Sveučilište Sjever

Preddiplomski stručni studij Multimedija, oblikovanje i primjena

ISVU šifra	Naziv predmeta	Status predmeta	Semestar
294841	Osnove umjetne inteligencije	Izborni	3

Tip predmeta	Oblici nastave (ukupan broj sati u semestru)				Samostalni rad (sati)	ECTS
	P	S	V	E-učenje		
Opći	15	30	0		30	3

Nastavnik	dr.sc. Vedran Kruljac, pred. doc.dr.sc. Tomislav Volarić
Suradnik	
Cilj predmeta	Studentima će biti omogućeno procijeniti sigurnu i pravilnu uporabu sustava umjetne inteligencije u suvremenome multimedijskom okruženju. Usporedbom odgovarajuće uporabe različitih metoda, alata i tehnika umjetne inteligencije kod studenata će se potvrditi njihove multimedijske kompetencije. Uporaba sustava umjetne inteligencije i njihovih prikaza od strane studenata bit će opravdana postupanjem u skladu s pravnim i etičkim pravilima.
Ishodi učenja	1. 1. utvrditi temeljne koncepte umjetne inteligencije, strojnih metoda i reprezentacije znanja 2. 2. kritički prosuditi pravne, regulativne i etičke izazove koje donosi uporaba sustava umjetne inteligencije u različitim domenama 3. 3. predvidjeti rizike, odgovornosti i mehanizme regulacije sustava umjetne inteligencije.
Uvjeti za upis predmeta (odslušan ili položen kolegij) te potrebna znanja i vještine	Nema preduvjeta
Vrste izvođenja predmeta	Predavanja Seminar i radionice E-učenje
Komentari	
Obveze studenata	• Popuniti online obrazac inicijalne samoevaluacije • Aktivno sudjelovanje u nastavi i online aktivnostima • Proučavati znanstvenu i stručnu literaturu, analizirati i vrednovati stručne tekstove, sintetizirati saznanja iz njih, primjeniti ih prilikom izrade sminarskog rada te ih prikazati prilikom prezentacije seminarskog rada • Ispuniti periodične online obrasce izvješća o ostvarenim zadatcima i obvezama. Isti će biti dostupni na stranicama kolegija • Osmisliti i prijaviti temu seminarskog rada, sukladno uputama na mrežnim stranicama kolegija • Izraditi i prezentirati seminarski rad • Participirati u recenzijama seminarskih radova, sukladno uputama na mrežnim stranicama kolegija • Nadopuniti i ispraviti seminarski rad sukladno recenzijama • Participirati u zajedničkom projektu izrade zbornika seminarskih radova i zbornika prezentacija • Popuniti online obrazac finalne samoevaluacije

Sadržaj predmeta

Nastavna cjelina	Oblici nastave (sati)			
	Predavanja	Seminari	Vježbe	E-učenje

Umjetna inteligencija (Uvod. Inteligentni agenti). Rješavanje problema (Rješavanje problema pretraživanjem. Pretraživanje u složenim okruženjima. Problemi zadovoljavanja ograničenja. Suparničko pretraživanje i igre.). Znanje, zaključivanje i planiranje (Logički agenti. Logika prvog reda. Zaključivanje u logici prvog reda. Predstavljanje znanja. Automatizirano planiranje.) Neizvjesno znanje i zaključivanje (Kvantificiranje neizvjesnosti. Probabilističko zaključivanje. Probabilističko zaključivanje tijekom vremena. Donošenje jednostavnih odluka. Donošenje složenih odluka. Višeagentsko odlučivanje. Probabilističko programiranje.). Strojno učenje (Učenje iz primjera. Znanje u učenju. Učenje probabilističkih modela. Duboko učenje. Učenje s potkrepljenjem.). Komunikacija, opažanje i djelovanje (Obrada prirodnog jezika. Duboko učenje za obradu prirodnog jezika. Robotika. Računalni vid.). Zaključci (Filozofija, etika i sigurnost umjetne inteligencije. Budućnost umjetne inteligencije.).	15			
Uredba o umjetnoj inteligenciji. Zabranjene prakse u području umjetne inteligencije. Visokorizični sustavi umjetne inteligencije. Obveze u pogledu transparentnosti za dobavljače određenih sustava umjetne inteligencije i subjekte koji ih uvode. Modeli umjetne inteligencije opće namjene. Mjere za potporu inovacijama. Upravljanje. Baza podataka EU-a za visokorizične sustave umjetne inteligencije. Praćenje nakon stavljanja na tržište, razmjena informacija i nadzor tržišta. Kodeksi ponašanja i smjernice. Delegiranje ovlasti i postupak odbora. Sankcije. Stvaranje sveobuhvatnog okvira za suzbijanje dezinformacija i jačanje integriteta informacija. Provedba politika za povećanje transparentnosti, odgovornosti i pluralizma izvora informacija. Poticanje društvene otpornosti na dezinformacije.		30		

Obvezna literatura	1. Russell, Stuart i Norvig, Peter: Artificial Intelligence: A Modern Approach (4th ed.), Pearson, 2022. (odabrana poglavlja 2. Uredba (EU) 2024/1689 Europskog parlamenta i Vijeća od 13. lipnja 2024. o utvrđivanju usklađenih pravila o umjetnoj inteligenciji i o izmjeni uredaba (EZ) br. 300/2008, (EU) br. 167/2013, (EU) br. 168/2013, (EU) 2018/858, (EU) 2018/1139 i (EU) 2019/2144 t 3. OECD: Facts not Fakes: Tackling Disinformation, Strengthening Information Integrity, OECD Publishing, 2024. (odabrani dijelovi)
Dopunska literatura	1. Floridi, Luciano: The Ethics of Artificial Intelligence, Oxford University Press, 2019. (odabrana poglavlja) 2. Goodfellow, Ian; Bengio, Yoshua i Courville, Aaron: Deep Learning, MIT Press, 2016. (odabrana poglavlja) 3. Hildebrandt, Mirelle: Law for Computer Scientists and Other Folk, Oxford University Press, 2020. (odabrana poglavlja) 4. UNESCO: Recommendation on the Ethics of Artificial Intelligence, UNESCO, 2021. (odabrane odredbe)

Način provjere ishoda učenja	Za svaku aktivnost polaznicima kolegija dodjeljuje se određen broj bodova. Svi bodovi bilježe se u online sustav za evaluaciju i razvoj kompetencija (posebno razvijeni moduli LMS sustava). Vrednuju se sljedeće aktivnosti: 1) Aktivnost na predavanjima, prijava i obrazloženje teme seminarskog rada: 10 % bodova 2) Seminarski rad: 30 % bodova 3) Prezentacija seminarskog rada: 30 % bodova 4) Online aktivnost, kvaliteta analiza i recenzija prijava i seminarskih radova: 30 % bodova. Svaki student radi analize i recenzije prijava i seminarskih radova te sudjeluje prilikom evaluacije prezentacija prema točno definiranim kriterijima. Sve recenzije rade se anonimno. Na naslovnim stranicama seminarskih radova nigdje se ne pojavljuje ime autora. Imena autora pridodaju se tek finalnim verzijama pripremljenim za objavu. Provjera i evaluacija ovog segmenta provodi se tako da se uspoređuju rezultati analiza i recenzija svakog studenta s analizom i recenzijama nastavnika. Veća podudarnost s nastavničkim recenzijama donosi veći broj bodova za studente.
Završni / Diplomski rad	Da