

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

Akadska godina 2026./2027.

OSNOVNI PODATCI O KOLEGIJU		
Naziv kolegija	Programiranje za umjetnu inteligenciju	
Studijski program	Sveučilišni diplomski studij Informatika	
Status kolegija	obvezni za modul IIS	
Semestar	1.	
Bodovna vrijednost i nastavno opterećenje	Broj ECTS bodova	6
	Broj sati (P+V+S)	30+30+0
Nositelj/ica kolegija	Prof. dr. sc. Ana Meštrović	
E-mail	amestrovic@uniri.hr	
Ured	O-511	
Vrijeme konzultacija	Srijedom od 13:00 sati (uz prethodni dogovor e-mailom)	
Asistent/ica	Dr. sc. Karlo Babić	
E-mail	karlo.babic@uniri.hr	
Ured	O-419	
Vrijeme konzultacija	Utorkom u 10:00 sati (uz prethodni dogovor emailom)	
DETALJNI OPIS KOLEGIJA		
Ciljevi kolegija		
Cilj kolegija je usvajanje temeljnih znanja iz područja programiranja za umjetnu inteligenciju što uključuje modeliranje i implementaciju inteligentnih agenata, primjenu logičkih formalizama i deklarativnog programiranja u zaključivanju te razvoj višeagentnih sustava. Nadalje, kolegij uključuje upoznavanje s osnovama neuronskih mreža i učenja i implementaciju jednostavnih modela neuronskih mreža. Dodatno, cilj kolegija je dati pregled suvremenih trendova te pružiti osvrt na filozofska i etička pitanja povezana s razvojem i primjenom umjetne inteligencije.		
Uvjeti za upis kolegija		
Nema uvjeta za upis kolegija.		
Očekivani ishodi učenja za kolegij		
Očekuje se da nakon izvršavanja svih programom predviđenih obveza studenti budu sposobni:		
11. Objasniti definicije i koncepte vezane uz pojam umjetne ineligencije, inteligentnih agenata i višeagentnih sustava.		
12. Implementirati odabranu tehniku numeričke linearne algebre za rješavanje zadanog problema iz područja umjetne inteligencije.		
13. Izabrati efikasan algoritam za rješavanje odabranih problema iz područja umjetne inteligencije.		
14. Kritički prosuditi i odabrati odgovarajuće tehnike deklarativnog programiranja za rješavanje postavljenog problema iz područja umjetne inteligencije.		
15. Primijeniti napredne tehnike programiranja zasnovane na povezivanju deklarativnog programiranja i drugih programskih paradigmi za pristup podacima i pripremu podataka za obradu.		
16. Analizirati postupak i opravdanost uvođenja elemenata umjetne inteligencije i inteligentnih agenata u informacijskih sustav.		

17. Implementirati module inteligentnih informacijskih sustava koristeći programske jezike za umjetnu inteligenciju i podatkovnu analitiku uz primjenu odgovarajućih programskih modula.		
18. Kritički raspraviti o etičkim i filozofskim pitanjima vezanim uz umjetnu inteligenciju		
Sadržaj kolegija		
Na kolegiju se obrađuju sljedeći sadržaji:		
– Pregled koncepata umjetne inteligencije, povijesni razvoj, trendovi, izazovi i ograničenja. (I1) – Implementacija različitih tipova inteligentnih agenata, okoline; tipovi agenata. (I2, I3, I4) – Napredne tehnike rješavanja problema u području UI: implementacija algoritama informiranog pretraživanja, adversarialnog pretraživanja u okviru mplementacie agenata za igre. (I2, I3, I4, I5) – Implementacija agenata temeljenih za znanju: reprezentacija znanja, logički formalizmi, primjena deklarativne programske paradigmeu psotupcima zaključivanja. – Višeagentni sustavi: koordinacija i emergentno ponašanje; simulacije kolektivnog ponašanja. (I5, I6, I7) – Implementacija neuronskih mreža i analiza metoda treniranja. Pregled različitih arhitektura neuronskih mreža. Duboke neuronske mreže, generativna umjetna inteligencija i primjene. Pregled osnova i primjene temeljnih modela (foundation models) i veliki jezični modeli (large language models). (I5, I6, I7) – Etika i filozofska pitanja u domeni umjetne inteligencije. (I8)		
Način izvođenja nastave	☒ 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 _____
Komentari		
Obvezna literatura (u trenutku prijave prijedloga studijskog programa)		
1. Russell, S., Norvig, P., & Intelligence, A. A modern approach. Artificial Intelligence. Prentice-Hall, Egnlewood Cliffs, 25(27), 79-80. (2022). 2. Chollet, F., & Chollet, F. Deep learning with Python. simon and schuster. (2021). 3. Jacob T. Vanderplas, Jake VanderPlas, Python Data Science Handbook, O'Reilly Media (2016.).		
Dopunska literatura (u trenutku prijave prijedloga studijskog programa)		
1. Charniak, Eugene, Christopher K. Riesbeck, Drew V. McDermott, and James R. Meehan. Artificial intelligence programming. Psychology Press, 2014. 2. Mark Hall, Ian W. Witten, Eibe Frank, Mark A. Hall, Christopher J. Pall (2017.), Data Mining, Practical Machine Learning Tools and Techniques, Morgan Kaufmann		
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	I1-I8	Prisutnost studenta	Popisivanje (evidencija)	0
Kontinuirana provjera teorijskog znanja	0,75	0,25	0	I1-I8	2 kratka testa iz teorijskog dijela	0-5 bodova ovisno o stupnju točnosti i potpunosti za oba kolokvija	10
Kontinuirana provjera praktičnog znanja	1,25	1,25	0	I1-I8	Praktični kolokvij	0-25 bodova ovisno o stupnju točnosti i potpunosti	25
Projektni zadatak	1	1	0	I3, I4, I5	Tijekom semestra studenti dobivaju za rješavanje projektni zadatak	0-30 bodova prema stupnju točnosti i potpunosti.	35
Ispit	1	0	0	I1-I8			30
UKUPNO	6	3,5	0				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. Kontinuirana provjera teorijskog znanja

Tijekom semestra pišu se dva kratka kolokvija iz teorije. Svaki kolokvij nosi po 5 bodova. Ova aktivnost **nema praga** prolaza.

3. Kontinuirana provjera praktičnog znanja (problemska nastava)

Tijekom semestra piše se jedan praktični kolokvij koji nosi 25 bodova. Ova aktivnost **nema praga** prolaza.

4. Projektni zadatak (problemska nastava)

Tijekom semestra studenti će dobiti jedan projektni zadatak vezan uz razvoj agenta. Projektni zadatak nosi 35 bodova. Za izlazak na ispit potrebno je postići najmanje 50% bodova iz projektnog zadatka.

4. Ispit (problemska nastava)

Ispit sastoji se od teorijskog dijela ispitivanja i zadataka koji obuhvaća cjelokupno gradivo obrađeno na predavanjima kroz cijeli semestar. Ispit nosi 30 bodova, a potrebno je skupiti najmanje 15 bodova za prolaz.

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

10.2.2027.
24.2.2027.
9.3.2027.
25.8.2027.

SATNICA IZVOĐENJA NASTAVE – zimski (1.) semestar akademske godine 2026./2027.

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

predavanja: četvrtkom u 10:00 u S-32

vježbe: srijedom u 14:00 u 366

Tj.	Datum	Prostor ¹	Tema	Nastava ²	Izvođač(i)
1.	07.10.26.	366	Uvod, sadržaj vježbi i obveze na vježbama. Zadavanje projekta (rok za upload projekta 26.01.2027. 09:00h ujutro). Jednostavni agenti bazirani na refleksima ("roomba").	V	Karlo Babić
1.	08.10.26.	S-32	Uvod, motivacija. Sadržaj predavanja. Obaveze studenata.	P	Ana Meštrović
2.	14.10.26.	366	Minimax ("gomoku") 1	V	Karlo Babić
2.	15.10.26.	S-32	Inteligentni agenati i okoline.	P	Ana Meštrović
3.	21.10.26.	366	Minimax ("gomoku") 2	V	Karlo Babić
3.	22.10.26.	S-32	Algoritmi pretraživanja. Adversarial search.	P	Ana Meštrović
4.	28.10.26.	366	Agenti temeljeni na logici i znanju ("wumpus world") 1	V	Karlo Babić
4.	29.10.26.	online	Primjena logičkih formalizama i logičkog programiranja u području umjetne inteligencije – uvod	P	Ana Meštrović
5.	04.11.26.	366	Agenti temeljeni na logici i znanju ("wumpus world") 2	V	Karlo Babić
5.	05.11.26.	S-32	Primjena logičkih formalizama i logičkog programiranja u području umjetne inteligencije – logički agenti. Višegametni sustavi.	P	Ana Meštrović
6.	11.11.26.	366	Multiagentno ponašanje ("flocking") 1	V	Karlo Babić
6.	12.11.26.	S-32	1. kviz iz teorije	P	Ana Meštrović
7.	18.11.26.	-	-	V	Karlo Babić
7.	19.11.26.	online	Primjena logičkih formalizama i logičkog programiranja u području umjetne inteligencije – logički agenti – dio 2	P	Ana Meštrović
8.	25.11.26.	366	Multiagentno ponašanje ("flocking") 2	V	Karlo Babić
8.	26.11.26.	S-32	Pregled trendova u razvoju područja UI: simbolička i konekcionistačka umjetna inteligencija; generativna UI	P	Ana Meštrović
9.	02.12.26.	366	Pathfinding 1	V	Karlo Babić
9.	03.12.26.	S-32	Uvod u neuronske mreže	P	Ana Meštrović
10.	09.12.26.	366	Praktični kolokvij	V	Karlo Babić
10.	10.12.26.	S-32	Neuronske mreže i duboko učenje	P	Ana Meštrović
11.	16.12.26.	366	Pathfinding 2	V	Karlo Babić
11.	17.12.26.	S-32	Neuronske mreže i duboko učenje – dio 2	P	Ana Meštrović
12.	23.12.26.	366	Python priprema, programiranje perceptrona Linearna algebra – osnove za neuronske mreže/duboko učenje	V	Karlo Babić
12.	7.1.27.	S-32	2. kviz iz teorije	P	Ana Meštrović
13.	13.01.27.	366	Neuronske mreže, treniranje	V	Karlo Babić
13.	14.01.27.	online	Primjena dubokog učenja u različitim domenama.	P	Ana Meštrović
14.	20.01.27.	366	Rad na agentima za turnir / testiranje	V	Karlo Babić

¹ Upisati broj prostorije ili online

² Upisati P za predavanja ili V za vježbe

14.	21.01.27.	S-32	Genrativna UI	P	Ana Meštrović
15.	27.01.27.	366	Prezentiranje projekata Turnir agenata	V	Karlo Babić
15.	28.01.27.	S-32	Filozofski i etički aspekti umjetne inteligencije	P	Ana Meštrović