

UNIVERZITET U TUZLI
FAKULTET ELEKTROTEHNIKE
Ul. Franjevačka br. 2.
TUZLA

O B A V I J E S T

Kandidat **Besim Alibegović, bachelor ing. el.**, javno će braniti magistarski rad pod naslovom: *Sistem za prepoznavanje govora u robotskoj aplikaciji*, dana **15.07.2020. godine u 12,00 sati** u Multimedijalnoj sali Univerziteta u Tuzli, pred Komisijom u sastavu:

1. Dr. sci. Lejla Banjanović-Mehmedović, vanr. prof. - predsjednik
Uža naučna oblast Automatika i robotika
Fakultet elektrotehnike Univerziteta u Tuzli
2. Dr. sci. Naser Prljača, red. prof. - mentor i član
Uža naučna oblast Automatika i robotika
Fakultet elektrotehnike Univerziteta u Tuzli
3. Dr. sci. Amira Šerifović-Trbalić, vanr. prof. – član,
Uža naučna oblast Automatika i robotika
Fakultet elektrotehnike Univerziteta u Tuzli

Završni magistarski rad može se pogledati u Sekretarijatu Fakulteta, radnim danom od 9,00 do 15,00 sati.

Pristup javnosti je slobodan.

Rezime

Sistemi automatskog prepoznavanja govora već decenijama su zanimljiva tema istraživanja. Nekoliko značajnih otkrića dogodilo se u posljednjih osam godina, gotovo isključivo kao rezultat korištenja neuronskih mreža na različite načine. Danas se koriste dva glavna pristupa: tradicionalni DNN-HMM i moderniji end-to-end pristup. Dostupno je dosta različitih rješenja za implementaciju ovakvih sistema. Neke od implementacija su s otvorenim izvornim kodom i izvršavaju se na uređaju, dok se druge izvršavaju na udaljenim serverima i nude API usluge u obliku crne kutije.

Najprirodniji način komunikacije za ljude je putem govora, a posebno prirodnog govora koji ne slijedi stroge unaprijed definirane oblike i fraze. Stoga je kao oblik interakcije sa robotom Franka Emika Panda izabran upravo prirodni ljudski govor. U ovom radu se uspoređuju različita rješenja kako bi se pronašlo najbolje koje će se koristiti za davanje komandi robotu. Testirana se dva rješenja na uređaju Kaldi (DNN-HMM) i Mozilla DeepSpeech (end-to-end). Osim lokalnih rješenja, testirana su i tri internet API-ja: IBM Watson, Microsoft Azure i Google Speech-to-Text. Sistemi su adaptirani ovom specifičnom domenu i ocjenjuju se na primjerima očekivanih ulaza. Kako je cilj zadržati sposobnost prepoznavanja opšteg jezika, sistemi se također ocjenjuju na primjerima svakodnevnog engleskog jezika.