[Medicinski fakultet u Rijeci]

Curriculum
2021/2022

[Za kolegij]

Uvod u medicinsko odlučivanje

Study program:	**Medicina (R)** (elective) [Sveučilišni integrirani prijediplomski i diplomski studij]
Department:	**[Katedra za biomedicinsku informatiku]**
Course coordinator:	**prof. dr. sc Bilić-Zulle Lidija, dipl. inž., specijalist med. biokemije**
Year of study:	**4**
ECTS:	**1.5**
Incentive ECTS:	**0 (0.00%)**
Foreign language:	**No**

Course information:

Kolegij **Uvod u medicinsko odlučivanje** je izborni predmet na IV. godini Integriranog preddiplomskog i diplomskog sveučilišnog studija Medicina koji se održava u zimskom semestru, a sastoji se od 5 sati predavanja i 20 sati seminara, ukupno 25 sati (1,5 ECTS).

Cilj kolegija je omogućiti studentima upoznavanje s procesom odlučivanja, formalizacijom odlučivanja te objasniti i razumjeti izabrane metode odlučivanja s izravnom primjenom u medicini, a uz pomoć digitalnih alata višekriterijskog odlučivanja.

Sadržaj predmeta je sljedeći:
Sadržaj kolegija obuhvaća tumačenje i usvajanje informacija i o procesu i formalizaciji odlučivanja, posljedicama odlučivanja, procjeni rizika odlučivanja, pravilima odlučivanja, metodama odlučivanja utemeljenim na znanju, primjeni strojnog učenja, prepoznavanja uzoraka, umjetnih neuronskih mreža i umjetne inteligencije u procesu donošenja odluka u medicini.
Medicinsko odlučivanje je središnji postupak u medicinskoj praksi i znanosti. Kako bi preuzeli primjerenu odgovornost medicinski djelatnici trebaju imati jasno osviješten proces odlučivanja i temeljiti ga na racionalnom procesu i sukladno medicini i medicinskoj praksi temeljenoj na dokazima. Bez obzira na način, put i potporu procesu donošenja odluke, odgovornost za odluku uvijek ostaje na medicinskom djelatniku i pacijentu koji odluku prihvaća.
Odlučivanje je kognitivni proces tijekom kojega se iz niza mogućnosti izabire jedna. Odlučivanje može biti intuitivno ili argumentirano te pristrano ili nepristrano, a kvaliteta odluke jasno je ovisna od ulaznih varijabli koje mogu biti rezultati učenja, pretraživanja i mjerenja, od kojih je svaki postupak podložan iskrivljenjima. Informacijska tehnologija omogućuje potporu u medicinskom odlučivanju korištenjem različitih metoda temeljenih na znanju, a mogućnošću pretraživanja velike količine informacija i obrade podataka u kratkom vremenu te strojnog učenja može doprinijeti racionalnom donošenju odluke.

ISHODI UČENJA ZA PREDMET:
I. KOGNITIVNA DOMENA – ZNANJE
1. Definirati proces odlučivanja i koncept formalizacije odlučivanja.
2. Identificirati metode odlučivanja utemeljene na znanju, opisati prednosti i nedostatke
3. Usporediti metodu stabla odlučivanja i pravila odlučivanja
4. Usporediti metode prepoznavanja uzoraka i umjetnih neuronskih mreža
5. Opisati primjenu umjetne inteligencije u procesu donošenja odluka u medicini.

II.PSIHOMOTORIČKA DOMENA – VJEŠTINE

1. Izraditi model odlučivanja primjenom metode stabla odlučivanja.

Izvođenje nastave:
Nastava se izvodi u online obliku na platformi Merlin.

Studentu je obveza pripremiti gradivo o kojem se raspravlja o temama iz sadržaja kolegija tijekom webinara i na forumima online kolegija.

Nastavnik ocjenjuje sudjelovanje studenta u radu tijekom izvođenja online kolegija prema predviđenim aktivnostima (pokazano znanje, razumijevanje, sposobnost postavljanja problema, zaključivanje, itd.).

List of assigned reading:

1. Coiera Enrico, Guide to health informatics, CRC Press, London, 2015.

List of optional reading:

1. Medicine, https://journals.lww.com/md-journal/pages/default.aspx

Curriculum:

[Predavanja] list (with titles and explanation):

P1-2 Uvod u process odlučivanja i koncept formalizacije odlučivanja

Ishodi učenja: Definirati proces odlučivanja i koncept formalizacije odlučivanja.

P3-4 Metode odlučivanja utemeljene na znanju

Ishodi učenja: Identificirati metode odlučivanja utemeljene na znanju, opisati prednosti i nedostatke.

P5 Stablo odlučivanja i pravila odlučivanja

Ishodi učenja: Usporediti metodu stabla odlučivanja i pravila odlučivanja

[Seminari] list (with titles and explanation):

S1-5 Informacije o procesu i formalizaciji odlučivanja. Posljedice odlučivanja. Procjena rizika odlučivanja.

Ishodi učenja: Identificirati posljedice (ishode) odlučivanja i potencijalne rizike donesenih odluka

S6-10 Odabrane metode odlučivanja utemeljene na znanju (AHP, ANP, stablo odlučivanja, pravila odlučivanja)

Ishodi učenja: Identificirati metode odlučivanja utemeljene na znanju, opisati prednosti i nedostatke.

S11-15 Uvod u metode strojnog učenja

Ishodi učenja: Usporediti metodu neuronske mreže i metodu prepoznavanja uzoraka

S16-20 Alati za primjenu metoda odlučivanja

Ishod učenja: Izraditi model odlučivanja u izabranom alatu

Student obligations:

Studenti su obvezni tijekom online nastave redovito pratiti online predavanja (webinare), koristiti interaktivne nastavne materijale, aktivno sudjelovati u primjeni online testova za samoprovjeru i/ili provjeru stečenih znanja, biti aktivni u vođenim diskusijama, izradi postavljenih zadataka bilo samostalnih ili u timu, izraditi prezentaciju završnog projekta izrade modela odlučivanja prema izabranoj metodi koja predstavlja završni ispit.

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

ECTS bodovni sustav ocjenjivanja:
Ocjenjivanje studenata provodi se prema važećem Pravilniku o studijima Sveučilišta u Rijeci, te prema Pravilniku o ocjenjivanju studenata na Medicinskom fakultetu u Rijeci (usvojenog na Fakultetskom vijeću Medicinskog fakulteta u Rijeci).
Rad studenata vrednovat će se i ocjenjivati tijekom izvođenja nastave, te na završnom ispitu. Od ukupno 100 bodova, tijekom nastave student može ostvariti 70 bodova, a na završnom ispitu 30 bodova.
I. Tijekom nastave vrednuje se (maksimalno do 70 bodova):
Vrednovanje rada studenta provoditi će se kontinuirano (formativno i sumativno vrednovanje) na način da će se vrednovati aktivnosti poput praćenja webinara, uporabe interaktivnih nastavnih materijala, aktivnost primjene online testova za samoprovjeru i /ili provjeru stečenih znanja, aktivnosti u vođenim diskusijama, izradi postavljenih zadataka bilo samostalnih ili u timu u čije vrednovanje mogu biti uključeni i ostali polaznici.

II. Završni ispit (do 30 bodova)
Završni ispit se sastoji od prezentacije projekta u kojem je izrađenmodel odlučivanja primjenom metode stabla odlučivanja na temu iz područja biomedicine. Maksimalan broj bodova koji se može ostvariti je 30 ocjenskih bodova. Minimum za prolazak završnog ispita je 15 ocjenskih bodova.

Tko može pristupiti završnom ispitu:
Završnom ispitu može pristupiti svaki student koji je stekao najmanje 35 ocjenskih bodova tijekom nastave.

Tko ne može pristupiti završnom ispitu:
• Studenti koji su tijekom nastave ostvarili 0 do 34,9 bodova ili koji imaju 30% i više izostanaka s nastave. Takav student je neuspješan (1) F i ne može izaći na završni ispit, tj. mora predmet ponovno upisati naredne akademske godine.

III. Konačna ocjena je zbroj ECTS ocjene ostvarene tijekom nastave i na završnom ispitu:

Konačna ocjena	
A (90-100%)	izvrstan (5)
B (75-89,9%)	vrlo dobar (4)
C (60-74,9%)	dobar (3)
D (50-59,9%)	dovoljan (2)
F (studenti koji su tijekom nastave ostvarili manje od 35 bodova ili nisu položili završni ispit)	nedovoljan (1)

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

-

COURSE HOURS 2021/2022
Uvod u medicinsko odlučivanje

[Predavanja] (Place and time or group)	**[Seminari]** (Place and time or group)

List of lectures, seminars and practicals:

[PREDAVANJA] (TOPIC)	Number of hours	Location
P1-2 Uvod u process odlučivanja i koncept formalizacije odlučivanja	2	
P3-4 Metode odlučivanja utemeljene na znanju	2	
P5 Stablo odlučivanja i pravila odlučivanja	1	

[SEMINARI] (TOPIC)	Number of hours	Location
S1-5 Informacije o procesu i formalizaciji odlučivanja. Posljedice odlučivanja. Procjena rizika odlučivanja.	5	
S6-10 Odabrane metode odlučivanja utemeljene na znanju (AHP, ANP, stablo odlučivanja, pravila odlučivanja)	5	
S11-15 Uvod u metode strojnog učenja	5	
S16-20 Alati za primjenu metoda odlučivanja	5	

EXAM DATES (final exam):