[Medicinski fakultet u Rijeci]

Curriculum
2021/2022

[Za kolegij]

Umjetna inteligencija

Study program:	**Medicina (R)** (elective) [Sveučilišni integrirani prijediplomski i diplomski studij]
Department:	**[Centar za biomodeliranje i inovacije u medicini]**
Course coordinator:	**izv. prof. dr. sc. Maričić Sven**
Year of study:	**2**
ECTS:	**1.5**
Incentive ECTS:	**0 (0.00%)**
Foreign language:	**Possibility of teaching in a foreign language**

Course information:

Pregled područja i razvoj umjetne inteligencije (UI). Turingov test. Važnost i perspektiva umjetne inteligencije u biomedicini. Topologija neuralnih mreža. Metode i tehnike umjetne inteligencije. Osnovni koncept strojnog učenja. Primjena neuralnih mreža, genetskog algoritma. Robotika i umjetna inteligencija u biomedicinskom području. Rad s podacima – procjena osnovnih parametara putem slikovnog zapisa. Perspektiva UI u biomedicinskim sustavima. Trendovi primjene i smjer budućeg razvoja.

List of assigned reading:

- Russel S., Norvig P.: Artificial Intelligence: A Modern Approach, 2021, ISBN: 978-0134610993
- Topol E.: Deep Medicine: How Artificial Intelligence Can Make Healthcare Human Again, 2019, ISBN: 978-1541644632
- Agah A.: Medical Applications of Artificial Intelligence, CRC Press 2017, ISBN: 978-1138072275

List of optional reading:

- Smith B., C.: The Promise of Artificial Intelligence, MIT press 2019, ISBN: 978-0262043045
- Crayton E.D.: Redefining Life Sciences with Artificial Intelligence and Blockchain, 2019, ISBN: 978-1795786737

Curriculum:

[Seminari] list (with titles and explanation):

Uvod u kolegij, pregled razvoja umjetne inteligencije. Osnovni pojmovi.

Pregled područja i dosadašnjeg razvoja umjetne inteligencije (UI). Pregled seminarskih tema.

Koncept i struktura neuralnih mreža. Strojno učenje. Turingov test.

Osnovne postavke, zadaci neuralnih mreža. Njihova uloga i primjena kod strojnog učenja. Elementi Turingovog testa. Važnost i značenje u biomedicinskom području.

Koncept neuralnih mreža. Koncept genetskog algoritma.

Primjena neuralnih mreža u laboratorijskom okruženju. Prikaz koncepta genetskog algoritma. Definiranje važnih parametara.

Primjena u biomedicinskoj robotici.

Analiza primjera iz biomedicinske robotike. Prednosti i nedostaci uporabe umjetne inteligencije u biomedicinskoj robotici.

Različita uporaba umjetne inteligencije: laboratorijski primjeri, klinički primjeri.

Analiza uporabe sustava baziranih na umjetnoj inteligenciji s naglaskom na laboratorijske i kliničke primjere. Prednosti uporabe, načini korištenja. Potencijalni nedostaci i ograničenja tehnologije.

Napredna tehnološka rješenja. Primjena u biomedicinskim sustavima.

Napredna tehnološka rješenja temeljena na primjeni umjetne inteligencije. Prikaz primjene u biomedicinskim sustavima. Prikaz tehnološkog rješenja.

Trendovi, budućnost razvoja umjetne inteligencije.

Pregled trendova razvoja. Naglasak na pratkičnu primjenu umjetne inteligencije.

Student obligations:

Redovito pohađanje nastave, pisanje seminarskog rada.

Exam (exam taking, description of the written/oral/practical part of the exam, point distribution, grading criteria):

Other notes (related to the course) important for students:

-

COURSE HOURS 2021/2022

Umjetna inteligencija

[Seminari] (Place and time or group)

List of lectures, seminars and practicals:

[SEMINARI] (TOPIC)	Number of hours	Location
Uvod u kolegij, pregled razvoja umjetne inteligencije. Osnovni pojmovi.	3	
Koncept i struktura neuralnih mreža. Strojno učenje. Turingov test.	4	
Koncept neuralnih mreža. Koncept genetskog algoritma.	3	
Primjena u biomedicinskoj robotici.	4	
Različita uporaba umjetne inteligencije: laboratorijski primjeri, klinički primjeri.	3	
Napredna tehnološka rješenja. Primjena u biomedicinskim sustavima.	4	
Trendovi, budućnost razvoja umjetne inteligencije.	4	

EXAM DATES (final exam):