OPĆE INFORMACIJE							
Nositelj kolegija	Krešimir Markota, pred.						
Naziv kolegija	Uvod u umjetnu inteligenciju						
Studijski program	Stručni prijediplomski studij Mehatronika						
Status kolegija	Izboran						
Godina	3.	**Semestar**	5.				
Bodovna vrijednost i način izvođenja nastave	**ECTS koeficijent opterećenja studenata**	**4**					
	Broj sati (P+V+S)	30 + 15 + 0	P	V		S	
				AV	LV		
			30	0	15	0	

OPIS KOLEGIJA

Ciljevi kolegija

Naučiti osnovne principe umjetne inteligencije

Uvjeti za upis kolegija

Jednaki uvjetima za pristupanje stjecanju kvalifikacije.

Očekivani ishodi učenja za kolegij

Skupovi ishoda učenja		Ishodi učenja	
SIU1	Uvod u umjetnu inteligenciju (2 ECTS-a)	**I1**	Opisati vrijednosti koje primjena umjetne inteligencije donosi za zadano područje
		I2	Analizirati postupke osnovnih metoda i algoritma iz područja umjetne inteligencije
SIU2	Primjena umjetne inteligencije (2 ECTS-a)	**I3**	Za definirani problem i metodu rješavanja, izraditi rješenje ili unaprijediti postojeći programski kod primjenom naučenih metoda
		I4	Ocjenjivati aplikacije i pozadinske algoritme korištene za njihovu realizaciju te kritički procijeniti njihovu efikasnost i alternative

Sadržaj kolegija

1. Osnove umjetne inteligencije(I1, I2)

Definicija umjetne inteligencije. Povijest razvoja umjetne inteligencije i etičke kontroverze (automatizacija rada, distopijske vizije AI-a). Primjene umjetne inteligencije u različitim područjima s naglaskom na potencijalne etičke dileme. Uvod u strojno učenje. Nenadgledano i nadgledano učenje. Regresijske i klasifikacijske metode. Klasteriranje podataka. Eksplorativna analiza podataka. Prikaz i tumačenje podataka.

2. Korištenje alata prilikom grafičkog prikazivanja podataka (I2)

Primjena različitih Python biblioteka za analizu skupova podataka poput: Pandas, Seaborn, Matplotlib, OS, OpenCv, Numpy, Scipy. Iscrtavanje različitih vrsta grafova pomoću Seaborn i Matplotlib biblioteke. Tehnike čišćenja i nadopuna nedostajućih podataka. Uklanjanje šumova iz podataka. Skaliranje podataka.

Standardizacija i normalizacija podataka. Pristranost u podacima i utjecaj na interpretaciju vizualizacija. Manipulacija grafičkim prikazima podataka i etičke implikacije.

3. Definiranje različitih modela strojnog učenja(I3)

Korištenje Tensorflow i Scikit learn biblioteke za definiranje modela. Linearne i nelinearne metode. Jednostruka i višestruka linearna regresija. Polinomna regresija. Stroj s potpornim vektorom. Metode smanjenja dimenzionalnosti. Neuronske mreže. Konvolucijske neuronske mreže. KNN model. Pristranost u treniranju modela i etičke posljedice automatiziranih odluka. Transparentnost i objašnjivost AI modela: trebaju li korisnici razumjeti kako model donosi odluke?

4. Prostorno pretraživanja stanja i prirodom inspirirani algoritmi (I3)

Problem pretraživanja prostora stanja. Algoritmi slijepog pretraživanja. Heuristika i usmjerena pretraživanja. A* pretraživanje. Genetski algoritmi i optimizacija roja čestica. Upotreba AI u automatiziranim sustavima donošenja odluka i problem odgovornosti.

5. Ocjenjivanje dobrote modela (I4)

Križna validacija. Matrica zabune. Točnost, preciznost, Odziv, F1-mjera. Huberova pogreška. Srednja apsolutna pogreška(MAE) i srednja kvadratna pogreška(MSE). Koeficijent determinacije(R-squared). Etička pitanja u evaluaciji modela: kako osigurati da modeli ne diskriminiraju određene skupine? Pogrešne metrike i posljedice njihovog korištenja u realnim sustavima.

6. Etička pitanja u primjeni umjetne inteligencije

Etička načela u umjetnoj inteligenciji: transparentnost, pravičnost, odgovornost i privatnost. Pogreške i pristranosti u podacima: problem diskriminacije i neetičnih modela. Odluke modela i odgovornost: tko je odgovoran za odluke koje donosi AI? Privatnost i zaštita podataka: etički problemi kod obrade osobnih podataka. Manipulacija kroz umjetnu inteligenciju: deepfake tehnologija i etičke dileme. Primjena AI u kritičnim sektorima (zdravstvo, financije, pravosuđe) i etičke posljedice.

Vrste izvođenja nastave	☒ predavanja ☐ seminari i radionice ☒ vježbe ☐ obrazovanje na daljinu ☐ terenska nastava	☒ samostalni zadaci ☐ multimedija i mreža ☒ laboratorij ☐ mentorski rad ☐ ostalo: obrnuta učionica

Obveze studenata

- **Pohađanje predavanja i laboratorijskih vježbi sukladno pravilniku o studiranju**

Praćenje rada studenata

Pohađanje nastave	X	Aktivnost u nastavi		Seminarski rad		Eksperimentalni rad	
Pismeni ispit		Usmeni ispit	X	Esej		Istraživanje	
Projekt	X	Kontinuirana provjera znanja		Referat		Praktični rad	X
Portfolio							

Ocjenjivanje i vrednovanje rada studenata tijekom nastave i na završnom ispitu

Kontinuirana provjera:

SIU	Ishodi	Projektni zadatak	Usmeni ispit	Prag	Max
SIU1	I1	20%		10%	20%
	I2	25%		12.5%	25%
SIU2	I3	25%		12.5%	25%
	I4	20%		10%	20%
			10%	5%	
	Ukupno	**90%**	**10%**	**50%**	**100%**

Ispitni rok:

SIU	Ishodi	Projektni zadatak	Usmeni ispit	Prag	Max
SIU1	I1	15%		7.5%	15%
	I2	20%		10%	20%
SIU2	I3	30%		15%	30%
	I4	25%		12.5%	25%
			10%	5%	
	Ukupno	**90%**	**10%**	**50%**	**100%**

Ocjenjivanje kolegija:
Temeljem sume svih ostvarenih bodova na kolegiju, ocjena se definira sukladno sljedećoj tablici:

Raspon bodova	Ocjena ispita
0,00 – 49,99	nedovoljan (1)
50,00 – 59,99	dovoljan (2)
60,00 – 74,99	dobar (3)
75,00 – 89,99	vrlo dobar (4)
90,00 – 100,00	izvrstan (5)

Obvezna literatura i broj primjeraka u odnosu na broj studenata koji trenutačno pohađaju nastavu na kolegiju

Naslov	Broj primjeraka	Broj studenata
● Krešimir Markota : Prezentacije predavanja i vježbi iz predmeta „Uvod u umjetnu inteligenciju“, Veleučilište u Bjelovaru.		30
		30
		30
		30
		30

Dopunska literatura

- Russell, Stuart J; Norvig, Peter (2020.), Artificial Intelligence: A Modern Approach, Prentice-Hall
- Patterson D.W. Introduction to Artificial Intelligence and Expert Systems
- Haykin, S. Neural Networks – A Comprehensive Foundation, 2nd edition
- C.M. Bishop Pattern Recognition and Machine Learning

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

Provođenje studentskih anketa i evaluacija podataka prema rezultatima Povjerenstva za provođenje studentske ankete.
Analiza indikatora kvalitete koja analizira studiranje studenata, prolaznost na ispitima, zaposlenost završenih studenata i druge pokazatelje kvalitete.
Redovito ažuriranje i osuvremenjivanje kolegija.