

OPĆE INFORMACIJE		
Naziv kolegija	Računalna fizika	
Studijski program	Sveučilišni prijediplomski studij Fizika	
Status kolegija	izborni	
Semestar	5.	
Bodovna vrijednost i način izvođenja nastave	ECTS bodovi	5
	Broj sati (P+V+S)	30+15+15
Nositelj kolegija	Prof. dr. sc. Dijana Dominis Prester	
Kontakt	dijana@phy.uniri.hr	
Vrijeme i mjesto konzultacija	Po dogovoru, ured O-110	
Suradnik na kolegiju	Karlo Mrakovčić	
Kontakt	karlo.mrakovcic@uniri.hr	
Vrijeme i mjesto konzultacija	Po dogovoru, ured O-S10	
Jezik izvođenja nastave	hrvatski	
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	30P+15V+15S, 100 %	
Virtualna nastava	0%	
Ispitni rokovi	2.2.2027.	
	23.2.2027.	
	7.9.2027.	

OPIS KOLEGIJA
1.1. Ciljevi kolegija
Upoznavanje s načinom rješavanja fizikalnih zadataka i složenijih problema primjenom numeričkih metoda. Upoznavanje s pojmom optimizacije i postizanje operativnosti u njezinoj primjeni. Uvježbavanje vještine programiranja. Preduvjeti: kolegiji opće fizike s preddiplomskog studija. Prethodno znanje osnova programiranja je poželjan, ali ne i nužan uvjet za upis kolegija. Kolegij je fokusiran na praktičnu primjenu programiranja u programskom jeziku FORTRAN u rješavanju problema u fizici. Studenti će steći vještinu programiranja pogodnu za primjenu na vrlo širokom spektru problema.
1.2. Uvjeti za upis kolegija
Odslušani kolegiji: Fizika I, Fizika II, Fizika III, Fizika IV, Moderna fizika 1.
1.3. Očekivani ishodi učenja za kolegij

1. Opisati i objasniti numeričke metode u fizici i matematici.
2. Izraditi jednostavne računalne programe koji koriste simulacije.
3. Primijeniti postojeće računalne pakete za simulacije, animaciju i vizualizaciju.
4. Definirati i objasniti optimizaciju.
5. Razlikovati postojeće metode optimizacije te njihove prednosti i nedostatke.
6. Opisati i objasniti genetičke algoritme.
7. Izraditi računalni program koji optimizira nelinerani problem koristeći odabranu metodu optimizacije.

1.4. Sadržaj kolegija

Osnove programskog jezika FORTRAN. Numeričke metode u fizici i matematici. Monte Carlo simulacija. Animacija i vizualizacija u računalnim simulacijama. Metode optimizacije rješenja skupa parametara fizikalnog sustava. Simplex algoritam. Neuralne mreže. Genetički algoritmi. Simulacije u fizici visokih energija i astrofizici. Računalna analiza simuliranih i mjerenih fizikalnih podataka.

1.5. Obvezna literatura

H. Gould and J. Tobochnik (2016): An Introduction to Computer Simulation Methods

M. Metcalf (1995): Fortran 90 Tutorial

1.6. Dopunska literatura

1. W. H. Press, B. P. Flannery, S. A. Teukolsky, W. T. Vetterling, *Numerical Recipes*, Cambridge University Press
2. D. Frenkel, B. Smit, *Understanding Molecular Simulation (from algorithms to applications)*, Academic Press
3. M. P. Allen, D. J. Tildesley, *Computer Simulation of Liquids*, Clarendon Press, Oxford

4. D. C. Rapaport, *The Art of Molecular Dynamics Simulation*, Cambridge University Press

5. S. E. Koonin, *Computational Physics*, Benjamin Cummings

6. W. Heermann, *Computer Simulation Methods in Theoretical Physics*, Springer-Verlag, Berlin

1.7. Obveze studenata, ocjenjivanje i vrednovanje rada studenata tijekom nastave i na završnom ispitu

Obveze studenta:

Pohađanje nastave, izrada domaćih zadaća, izrada računalnih programa, izrada i usmena prezentacija projektnog rada.

Sustav ocjenjivanja:

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)

0 – 49.9 bodova E Nedovoljan (1)

Aktivnost koja se ocjenjuje	Udio aktivnosti u ECTS bodovima	Maximalan broj bodova
Kontinuirana provjera znanja	0.8	20
Domaće zadaće	1,2	35
Aktivnost	2	15

Završni ispit	1	30
1.8. Dodatne informacije		
Sve nastavne materijale, obavijesti, detaljne informacije, teme i rokove seminara, studenti mogu naći na Merlin e-stranici kolegija.		

POPIS TEMA PO TJEDNIMA NASTAVE			
Tjedan	Oblik nastave*	Sati	Tema
1.	P1	2	Uvod u Linux, rad u komandnoj liniji, rad sa serverima I prijenos podataka
1.	V1	2	Uvod u Linux, rad u komandnoj liniji, rad sa serverima I prijenos podataka
2.	P2	4	Uvod u FORTRAN
3.	P3	2	Vrste podataka
3.	V3	2	Vrste podataka
4.	P4	2	Kontrola toka izvršavanja programa
4.	V4	2	Kontrola toka izvršavanja programa
5.	P5	2	Funkcije
5.	V5	2	Funkcije
6.	P6	2	Potprogrami
6.	V6	2	Potprogrami
7.	P7	2	Složene vrste podataka
7.	V7	2	Složene vrste podataka
8.	P8	4	Formati podataka
9.	S9	4	Kolokvij
10.	P10, S10	2	Rad s datotekama u FORTRAN-u
10.	V10	2	Rad s datotekama u FORTRAN-u
11.	P11, V11	2	Grafički prikaz podataka
11.	P12	2	Napredne funkcije u FORTRAN-u
12.	V12	4	Napredne funkcije u FORTRAN-u
13.	P13, S13	4	Genetički algoritmi
14.	V14	4	Optimizacija genetičkim algoritmom PIKAIA
15.	S15	4	Prezentacija projektnog zadatka

KONSTRUKTIVNO POVEZIVANJE			
ISHODI UČENJA	SADRŽAJ	AKTIVNOSTI ZA NASTAVNIKE I STUDENTE (metode poučavanja i učenja)	METODE VREDNOVANJA
1. Opisati i objasniti numeričke metode u fizici i matematici.	Numeričke metode (Eulerova metoda, Runge-Kutta metode).	Predavanja, diskusije, rješavanje zadataka.	Analiza pisanih provjera znanja i vještina (kolokvij), opažanje izvedbe studenta

			tijekom rješavanja zadataka na vježbama.
2. Izraditi jednostavne računalne programe koji koriste simulacije.	Programiranje u Fortranu, simulacija gibanja čestica.	Vježbe, samostalni rad, rješavanje problemskih zadataka.	Analiza pisanih provjera (kolokvij), analiza studentskih izvješća (projektni zadatak).
3. Primijeniti postojeće računalne pakete za simulacije, animaciju i vizualizaciju.	Animacija i vizualizacija simulacija korištenjem Gnuplota.	Vježbe, rješavanje problemskih zadataka.	Analiza studentskih izvješća (projektni zadatak), opažanje izvedbe studenta tijekom praktičnih vježbi.
4. Definirati i objasniti optimizaciju.	Osnove optimizacije, Simplex algoritam.	Predavanja, diskusija.	Analiza studentskih izvješća (projektni zadatak), usmena i pisana provjera znanja (završni ispit).
5. Razlikovati postojeće metode optimizacije te njihove prednosti i nedostatke.	Simplex algoritam, genetički algoritmi.	Predavanja, diskusija, samostalni rad.	Analiza studentskih izvješća (projektni zadatak), usmena i pisana provjera znanja (završni ispit).
6. Opisati i objasniti genetičke algoritme.	Genetički algoritmi u optimizaciji.	Predavanja, diskusija, samostalni rad.	Analiza studentskih izvješća (projektni zadatak), opažanje izvedbe studenta tijekom rada na projektu, usmena i pisana provjera znanja (završni ispit).
7. Izraditi računalni program koji optimizira nelinerani problem koristeći odabranu metodu optimizacije.	Programiranje optimizacijskih algoritama.	Vježbe, diskusija, rad na projektnom zadatku.	Analiza studentskih izvješća (projektni zadatak), usmena i pisana provjera znanja (završni ispit).