

OPĆE INFORMACIJE		
Naziv kolegija	Obrada eksperimentalnih podataka u fizici	
Studijski program	Sveučilišni prijediplomski studij Fizika	
Status kolegija	obvezni	
Semestar	2.	
Bodovna vrijednost i način izvođenja nastave	ECTS bodovi	4
	Broj sati (P+V+S)	30 + 30 + 0
Nositelj kolegija	Izv. prof. dr. sc. Robert Peter	
Kontakt	e-mail: rpeter@uniri.hr	
Vrijeme i mjesto konzultacija	Po dogovoru, ured O-113	
Suradnik na kolegiju	Klaudija Lončarić, v. pred.	
Kontakt	e-mail: klaudija.loncaric@phy.uniri.hr	
Vrijeme i mjesto konzultacija	Po dogovoru, ured O-S13	
Jezik izvođenje 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+30V+0S, 100 %	
Virtualna nastava	0 %	
Ispitni rokovi	1. 7. 2027. u 10 h	
	15. 7. 2027. u 10 h	
	14. 9. 2027. u 10 h	

OPIS KOLEGIJA
1.1. Ciljevi kolegija
Upoznati studente s osnovama statističkih metoda i njihovoj primjeni kod fizikalnih mjerenja. Posebno, studentima će biti pojašnjen račun pogrešaka kao priprema za rad u praktikumima i laboratorijima. Dodatno, elementarna teorija vjerojatnosti nužna je za shvaćanje osnovnih postavki statističke fizike i kvantne mehanike.
1.2. Uvjeti za upis kolegija
Nema preduvjeta za upis kolegija Obrada eksperimentalnih podataka u fizici. Kolegij se izvodi u 2. semestru na 1. godini pa će za veći dio matematičke razrade biti potrebna samo naprednija razina srednjoškolske matematike te osnovna znanja iz područja infinitezimalnog računa. Poželjno je da student ima osnovna srednjoškolska znanja iz vjerojatnosti i statistike.
1.3. Očekivani ishodi učenja za kolegij
Studenti će nakon položenog ispita biti u stanju:
1) Grafički prikazati podatke mjerenja i izračunati osnovne statističke parametre niza podataka.
2) Definirati teorijsku (a priori) i empirijsku (a posteriori) vjerojatnost te izreći Kolmogorovljeve aksiome vjerojatnosti.
3) Izračunati osnovne primjere iz vjerojatnosti upotrebom kombinatornih prebrojavanja, primijeniti Bayesov

teorem.

- 4) Iskazati osnovna svojstva diskretnih razdioba (Poissonova, binomna, geometrijska razdioba) i primijeniti ih u fizikalnim problemima.
- 5) Iskazati osnovna svojstva neprekinutih razdioba (normalna, eksponencijalna razdioba) i primijeniti ih u fizikalnim problemima.
- 6) Izračunati parametre raspršenosti podataka i koeficijent linearne korelacije dviju varijabli.
- 7) Iskazati centralni granični teorem i objasniti njegovo značenje.
- 8) Primijeniti metodu najmanjih kvadrata za linearnu i nelinearnu prilagodbu podataka mjerenja.
- 9) Definirati funkciju izglednosti i primijeniti kriterij najveće izglednosti u procjeni parametara.
- 10) Primijeniti statističke testove (Hi-kvadrat, Studentov t-test) za testiranje hipoteze.

1.4. Sadržaj kolegija

Uvod u analizu pogrešaka kod mjerenih podataka: pojam mjerenja i mjerne pogreške, vrste i procjena mjernih pogrešaka, zapis rezultata mjerenja, statistička obrada slučajnih pogrešaka. *Opisna statistika:* tablični i grafički opis podataka, distribucije frekvencija i histogrami, numerički opis podataka - pokazatelji smještaja i raspršenosti podataka, statistički podaci o dvodimenzionalnom obilježju (kovarijanca i korelacija). *Osnovni pojmovi teorije vjerojatnosti:* slučajni pokusi, prostor elementarnih događaja, kombinatorika, uvjetna vjerojatnost i Bayesov teorem, slučajne varijable, matematičko očekivanje i varijanca, aksiomska izgradnja teorije vjerojatnosti. *Teorijske razdiobe:* diskretne razdiobe (Binomna, Poissonova, geometrijska) i neprekinute razdiobe (Gaussova, eksponencijalna). *Analiza pogrešaka:* pojam granične razdiobe, slučajni uzorci, centralni granični teorem. *Procjena parametara:* procjena matematičkog očekivanja i varijance, funkcija izglednosti, kriterij najveće izglednosti. *Metoda najmanjih kvadrata:* linearna prilagodba, Hi-kvadrat razdioba, nelinearna prilagodba. *Statistički testovi:* testiranje hipoteze, točnost prilagodbe teorijske razdiobe empirijskim podacima; Neyman-Pearsonov test, Hi-kvadrat test, Studentov t-test.

1.5. Obvezna literatura

1. Barlow R., *Statistics - A Guide to the Use of Statistical Methods in the Physical Sciences*, John Wiley, New York, 1989.
2. Taylor, J. R., *An Introduction to Error Analysis*, 2nd ed., University Science Books, Sausalito, 1997.

1.6. Dopunska literatura

1. Bevington P. R., Robinson K. D., *Data reduction and Error Analysis for Physical Sciences*, 3rd ed., McGraw-Hill, New York, 2003.
2. Elezović N., *Vjerojatnost i statistika: diskretna vjerojatnost*, Element, Zagreb, 2007.
3. Elezović N., *Vjerojatnost i statistika: slučajne varijable*, Element, Zagreb, 2007.
4. Elezović N., *Vjerojatnost i statistika: statistika i procesi*, Element, Zagreb, 2007.
5. Spiegel M. R., *Schaum's Outline of Probability and Statistics*, 3rd ed., McGraw-Hill, New York, 2009.
6. Spiegel M. R., *Schaum's Outline of Statistics*, 4th ed., McGraw-Hill, New York, 2008.

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	2,0	/
Aktivnost u nastavi	0,2	10
Kontinuirana provjera znanja (kolokviji)	0,8	50
Završni ispit	1,0	40
UKUPNO	4	100

Opisi aktivnosti koje se ocjenjuju

Aktivnost u nastavi (maksimalno 10 bodova)

Ove bodove student može ostvariti tijekom nastave, ako se ističe u radu te ako uspješno riješi zadane zadatke.

Kontinuirana provjera znanja (maksimalno 50 bodova)

Tijekom nastave kolegija na vježbama će biti održana dva kolokvija s numeričkim zadacima (2 x 25 bodova).

Uvjet za izlazak na završni ispit je minimalno 25 ostvarenih bodova (od mogućih 50) na kolokvijima s numeričkim zadacima i minimalno 30 ostvarenih bodova (od mogućih 60) tijekom nastave.

Studenti koji skupe 29,9 ili manje ocjenskih bodova tijekom nastave ocjenjuju se ocjenom F (neuspješan), ne mogu steći ECTS bodove i moraju ponovno upisati kolegij.

Završni ispit (maksimalno 40 bodova) - sastoji se od četiri pitanja na koja ispitanik odgovara usmeno, a kvaliteta odgovora na svako pitanje ocjenjuje se s 1-10 bodova:

- 1-2 boda – zadovoljava minimalne kriterije
- 3-4 boda – zadovoljavajući, ali sa znatnim nedostacima
- 5-6 bodova – prosječan s primjetnim pogreškama
- 7-8 bodova – iznadprosječan, s ponekom pogreškom
- 9-10 bodova – izniman odgovor

Ako je završni ispit pozitivan, konačna ocjena se određuje prema Pravilniku o studijima Sveučilišta u Rijeci zbrajanjem bodova ostvarenih tijekom nastave i na završnom ispitu:

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	2	Pogreške pri mjerenju.
1.	P2	2	Račun pogreške.
2.	V1	2	Račun pogreške.
2.	P3	2	Grafičko prikazivanje rezultata mjerenja. Metoda najmanjih kvadrata.
3.	V2	2	Grafičko prikazivanje rezultata mjerenja. Metoda najmanjih kvadrata.
3.	P4	2	Opisna statistika. Kovarijanca i korelacija.
4.	V3	2	Opisna statistika.
4.	V4	2	Kovarijanca i korelacija.

5.	P5	2	Osnove kombinatorike.
5.	V5	2	Osnove kombinatorike.
6.	P6	2	Uvod u teoriju vjerojatnosti.
6.	V6	2	Uvod u teoriju vjerojatnosti.
7.	P7	2	Uvjetna vjerojatnost.
7.	V7	2	Uvjetna vjerojatnost.
8.	P8	2	Diskretne slučajne varijable.
8.	V8	2	Prvi kolokvij.
9.	V9	2	Diskretne slučajne varijable.
9.	P9	2	Binomna, Poissonova i geometrijska razdioba.
10.	V10	2	Binomna, Poissonova i geometrijska razdioba.
10.	P10	2	Neprekinute slučajne varijable.
11.	V11	2	Neprekinute slučajne varijable.
11.	P11	2	Normalna i eksponencijalna razdioba.
12.	V12	2	Normalna i eksponencijalna razdioba.
12.	P12	2	Procjena parametara razdiobe. Kriterij najveće izglednosti.
13.	V13	2	Procjena parametara razdiobe. Kriterij najveće izglednosti.
13.	P13	2	Metoda najmanjih kvadrata i hi-kvadrat razdioba.
14.	P14	2	Testiranje hipoteze i hi-kvadrat test.
14.	V14	2	Testiranje hipoteze i hi-kvadrat test.
15.	P15	2	Centralni granični teorem.
15.	V15	2	Drugi kolokvij.

*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) Grafički prikazati podatke mjerenja i izračunati osnovne statističke parametre niza podataka.	Pogreške pri mjerenju. Račun pogreške. Grafičko prikazivanje rezultata mjerenja. Metoda najmanjih kvadrata.	Izlaganje Rasprava Rješavanje numeričkih zadataka Rješavanje problemskih zadataka Samostalni rad	Analiza pisanih provjera znanja i vještina (kolokvij, aktivnost u nastavi) Usmene provjere znanja i vještina (završni ispit) Opažanje izvedbe studenta u nekoj aktivnosti (aktivnost u nastavi)
I2) Definirati teorijsku (a priori) i empirijsku (a posteriori) vjerojatnost te	Uvod u teoriju vjerojatnosti. Uvjetna vjerojatnost.	Izlaganje Rasprava	Analiza pisanih provjera znanja i vještina (kolokvij, aktivnost u nastavi)

izreči Kolmogorovljeve aksiome vjerojatnosti.		Rješavanje numeričkih zadataka Rješavanje problemskih zadataka Samostalni rad	Usmene provjere znanja i vještina (završni ispit) Opažanje izvedbe studenta u nekoj aktivnosti (aktivnost u nastavi)
13) Izračunati osnovne primjere iz vjerojatnosti upotrebom kombinatornih prebrojavanja, primijeniti Bayesov teorem.	Osnove kombinatorike. Uvod u teoriju vjerojatnosti. Uvjetna vjerojatnost.	Izlaganje Rasprava Rješavanje numeričkih zadataka Rješavanje problemskih zadataka Samostalni rad	Analiza pisanih provjera znanja i vještina (kolokvij, aktivnost u nastavi) Usmene provjere znanja i vještina (završni ispit) Opažanje izvedbe studenta u nekoj aktivnosti (aktivnost u nastavi)
14) Iskazati osnovna svojstva diskretnih razdioba (Poissonova, binomna, geometrijska razdioba) i primijeniti ih u fizikalnim problemima.	Diskretne slučajne varijable. Binomna, Poissonova i geometrijska razdioba.	Izlaganje Rasprava Rješavanje numeričkih zadataka Rješavanje problemskih zadataka Samostalni rad	Analiza pisanih provjera znanja i vještina (kolokvij, aktivnost u nastavi) Usmene provjere znanja i vještina (završni ispit) Opažanje izvedbe studenta u nekoj aktivnosti (aktivnost u nastavi)
15) Iskazati osnovna svojstva neprekinutih razdioba (normalna, eksponencijalna razdioba) i primijeniti ih u fizikalnim problemima.	Neprekinute slučajne varijable. Normalna i eksponencijalna razdioba.	Izlaganje Rasprava Rješavanje numeričkih zadataka Rješavanje problemskih zadataka Samostalni rad	Analiza pisanih provjera znanja i vještina (kolokvij, aktivnost u nastavi) Usmene provjere znanja i vještina (završni ispit) Opažanje izvedbe studenta u nekoj aktivnosti (aktivnost u nastavi)
16) Izračunati parametre raspršenosti podataka i koeficijent linearne korelacije dviju varijabli.	Opisna statistika. Kovarijanca i korelacija.	Izlaganje Rasprava Rješavanje numeričkih zadataka Rješavanje problemskih zadataka Samostalni rad	Analiza pisanih provjera znanja i vještina (kolokvij, aktivnost u nastavi) Usmene provjere znanja i vještina (završni ispit) Opažanje izvedbe studenta u nekoj aktivnosti (aktivnost u nastavi)
17) Iskazati centralni granični teorem i objasniti njegovo značenje.	Centralni granični teorem.	Izlaganje Rasprava Rješavanje numeričkih zadataka	Analiza pisanih provjera znanja i vještina (kolokvij, aktivnost u nastavi)

		Rješavanje problemskih zadataka Samostalni rad	Usmene provjere znanja i vještina (završni ispit) Opažanje izvedbe studenta u nekoj aktivnosti (aktivnost u nastavi)
18) Primijeniti metodu najmanjih kvadrata za linearnu i nelinearnu prilagodbu podataka mjerenja.	Grafičko prikazivanje rezultata mjerenja. Metoda najmanjih kvadrata i hi-kvadrat razdioba.	Izlaganje Rasprava Rješavanje numeričkih zadataka Rješavanje problemskih zadataka Samostalni rad	Analiza pisanih provjera znanja i vještina (kolokvij, aktivnost u nastavi) Usmene provjere znanja i vještina (završni ispit) Opažanje izvedbe studenta u nekoj aktivnosti (aktivnost u nastavi)
19) Definirati funkciju izglednosti i primijeniti kriterij najveće izglednosti u procjeni parametara.	Procjena parametara razdiobe. Kriterij najveće izglednosti.	Izlaganje Rasprava Rješavanje numeričkih zadataka Rješavanje problemskih zadataka Samostalni rad	Analiza pisanih provjera znanja i vještina (kolokvij, aktivnost u nastavi) Usmene provjere znanja i vještina (završni ispit) Opažanje izvedbe studenta u nekoj aktivnosti (aktivnost u nastavi)
110) Primijeniti statističke testove (Hi-kvadrat, Studentov t-test) za testiranje hipoteze.	Testiranje hipoteze i hi-kvadrat test.	Izlaganje Rasprava Rješavanje numeričkih zadataka Rješavanje problemskih zadataka Samostalni rad	Analiza pisanih provjera znanja i vještina (kolokvij, aktivnost u nastavi) Usmene provjere znanja i vještina (završni ispit) Opažanje izvedbe studenta u nekoj aktivnosti (aktivnost u nastavi)