređene integrale nekih funkcija simbolički. 4. Numerički izračunati određeni integral složenije funkcije. 5. Provoditi različite računske operacije s matricama (produkt matrica, izračun svojstvenih vrijednosti i vektora,...). 6. Riješiti sustav linearnih i nelinearnih jednadžbi, po potrebi numerički. 7. Koristiti liste i tablice za jednostavne primjene.		
1.4. Sadržaj kolegija		
Osnovne operacije s brojevima, matematičkim izrazima i funkcijama: računanje s brojevima i ugrađenim funkcijama, crtanje grafova, rješavanje jednadžbi. Uvod u liste i tablice: liste i operacije nad listama. Matrice i vektori: uvod u računanje s matricama i vektorima, sustavi linearnih jednadžbi, svojstvene vrijednosti i svojstveni vektori. Matematička analiza: limesi i kontinuitet, derivacije, integracije, redovi. Diferencijalne jednadžbe: diferencijalne jednadžbe prvog i drugog reda, sustavi diferencijalnih jednadžbi.		
1.5. Obvezna literatura		
1. Ayars E., Wilde M., Nakroshis P. A. (2013): Computational Physics with Python 2. Pine D. (2013): Introduction to Python for Science		
1.6. Dopunska literatura		
1.7. Obveze studenata, ocjenjivanje i vrednovanje rada studenata tijekom nastave i na završnom ispitu		
Sustav ocjenjivanja		
Aktivnost koja se ocjenjuje	Udio aktivnosti u ECTS bodovima	Maksimalan broj bodova
Pohađanje nastave	1,0	/
Kontinuirana provjera znanja	0,2	50
Aktivnost	0,8	20
Završni rad/ispit	1	30
UKUPNO	3	100
Opisi aktivnosti koje se ocjenjuju		
Aktivnost (maksimalno 10 bodova) Kolegij je osmišljen interaktivno i zahtijeva aktivno sudjelovanje studenata tijekom nastave (10 bodova).		
Kontinuirana provjera znanja (maksimalno 30 bodova) U nastavi će biti rutinske domaće zadaće i vježbe (30 bodova).		
Seminar (maksimalno 30 bodova) Za seminar će biti projekt u kojem se studenti vode da napišu program za rješavanje određenog problema (30 bodova).		
Završni ispit (maksimalno 30 bodova)		

Uvjet za izlazak na završni ispit je minimalno 20 bodova ostvarenih (od mogućih 30) na seminaru i minimalno 35 bodova ostvarenih (od mogućih 70) tijekom nastave.

Konačna ocjena određuje se zbrajanjem bodova prikupljenih na svim elementima koji su se procjenjivali i donosi se prema sljedećim kriterijima:

90 – 100 bodova	A	Izvrstan (5)
75 – 89,9 bodova	B	Vrlo dobar (4)
60 – 74,9 bodova	C	Dobar (3)
50 – 59,9 bodova	D	Dovoljan (2)

1.8. Dodatne informacije

POPIS TEMA PO TJEDNIMA NASTAVE			
Tjedan	Oblik nastave*	Sati	Tema
1.	P1	1	Uvodno predavanje, Instalacija Pythona, Jupyter sučelje. Osnovne operacije.
1.	V1	1	Vježba.
2.	P2	1	Liste i drugi spremnici.
2.	V2	1	Vježba.
3.	P3	1	Kontrola toka izvršavanja.
3.	V3	1	Vježba.
4.	P4	1	Crtanje krivulja i ploha.
4.	V4	1	Vježba.
5.	P5	1	Simbolički izrazi, Jednadžbe, Limesi, derivacije i integrali.
5.	V5	1	Vježba.
6.	P6	1	Matrice i vektori, Diferencijalne jednadžbe.
6.	V6	1	Vježba.
7.	P7	1	Funkcije, Prilagodba funkcije podacima.
7.	V7	1	Vježba.
8.	P8	1	Statistika.
8.	V8	1	Vježba.
9.	P9	1	Uvod u programiranje.
9.	V9	1	Vježba.
10.	P10	1	Uvod u Mathematicu, Rješavanje algebarskih jednadžbi, određeni i neodređeni integral, Numeričke procjene.
10.	V10	1	Vježba.
11.	P11	1	2D i 3D crtanje, Sustav običnih diferencijalnih jednadžbi, Parcijalne diferencijalne jednadžbe.
11.	V11	1	Vježba.

12.	P12	1	Proračuni linearne algebre, problem svojstvene vrijednosti, problem rubne vrijednosti.
12.	V12	1	Vježba.
13.	P13	1	Uvod u pakete za diferencijalnu geometriju i teoriju grupa.
13.	V13	1	Vježba.
14.	P14	1	Uvod u Cadabru, Instalacija, Osnovna funkcionalnost.
14.	V14	1	Vježba.
15.	P15	1	Kompletan primjer osnovnih i naprednih operacija u Cadabri.
15.	V15	1	Vježba.

*Napomena: navesti ukoliko se određeni sat/tema izvodi online

KONSTRUKTIVNO POVEZIVANJE			
ISHODI UČENJA	SADRŽAJ	AKTIVNOSTI ZA NASTAVNIKE I STUDENTE (metode poučavanja i učenja)	METODE VREDNOVANJA
I1. Koristiti određeni programski paket za simboličko programiranje kod jednostavnih simboličkih i numeričkih izračunavanja. Koristiti liste i tablice za jednostavne primjene.	Učeći funkcionalno programiranje na jeziku Python.	Izlaganje Rasprava Zadaci	Aktivnosti tijekom nastave Uspješnost u izvođenju zadataka na satu Uspješnost u domaćim zadaćama Sposobnost pisanja jednostavnog Python koda za izvođenje željenih izračuna
I2. Crtati grafove funkcija u 2D i 3D te pri tom mijenjati opcije (na primjer, crtati grafove u bojama,...). Računati derivacije i neodređene integrale nekih funkcija simbolički. Numerički izračunati određeni integral složenije funkcije. Provoditi različite računske operacije s matricama (produkt matrica, izračun svojstvenih vrijednosti i vektora,...). Riješiti sustav linearnih i nelinearnih jednadžbi, po potrebi numerički.	Naučiti koristiti mnogo različitih Python biblioteka za izvođenje različitih zadataka i operacija.	Izlaganje Rasprava Zadaci	Aktivnosti tijekom nastave Uspješnost u izvođenju zadataka na satu Uspješnost u domaćim zadaćama Sposobnost pisanja jednostavnog Python koda za izvođenje željenih izračuna
I3. Sposobnost korištenja Mathematice i njezinih paketa za osnovne i napredne izračune u fizici.	Naučiti koristiti Mathematicu i upoznati se s njezinim paketima.	Izlaganje Rasprava Zadaci	Aktivnosti tijekom nastave Uspješnost u izvođenju zadataka na satu Uspješnost u domaćim zadaćama

			Sposobnost pisanja jednostavnog Python koda za izvođenje željenih izračuna
I4. Sposobnost korištenja simboličkih analitičkih izračuna.	Korištenje Cadabre za izvođenje simboličkog izračuna, poput varijacijskog principa.	Izlaganje Rasprava Zadaci	Aktivnosti tijekom nastave Uspješnost u izvođenju zadataka na satu Uspješnost u domaćim zadaćama Sposobnost pisanja jednostavnog Python koda za izvođenje željenih izračuna