

OPĆE INFORMACIJE						
Nositelj kolegija	Krešimir Markota, pred.					
Naziv kolegija	Računalni vid					
Studijski program	Stručni prijediplomski studij Mehatronika					
Status kolegija	Izboran					
Godina	3.	Semestar			6.	
Bodovna vrijednost i način izvođenja nastave	ECTS koeficijent opterećenja studenata	4				
	Broj sati (P+V+S)	20 + 25 + 0	P	V		S
				AV	LV	
				20	0	25
OPIS KOLEGIJA						
Ciljevi kolegija						
Cilj predmeta je izraditi programsko rješenje za interpretaciju i analizu podataka s digitalnih slika primjenom algoritmima računalnoga vida.						
Uvjeti za upis kolegija						
Jednaki uvjetima za pristupanje stjecanju kvalifikacije.						
Očekivani ishodi učenja za kolegij						
Skupovi ishoda učenja		Ishodi učenja				
SIU1	Osnove obrade slike i računalnog vida (4 ECTS-a)	I1	Razlikovati metode za upravljanje digitalnom slikom, formatima i modelom kamere			
		I2	Primijeniti osnovne algoritme i operacije za obradu digitalne slike			
		I3	Primijeniti osnovne algoritme za analizu slike iz područja računalnog vida			
		I4	Analizirati programska rješenja zasnovana na algoritmima obrade slike i računalnog vida			
		I5	Implementirati programsko rješenje zasnovano na algoritmima obrade slike i računalnog vida			
Sadržaj kolegija						
1. Uvod (Ishod I1) Fizika vida. Uvod u računarski vid. Pregled softverske podrške za analizu slike (Tensorflow, PyTorch, OpenCV). Prikaz slike u računalu. 2. Kamera i akvizicija (Ishod I1, I2) Pregled hardverske podrške za akviziciju slike. Tipovi kamera. Komunikacijski protokoli za prijenos slike. Osvjetljenje. Parametri slike prilikom akvizicije. Matematički model kamere. Kalibracija kamere. 3. Obrada slike (Ishod I2) Regija interesa. Osnovni operatori na slici. Rotiranje slike. Zrcaljenje slike. Deformacija slike. Filtriranje slike. Zaglađivanje slike. Značajke slike. 4. Analiza slike (Ishod I3, I4) Morfološka obrada slike. Izdvajanje rubova. Detekcija oblika. Histogrami. Detekcija lica. 5. OpenCV (Ishod I2, I3, I5)						

Pregled OpenCV biblioteke za predobradu i analizu slike. Akvizicija slike. Obrada i analiza slike. Primjeri iz prakse.

6. Napredne aplikacije i primjena (Ishod I4, I5)

Robotski vid. Dobivanje dubinske slike iz jedne kamere. Dobivanje dubinske slike iz dvije kamere (stereo vid). OCR. Detekcija objekata. Klasifikacija slika.

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

Obveze studenata

- Prisutnost na 70% laboratorijskih vježbi za redovite studente
- Prisutnost na 50% laboratorijskih vježbi za izvanredne studente
- Izrada projektnog zadatka

Praćenje rada studenata

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

Ocjenjivanje i vrednovanje rada studenata tijekom nastave i na završnom ispitu

Kontinuirana provjera:

SIU	Ishodi	Obrana projektnog zadatka	Prag	Max
SIU1	I1	20%	10%	20%
	I2	20%	10%	20%
	I3	20%	10%	20%
	I4	20%	10%	20%
	I5	20%	10%	20%
	Ukupno	100%	50%	100%

Izrada projektnog zadatka obvezna je za svakog studenta i izrađuje se samostalno. Temu projektnog zadatka student dogovara s nositeljem kolegija. Projekt se odnosi na razvoj jednostavnog rješenja iz područja računalnog vida. Student je obavezan analizirati problem, odabrati odgovarajuće metode i alate za obradu i

analizu slike ili videa, implementirati rješenje te provesti njegovo testiranje i evaluaciju. Student je prošao kolegij ako je na obrani projektnog zadatka ostvario broj bodova koji je veći ili jednak definiranom pragu za svaki ishod učenja. Ostvareni bodovi na položenim ishodima učenja brišu se godinu dana nakon početka semestra u kojem se kolegij izvodi.

Ispitni rok:

SIU	Ishodi	Obrana projektnog zadatka	Prag	Max
SIU1	I1	20%	10%	20%
	I2	20%	10%	20%
	I3	20%	10%	20%
	I4	20%	10%	20%
	I5	20%	10%	20%
	Ukupno	100%	50%	100%

Izrada projektnog zadatka obvezna je za svakog studenta i izrađuje se samostalno. Temu projektnog zadatka student dogovara s nositeljem kolegija. Projekt se odnosi na razvoj jednostavnog rješenja iz područja računalnog vida. Student je obavezan analizirati problem, odabrati odgovarajuće metode i alate za obradu i analizu slike ili videa, implementirati rješenje te provesti njegovo testiranje i evaluaciju. Student je prošao kolegij ako je na obrani projektnog zadatka ostvario broj bodova koji je veći ili jednak definiranom pragu za svaki ishod učenja. Ostvareni bodovi na položenim ishodima učenja brišu se godinu dana nakon početka semestra u kojem se kolegij izvodi.

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
--------	-----------------	----------------

Ante Javor: Prezentacije predavanja i vježbi s predmeta Računalni vid, dostupno na sustavu za e-učenje Merlinu	online	30
Dopunska literatura		
• Rafael C. Gonzales, Richard E. Woods, Digital image processing, Person, 2017 4. izdanje. • Richard Szelinski, Computer Vision: Algorithms and Application, Springer, 2021		
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.		