



Univerzitet Crne Gore
Prirodno-matematički fakultet

Džordža Vašingtona b.b.
1000 Podgorica, Crna Gora

tel: +382 (0)20 245 204
fax: +382 (0)20 245 204
www.pmf.ac.me

Broj: 2025/01-197+2
Datum: 25. 09. 2023

Vijeću Prirodno-matematičkog fakulteta

Molim Vijeće Prirodno-matematičkog fakulteta da odobri uvođenje izbornog predmeta
Vjerovatnosna robotika na doktorskim studijama računarskih nauka.

Vjerovatnosna robotika – Probabilistic robotics je moderan pristup robotici koji naglašava permanentno prisustvo neizvjesnosti (*uncertainty*) u robotskim akcijama i percepциji. Centralna ideja ove naučne discipline je da, koristeći se teorijom vjerovatnoće i algoritmima, matematički utemeljeno predstavi sve informacije vezane za funkcionisanje robota pomoću raspodjela vjerovatnoće. Na navedeni način se kvantificuje i uzima u obzir neizvjestnost koja dolazi iz raznih izvora kao što su predefinisani model kretanja robota i obzervacije sa senzora.

Cilj kursa je pregled problema poput lokalizacije robota i mapiranja sredine u kojoj se robot kreće, i algoritama za njihovo rješavanje. Problemi i rješenja se ilustruju kroz praktične zadatke i implementaciju i evaluaciju algoritama.

U Podgorici
25.09.2023.

Doc. dr Igor Jovančević

I. Jovančević

Tabela S2.6.4. Forma za pripremu informacionih lista predmeta

Naziv predmeta	Vjerovatnosna robotika			
Šifra predmeta	Status predmeta	Semestar	Broj ECTS kredita	Fond časova
	izborni	II	10	4P+0V

Studijski programi za koje se organizuje

Računarske nauke (akademske doktorske studije, studije traju 6 semestara, 180 ECTS kredita)

Uslovljenost drugim predmetima

Ciljevi izučavanja predmeta

Izučavanjem ovog predmeta studenti se upoznaju sa najvažnijim konceptima i algoritmima iz domena vjerovatnosne robotike. Obrađuju se vjerovatnosni modeli kretanja i percepcije u robotici, problemi lokalizacije, mapiranja, kao i istovremene lokalizacije i mapiranja (SLAM). Takođe, obrađuju se i problemi planiranja u vjerovatnosnoj robotici, kao i primjene mašinskog učenja, konkretno reinforcement learning (RL) paradigme.

Sadržaj predmeta (nastavne cjeline, oblici individualnog rada studenata, oblici provjere znanja) prikazan prema radnim nedjeljama u akademskom kalendaru:

Pripremna nedjelja	
I nedjelja	Podsjećanje na osnovne pojmove iz vjerovatnoće. Uvod u vjerovatnosnu robotiku. Izvori neizvjesnosti (uncertainty) u robotici. Nedostaci tradicionalnih (determinističkih) pristupa i razlozi za uvođenje vjerovatnosnih modela. Pregled osnovnih koncepta: stanje, kontrola, mjerjenje, uvjerenje (belief). Pregled Python biblioteka koje će biti korišćene u praktičnim eksperimentima.
II nedjelja	Vjerovatnosni modeli kretanja robota. Model translatornih i rotacionih brzina. Odometrijski model. Implementacija jednog modela kretanja u Python-u (izvlačenje uzorka i estimacija gustine raspodjele).
III nedjelja	Robotska percepcija i modeli senzornih mjerjenja. Modeli sirovih mjerjenja (range scan) i modeli zanovani na ekstrakciji svojstava iz sirovih podataka (feature extraction). Pojam orientirja (landmarks) i senzorni modeli zasnovani na njima. Implementacija jednog ili više senzornih modela u Python-u (izvlačenje uzorka i estimacija gustine raspodjele).
IV nedjelja	Rekurzivna estimacija stanja. Bayesov filter i njegove varijante: Gausovi i neparametarski filteri. Predstavnici Gausovih filtera: Kalmanov filter i njegova proširena varijanta (EKF), informacioni filter. Predstavnici neparametarskog pristupa: histogram filter i particle filter. Razvoj jednostavne 2D simulacije koja će uključivati prethodno implementirane vjerovatnosne modele kretanja i percepcije robota.
V nedjelja	Problemi lokalizacije robota i njegove varijante: praćenje pozicije, globalna lokalizacija i problem kidnapovanog robota. Algoritam za lokalizaciju zasnovan na proširenom Kalmanovom filteru (EKF). Implementacija EKF algoritma za lokalizaciju robota na osnovu orientirja (landmarks) u prethodno razvijenoj 2D simulaciji.
VI nedjelja	Neparametarski pristupi lokalizaciji robota: grid i Monte Carlo lokalizacija. Mogućnost primjene ovih metoda u sistemima sa sirovim mjerjenjima. Poređenje sa Kalmanovim filterima i pregled prednosti i nedostataka. Implementacija jednog od neparametarskih algoritama za lokalizaciju.
VII nedjelja	Problem mapiranja nepoznatog okruženja. Koncept mreže popunjenoosti (occupancy grid) i algoritmi za mapiranje zasnovani na njemu. Online i offline mapiranje. Proširenje 2D simulacije sa preprekama koje je potrebno mapirati. Implementacija osnovnog (online) algoritma za konstrukciju mreže popunjenoosti, kao i offline varijante u vidu MAP (maximum a-posteriori) algoritma za mapiranje.
VIII nedjelja	Problem istovremene lokalizacije i mapiranja (SLAM - Simultaneous Localization And Mapping) i njegove varijante. Estimacija trenutne pozicije robota i mape njegovog okruženja (online SLAM). Estimacija niza pozicija od početka kretanja robota i mape njegovog okruženja (full SLAM). EKF-SLAM algoritam zasnovan na prošrenom Kalmanovom filteru. Implementacija EKF-SLAM algoritma za rješenje online SLAM problema u 2D simulaciji sa orientirima.
IX nedjelja	Modeliranje full SLAM problema grafom i GraphSLAM algoritmom. Pozicije robota i vrijednosti mjerjenja dobijenih iz senzora kao čvorovi u grafu. Povezivanje čvorova granama koje se odnose na kontrole za kretanje i mjerjenja dobijena tokom kretanja. Implementacija GraphSLAM algoritma u 2D simulaciji sa orientirima.
X nedjelja	Pregled drugih poznatih SLAM algoritama: SEIF (Sparse Extended Information Filter) i FastSLAM (zasnovan na konceptu particle filtera). Implementacija FastSLAM algoritma.
XI nedjelja	Problem planiranja u vjerovatnosnoj robotici. Markovljevi procesi odlučivanja (MDP - Markov Decision Proces). MDP kao vjerovatnosno uopštenje grafovskog prostora pretrage iz tradicionalne robotike. Implementacija osnovnih algoritama za MDP planiranje i analiza njihovog funkcionisanja na jednostavnim 2D primjerima.

XII nedjelja	POMDP (Partially Observable MDP) kao dodatna generalizacija. Ilustracija koncepta kroz jednostavne primjere. Osnovni algoritam za POMDP planiranje i njegovi nedostaci. QMDP algoritam za nalaženje približnih rješenja. Implementacija jednog od PODMP algoritama za planiranje optimalne putanje u jednostavnom 2D okruženju.
XIII nedjelja	Primjene mašinskog učenja u robotici. Reinforcement learning. MDP modeli kao teorijska osnova za razvoj RL algoritama. Elementarni RL algoritmi: Q-Learning i SARSA. OpenAI Gym biblioteka sa 2D i 3D simulacijama za testiranje RL algoritama. Implementacija Q-Learning algoritma na primjeru neke od jednostavnijih simulacija.
XIV nedjelja	Uvođenje dubokih neuronskih mreža u RL paradigmu. Neki predstavnici RL algoritama za obučavanje dubokih mreža: DQN (Deep Q-Learning), actor-critic pristupi, PPO (Proximal Policy Optimization), REINFORCE algoritmi, TF-Agents biblioteka za reinforcement learning, bazirana na TensorFlow framework-u. Primjena TF-Agents funkcionalnosti za rješavanje jednog od problema kontinualne kontrole iz OpenAI Gym biblioteke.
XV nedjelja	Obrane projekata.
Metode obrazovanja Predavanja, praćenje rada studenata na praktičnim projektima.	
Opterećenje studenata	
<u>Nedjeljno</u> $10 \times 40/30 = 13$ sati i 20 minuta Predavanja: 4 sata Vježbe: 0 sati Ostale nastavne aktivnosti: 0 Individualni rad studenata: 9 sati i 20 minuta	<u>U semestru</u> Nastava i završni ispit: $(13$ sati i 20 minuta $) \times 16 = 213$ sati i 20 minuta Neophodne pripreme (administracija, upis, ovjera prije početka semestra): $2 \times (13$ sati i 20 minuta $) = 26$ sati i 40 minuta <u>Ukupno opterećenje za predmet : $10 \times 30 = 300$ sati</u> <u>Dopunski rad: od 0 do 60 sati</u> <u>Struktura opterećenja:</u> 213 sati i 20 min(Nastava) + 26 sati i 40 minuta (Priprema) + 60 sati (Dopunski rad)
Obaveze studenata u toku nastave: Prisustvo nastavi, rad na praktičnom projektu, pisanje seminarskog rada i polaganje završnog ispita.	
Literatura: <ol style="list-style-type: none"> Thrun, S., Burgard, W., & Fox, D. (2006). Probabilistic Robotics. The MIT Press. Russel, S., & Norvig, P. (2010). Artificial Intelligence: A Modern Approach (3rd ed.). Prentice Hall. Sutton, R., & Barto, A. (2018). Reinforcement Learning: An Introduction (2nd ed.). The MIT Press. Naučni radovi navedeni tokom predavanja 	
Ishodi učenja (uskladeni sa ishodima za studijski program): Student se obučava da algoritmatski rješava probleme vjerovatnosne prirode koji se javljaju u robotici i autonomnim sistemima. Nakon što položi ovaj ispit, student će imati kompetencije da:	
<ol style="list-style-type: none"> Implementira poznate algoritme za probleme lokalizacije, mapiranja i istovremene lokalizacije i mapiranja (SLAM), razumije njihova svojstva i ograničenja i analizira rezultate njihove primjene. Vlada konceptima kao što su prošireni Kalmanov filter, histogram filter, particle filter, Markovljev proces odlučivanja. Razumije primjene reinforcement learning paradigmе mašinskog učenja u robotici i samostalno obučava duboke neuronske mreže primjenama RL algoritama. 	
Oblici provjere znanja i ocjenjivanje: Seminarski rad 30 bodova, izrada i obrana praktičnog projekta 40 bodova i završni ispit 30 bodova. Za prelaznu ocjenu potrebno je imati 51 i više bodova.	
Ime i prezime nastavnika: Doc. dr Igor Jovančević	
	
Napomena (ukoliko je potrebno):	