

Faculty of Medicine in Rijeka

**Curriculum
2026/2027**

For course

Matematičko i računalno modeliranje ekoloških sustava

Study program: **Sanitarno inženjerstvo (R)**
University graduate study
Department: **Department of Medical Chemistry, Biochemistry and Clinical Chemistry**
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:

Matematičko i računalno modeliranje ekoloških sustava obvezni je kolegij na drugoj godini (I. trimestar) Diplomskog sveučilišnog studija Sanitarno inženjerstvo. Kolegij obuhvaća 25 sati predavanja i 20 sati računalnih vježbi, odnosno ukupno 45 sati nastave (3 ECTS boda).

Nastava se izvodi u prostorijama Medicinskog fakulteta Sveučilišta u Rijeci (predavaonice i informatička učionica).

Ciljevi kolegija

Cilj je kolegija upoznati studente s teorijskim osnovama, metodologijom i praktičnom primjenom matematičkog i računalnog modeliranja u analizi kemijskih, bioloških i ekoloških sustava. Studenti će usvojiti temeljna znanja o matematičkom opisu procesa, postavljanju i rješavanju modelnih jednadžbi te primjeni računalnih simulacija za analizu ponašanja različitih sustava.

Poseban naglasak stavlja se na formuliranje matematičkih modela na temelju bilanci tvari i energije, opisivanje kinetike kemijskih i biokemijskih procesa, procjenu parametara modela te primjenu numeričkih metoda i računalnih programa za simulaciju procesa.

Studenti će razviti sposobnost odabira odgovarajućeg matematičkog modela, analize i interpretacije rezultata simulacija te procjene pouzdanosti i ograničenja primijenjenih modela. Stečena znanja omogućit će im primjenu matematičkog i računalnog modeliranja u analizi procesa relevantnih za sanitarno inženjerstvo i zaštitu okoliša.

Sadržaj predmeta

PREDAVANJA

Osnove matematičkog i računalnog modeliranja. Uvodni pojmovi o sustavima, matematičkom modeliranju i primjeni modela. Procesni prostor, ulazne i izlazne veličine te zavisne i nezavisne varijable. Klasifikacija matematičkih modela. Računalna simulacija, upravljanje i optimiranje procesa.

Kemijska kinetika i reakcijsko inženjerstvo. Osnovni pojmovi kemijskog reakcijskog inženjerstva. Brzina kemijske reakcije i kinetika reakcija u homogenim sustavima. Teorija sudara i teorija prijelaznog stanja. Ovisnost brzine reakcije o temperaturi. Eksperimentalno određivanje brzine kemijske reakcije i formuliranje kinetičkih modela.

Bilance tvari i energije te reaktorski modeli. Bilance mase, množine tvari i energije. Matematički opis općih bilanci množine tvari. Podjela kemijskih reaktora i modeli osnovnih idealnih tipova reaktora: kotlasti, protočni kotlasti i cijevni reaktor. Eksperimentalne metode u kemijskoj kinetici i odabir eksperimentalnog reaktora.

Razvoj i analiza matematičkih modela. Odabir kinetičkog modela, procjena parametara modela i analiza pogrešaka. Postavljanje bilanci, određivanje parametara, odabir numeričkih metoda i računalna simulacija primjenom programskog paketa Berkeley Madonna. Procjena prikladnosti modela na temelju usporedbe simulacijskih i eksperimentalnih rezultata.

Modeliranje ekoloških sustava. Analiza i primjena matematičkih modela kemijskih i bioloških procesa u okolišu. Modeli s prostornom ovisnošću varijabli stanja te modeli s vremenskom i prostornom ovisnošću varijabli stanja.

Statistički i napredni modeli. Statistički i kemometrijski modeli. Linearno programiranje. Modeli umjetnih neuronskih mreža i neizrazite logike. Primjena genetičkih algoritama za prilagodbu i optimiranje modela.

RAČUNALNE VJEŽBE

Upoznavanje s programskim paketom Berkeley Madonna i osnovama njegove primjene u matematičkom i računalnom modeliranju. Determinante i matrice. Matematički opis kemijskih i biokemijskih reakcijskih mehanizama primjenom linearnih kinetičkih modela. Postavljanje bilanci tvari i simulacija matematičkih modela. Analiza i grafički prikaz rezultata računalnih simulacija.

Primjena matematičkih i računalnih modela na odabrane ekološke sustave, uključujući biološko pročišćavanje otpadnih voda te prijenos i raspodjelu onečišćivala u rijekama, jezerima i moru.

Izvođenje nastave

Kolegij se izvodi kroz predavanja i računalne vježbe. Oba oblika nastave sadržajno su usklađena s definiranim ishodima učenja.

Predavanja su usmjerena na usvajanje teorijskih osnova matematičkog modeliranja, razumijevanje kemijskih i bioloških procesa te upoznavanje s metodama razvoja, analize i primjene matematičkih modela.

Na računalnim vježbama studenti primjenjuju stečena teorijska znanja pri postavljanju i rješavanju matematičkih modela, provedbi računalnih simulacija te obradi, grafičkom prikazivanju i interpretaciji dobivenih rezultata.

Računalne vježbe izvode se u informatičkoj učionici Medicinskog fakulteta Sveučilišta u Rijeci, uz primjenu odgovarajućih računalnih programa.

Svi oblici nastave izvode se uz aktivno sudjelovanje i interakciju sa studentima.

[Ishodi učenja]:

ISHODI UČENJA ZA PREDMET

I. KOGNITIVNA DOMENA - ZNANJE

Nakon položenog kolegija student će moći:

Opisati i objasniti osnovna načela matematičkog i računalnog modeliranja, klasifikaciju matematičkih modela te mogućnosti njihove primjene u analizi kemijskih, bioloških i ekoloških sustava.

Objasniti osnovne zakonitosti kemijske kinetike, čimbenike koji utječu na brzinu kemijskih reakcija te načela formuliranja i primjene kinetičkih modela.

Opisati i objasniti načela postavljanja bilanci tvari i energije te matematičke modele osnovnih tipova kemijskih reaktora.

Objasniti postupak razvoja matematičkog modela, uključujući postavljanje modelnih jednadžbi, određivanje parametara, odabir numeričkih metoda i procjenu prikladnosti modela.

Razlikovati matematičke modele s vremenskom i prostornom ovisnošću varijabli stanja te objasniti mogućnosti njihove primjene u modeliranju procesa u okolišu.

Opisati osnovna načela statističkih i kemometrijskih modela, linearnog programiranja, umjetnih neuronskih mreža, neizrazite logike i genetičkih algoritama te mogućnosti njihove primjene u analizi i optimiranju ekoloških sustava.

II. PSIOMOTORIČKA DOMENA - VJEŠTINE

Nakon položenog kolegija student će moći:

Primijeniti odgovarajuće računalne programe, osobito Berkeley Madonna, za postavljanje i simulaciju jednostavnijih matematičkih modela kemijskih, bioloških i ekoloških procesa.

Formulirati i riješiti jednostavnije matematičke modele na temelju kinetičkih jednadžbi i bilanci tvari te analizirati utjecaj odabranih parametara na ponašanje modeliranog sustava.

Primijeniti računalne simulacije na odabrane primjere ekoloških sustava, uključujući procese biološkog pročišćavanja otpadnih voda i prijenosa onečišćivala u vodenom okolišu.

Izračunati, tablično i grafički prikazati te interpretirati rezultate računalnih simulacija, uključujući vremensku promjenu odabranih varijabli stanja sustava.

Procijeniti prikladnost i pouzdanost matematičkog modela na temelju usporedbe simulacijskih i dostupnih eksperimentalnih podataka te prepoznati moguće izvore odstupanja i ograničenja modela.

List of assigned reading:

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

List of optional reading:

1. Thibodeaux, L. J. *Environmental Chemodynamics*. John Wiley & Sons, 1996.
2. Schnoor, J. L. *Environmental Modeling: Fate and Transport of Pollutants in Water, Air, and Soil*. John Wiley & Sons, 1996.
3. Koch, A. L. *Mathematical Modeling in Microbial Ecology*. Springer, 1998.
4. Hritonenko, N., Yatsenko, Y. *Mathematical Modeling in Economics, Ecology and the Environment*. Springer, 2013.

Method of examination.:

Završni ispit polaže se u pisanom obliku i obuhvaća nastavne sadržaje predavanja i računalnih vježbi, u skladu s definiranim ishodima učenja.

Pravo pristupanja završnom ispitu ostvaruje student koji je ispunio propisane nastavne obveze i uspješno položio parcijalni test tijekom nastave.

Na pisanom završnom ispitu moguće je ostvariti najviše 50 ocjenskih bodova, uz minimalni prag uspješnosti od 50 %.

Konačna ocjena utvrđuje se na temelju ukupnog broja ocjenskih bodova ostvarenih tijekom nastave i na završnom ispitu, uz uvjet da su obje provjere znanja uspješno položene.

Detailed overview of grading within the European Credit Transfer System:

Ocjenjivanje studenata temelji se na vrednovanju znanja i vještina tijekom nastave te na pisanom završnom ispitu.

Od ukupno 100 ocjenskih bodova student može ostvariti najviše 50 bodova na parcijalnom testu tijekom nastave i 50 bodova na pisanom završnom ispitu.

Za uspješno polaganje kolegija potrebno je ostvariti najmanje 50 % uspješnosti na svakoj provjeri znanja te najmanje 50 ukupnih ocjenskih bodova.

Konačna ocjena određuje se prema ukupnom broju ostvarenih bodova:

90 – 100 bodova: izvrstan (5), A

75 – 89,99 bodova: vrlo dobar (4), B

60 – 74,99 bodova: dobar (3), C

50 – 59,99 bodova: dovoljan (2), D

Manje od 50 bodova ili nepoložena obvezna provjera znanja: nedovoljan (1), F

Detaljna raspodjela bodova, kriteriji vrednovanja pojedinih provjera znanja i uvjeti pristupanja završnom ispitu navedeni su u poglavlju „Uvjeti ispita“.

Uspješnim završetkom kolegija student ostvaruje 3 ECTS boda.

Curriculum:

Lectures 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

Practicals 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 su obvezni redovito pohađati predavanja i računalne vježbe te aktivno sudjelovati u nastavnim aktivnostima. Nastava obuhvaća 25 sati predavanja i 20 sati računalnih vježbi.

Tijekom računalnih vježbi studenti su obvezni sudjelovati u rješavanju zadataka, izradi matematičkih modela, provedbi računalnih simulacija te analizi i interpretaciji dobivenih rezultata.

Studenti su dužni pripremati se za nastavu korištenjem preporučene literature i nastavnih materijala te pravodobno izvršavati predviđene nastavne obveze.

Obveze studenata uključuju pristupanje parcijalnom testu tijekom nastave te pisanom završnom ispitu nakon ispunjavanja propisanih uvjeta.

Za uspješno završavanje kolegija potrebno je ostvariti najmanje 50 % uspješnosti na parcijalnom testu i pisanom završnom ispitu, uz ispunjavanje obveza pohađanja nastave u skladu s važećim pravilima Fakulteta.

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

UVJETI ISPITA

ECTS bodovni sustav ocjenjivanja

Vrednovanje i ocjenjivanje studenata provodi se u skladu s važećim propisima Sveučilišta u Rijeci i Medicinskog fakulteta Sveučilišta u Rijeci.

Znanje i rad studenata vrednuju se tijekom nastave putem parcijalnog testa te na pisanom završnom ispitu. Od ukupno 100 ocjenskih bodova student može ostvariti najviše 50 bodova tijekom nastave i 50 bodova na završnom ispitu.

Za uspješno polaganje kolegija student mora ostvariti najmanje 50 % uspješnosti na svakoj pojedinačnoj provjeri znanja.

Tablica 1. Raspodjela ocjenskih bodova

Oblik vrednovanja	Najveći broj bodova
I. Tijekom nastave	
Parcijalni test iz računalnih vježbi	50
Ukupno tijekom nastave	50
II. Završni ispit	
Pisani završni ispit	50
Ukupno završni ispit	50
SVEUKUPNO	100

I. Vrednovanje tijekom nastave (50 bodova)

Tijekom nastave provodi se jedan parcijalni test kojim se provjerava razumijevanje i primjena znanja stečenih na računalnim vježbama. Test obuhvaća postavljanje i rješavanje matematičkih modela, provedbu računalnih simulacija te analizu i interpretaciju rezultata.

Parcijalnim testom student može ostvariti najviše 50 ocjenskih bodova. Za uspješno polaganje potrebno je ostvariti najmanje 50 % uspješnosti, odnosno najmanje 25 ocjenskih bodova.

Studentima koji nisu položili parcijalni test ili mu nisu pristupili omogućuje se pristupanje popravnom parcijalnom testu u skladu s organizacijom nastave i važećim pravilima Fakulteta.

Student koji želi poboljšati ostvareni rezultat može pristupiti popravnom parcijalnom testu, pri čemu se kao konačan rezultat uzima rezultat posljednjeg pristupanja, neovisno o prethodno ostvarenim bodovima.

II. Završni ispit (50 bodova)

Završni ispit provodi se u pisanom obliku i obuhvaća nastavne sadržaje predavanja i računalnih vježbi, u skladu s definiranim ishodima učenja.

Na završnom ispitu student može ostvariti najviše 50 ocjenskih bodova. Za uspješno polaganje potrebno je ostvariti najmanje 50 % uspješnosti, odnosno najmanje 25 ocjenskih bodova.

III. Vrednovanje parcijalnog testa i pisanog završnog ispita

Parcijalni test i pisani završni ispit vrednuju se prema jednakim kriterijima prikazanim u Tablici 2.

Tablica 2. Pretvaranje postotka uspješnosti u ocjenske bodove

Postotak uspješnosti (%)	Ocjenski bodovi
--------------------------	-----------------

Manje od 50	0
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

IV. Uvjeti pristupanja završnom ispitu

Pravo pristupanja završnom ispitu ostvaruje student koji je:

ispunio propisane obveze pohađanja nastave;

uspješno položio parcijalni test, odnosno ostvario najmanje 25 od mogućih 50 ocjenskih bodova;

izvršio ostale nastavne obveze predviđene izvedbenim planom kolegija.

Student koji nije ostvario minimalnu uspješnost na parcijalnom testu ne može pristupiti završnom ispitu dok ne ispuni navedeni uvjet.

V. Konačna ocjena

Konačna ocjena utvrđuje se zbrajanjem ocjenskih bodova ostvarenih tijekom nastave i na završnom ispitu, uz uvjet da je student uspješno položio obje provjere znanja.

Tablica 3. Konačna ocjena prema ukupnom broju bodova

Ukupni broj bodova	ECTS ocjena	Brojčana ocjena
90 - 100	A	Izvrstan (5)
75 - 89,99	B	Vrlo dobar (4)
60 - 74,99	C	Dobar (3)
50 - 59,99	D	Dovoljan (2)
Manje od 50 ili nepoložena obvezna provjera znanja	F	Nedovoljan (1)

Za uspješno polaganje kolegija potrebno je ostvariti najmanje 50 ukupnih ocjenskih bodova, uz prethodno zadovoljene minimalne kriterije uspješnosti na parcijalnom testu i pisanom završnom ispitu.

Nakon uspješno položenog kolegija student ostvaruje 3 ECTS boda.

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

OSTALE NAPOMENE

Pohađanje nastave

Predavanja i računalne vježbe održavaju se u prostorijama Medicinskog fakulteta Sveučilišta u Rijeci. Računalne vježbe izvode se u informatičkoj učionici, prema utvrđenom rasporedu i organizaciji nastavnih skupina.

Pohađanje nastave evidentira se za sve oblike nastave. Studenti su obvezni redovito pohađati nastavu i aktivno sudjelovati u predviđenim nastavnim aktivnostima, uz dopuštene izostanke u skladu s važećim pravilima Fakulteta.

U slučaju izostanka s računalnih vježbi student je dužan, u dogovoru s nastavnikom, nadoknaditi propuštene nastavne sadržaje i izvršiti pripadajuće obveze, kada je to organizacijski moguće.

Provjere znanja

Tijekom nastave provodi se jedan parcijalni test kojim se provjerava usvojenost znanja i vještina iz računalnih vježbi. Nakon ispunjavanja propisanih nastavnih obveza studenti pristupaju pisanom završnom ispitu.

Način vrednovanja, raspodjela ocjenskih bodova, minimalni pragovi uspješnosti i uvjeti pristupanja završnom ispitu detaljno su opisani u poglavlju „Uvjeti ispita“.

Kašnjenje i izvršavanje nastavnih obveza

Od studenata se očekuje pravodoban dolazak na predavanja i računalne vježbe te odgovorno i pravodobno izvršavanje svih nastavnih obveza.

U slučaju opravdanog kašnjenja ili nemogućnosti izvršavanja pojedine obveze student se treba pravodobno obratiti predmetnom nastavniku radi dogovora o mogućnostima nadoknade, u skladu s organizacijom nastave i važećim pravilima Fakulteta.

Akadska čestitost i ponašanje tijekom nastave

Studenti su obvezni pridržavati se načela akademske čestitosti, samostalno pristupati provjerama znanja te poštovati pravila profesionalne i odgovorne komunikacije.

Tijekom predavanja i računalnih vježbi očekuje se aktivno sudjelovanje studenata i primjereno korištenje elektroničkih uređaja u nastavne svrhe.

Svi oblici akademskog nepoštenja i neprimjerenog ponašanja razmatraju se u skladu s važećim etičkim aktima Sveučilišta u Rijeci i Medicinskog fakulteta Sveučilišta u Rijeci.

Komunikacija s nastavnicima

Studenti se potiču na aktivno sudjelovanje u nastavi, postavljanje pitanja i konstruktivnu raspravu o nastavnim sadržajima.

Konzultacije s nastavnicima održavaju se prema objavljenim terminima ili u dogovoru s predmetnim nastavnikom.

Informiranje o kolegiju

Sve važne informacije o organizaciji nastave, nastavnim materijalima, provjerama znanja i ispitnim terminima objavljuju se putem sustava Merlin i drugih službenih komunikacijskih kanala Fakulteta.

Studenti su obvezni redovito pratiti objavljene obavijesti i pravodobno se informirati o svojim nastavnim obvezama.

Očekivane opće kompetencije studenata pri upisu kolegija

Od studenata se očekuje poznavanje temeljnih sadržaja iz područja kemije, matematike, statistike i informatike, stečenih tijekom prethodnog obrazovanja.

Poželjno je poznavanje osnova rada na računalu, primjene tabličnih kalkulatora (MS Excel), osnovnih postupaka statističke obrade podataka te tabličnog i grafičkog prikazivanja numeričkih rezultata.

COURSE HOURS 2026/2027

Matematičko i računalno modeliranje ekoloških sustava

Lectures (Place and time or group)	Practicals (Place and time or group)
15.10.2026	
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.: • P01 (08:00 - 10:00) ^[347] ◦ MRMES_PREDAVANJA	
prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. ^[347]	
19.10.2026	
P3,P4 Klasifikacija matematičkih modela. Osnovni pojmovi o kemijskom reakcijskom inženjerstvu. Brzine kemijskih reakcija: Osnovni pojmovi i veličine.: • P04 (10:00 - 12:00) ^[347] ◦ MRMES_PREDAVANJA	
prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. ^[347]	
22.10.2026	
P5,P6 Kinetika reakcija u homogenim sustavima. Osnove teorije o reakcijskom putu (Teorija sudara, Teorija prijelaznog stanja).: • P02 (11:00 - 12:00) ^[347] ◦ MRMES_PREDAVANJA • P09 - TEACHING IN ENGLISH (12:00 - 13:00) ^[347] ◦ MRMES_PREDAVANJA	
prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. ^[347]	
23.10.2026	
	V1,V2. Uvodne napomene o programskom paketu „Berkeley Madonna“. Determinante i matrice.: • P03 - IT CLASSROOM (11:00 - 13:00) ^[347] ◦ MRMES_1 • P03 - IT CLASSROOM (13:00 - 15:00) ^[347] ◦ MRMES_2
prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. ^[347]	
27.10.2026	
	V3,V4. Analiza i primjena matematičkih modela u različitim kemijskih i biokemijskim procesima. - 1. DIO: • P09 - TEACHING IN ENGLISH (10:00 - 12:00) ^[347] ◦ MRMES_2 • P09 - TEACHING IN ENGLISH (12:00 - 14:00) ^[347] ◦ MRMES_2
prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. ^[347]	
28.10.2026	

P7,P8 Ovisnost brzine reakcije o temperaturi. Eksperimentalni podaci i brzina kemijske reakcije. Kinetički model.: • P09 - TEACHING IN ENGLISH (08:00 - 09:00) ^[347] ◦ MRMES_PREDAVANJA • P09 - TEACHING IN ENGLISH (09:00 - 10:00) ^[347] ◦ MRMES_PREDAVANJA	
prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. ^[347]	
29.10.2026	
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.: • P01 (10:00 - 11:00) ^[347] ◦ MRMES_PREDAVANJA • V (11:00 - 12:00) ^[347] ◦ MRMES_PREDAVANJA	
prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. ^[347]	
30.10.2026	
	V5,V6 Analiza i primjena matematičkih modela u različitim kemijskih i biokemijskim procesima. - 2 DIO: • P03 - IT CLASSROOM (08:00 - 10:00) ^[347] ◦ MRMES_1 • P03 - IT CLASSROOM (13:00 - 15:00) ^[347] ◦ MRMES_2
prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. ^[347]	
02.11.2026	
	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 - IT CLASSROOM (08:00 - 10:00) ^[347] ◦ MRMES_2 • P03 - IT CLASSROOM (10:00 - 12:00) ^[347] ◦ MRMES_1
prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. ^[347]	
04.11.2026	
P11 Eksperimentalne metode u kinetici. Izbor eksperimentalnog reaktora. Izbor kinetičkog modela, procjena vrijednosti parametara modela, analiza grešaka.: • P09 - TEACHING IN ENGLISH (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).: • P09 - TEACHING IN ENGLISH (09:00 - 10:00) ^[347] ◦ MRMES_PREDAVANJA	
prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. ^[347]	

05.11.2026

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:

- P09 - TEACHING IN ENGLISH (08:00 - 10:00) ^[347]
 - MRMES_PREDAVANJA

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

06.11.2026

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:

- P09 - TEACHING IN ENGLISH (11:00 - 13:00) ^[347]
 - MRMES_PREDAVANJA

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

10.11.2026

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

- v (11:00 - 14:00) ^[347]
 - MRMES_PREDAVANJA

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

11.11.2026

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

- P01 (08:00 - 10:00) ^[347]
 - MRMES_PREDAVANJA

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

16.11.2026

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 - IT CLASSROOM (08:00 - 10:00) ^[347]
 - MRMES_2
- P03 - IT CLASSROOM (10:00 - 12:00) ^[347]
 - MRMES_1

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

19.11.2026

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. Prihvatanje ili odbacivanje modela. - 1. DIO: • P15 - TOWN HALL (08:00 - 10:00) ^[347] ◦ MRMES_PREDAVANJA	
prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. ^[347]	
20.11.2026	
	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: • P09 - TEACHING IN ENGLISH (08:00 - 10:00) ^[347] ◦ MRMES_1 • P09 - TEACHING IN ENGLISH (10:00 - 12:00) ^[347] ◦ MRMES_2
prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. ^[347]	
23.11.2026	
	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 - IT CLASSROOM (08:00 - 10:00) ^[347] ◦ MRMES_1 • P03 - IT CLASSROOM (10:00 - 12:00) ^[347] ◦ MRMES_2
prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. ^[347]	
24.11.2026	
	V15,V16 Optimiranje procesa uz uporabu eksperimentalnih rezultata. Simulacija procesa pomoću matematičkog modela. Procjena vrijednosti parametara modela. Prihvatanje ili odbacivanje modela. - 1. DIO: • P03 - IT CLASSROOM (11:00 - 13:00) ^[347] ◦ MRMES_2 • P03 - IT CLASSROOM (13:00 - 15:00) ^[347] ◦ MRMES_1
prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. ^[347]	
26.11.2026	

P23,P24 Optimiranje procesa uz uporabu eksperimentalnih rezultata. Simulacija procesa pomoću matematičkog modela. Procjena vrijednosti parametara modela. Prihvatanje 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: • P15 - TOWN HALL (08:00 - 10:00) ^[347] ◦ MRMES_PREDAVANJA	
prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. ^[347]	
27.11.2026	
	V17,V18 Optimiranje procesa uz uporabu eksperimentalnih rezultata. Simulacija procesa pomoću matematičkog modela. Procjena vrijednosti parametara modela. Prihvatanje ili odbacivanje modela. - 2. DIO: • P09 - TEACHING IN ENGLISH (08:00 - 10:00) ^[347] ◦ MRMES_1 • P09 - TEACHING IN ENGLISH (10:00 - 12:00) ^[347] ◦ MRMES_2
prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. ^[347]	
01.12.2026	
	V19,V20 Viševarijabilni modeli. Linearni modeli. Nelinearni. Nelinearni dinamički modeli. PCA (glavne komponente) modeli.: • P09 - TEACHING IN ENGLISH (11:00 - 13:00) ^[347] ◦ MRMES_1 • P09 - TEACHING IN ENGLISH (13:00 - 15:00) ^[347] ◦ MRMES_2
prof. dr. sc. Broznić Dalibor, dipl. sanit. ing. ^[347]	

List of lectures, seminars and practicals:

LECTURES (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	P01
P3,P4 Klasifikacija matematičkih modela. Osnovni pojmovi o kemijskom reakcijskom inženjerstvu. Brzine kemijskih reakcija: Osnovni pojmovi i veličine.	2	P04
P5,P6 Kinetika reakcija u homogenim sustavima. Osnove teorije o reakcijskom putu (Teorija sudara, Teorija prijelaznog stanja).	2	P02 P09 - TEACHING IN ENGLISH
P7,P8 Ovisnost brzine reakcije o temperaturi. Eksperimentalni podaci i brzina kemijske reakcije. Kinetički model.	2	P09 - TEACHING IN ENGLISH
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	P01 v
P11 Eksperimentalne metode u kinetici. Izbor eksperimentalnog reaktora. Izbor kinetičkog modela, procjena vrijednosti parametara modela, analiza grešaka.	1	P09 - TEACHING IN ENGLISH

P12 Eksperimentalne metode u kinetici. Izbor eksperimentalnog reaktora. Izbor kinetičkog modela, procjena vrijednosti parametara modela, analiza grešaka (II).	1	P09 - TEACHING IN ENGLISH
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	P09 - TEACHING IN ENGLISH
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	P09 - TEACHING IN ENGLISH
P17,P18 Primjeri matematičkih modela uz prostornu ovisnost veličina stanja. Primjeri modela uz vremensku i prostornu ovisnost veličina stanja. - 1. DIO	2	v
P19,P20 Primjeri matematičkih modela uz prostornu ovisnost veličina stanja. Primjeri modela uz vremensku i prostornu ovisnost veličina stanja. - 2. DIO	2	P01
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. Prihvatanje ili odbacivanje modela. - 1. DIO	2	P15 - TOWN HALL
P23,P24 Optimiranje procesa uz uporabu eksperimentalnih rezultata. Simulacija procesa pomoću matematičkog modela. Procjena vrijednosti parametara modela. Prihvatanje 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	P15 - TOWN HALL
P25 Viševarijabilni modeli. Linearni modeli. Nelinearni. Nelinearni dinamički modeli. PCA (glavne komponente) modeli. Modeli neizrazite logike (Fuzzy logic). Neuronske mreže. - 2. DIO	1	

PRACTICALS (TOPIC)	Number of hours	Location
V1,V2. Uvodne napomene o programskom paketu „Berkeley Madonna“. Determinante i matrice.	2	P03 - IT CLASSROOM
V3,V4. Analiza i primjena matematičkih modela u različitim kemijskih i biokemijskim procesima. - 1. DIO	2	P09 - TEACHING IN ENGLISH
V5,V6 Analiza i primjena matematičkih modela u različitim kemijskih i biokemijskim procesima. - 2 DIO	2	P03 - IT CLASSROOM
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 - IT CLASSROOM
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 - IT CLASSROOM
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	P09 - TEACHING IN ENGLISH

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 - IT CLASSROOM
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 - IT CLASSROOM
V17,V18 Optimiranje procesa uz uporabu eksperimentalnih rezultata. Simulacija procesa pomoću matematičkog modela. Procjena vrijednosti parametara modela. Prihvaćanje ili odbacivanje modela. - 2. DIO	2	P09 - TEACHING IN ENGLISH
V19,V20 Viševarijabilni modeli. Linearni modeli. Nelinearni. Nelinearni dinamički modeli. PCA (glavne komponente) modeli.	2	P09 - TEACHING IN ENGLISH

EXAM DATES (final exam):

1.	13.01.2027.
2.	27.01.2027.
3.	23.06.2027.
4.	07.09.2027.