

Sveučilište u Rijeci
Fakultet informatike i digitalnih tehnologija
Radmile Matejčić 2, Rijeka

Akadska godina 2026./2027.

OSNOVNI PODATCI O KOLEGIJU		
Naziv kolegija	Strojno i duboko učenje	
Studijski program	Sveučilišni diplomski studij Informatika	
Status kolegija	obvezni za modul IIS	
Semestar	2.	
Bodovna vrijednost i nastavno opterećenje	Broj ECTS bodova	6
	Broj sati (P+V+S)	30+30+0
Nositelj/ica kolegija	prof. dr. sc. Marina Ivašić-Kos	
E-mail	marinai@inf.uniri.hr	
Ured	O-510	
Vrijeme konzultacija	Utorkom nakon nastave, 13:30-14:30, uz prethodni dogovor e-mailom	
Asistent/ica	Kristina Host	
E-mail	kristina.host@inf.uniri.hr	
Ured	O-521	
Vrijeme konzultacija	četvrtkom od 14:00 do 15:00 uz prethodni dogovor e-mailom	
DETALJNI OPIS KOLEGIJA		
<i>Ciljevi kolegija</i>		
Cilj predmeta je predstaviti područja primjene umjetne inteligencije te osnovne postupke strojnog i dubokog učenja s pregledom mogućnosti njihove primjene. Predmet obuhvaća dva osnovna pristupa strojnog učenja: nadzirano učenje (klasifikacija i regresija) i nenadzirano učenje (grupiranje) te ključne gradivne elemente i metode učenja dubokih modela.		
<i>Uvjeti za upis kolegija</i>		
Nema uvjeta za upis predmeta.		
<i>Očekivani ishodi učenja za kolegij</i>		
Očekuje se da nakon izvršavanja svih programom predviđenih obveza studenti budu sposobni:		
11. Usporediti prednosti i nedostatke temeljnih algoritama strojnog učenja posebno onih koji se odnose na klasifikaciju, grupiranje i linearne regresiju.		
12. Prikupiti i pretprocesirati podatke za strojno/duboko učenje, izlučiti značajke te odabrati najpovoljniji skup značajki za reprezentaciju podataka.		
13. Analizirati i primijeniti odgovarajuće metode strojnog učenja pri rješavanju konkretnih problema klasifikacije, grupiranja i regresije.		
14. Analizirati i odabrati metode dubokog učenja koje su prikladne za nadzirano, polunadzirano i nenadzirano učenje.		
15. Vrednovati performanse i interpretirati rezultate modela te temeljem toga odabrati najbolji model strojnog ili dubokog učenja za zadani problem.		
16. Dizajnirati i primijeniti model dubokog učenja za samostalno definirani problem strojnog učenja.		

17. Diskutirati područja primjene umjetne inteligencije te objasniti povezane probleme kao što su objašnjivost, interpretabilnost, transparentnost, zaštitu osobnih podataka i etičke izazove u raznim područjima primjene umjetne inteligencije.

Sadržaj kolegija

Na kolegiju se obrađuju sljedeći sadržaji:

- Intelligentni sustavi, definicije, povijest, područja primjene. (I1, I4, I7)
- Uvod u strojno učenje, pregled pojmova i definicija. Primjeri zadataka strojnog učenja. (I1, I4)
- Nenadzirano učenje i pronalaženje čestih uzoraka. Metode grupiranja podataka: metoda k-srednjih vrijednosti. (I1, I3, I5)
- Nadzirano učenje. Problemi klasifikacije i regresije. Metode nadziranog strojno učenje: linearne metode, metoda k najbližih susjeda, stabla i pravila odlučivanja, metode strojno potpornih vektora. (I1-I3, I5)
- Metode evaluacije. Vrednovanje i odabir modela. (I3, I5, I7)
- Skupovi podataka i predprocesiranje (nepotpuni, nepostojeći, strukturirani i nestrukturirani). Reprezentacija podataka: odabir, rangiranje i izlučivanje značajki. Normalizacija. (I2)
- Umjetne neuronske mreže. Perceptron. Višeslojni perceptron. (I1, I3, I6, I7)
- Arhitektura višeslojne neuronske mreže, aktivacijske funkcije i principi učenja. Regularizacija parametara, overfitting i generalizacija. (I1, I3, I4)
- Uvod u duboko učenje. Pregled pojmova i definicija. (I1, I7)
- Osnovna arhitektura duboke neuronske mreže, hiperparametri, funkcije gubitka, algoritmi optimizacije. (I2, I3, I6)
- Tipične arhitekture dubokih neuronskih mreža (CNN, RNN, ...). (I1, I4)
- Konvolucijske neuronske mreže i primjena na slikovnim podacima. (I2, I4, I7)
- Problem objašnjivosti, interpretabilnosti, transparentnosti modela. Pravni okviri i etički izazovi. Zaštita osobnih podataka. (I5, I7)
- Korištenje okolina i servisa za definiranje arhitekture duboke neuronske mreže i razvoj aplikacija dubokog učenja (npr. TensorFlow, Keras i Google Colab). (I1-I7)

<i>Način izvođenja nastave</i>	☒ predavanja	☒ samostalni zadaci
	☒ seminari i radionice	☐ multimedija i mreža
	☒ vježbe	☒ laboratorij
	☒ obrazovanje na daljinu	☐ mentorski rad
	☐ terenska nastava	☒ problemska nastava
	☒ učenje temeljeno na izazovima iz stvarnoga svijeta	☐ ostalo _____

<i>Komentari</i>	Svi materijali s predavanja i vježbi, korisni linkovi i literatura te obavijesti vezano za izvedbu predmeta kao i prostori za dostavu rezultata kolokvija i projekata studentima su dostupni putem sustava za e-učenje. Na predmetu se kombinira samostalni rad prilikom usvajanja koncepata i timski i projektni rad pri rješavanju konkretnih problema.
------------------	---

Obvezna literatura (u trenutku prijave prijedloga studijskog programa)

1. Christopher M. Bishop (2007.), Pattern Recognition and Machine Learning, Springer

2. Ian Goodfellow and Yoshua Bengio and Aaron Courville: Deep Learning, The MIT Press, 2016.
3. Josh Patterson, Adam Gibson, Deep Learning, A practitioner's approach, O'Reilly Media, 2017
4. Aurélien Géron. Hands-On Machine Learning with Scikit-Learn, Keras and TensorFlow, O'Reilly, Media 2019.

Dopunska literatura (u trenutku prijave prijedloga studijskog programa)

1. Christopher Molnar (2022.), Interpretable Machine Learning: A Guide for Making Black Box Models Explainable, Leanpub, <https://christophm.github.io/interpretable-ml-book/>
2. Kevin P. Murphy (2012.), Machine Learning, MIT Press
3. François Chollet (2018.), Deep learning with Python, Manning, NY
4. Nikhil Buduma, Nicholas Locascio (2017.), Fundamentals of Deep Learning, "O'Reilly Media, Inc."
5. Sadržaji pripremljeni za učenje putem sustava za učenje.

Načini praćenja kvalitete koji osiguravaju stjecanje izlaznih znanja, vještina i kompetencija

Predviđa se periodičko provođenje evaluacije s ciljem osiguravanja i kontinuiranog unapređivanja kvalitete nastave i studijskog programa (u okviru aktivnosti Odbora za osiguravanje i unaprjeđivanje kvalitete Fakulteta informatike i digitalnih tehnologija). U zadnjem tjednu nastave provodit će se anonimna evaluacija kvalitete održane nastave od strane studenata. Provest će se i analiza uspješnosti studenata na kolegiju (postotak studenata koji su položili kolegij i prosjek njihovih ocjena).

Jezik izvođenja nastave Hrvatski jezik

Mogućnost izvođenja na stranom jeziku Ne

OBVEZE, PRAĆENJE RADA I VREDNOVANJE STUDENATA

Konstruktivno povezivanje

Vrsta aktivnosti	ECTS bodovi			Ishodi učenja	Specifična aktivnost	Metoda procjenjivanja	Bodovi (max.)
	Ukupno	Praktičan rad	Timski projektni rad				
Pohađanje nastave i aktivnosti u nastavi	2	1	0	1-5,7	Prisutnost studenata	Popisivanje (evidencija)	0
					Aktivnost na kolegiju, samostalno rješavanje zadataka	0-15 bodova ovisno o razini aktivnosti na kolegiju i stupnju točnosti/potpunosti samostalnog rješavanja zadataka	15
Kolokviji	1,5	1,5	0	1,3,4,5	Kontinuirane provjere znanja koje student rješava samostalno na računalu	0-35 bodova ovisno o stupnju točnosti i potpunosti rješavanja zadataka u provjeri znanja	35
Eksperimentalni zadaci	1	1	1	1,3-5	Rješavanje eksperimentalnog zadatka i dokumentiranje rješenja za zadani problem	0-20 ovisno o potpunosti, funkcionalnosti i objašnjenju rješenja	20
Ispit – Projektni zadatak	1,5	1,5	1,5	1,2,5,6,7	Rješavanje i obrazlaganje praktičnih problema iz područja AI (Definiranje projektnog zadatka, obrada i priprema podataka, izvođenje eksperimenta s prezentacijom i dokumentacijom)	0-30 bodova ovisno o potpunosti, funkcionalnosti i objašnjenju definiranog modela	30
UKUPNO	6	5	2,5				100

Obveze i vrednovanje studenata – puna nastavna satnica

1. Pohađanje nastave i aktivnosti u nastavi

Nastava se izvodi u hibridnom modelu, kombinacijom izravne, učioničke nastave i *online* oblika nastave uz pomoć sustava za e-učenje prema rasporedu koji je prikazan tablicom u nastavku. Studenti su dužni koristiti sustav za e-učenje Merlin (<https://moodle.srce.hr/>) gdje će se objavljivati informacije o kolegiju, materijali za učenje, zadaci za vježbu, zadaci za domaće zadaće i slične aktivnosti te obavijesti vezane za izvođenje nastave (putem foruma Obavijesti).

Studenti koji studiraju u punoj nastavnoj satnici (u redovitom i izvanrednom statusu) dužni su redovito pohađati nastavu prema predviđenom rasporedu, aktivno sudjelovati u aktivnostima tijekom izvođenja nastave te izvršavati aktivnosti kolegija u okviru sustava Merlin koje će nastavnici najavljivati putem foruma.

2. Aktivnost

Tijekom semestra student je dužan biti aktivan na nastavi i samostalno rješavati dodijeljene zadatke.

Svojom aktivnošću i rješavanjem zadataka tijekom vježbi ili domaćih zadaća student može ostvariti do 15 ocjenskih bodova.

3. Kolokviji

Tijekom semestra student je dužan samostalno riješiti više praktičnih zadataka koji uključuju primjenu metoda strojnog i dubokog učenja obrađenih na vježbama. Tijekom nastave na kolegiju predviđena su dva kolokvija koji se izvode na računalima. Pisanje oba kolokvija je obavezno. Student može rješavanjem kolokvija ostvariti do 35 ocjenskih bodova.

Za pristup završnom ispitu potrebno je ostvariti 40% bodova na svakom kolokviju. Studentima koji nisu ostvarili uvjet prolaska će se omogućiti popravak jednog kolokvija na samom kraju semestra u dogovorenom terminu. U tom slučaju novoostvareni bodovi zamjenjuju prethodno postignute bodove.

Studentima koji su zbog opravdanih razloga (pravdano liječničkom ispričnicom) izostali s pisanja kolokvija, na kraju semestra omogućit će se nadoknada kolokvija. Opravdani izostanak potrebno je prijaviti e-mailom asistentu koji provodi vježbe najkasnije na dan pisanja kolokvija, prije termina kolokvija. Studenti koji su opravdano izostali s kolokvija dužni su dostaviti valjanu ispričnicu najkasnije 10 dana od datuma pisanja kolokvija kako bi ostvarili mogućnost nadoknade. Studenti koji to ne učine, neće biti u mogućnosti naknadno pisati kolokvij.

4. Eksperimentalni zadaci (učenje temeljeno na izazovima iz stvarnoga svijeta, problemska nastava)

Tijekom semestra student će dobiti eksperimentalne zadatke na zadanu temu koji uključuju primjenu recentnih metoda dubokog učenja na zadanim zadacima kao što su klasifikacija, predviđanje, detekcija, segmentacija i praćenje objekata, generiranje sadržaja. Studenti ih rješavaju samostalno ili u paru. Tijekom rješavanja identificiraju izazove, analiziraju problem i obrazlažu postignuta rješenja. O provedenom istraživanju, korištenim metodama i modelima te postignutim rezultatima student je dužan napraviti kratki izvještaj te iste predstaviti u za to predviđenom terminu.

Aktivnost nema prag prolaza, a maksimalno nosi 20 ocjenskih bodova.

4. Ispit - Projektni zadatak: definiranje zadatka, izrada eksperimenta i predstavljanje rezultata (učenje temeljeno na izazovima iz stvarnoga svijeta, problemska nastava)

Za projektni zadatak student treba proučiti odgovarajuću literaturu i samostalno odabrati temu problemskog zadatka iz nekog od relevantnih područja primjene umjetne inteligencije (raspoznavanje uzoraka, računarski vid, biometrija, bio-informatika, ...). Kroz ovaj praktični projektni zadatak student primjenjuje teorijske osnove i znanja o različitim metodama strojnog i dubokog učenja i primjenjuje ih na odgovarajućem problemu kojeg je sam osmislio.

Student treba osmisliti i definirati projektni zadatak, odabrati podatke i odgovarajuće metode strojnog i dubokog učenja ili različite metode dubokog učenja koje će koristiti i prilagoditi za učenje modela i rješavanje zadatka. Provedene korake eksperimenta treba dokumentirati u izvještaju i usmeno prezentirati na završnom ispitu.

Izveštaj treba uključivati motivaciju, zadatak koji se rješava, opis podataka koji se koriste za učenje i testiranje modela (statistiku) i metoda koje će se koristiti u eksperimentu, zatim usporedbu, opis eksperimenta, analizu dobivenih rezultata za odabrane metode kod različitih postavka eksperimenta prikladne za rješavanje danog zadatka (hiperparametri, parametri učenja, augmentacija podataka, pomaci domene, prijenosi znanja,...) i objašnjenje najboljeg rezultata koji je postignut.

Na projektu se može raditi u paru, timu ili samostalno. U slučaju rada u paru ili timu, članovi tima trebaju podijeliti uloge.

Osmišljavanje projekta, izvršenje eksperimenta i njegova elaboracija, dokumentiranje i obrazlaganje nose do 30 bodova. Bodovi će biti dodijeljeni prema unaprijed definiranim kriterijima kao što je funkcionalnosti definiranog modela, potpunost i objašnjenje rezultata usmeno i u izvještaju korištenjem usvojenih teorijskih koncepata.

Završni ispit nosi udio od maksimalno 30 ocjenskih bodova, a smatra se položenim samo ako na njemu student postigne minimalno 50%-ni uspjeh (ispitni prag je 50% uspješno riješenih zadataka).

Ocjenjivanje

Kontinuiranim radom tijekom semestra na prethodno opisani način studenti mogu ostvariti najviše 70 ocjenskih bodova, a da bi mogli pristupiti ispitu moraju ostvariti 50% i više ocjenskih bodova (minimalno 35) koje je bilo moguće steći kroz kontinuirano vrednovanje, uz zadovoljenje dodatnih uvjeta propisanih ovim izvedbenim planom.

Ispit nosi udio od maksimalno 30 ocjenskih bodova. Na ispitu student mora ostvariti barem 50% od ocjenskih bodova koje je bilo moguće steći na ispitu kako bi ostvario ECTS bodove kolegija odnosno kako bi uspješno položio kolegij.

Ako je ispit prolazan, konačnu ocjenu na kolegiju čini zbroj ocjenskih bodova postignutih u kontinuiranom praćenju i vrednovanju i ocjenskih bodova postignutih na ispitu. U suprotnom, student ima pravo pristupa ispitu još 2 puta (ukupno do 3 puta tijekom akademske godine).

Konačna ocjena ostvarenosti ishoda učenja na kolegiju

Ocjena ostvarenosti ishoda učenja na kolegiju donosi se kako slijedi:

- za ostvarenih 90 do 100% ocjenskih bodova ocjena izvrstan (5), slovna ocjena A,
- za ostvarenih 75 do 89% ocjenskih bodova ocjena vrlo dobar (4), slovna ocjena B,
- za ostvarenih 60 do 74% ocjenskih bodova ocjena dobar (3), slovna ocjena C,
- za ostvarenih 50 do 59% ocjenskih bodova ocjena dovoljan (2), slovna ocjena D,
- za ostvarenih do 49% ocjenskih bodova ocjena nedovoljan (1), slovna ocjena F.

Sve granične vrijednosti postotaka navedene iznad uključive su za pripadnu ocjenu.

Ispitni termini

24.06.2027.
07.07.2027.
01.09.2027.
08.09.2027.

SATNICA IZVOĐENJA NASTAVE – ljetni (II.) semestar akademske godine 2026./2027.

Nastava će se na kolegiju odvijati u ljetnom semestru prema sljedećem rasporedu:

predavanja: utorkom u 12:00 u O-S32

vježbe: četvrtkom u 16:00 u O-366

Tj.	Datum	Prostor ¹	Tema	Nastava ²	Izvođač(i)
1.	02.03.	O-S32	Opće informacije. Uvod u predmet.	P1 i V1	prof. dr. sc. Marina Ivašić-Kos Kristina Host
2.	09.03.	O-S32	Inteligentni sustavi, definicije, povijest, područja	P2	prof. dr. sc. Marina Ivašić-Kos
2.	11.03.	O-366	Alati za strojno učenje Biblioteke, rad s funkcijama, učitavanje podataka	V2	Kristina Host
3.	16.03.	O-S32	Uvod u strojno učenje. Priprema podataka za strojno učenje.	P3	prof. dr. sc. Marina Ivašić-Kos
3.	18.03.	365	Priprema podataka za strojno učenje	V3	Kristina Host
4.	23.03.	O-S32	Grupiranje i algoritmi za grupiranje (k-srednjih vrijednosti, EM algoritam)	P4	prof. dr. sc. Marina Ivašić-Kos
4.	25.03.	O-366	Grupiranje	V4	Kristina Host
5.	30.03.	O-S32	Regresija. Linearna regresija. Kvadratna regresija	P5	prof. dr. sc. Marina Ivašić-Kos
5.	01.04.	O-366	Grupiranje, regresija	V5	Kristina Host
6.	06.04.	O-S32	Klasifikacija i metode klasifikacija (k-NN, SVM, ...). Analiza i priprema podataka za izvođenje eksperimenta. Izlučivanje značajki.	P6	prof. dr. sc. Marina Ivašić-Kos
6.	08.04.	O-366	Metode klasifikacije.	V6	Kristina Host
7.	13.04.	O-S32	Faze provedbe eksperimenta. Evaluacija, analiza i unaprjeđenje modela	P7	prof. dr. sc. Marina Ivašić-Kos
7.	15.04.	online	Metode klasifikacije.	V7	Kristina Host
8.	20.04.	O-S32	Neuronske mreže. Jednoslojni i višeslojni perceptron.	P8	prof. dr. sc. Marina Ivašić-Kos
8.	22.04.	O-366	Kolokvij	V8	Kristina Host
9.	27.04.	O-S32	Duboko učenje. Duboke konvolucijske neuronske mreže.	P9	prof. dr. sc. Marina Ivašić-Kos
9.	29.04.	O-366	Neuronske mreže, Duboke neuronske mreže	V9	Kristina Host
10.	04.05.	O-S32	Učenje modela. Podešavanje hiperparametara.	P10	prof. dr. sc. Marina Ivašić-Kos
10.	06.05.	O-366	Duboke konvolucijske neuronske mreže	V10	Kristina Host
11.	11.05.	O-S32/ online	Arhitekture dubokih neuronskih mreža: Rekurentne neuronske mreže (RNN, LSTM).	P11	prof. dr. sc. Marina Ivašić-Kos
11.	13.05.	online	Autoenkoderi	V11	Kristina Host
12.	18.05.	O-S32/ online	Autoenkoderi. Transformeri.	P12	prof. dr. sc. Marina Ivašić-Kos

¹ Upisati broj prostorije ili online

² Upisati P za predavanja ili V za vježbe

12.	20.05.	O-366	Postojeće duboke neuronske mreže	V12	Kristina Host
13.	25.05.	O-S32	Postojeće duboke neuronske mreže (Open world, VIT, VL modeli): Predstavljanje studija slučaja	P13	prof. dr. sc. Marina Ivašić-Kos
13.	27.05.	online	Postojeće duboke neuronske mreže	V13	Kristina Host
14.	01.06.	O-S32	Primjeri korištenja postojećih modela dubokih neuronske mreže: Predstavljanje i analiza rezultata eksperimenta	P14	prof. dr. sc. Marina Ivašić-Kos
14.	03.06.	O-366	Kolokvij	V14	Kristina Host
15.	08.06.	O-S32	Problem objašnjivosti, interpretabilnosti, transparentnosti modela. Zaključna razmatranja.	P15	prof. dr. sc. Marina Ivašić-Kos
15.	10.06.	O-366	Ispravak kolokvija	V15	Kristina Host

Predviđeno je fleksibilno izvođenje nastave koja se po potrebi može održati u virtualnom okruženju.