[Medicinski fakultet u Rijeci]

Curriculum
2024/2025

[Za kolegij]

Matematičko i računalno modeliranje ekoloških sustava

Study program:	**Sanitarno inženjerstvo (R)** [Sveučilišni diplomski studij]
Department:	**[Katedra za medicinsku kemiju, biokemiju i kliničku kemiju]**
Course coordinator:	**prof. dr. sc. Broznić Dalibor, dipl. sanit. ing.**
Year of study:	**2**
ECTS:	**3**
Incentive ECTS:	**0 (0.00%)**
Foreign language:	**No**

Course information:

Kolegij **Matematičko i računalno modeliranje ekoloških sustava** je obvezni kolegij na drugoj godini (I trimestar) Diplomskog sveučilišnog studija Sanitarno inženjerstvo i sastoji se od 25 sati predavanja i 20 sati vježbi, ukupno 45 sati (3 ECTS). Kolegij se izvodi u prostorijama Medicinskog fakulteta Sveučilišta u Rijeci (predavaone i Informatička učiona).

Ciljevi i očekivani ishodi kolegija (razvijanje općih kompetencija)

Stjecanje znanja, vještina i praktičnih iskustava iz metodologije modeliranja i primjene računalnih simulacijskih sustava koje mogu imati primjenu u bilo kojem području temeljnih ili primijenjenih znanosti.

Korelativnost i korespondentnost programa

Program je osmišljen u skladu s programima Matematičkih i računalnih simulacija i modeliranja na srodnim studijima na europskim i svjetskim sveučilištima.
Nastavni sadržaji kolegija temeljeni su i usko povezani sa sadržajima i znanjem koje su studenti prethodno usvojili slušajući kolegije različitih područja Kemije, Matematike, Statistike i Informatike.

Sadržaj predmeta je sljedeći:

Predavanja:
Uvodni pojmovi o sustavu, matematičkom modeliranju i primjeni modela. Procesni prostor, ulazne i izlazne veličine, zavisne i nezavisne veličine. Računalna simulacija, upravljanje procesom, optimiranje procesa. Klasifikacija matematičkih modela. Osnovni pojmovi o kemijskom reakcijskom inženjerstvu. Brzine kemijskih reakcija: Osnovni pojmovi i veličine. Kinetika reakcija u homogenim sustavima. Osnove teorije o reakcijskom putu (Teorija sudara, Teorija prijelaznog stanja). Ovisnost brzine reakcije o temperaturi. Eksperimentalni podaci i brzina kemijske reakcije. Kinetički model. Podjela kemijskih reaktora. Bilance mase, množine tvari i topline. Matematički opis općih bilanci množine tvari. Reaktorski modeli osnovnih „idealnih“ tipova reaktora. Kotlasti reaktor, Protočni kotlasti reaktor, Cijevni reaktor. Eksperimentalne metode u kinetici. Izbor eksperimentalnog reaktora. Izbor kinetičkog modela, procjena vrijednosti parametara modela, analiza grešaka. Analiza i primjena matematičkih modela različitih kemijskih i bioloških procesa koji se odvijaju u okolišu. Razvoj matematičkog modela: postavljanje bilanci, utvrđivanje parametara modela, odabir numeričkih metoda u rješavanju modela, simulacija programskim paketom (Berkeley Madonna), prihvaćanje ili odbacivanje modela. Primjer matematičkog modela uz prostornu ovisnost veličina stanja. Primjer modela uz vremensku i prostornu ovisnost veličina stanja. Statistički kemometrijski modeli, Linearno programiranja, Modeli neuronskih mreža, neizrazite logike. Adaptacija modela genetičkim algoritmom.

Računalne vježbe:

Uvodne napomene o programskom paketu „Berkeley Madonna“. Determinante i matrice. Kemijski i biokemijski reakcijski mehanizami (linearni kinetički modeli). Postavljanje bilanci i simulacija modela. Primjeri modeliranja ekoloških sustava (biološko pročišćavanje otpadnih voda, distribucija onečišćenja dospjelog u rijeku, more ili jezero).

ISHODI UČENJA ZA PREDMET:

I. **KOGNITIVNA DOMENA – ZNANJE**

1. Opisati i objasniti opća načela homogenih i distribuiranih bilanci tvari, prijenosa količine gibanja i energije.
2. Prepoznati i objasniti svojstva ekosustava bitna za izradu matematičkog modela.
3. Opisati ekosustav matematičkim formulama te izvesti izraze homogenih i distribuiranih bilanci tvari, prijenosa količine gibanja i energije.
4. Opisati i objasniti modele kemometrijske analize, neuronskih mreža, „fuzzy logic“ i genetičkog algoritma.

II.PSIHOMOTORIČKA DOMENA – VJEŠTINE

1. Primijeniti simulacijske računalne sustave Berkeley Madonna, Statistica za rješavanje problema u ekološkim sustavima.
2. Primijeniti modele kemometrijske analize, neuronskih mreža, „fuzzy logic“ i genetičkog algoritma
3. Primijeniti stečeno znanje u prosudbi točnosti i preciznosti dobivenih modelnih podataka a na osnovu utjecaja pogrešaka koje se mogu javiti uslijed simulacijske analize.
4. Izračunati i grafički prikazati ponašanje pojedinih varijabli dinamičkog modela sustava te primijeniti teoretsko znanje u interpretaciji rezultata.

Izvođenje nastave:

Kolegij se sastoji od predavanja i vježbi koje se izvode na računalima, prilagođenim postizanju ispred navedenih ishoda. Na predavanjima se podučava i raspravlja teorijski dio gradiva, na računalnim vježbama se rješavaju računski zadaci vezani uz određene dijelove gradiva.

Studentu je obveza pripremiti gradivo o kojem se raspravlja

Od studenata se očekuje da se na temelju predložene literature i detaljnog nastavnog programa pripreme za tematiku koja će se obrađivati te se od njih očekuje aktivno sudjelovanje u nastavnom procesu. Tijekom predavanja posebno će biti istaknuti pojedini dijelovi kolegija koji zahtijevaju posebnu pozornost zbog svog izuzetnog značaja.

List of assigned reading:

1. Z. Gomzi, Ž. Kurtanjek: Modeliranje u kemijskom inženjerstvu, Hrvatsko društvo kemijskih inženjera i tehnologa, Fakultet kemijskog inženjerstva i tehnologije Sveučilišta u Zagrebu, 2019.

List of optional reading:

1. J. Thibodeaux: Environmental Chemodynamics, J. Wiley, 1996; J.L. Schnoor, Environmental Modeling; J. Wiley, 1999.
2. A.L. Koch: Mathematical Modeling in Microbial Ecology, Springer, 1998.
3. N.Hritonenko, Y.Yatsenko: Mathematical Modeling in Economics, Ecology and the Environment, Springer, 2013.

Curriculum:

[Predavanja] list (with titles and explanation):

P1,P2 Uvodni pojmovi o sustavu, matematičkom modeliranju i primjeni modela. Procesni prostor, ulazne i izlazne veličine, zavisne i nezavisne veličine. Računalna simulacija, upravljanje procesom, optimiranje procesa.

- definirati sustav, granice sustava, ulazne i izlazne veličine, zavisne i nezavisne veličine procesa
- definirati matematičko modeliranje te utvrditi ciljeve modeliranja
- matematički interpretirati odnose između varijabli i parametara u nekom sustavu
- objasniti proces računalne simulacije
- definirati postupak upravljanja procesom i optimiranje procesa

P3,P4 Klasifikacija matematičkih modela. Osnovni pojmovi o kemijskom reakcijskom inženjerstvu. Brzine kemijskih reakcija: Osnovni pojmovi i veličine.

- klasificirati matematičke modele
- definirati brzinu kemijske reakcije uz pojam iznosa ili dosega reakcije
- definirati pojmove i objasniti razliku između konverzije i dosega reakcije

P5,P6 Kinetika reakcija u homogenim sustavima. Osnove teorije o reakcijskom putu (Teorija sudara, Teorija prijelaznog stanja).

- objasniti pojam homogenog sustava
- navesti i objasniti osnovne teorije o reakcijskom putu
- klasificirati vrstu reakcija s obzirom na broj koraka reakcije
- definirati pojmove mehanizma reakcije, prijelaznog kompleksa

P7,P8 Ovisnost brzine reakcije o temperaturi. Eksperimentalni podaci i brzina kemijske reakcije. Kinetički model.

- objasniti utjecaj temperature na brzinu kemijske reakcije
- objasniti pojmove molekularnost reakcije i specifičnu brzinu
- definirati pojmove kinetičkog modela, mehanističkog i empirijskog kinetičkog modela

P9,P10 Podjela kemijskih reaktora. Bilance mase, množine tvari i topline. Matematički opis općih bilanci množine tvari. Reaktorski modeli osnovnih „idealnih“ tipova reaktora. Kotlasti reaktor, Protočni kotlasti reaktor, Cijevni reaktor.

- definirati pojam kemijskog reaktora
- klasificirati kemijske reaktore s obzirom na izmjenu reakcijske smjese s okolinom, s obzirom promjena veličina stanja s vremenom i s obzirom na promjenu veličina unutar reakcijskog prostora
- navesti karakteristike i objasniti razlike između pojedinih vrsta kemijskih reaktora
- shematski prikazati pojedinu vrstu kemijskog reaktora
- objasniti pojmove bilance mase, množine tvari i topline
- matematičkim izrazima prikazati bilance mase, množine tvari i topline za pojedine vrste kemijskih reaktora
- objasniti pojam idealnog reaktora te navesti pretpostavke idealiziranih stanja kod kemijskih reaktora

P11 Eksperimentalne metode u kinetici. Izbor eksperimentalnog reaktora. Izbor kinetičkog modela, procjena vrijednosti parametara modela, analiza grešaka.

- navesti i objasniti ciljeve kinetičkog istraživanja
- prikazati izraze za računanje brzine kemijske reakcije u pojedinim vrstama kemijskih reaktora
- navesti varijable koje se mjere u kinetičkim eksperimentima
- objasniti pojam testiranja kinetičkog modela s eksperimentalnim rezultatima
- navesti i objasniti čimbenike na osnovu kojih se utvrđuje odabir „najboljeg“ modela

P12 Eksperimentalne metode u kinetici. Izbor eksperimentalnog reaktora. Izbor kinetičkog modela, procjena vrijednosti parametara modela, analiza grešaka (II).

- navesti i objasniti ciljeve kinetičkog istraživanja
- prikazati izraze za računanje brzine kemijske reakcije u pojedinim vrstama kemijskih reaktora
- navesti varijable koje se mjere u kinetičkim eksperimentima
- objasniti pojam testiranja kinetičkog modela s eksperimentalnim rezultatima

navesti i objasniti čimbenike na osnovu kojih se utvrđuje odabir „najboljeg“ modela

P13,P14 Analiza i primjena matematičkih modela različitih kemijskih i bioloških procesa koji se odvijaju u okolišu. Razvoj matematičkog modela: postavljanje bilanci, utvrđivanje parametara modela, odabir numeričkih metoda u rješavanju modela - 1. DIO.

- postavljati matematičke modele kemijskih i bioloških procesa koji se odvijaju u okolišu
- za određeni kemijski i biološki proces identificirati ulazne i izlazne procesne tokove i procesne veličine
- primijeniti zakon o očuvanju mase i energije te postaviti bilance tvari i energije određenih kemijskih i bioloških procesa koji se odvijaju u okolišu
- primijeniti numeričke metode u rješavanju matematičkog modela kemijskih i bioloških procesa koji se odvijaju u okolišu

P15,P16 Analiza i primjena matematičkih modela različitih kemijskih i bioloških procesa koji se odvijaju u okolišu. Razvoj matematičkog modela: postavljanje bilanci, utvrđivanje parametara modela, odabir numeričkih metoda u rješavanju modela. - 2. DIO

- postavljati matematičke modele kemijskih i bioloških procesa koji se odvijaju u okolišu
- za određeni kemijski i biološki proces identificirati ulazne i izlazne procesne tokove i procesne veličine
- primijeniti zakon o očuvanju mase i energije te postaviti bilance tvari i energije određenih kemijskih i bioloških procesa koji se odvijaju u okolišu
- primijeniti numeričke metode u rješavanju matematičkog modela kemijskih i bioloških procesa koji se odvijaju u okolišu

P17,P18 Primjeri matematičkih modela uz prostornu ovisnost veličina stanja. Primjeri modela uz vremensku i prostornu ovisnost veličina stanja. - 1. DIO

- postavljati matematičke modele uz prostornu ovisnost veličina stanja te uz vremensku i prostornu ovisnost veličina stanja kemijskih i bioloških procesa koji se odvijaju u okolišu
- za određeni kemijski i biološki proces identificirati ulazne i izlazne procesne tokove i procesne veličine
- primijeniti zakon o očuvanju mase i energije te postaviti bilance tvari i energije određenih kemijskih i bioloških procesa koji se odvijaju u okolišu
- primijeniti numeričke metode u rješavanju matematičkog modela kemijskih i bioloških procesa koji se odvijaju u okolišu

P19,P20 Primjeri matematičkih modela uz prostornu ovisnost veličina stanja. Primjeri modela uz vremensku i prostornu ovisnost veličina stanja. - 2. DIO

- postavljati matematičke modele uz prostornu ovisnost veličina stanja te uz vremensku i prostornu ovisnost veličina stanja kemijskih i bioloških procesa koji se odvijaju u okolišu
- za određeni kemijski i biološki proces identificirati ulazne i izlazne procesne tokove i procesne veličine
- primijeniti zakon o očuvanju mase i energije te postaviti bilance tvari i energije određenih kemijskih i bioloških procesa koji se odvijaju u okolišu
- primijeniti numeričke metode u rješavanju matematičkog modela kemijskih i bioloških procesa koji se odvijaju u okolišu

P21,P22 Primjeri matematičkih modela uz prostornu ovisnost veličina stanja. Primjeri modela uz vremensku i prostornu ovisnost veličina stanja. - 3 DIO; Optimiranje procesa uz uporabu eksperimentalnih rezultata. Simulacija procesa pomoću matematičkog modela. Procjena vrijednosti parametara modela. Prihvaćanje ili odbacivanje modela. - 1. DIO

- postavljati matematičke modele uz prostornu ovisnost veličina stanja te uz vremensku i prostornu ovisnost veličina stanja kemijskih i bioloških procesa koji se odvijaju u okolišu
- za određeni kemijski i biološki proces identificirati ulazne i izlazne procesne tokove i procesne veličine
- primijeniti zakon o očuvanju mase i energije te postaviti bilance tvari i energije određenih kemijskih i bioloških procesa koji se odvijaju u okolišu
- primijeniti numeričke metode u rješavanju matematičkog modela kemijskih i bioloških procesa koji se odvijaju u okolišu
- optimirati proces uz uporabu rezultata dobivenih eksperimentom
- simulirati proces uz primjenu određenog matematičkog modela
- procijeniti prihvatljivost matematičkog modela na osnovu odgovarajućih statističkih pokazatelja

P23,P24 Optimiranje procesa uz uporabu eksperimentalnih rezultata. Simulacija procesa pomoću matematičkog modela. Procjena vrijednosti parametara modela. Prihvaćanje ili odbacivanje modela. - 2. DIO; Viševarijabilni modeli. Linearni modeli. Nelinearni. Nelinearni dinamički modeli. PCA (glavne komponente) modeli. Modeli neizrazite logike (Fuzzy logic). Neuronske mreže. - 1. DIO

optimirati proces uz uporabu rezultata dobivenih eksperimentom
- simulirati proces uz primjenu određenog matematičkog modela
- procijeniti prihvatljivost matematičkog modela na osnovu odgovarajućih statističkih pokazatelja
- navesti neke viševarijabilne modele
- navesti osnovne karakteristike viševarijabilnih modela
- procijeniti parametre viševarijabilnih modela
- validirati model
- utvrditi pogreške parametara te interval pouzdanosti procjene

P25 Viševarijabilni modeli. Linearni modeli. Nelinearni. Nelinearni dinamički modeli. PCA (glavne komponente) modeli. Modeli neizrazite logike (Fuzzy logic). Neuronske mreže. - 2. DIO

- navesti neke viševarijabilne modele
- navesti osnovne karakteristike viševarijabilnih modela
- procijeniti parametre viševarijabilnih modela
- validirati model
- utvrditi pogreške parametara te interval pouzdanosti procjene

[Vježbe] list (with titles and explanation):

V1,V2. Uvodne napomene o programskom paketu „Berkeley Madonna“. Determinante i matrice.

- izvesti matematičke operacije s determinantama i matricama

V3,V4. Analiza i primjena matematičkih modela u različitim kemijskih i biokemijskim procesima. - 1. DIO

- izračunati i grafički prikazati ponašanje pojedinih varijabli dinamičkog modela sustava
- primijeniti teoretsko znanje u interpretaciji rezultata

V5,V6 Analiza i primjena matematičkih modela u različitim kemijskih i biokemijskim procesima. - 2 DIO

- izračunati i grafički prikazati ponašanje pojedinih varijabli dinamičkog modela sustava
- **primijeniti teoretsko znanje u interpretaciji rezultata**

V7,V8 Analiza i primjena matematičkih modela različitih kemijskih i bioloških procesa koji se odvijaju u okolišu. Razvoj matematičkog modela: postavljanje bilanci, utvrđivanje parametara modela, odabir numeričkih metoda u rješavanju modela.(biološko pročišćavanje otpadnih voda, distribucija onečišćenja dospjelog u rijeku, more ili jezero). - 1 DIO

- izračunati i grafički prikazati ponašanje pojedinih varijabli dinamičkog modela sustava
- primijeniti teoretsko znanje u interpretaciji rezultata

V9,V10 Analiza i primjena matematičkih modela različitih kemijskih i bioloških procesa koji se odvijaju u okolišu. Razvoj matematičkog modela: postavljanje bilanci, utvrđivanje parametara modela, odabir numeričkih metoda u rješavanju modela.(biološko pročišćavanje otpadnih voda, distribucija onečišćenja dospjelog u rijeku, more ili jezero). - 2. DIO

- izračunati i grafički prikazati ponašanje pojedinih varijabli dinamičkog modela sustava
- primijeniti teoretsko znanje u interpretaciji rezultata

V11,V12 Analiza i primjena matematičkih modela različitih kemijskih i bioloških procesa koji se odvijaju u okolišu. Razvoj matematičkog modela: postavljanje bilanci, utvrđivanje parametara modela, odabir numeričkih metoda u rješavanju modela.(biološko pročišćavanje otpadnih voda, distribucija onečišćenja dospjelog u rijeku, more ili jezero). - 3 DIO

- izračunati i grafički prikazati ponašanje pojedinih varijabli dinamičkog modela sustava
- primijeniti teoretsko znanje u interpretaciji rezultata

V13,V14 Analiza i primjena matematičkih modela različitih kemijskih i bioloških procesa koji se odvijaju u okolišu. Razvoj matematičkog modela: postavljanje bilanci, utvrđivanje parametara modela, odabir numeričkih metoda u rješavanju modela.(biološko pročišćavanje otpadnih voda, distribucija onečišćenja dospjelog u rijeku, more ili jezero). - 4 DIO

- izračunati i grafički prikazati ponašanje pojedinih varijabli dinamičkog modela sustava
- primijeniti teoretsko znanje u interpretaciji rezultata

V15,V16 Optimiranje procesa uz uporabu eksperimentalnih rezultata. Simulacija procesa pomoću matematičkog modela. Procjena vrijednosti parametara modela. Prihvaćanje ili odbacivanje modela. - 1. DIO

- simulirati proces uz primjenu određenog matematičkog modela
- grafički prikazati ponašanje pojedinih varijabli dinamičkog modela sustava
- procijeniti prihvatljivost matematičkog modela na osnovu odgovarajućih statističkih pokazatelja
- primijeniti teoretsko znanje u interpretaciji rezultata

V17,V18 Optimiranje procesa uz uporabu eksperimentalnih rezultata. Simulacija procesa pomoću matematičkog modela. Procjena vrijednosti parametara modela. Prihvaćanje ili odbacivanje modela. - 2. DIO

- simulirati proces uz primjenu određenog matematičkog modela
- grafički prikazati ponašanje pojedinih varijabli dinamičkog modela sustava
- procijeniti prihvatljivost matematičkog modela na osnovu odgovarajućih statističkih pokazatelja
- primijeniti teoretsko znanje u interpretaciji rezultata

V19,V20 Viševarijabilni modeli. Linearni modeli. Nelinearni. Nelinearni dinamički modeli. PCA (glavne komponente) modeli.

- izračunati i grafički prikazati ponašanje pojedinih varijabli modela sustava
- primijeniti teoretsko znanje u interpretaciji rezultata

Student obligations:

Studenti slušaju kolegij Matematičko i računalno modeliranje ekoloških sustava u I trimestru druge godine Diplomskog studija (25 P + 20 V). Studenti trebaju odslušati minimalno 70% svih oblika nastave te pristupiti provjerama znanja.
Završni ispit sastoji se od pismenog dijela. Na Završnom ispitu studenti moraju zadovoljiti u 50% odgovora.
Pristup završnom ispitu dozvoljen je tek nakon što su ispunjene sve prethodno navedene obveze.
Po položenom završnom ispitu, student stječe pravo na 3 ECTS boda

Exam (exam taking, description of the written/oral/practical part of the exam, point distribution, grading criteria):

ECTS bodovni sustav ocjenjivanja:
Ocjenjivanje studenata provodi se prema važećem Pravilniku o studijima Sveučilišta u Rijeci, te prema Pravilniku o ocjenjivanju studenata na Medicinskom fakultetu u Rijeci (usvojenog na Fakultetskom vijeću Medicinskog fakulteta u Rijeci).
Rad studenata vrednovat će se i ocjenjivati tijekom izvođenja nastave preko vrednovanja parcijalnog testa i završnog ispita.
Od ukupno 100 bodova, tijekom nastave student može ostvariti 50 bodova, a na završnom ispitu 50 bodova.

Za SVAKU aktivnost za vrijeme nastave student mora ostvariti minimalno 50% uspješnosti .

I. Tijekom nastave vrednuje se (maksimalno 50 bodova):
Studenti koji nisu položili parcijalni test ili nisu pristupili parcijalnom testu ili žele popraviti ukupan broj bodova (kao zadnja ocjena uzima se zadnji pisani test koji može značiti i negativnu ocjenu) moraju pristupiti popravku Parcijalnog testa kako bi stekli uvjete za izlazak na Završni ispit.

Struktura ocjene kolegija Matematičko i računalno modeliranje ekoloških sustava u akademskoj godini 2024./2025. prikazana je u Tablici 1.

Tablica 1.

	VREDNOVANJE	MAX.BROJ OCJENSKIH BODOVA
Parcijalni testovi	Parcijalni test iz seminarskih zadataka	50
	Ukupno	**50**
Završni ispit	Pisani dio	50
	Ukupno	**50**
UKUPNO		**100**

Parcijalni testovi:

Tijekom trimestra predviđen je jedan parcijalni test. Parcijalni test obuhvaća gradivo eksperimentalnih vježbi V1 – V14. Testom je moguće ostvariti najviše 50 ocjenskih bodova. Postignuća na parcijalnom testu vrednuju se prema **Tablici 2**.

Tablica 2.

Postotak točno riješenih zadataka (%)	Ocjenski bodovi
50-54,99	25
55-59,99	27
60-64,99	30
65-69,99	33
70-74,99	36
75-79,99	39

80-84,99	42
85-89,99	45
90-94,99	48
95-100	50

II. Završni ispit (50 bodova)

Završni ispit sastoji se od pismenog (50 ocjenskih bodova) dijela. Završni ispit obuhvaća gradivo eksperimentalnih vježbi V14 – V20 i predavanja P1 – P25. Student mora zadovoljiti na pismenom dijelu završnog ispita s minimalno 50%-tnom uspješnosti.

Vrednovanje pismenog dijela završnog ispita (Tablica 3):

Tablica 3.

Postotak točno riješenih zadataka (%)	Ocjenski bodovi
50-54,99	25
55-59,99	27
60-64,99	30
65-69,99	33
70-74,99	36
75-79,99	39
80-84,99	42
85-89,99	45
90-94,99	48
95-100	50

Tko **može** pristupiti završnom ispitu:

Konačna ocjena je zbroj bodova ostvarenih na parcijalnom testu i bodova ostvarenih na završnom ispitu.
Studenti koji su tijekom nastave ostvarili:
- **više od 50 ocjenskih bodova** – mogu pristupiti završnom ispitu.

Studenti na završnom ispitu (pismeni) mogu ostvariti 50% konačne ocjene, a ispitni prag na pismenom završnom ispitu ne može biti niži od 50% uspješno riješenih zadataka.

Tko **ne može** pristupiti završnom ispitu:
- **Studenti koji su tijekom nastave ostvarili 0 do 49,9 bodova ili koji imaju 30% i više izostanaka s nastave** . Takav student je neuspješan (1) F i ne može izaći na završni ispit, tj. mora predmet ponovno upisati naredne akademske godine.

III. Konačna ocjena je zbroj ECTS ocjene ostvarene tijekom nastave i na završnom ispitu:

Konačna ocjena	
A (90-100%)	izvrstan (5)
B (75-89,9%)	vrlo-dobar (4)
C (60-74,9%)	dobar (3)
D (50-59,9%)	dovoljan (2)
F (studenti koji su tijekom nastave ostvarili manje od 49,9 bodova ili nisu položili završni ispit)	nedovoljan (1)

Termini održavanja testova tijekom nastave:

12.12.2024. Parcijalni test (V1 – V14)

Other notes (related to the course) important for students:

Pohađanje nastave

Predavanja će biti održavana na Medicinskom fakultetu u Rijeci, a vježbe u Informatičkoj učioni Medicinskog fakulteta u Rijeci. Svi studenti zajedno pohađaju predavanja, dok su na eksperimentalnim vježbama podijeljeni u dvije grupe. Prisustvovanje svim oblicima nastave se bilježi.
Maksimalan broj opravdanih izostanaka s vježbi iznosi **30% (6 sati)**, uz obvezu kolokviranja propuštenog gradiva. Izostanci moraju biti opravdani odgovarajućim liječničkim potvrdama. Neopravdani izostanak s vježbi povlači negativnu konačnu ocjenu, a izostanci koji premašuju maksimalan broj dopuštenih sati onemogućuje pristup Završnom ispitu.
Studenti i nastavnici moraju se pridržavati konstruktivne i pozitivne komunikacije, što je od izuzetne važnosti obzirom na naglašenu interaktivnost kolegija. Tijekom predavanja i izvođenja vježbi strogo je zabranjena uporaba mobilnih telefona i ostalih elektroničkih uređaja koji odvraćaju pažnju ili remete koncentraciju nastavne grupe. Student koji opetovano remeti pozitivnu radnu atmosferu bit će udaljen s nastave te će mu biti evidentiran izostanak.

Pismeni radovi
U pismene radove ubrajaju se parcijalni test, popravci parcijalnog testa te pismeni Završni ispit.

Parcijalni test: Piše se tijekom trajanja kolegija, nakon odrađenih eksperimentalnih vježbi. Studenti se pripremaju iz zadane literature, kao dopunu predavanjima. Test je pismeni.

Popravni parcijalni test: Studenti koji nisu uspjeli ostvariti minimalno 50 ocjenskih bodova tijekom odvijanja nastave ili nisu položili parcijalni test ili nisu pristupili parcijalnom testu ili žele popraviti ukupan broj bodova (kao zadnja ocjena uzima se zadnji pisani test koji može značiti i negativnu ocjenu) moraju pristupiti popravku Parcijalnog testa kako bi stekli uvjete za izlazak na Završni ispit.

Završni pismeni ispit: Obuhvaća gradivo određeno planom i programom kolegija.

Kašnjenjenje i/ili neizvršavanje zadataka
Studenti se upućuju na točnost u dolasku na predavanja i eksperimentalne vježbe. U slučaju kašnjenja studenta na vježbe iz objektivnog razloga, voditelj/asistent će pokušati prilagoditi plan izvođenja vježbe. U slučaju kašnjenja više od 15 min., student gubi pravo na izvođenje vježbe te se takav dolazak vodi kao izostanak.
Prilikom predavanja, studentima nije dozvoljen ulazak u predavaonu po isteku 15 min od početka predavanja.
Sve obveze student bi trebao izvršavati na vrijeme (i uspješno) kako bi mogao slijediti nastavu definiranu predviđenim programom i rasporedom. Ako student ne obavi sve programom predviđene dijelove na vrijeme i barem s minimalnim uspjehom (min. 50%), mora ponovno upisati predmet.

Akademska čestitost
Studenti su upućeni na samostalnost prilikom izrade ocjenskih radova (parcijalni test, pismeni ispit), međukolegijalno poštovanje te promicanje akademske diskusije. Prilikom rada studenata u grupama, podjela zadataka mora biti jasno iskazana od strane studenata te prepoznata od strane nastavnika. Nastavnici su obvezni držati se društvenih normi kao što su nepristranost s obzirom na spol, nacionalnu pripadnost i vjeru.
Dokumenti koji se odnose na akademsku čestitost su Etički kodeks Sveučilišta u Rijeci te Etički kodeks za studente.

Kontaktiranje s nastavnicima
Studenti se upućuju na aktivnu i konstruktivnu diskusiju s nastavnicima. Izvan nastavnog vremena, voditelj kolegija dostupan je za konzultacije unutar termina koji će biti naznačen prilikom prvog predavanja.

Informiranje o predmetu
Informacije o predmetu studenti mogu naći na web stranicama kolegija (Platforma Merlin). Studenti su obvezni sami potražiti odgovarajuće informacije na gore navedenom mjestu. U slučaju hitne promjene termina nastave, ispita ili drugih važnih promjena, studenti će biti informirani putem Platforme Merlin ili e-maila.
Očekivane opće kompetencije studenata pri upisu predmeta
Od studenata se očekuje sistematizirano temeljno znanje stečeno iz područja kolegija Kemije, Matematike, Statistike i Informatike.
Rad na elektroničkom računalu (pisanje, skiciranje, MS Excel).
Osnove statističke obrade numeričkih podataka te njihovo grafičko prikazivanje.

COURSE HOURS 2024/2025

Matematičko i računalno modeliranje ekoloških sustava

[Predavanja] (Place and time or group)	**[Vježbe]** (Place and time or group)
04.11.2024	
P1,P2 Uvodni pojmovi o sustavu, matematičkom modeliranju i primjeni modela. Procesni prostor, ulazne i izlazne veličine, zavisne i nezavisne veličine. Računalna simulacija, upravljanje procesom, optimiranje procesa.: • [P04] (08:00 - 10:00) [347] ○ MRMES_PREDAVANJA	
prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. [347]	
06.11.2024	
P3,P4 Klasifikacija matematičkih modela. Osnovni pojmovi o kemijskom reakcijskom inženjerstvu. Brzine kemijskih reakcija: Osnovni pojmovi i veličine.: • [P02] (13:00 - 15:00) [347] ○ MRMES_PREDAVANJA	
prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. [347]	
07.11.2024	
P5,P6 Kinetika reakcija u homogenim sustavima. Osnove teorije o reakcijskom putu (Teorija sudara, Teorija prijelaznog stanja).: • [P01] (12:00 - 14:00) [347] ○ MRMES_PREDAVANJA	
prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. [347]	
08.11.2024	
P7,P8 Ovisnost brzine reakcije o temperaturi. Eksperimentalni podaci i brzina kemijske reakcije. Kinetički model.: • [P15 - VIJEĆNICA] (11:00 - 13:00) [347] ○ MRMES_PREDAVANJA	
prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. [347]	
12.11.2024	

	V1,V2. Uvodne napomene o programskom paketu „Berkeley Madonna“. Determinante i matrice.:
	• [P03 - INFORMATIČKA UČIONICA] (10:00 - 12:00) [347]
	  ○ MRMES_1
	• [P03 - INFORMATIČKA UČIONICA] (12:00 - 14:00) [347]
	  ○ MRMES_2

prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. [347]	
13.11.2024	
P9,P10 Podjela kemijskih reaktora. Bilance mase, množine tvari i topline. Matematički opis općih bilanci množine tvari. Reaktorski modeli osnovnih „idealnih“ tipova reaktora. Kotlasti reaktor, Protočni kotlasti reaktor, Cijevni reaktor.: • [P02] (13:00 - 15:00) [347] ○ MRMES_PREDAVANJA	

prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. [347]	
14.11.2024	

P11 Eksperimentalne metode u kinetici. Izbor eksperimentalnog reaktora. Izbor kinetičkog modela, procjena vrijednosti parametara modela, analiza grešaka.:
• [P08] (08:00 - 09:00) [347]
  ○ MRMES_PREDAVANJA
 	
P12 Eksperimentalne metode u kinetici. Izbor eksperimentalnog reaktora. Izbor kinetičkog modela, procjena vrijednosti parametara modela, analiza grešaka (II).:
• [P03 - INFORMATIČKA UČIONICA] (09:30 - 10:30) [347]
  ○ MRMES_PREDAVANJA	

prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. [347]	
15.11.2024	
P13,P14 Analiza i primjena matematičkih modela različitih kemijskih i bioloških procesa koji se odvijaju u okolišu. Razvoj matematičkog modela: postavljanje bilanci, utvrđivanje parametara modela, odabir numeričkih metoda u rješavanju modela - 1. DIO.: • [P06] (08:00 - 10:00) [347] ○ MRMES_PREDAVANJA	
prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. [347]	
19.11.2024	

	V3,V4. Analiza i primjena matematičkih modela u različitim kemijskih i biokemijskim procesima. - 1. DIO:
	• [P03 - INFORMATIČKA UČIONICA] (11:00 - 13:00) [347]
	  ○ MRMES_2
	• [P03 - INFORMATIČKA UČIONICA] (13:00 - 15:00) [347]
	  ○ MRMES_1

prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. [347]	
21.11.2024	
P15,P16 Analiza i primjena matematičkih modela različitih kemijskih i bioloških procesa koji se odvijaju u okolišu. Razvoj matematičkog modela: postavljanje bilanci, utvrđivanje parametara modela, odabir numeričkih metoda u rješavanju modela. - 2. DIO: • [P02] (08:00 - 10:00) [347] ○ MRMES_PREDAVANJA	
prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. [347]	
25.11.2024	

	V5,V6 Analiza i primjena matematičkih modela u različitim kemijskih i biokemijskim procesima. - 2 DIO:
	• [P03 - INFORMATIČKA UČIONICA] (08:00 - 10:00) [347]
	  ○ MRMES_1
	• [P03 - INFORMATIČKA UČIONICA] (13:00 - 15:00) [347]
	  ○ MRMES_2

prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. [347]	
28.11.2024	

P17,P18 Primjeri matematičkih modela uz prostornu ovisnost veličina stanja. Primjeri modela uz vremensku i prostornu ovisnost veličina stanja. - 1. DIO: • [P15 - VIJEĆNICA] (08:00 - 10:00) [347] ◦ MRMES_PREDAVANJA	
prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. [347]	
29.11.2024	

	V7,V8 Analiza i primjena matematičkih modela različitih kemijskih i bioloških procesa koji se odvijaju u okolišu. Razvoj matematičkog modela: postavljanje bilanci, utvrđivanje parametara modela, odabir numeričkih metoda u rješavanju modela.(biološko pročišćavanje otpadnih voda, distribucija onečišćenja dospjelog u rijeku, more ili jezero). - 1 DIO:
	• [P03 - INFORMATIČKA UČIONICA] (10:00 - 12:00) [347]
	  ◦ MRMES_2
	• [P03 - INFORMATIČKA UČIONICA] (12:00 - 14:00) [347]
	  ◦ MRMES_1

prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. [347]	
02.12.2024	

	V9,V10 Analiza i primjena matematičkih modela različitih kemijskih i bioloških procesa koji se odvijaju u okolišu. Razvoj matematičkog modela: postavljanje bilanci, utvrđivanje parametara modela, odabir numeričkih metoda u rješavanju modela.(biološko pročišćavanje otpadnih voda, distribucija onečišćenja dospjelog u rijeku, more ili jezero). - 2. DIO:
	• [P03 - INFORMATIČKA UČIONICA] (08:00 - 10:00) [347]
	  ◦ MRMES_1
	• [P03 - INFORMATIČKA UČIONICA] (10:00 - 12:00) [347]
	  ◦ MRMES_2

prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. [347]	
04.12.2024	
P19,P20 Primjeri matematičkih modela uz prostornu ovisnost veličina stanja. Primjeri modela uz vremensku i prostornu ovisnost veličina stanja. - 2. DIO: • [P03 - INFORMATIČKA UČIONICA] (12:00 - 14:00) [347] ◦ MRMES_PREDAVANJA	
prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. [347]	
05.12.2024	
P21,P22 Primjeri matematičkih modela uz prostornu ovisnost veličina stanja. Primjeri modela uz vremensku i prostornu ovisnost veličina stanja. - 3 DIO; Optimiranje procesa uz uporabu eksperimentalnih rezultata. Simulacija procesa pomoću matematičkog modela. Procjena vrijednosti parametara modela. Prihvaćanje ili odbacivanje modela. - 1. DIO: • [P15 - VIJEĆNICA] (08:00 - 10:00) [347] ◦ MRMES_PREDAVANJA	
prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. [347]	
06.12.2024	

	V11,V12 Analiza i primjena matematičkih modela različitih kemijskih i bioloških procesa koji se odvijaju u okolišu. Razvoj matematičkog modela: postavljanje bilanci, utvrđivanje parametara modela, odabir numeričkih metoda u rješavanju modela.(biološko pročišćavanje otpadnih voda, distribucija onečišćenja dospjelog u rijeku, more ili jezero). - 3 DIO:
	• [P03 - INFORMATIČKA UČIONICA] (10:00 - 12:00) [347]
	  ◦ MRMES_2
	• [P03 - INFORMATIČKA UČIONICA] (12:00 - 14:00) [347]
	  ◦ MRMES_1

prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. [347]	
09.12.2024	

	V13,V14 Analiza i primjena matematičkih modela različitih kemijskih i bioloških procesa koji se odvijaju u okolišu. Razvoj matematičkog modela: postavljanje bilanci, utvrđivanje parametara modela, odabir numeričkih metoda u rješavanju modela.(biološko pročišćavanje otpadnih voda, distribucija onečišćenja dospjelog u rijeku, more ili jezero). - 4 DIO:
	• [P03 - INFORMATIČKA UČIONICA] (08:00 - 10:00) [347]
	  ◦ MRMES_1
	• [P03 - INFORMATIČKA UČIONICA] (10:00 - 12:00) [347]
	  ◦ MRMES_2

prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. [347]	
11.12.2024	
P23,P24 Optimiranje procesa uz uporabu eksperimentalnih rezultata. Simulacija procesa pomoću matematičkog modela. Procjena vrijednosti parametara modela. Prihvaćanje ili odbacivanje modela. - 2. DIO; Viševarijabilni modeli. Linearni modeli. Nelinearni. Nelinearni dinamički modeli. PCA (glavne komponente) modeli. Modeli neizrazite logike (Fuzzy logic). Neuronske mreže. - 1. DIO: • [P09 - NASTAVA NA ENGLESKOM JEZIKU] (10:00 - 12:00) [347] ◦ MRMES_PREDAVANJA	
prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. [347]	
12.12.2024	
P25 Viševarijabilni modeli. Linearni modeli. Nelinearni. Nelinearni dinamički modeli. PCA (glavne komponente) modeli. Modeli neizrazite logike (Fuzzy logic). Neuronske mreže. - 2. DIO: • [P09 - NASTAVA NA ENGLESKOM JEZIKU] (08:00 - 09:00) [347] ◦ MRMES_PREDAVANJA	
prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. [347]	
17.12.2024	

	V15,V16 Optimiranje procesa uz uporabu eksperimentalnih rezultata. Simulacija procesa pomoću matematičkog modela. Procjena vrijednosti parametara modela. Prihvaćanje ili odbacivanje modela. - 1. DIO: • [P03 - INFORMATIČKA UČIONICA] (08:00 - 10:00) [347] ◦ MRMES_2 • [P03 - INFORMATIČKA UČIONICA] (14:00 - 16:00) [347] ◦ MRMES_1 V17,V18 Optimiranje procesa uz uporabu eksperimentalnih rezultata. Simulacija procesa pomoću matematičkog modela. Procjena vrijednosti parametara modela. Prihvaćanje ili odbacivanje modela. - 2. DIO: • [P03 - INFORMATIČKA UČIONICA] (10:00 - 12:00) [347] ◦ MRMES_1 • [P03 - INFORMATIČKA UČIONICA] (12:00 - 14:00) [347] ◦ MRMES_2
prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. [347]	
18.12.2024	
	V19,V20 Viševarijabilni modeli. Linearni modeli. Nelinearni. Nelinearni dinamički modeli. PCA (glavne komponente) modeli.: • [P03 - INFORMATIČKA UČIONICA] (08:00 - 10:00) [347] ◦ MRMES_1 • [P03 - INFORMATIČKA UČIONICA] (10:00 - 12:00) [347] ◦ MRMES_2
prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. [347]	

List of lectures, seminars and practicals:

[PREDAVANJA] (TOPIC)	Number of hours	Location
P1,P2 Uvodni pojmovi o sustavu, matematičkom modeliranju i primjeni modela. Procesni prostor, ulazne i izlazne veličine, zavisne i nezavisne veličine. Računalna simulacija, upravljanje procesom, optimiranje procesa.	2	[P04]
P3,P4 Klasifikacija matematičkih modela. Osnovni pojmovi o kemijskom reakcijskom inženjerstvu. Brzine kemijskih reakcija: Osnovni pojmovi i veličine.	2	[P02]
P5,P6 Kinetika reakcija u homogenim sustavima. Osnove teorije o reakcijskom putu (Teorija sudara, Teorija prijelaznog stanja).	2	[P01]
P7,P8 Ovisnost brzine reakcije o temperaturi. Eksperimentalni podaci i brzina kemijske reakcije. Kinetički model.	2	[P15 - VIJEĆNICA]
P9,P10 Podjela kemijskih reaktora. Bilance mase, množine tvari i topline. Matematički opis općih bilanci množine tvari. Reaktorski modeli osnovnih „idealnih“ tipova reaktora. Kotlasti reaktor, Protočni kotlasti reaktor, Cijevni reaktor.	2	[P02]
P11 Eksperimentalne metode u kinetici. Izbor eksperimentalnog reaktora. Izbor kinetičkog modela, procjena vrijednosti parametara modela, analiza grešaka.	1	[P08]
P12 Eksperimentalne metode u kinetici. Izbor eksperimentalnog reaktora. Izbor kinetičkog modela, procjena vrijednosti parametara modela, analiza grešaka (II).	1	[P03 - INFORMATIČKA UČIONICA]
P13,P14 Analiza i primjena matematičkih modela različitih kemijskih i bioloških procesa koji se odvijaju u okolišu. Razvoj matematičkog modela: postavljanje bilanci, utvrđivanje parametara modela, odabir numeričkih metoda u rješavanju modela - 1. DIO.	2	[P06]

P15,P16 Analiza i primjena matematičkih modela različitih kemijskih i bioloških procesa koji se odvijaju u okolišu. Razvoj matematičkog modela: postavljanje bilanci, utvrđivanje parametara modela, odabir numeričkih metoda u rješavanju modela. - 2. DIO	2	[P02]
P17,P18 Primjeri matematičkih modela uz prostornu ovisnost veličina stanja. Primjeri modela uz vremensku i prostornu ovisnost veličina stanja. - 1. DIO	2	[P15 - VIJEĆNICA]
P19,P20 Primjeri matematičkih modela uz prostornu ovisnost veličina stanja. Primjeri modela uz vremensku i prostornu ovisnost veličina stanja. - 2. DIO	2	[P03 - INFORMATIČKA UČIONICA]
P21,P22 Primjeri matematičkih modela uz prostornu ovisnost veličina stanja. Primjeri modela uz vremensku i prostornu ovisnost veličina stanja. - 3 DIO; Optimiranje procesa uz uporabu eksperimentalnih rezultata. Simulacija procesa pomoću matematičkog modela. Procjena vrijednosti parametara modela. Prihvaćanje ili odbacivanje modela. - 1. DIO	2	[P15 - VIJEĆNICA]
P23,P24 Optimiranje procesa uz uporabu eksperimentalnih rezultata. Simulacija procesa pomoću matematičkog modela. Procjena vrijednosti parametara modela. Prihvaćanje ili odbacivanje modela. - 2. DIO; Viševarijabilni modeli. Linearni modeli. Nelinearni. Nelinearni dinamički modeli. PCA (glavne komponente) modeli. Modeli neizrazite logike (Fuzzy logic). Neuronske mreže. - 1. DIO	2	[P09 - NASTAVA NA ENGLESKOM JEZIKU]
P25 Viševarijabilni modeli. Linearni modeli. Nelinearni. Nelinearni dinamički modeli. PCA (glavne komponente) modeli. Modeli neizrazite logike (Fuzzy logic). Neuronske mreže. - 2. DIO	1	[P09 - NASTAVA NA ENGLESKOM JEZIKU]

[VJEŽBE] (TOPIC)	Number of hours	Location
V1,V2. Uvodne napomene o programskom paketu „Berkeley Madonna“. Determinante i matrice.	2	[P03 - INFORMATIČKA UČIONICA]
V3,V4. Analiza i primjena matematičkih modela u različitim kemijskih i biokemijskim procesima. - 1. DIO	2	[P03 - INFORMATIČKA UČIONICA]
V5,V6 Analiza i primjena matematičkih modela u različitim kemijskih i biokemijskim procesima. - 2 DIO	2	[P03 - INFORMATIČKA UČIONICA]
V7,V8 Analiza i primjena matematičkih modela različitih kemijskih i bioloških procesa koji se odvijaju u okolišu. Razvoj matematičkog modela: postavljanje bilanci, utvrđivanje parametara modela, odabir numeričkih metoda u rješavanju modela.(biološko pročišćavanje otpadnih voda, distribucija onečišćenja dospjelog u rijeku, more ili jezero). - 1 DIO	2	[P03 - INFORMATIČKA UČIONICA]
V9,V10 Analiza i primjena matematičkih modela različitih kemijskih i bioloških procesa koji se odvijaju u okolišu. Razvoj matematičkog modela: postavljanje bilanci, utvrđivanje parametara modela, odabir numeričkih metoda u rješavanju modela.(biološko pročišćavanje otpadnih voda, distribucija onečišćenja dospjelog u rijeku, more ili jezero). - 2. DIO	2	[P03 - INFORMATIČKA UČIONICA]
V11,V12 Analiza i primjena matematičkih modela različitih kemijskih i bioloških procesa koji se odvijaju u okolišu. Razvoj matematičkog modela: postavljanje bilanci, utvrđivanje parametara modela, odabir numeričkih metoda u rješavanju modela.(biološko pročišćavanje otpadnih voda, distribucija onečišćenja dospjelog u rijeku, more ili jezero). - 3 DIO	2	[P03 - INFORMATIČKA UČIONICA]
V13,V14 Analiza i primjena matematičkih modela različitih kemijskih i bioloških procesa koji se odvijaju u okolišu. Razvoj matematičkog modela: postavljanje bilanci, utvrđivanje parametara modela, odabir numeričkih metoda u rješavanju modela.(biološko pročišćavanje otpadnih voda, distribucija onečišćenja dospjelog u rijeku, more ili jezero). - 4 DIO	2	[P03 - INFORMATIČKA UČIONICA]
V15,V16 Optimiranje procesa uz uporabu eksperimentalnih rezultata. Simulacija procesa pomoću matematičkog modela. Procjena vrijednosti parametara modela. Prihvaćanje ili odbacivanje modela. - 1. DIO	2	[P03 - INFORMATIČKA UČIONICA]

V17,V18 Optimiranje procesa uz uporabu eksperimentalnih rezultata. Simulacija procesa pomoću matematičkog modela. Procjena vrijednosti parametara modela. Prihvaćanje ili odbacivanje modela. - 2. DIO	2	[P03 - INFORMATIČKA UČIONICA]
V19,V20 Viševarijabilni modeli. Linearni modeli. Nelinearni. Nelinearni dinamički modeli. PCA (glavne komponente) modeli.	2	[P03 - INFORMATIČKA UČIONICA]

EXAM DATES (final exam):

1.	10.01.2025.
2.	24.01.2025.
3.	05.06.2025.
4.	05.09.2025.