

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

O B A V I J E S T

Kandidat **Semir Omerović, bachelor ing. el.**, javno će braniti završni magistarski rad pod naslovom: *Detekcija pneumonije na RTG slikama primjenom metoda dubokog učenja*, dana **24.11.2022. godine u 12,30 sati** u Multimedijalnoj sali Univerziteta u Tuzli, pred Komisijom u sastavu:

1. Dr. sc. Naser Prljača, red.prof. - predsjednik
Uža naučna oblast Automatika i robotika
Fakultet elektrotehnike Univerziteta u Tuzli
2. Dr. sc. Amira Šerifović-Trbalić, vanr.prof. - mentor i član
Uža naučna oblast Automatika i robotika
Fakultet elektrotehnike Univerziteta u Tuzli
3. Dr. sc. Damir Demirović, vanr.prof. – član,
Uža naučna oblast Računarstvo i informatika
Fakultet elektrotehnike Univerziteta u Tuzli

Zamjenski član komisije dr. sci. Amila Dubravić, vanredni profesor, 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

Pneumonija je respiratorna infekcija uzrokovana bakterijama ili virusima. Široko je rasprostranjena, naročito u zemljama u razvoju i nerazvijenim zemljama, gdje su visoke razine zagađenja i nehigijenski životni uvjeti relativno česti, zajedno s neadekvatnom medicinskom infrastrukturom. Upala pluća može varirati od blage pa do opasne po život. Najveću opasnost predstavlja za dojenčad i malu djecu, osobe starije od 65 godina, te osobe sa zdravstvenim problemima ili oslabljenim imunološkim sustavom. Rana dijagnoza upale pluća ključna je za osiguranje uspješnog liječenja i povećanje stope preživljavanja. RTG grudnog koša je najčešće korištena metoda za dijagnosticiranje upale pluća. Međutim, pregled rendgenskih snimaka grudnog koša predstavlja zahtjevan zadatak i podložan je subjektivnoj varijabilnosti.

U ovom radu razvili smo kompjuterski potpomognuti dijagnostički sistem za automatsku detekciju upale pluća pomoću rendgenskih slika grudnog koša. Za razvijanje, testiranje i

validaciju različitih modela dubokih neuronskih mreža biće korišten standardni RSNA skup podataka zajedno sa jošjednim manjim skupom kako bi sistem bio što robusniji. Prilikom razvoja modela korišten je pristup prenosa učenja sa nekih od najpoznatijih konvolucionih neuronskih mreža kao što su: VGG16, ResNet50, MobileNet te InceptionV3. Osim toga, izgrađen je i novi model od početka pri čemu je prikazana postepena izgradnja modela kako bi se osvrnuli na probleme koji su proizašli, te kako su ti problemi riješeni. Izvršena je komparacija razvijenih rješenja u pogledu tačnosti detekcije nad izdvojenim testnim setom podataka.