

PRIMJENA ALATA UMJETNE INTELIGENCIJE U ANALIZI SNIMAKA KOMPJUTORIZIRANE TOMOGRAFIJE TORAKSA KOD BOLESNIKA S COVID - 19 PNEUMONIJOM

Mrvoš, Nina

Undergraduate thesis / Završni rad

2024

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Rijeka, Faculty of Health Studies / Sveučilište u Rijeci, Fakultet zdravstvenih studija**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:184:772905>

Rights / Prava: [In copyright](#)/[Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-08-23**

Repository / Repozitorij:

[Repository of the University of Rijeka, Faculty of Health Studies - FHSRI Repository](#)



SVEUČILIŠTE U RIJECI
FAKULTET ZDRAVSTVENIH STUDIJA
PRIJEDIPLOMSKI STRUČNI STUDIJ RADIOLOŠKA TEHNOLOGIJA

Nina Mrvoš

PRIMJENA ALATA UMJETNE INTELIGENCIJE U ANALIZI SNIMAKA
KOMPJUTORIZIRANE TOMOGRAFIJE TORAKSA KOD BOLESNIKA S
COVID – 19 PNEUMONIJOM

Završni rad

Rijeka, 2024.

UNIVERSITY OF RIJEKA
FACULTY OF HEALTH STUDIES

UNDREGRADUATE PROFESSIONAL STUDY OF RADIOLOGIC TECHNOLOGY

Nina Mrvoš

APPLICATION OF ARTIFICIAL INTELLIGENCE TOOLS IN THE ANALYSIS
OF COMPUTED TOMOGRAPHY IMAGES OF THORAX IN PATIENTS
WITH COVID – 19 PNEUMONIA

Final thesis

Rijeka, 2024

Mentor rada: doc. prim. dr. sc. Klaudija Višković, dr. med.

Završni rad obranjen je dana 15.7.2024. na Fakultetu zdravstvenih studija Sveučilišta u Rijeci, pred povjerenstvom u sastavu:

1. izv. prof. dr. sc. Melita Kukuljan, dr. med.
2. Maja Karić, bacc. radiol. techn., univ. mag. admin. sanit.
3. doc. prim. dr. sc. Klaudija Višković, dr. med.

Izvešće o provedenoj provjeri izvornosti studentskog rada

Opći podatci o studentu:

Sastavnica	Fakultet zdravstvenih studija
Studij	Preddiplomski stručni studij radiološke tehnologije
Vrsta studentskog rada	Završni rad
Ime i prezime studenta	Nina Mrvoš
JMBAG	2211002365063

Podatci o radu studenta:

Naslov rada	Primjena alata umjetne inteligencije u analizi snimaka kompjutorizirane tomografije toraksa kod bolesnika s COVID-19 pneumonijom
Ime i prezime mentora	Klaudija Višković
Datum predaje rada	
Identifikacijski br. podneska	2401791680
Datum provjere rada	13.06.2024.
Ime datoteke	12.6.2024_završni_rad-Nina_Mrvoš.docx
Veličina datoteke	2.01M
Broj znakova	74,018
Broj riječi	12,206
Broj stranica	51

Podudarnost studentskog rada:

Podudarnost (%)	6%
-----------------	----

Izjava mentora o izvornosti studentskog rada

Mišljenje mentora	
Datum izdavanja mišljenja	17.06.2024.
Rad zadovoljava uvjete izvornosti	DA <input checked="" type="checkbox"/>
Rad ne zadovoljava uvjete izvornosti	<input type="checkbox"/>
Obrazloženje mentora (po potrebi dodati zasebno)	

Datum

17. 06. 2024.

Potpis mentora

Klaudija Višković

SADRŽAJ:

POPIS KRATICA	6
SAŽETAK.....	8
SUMMARY	9
1. UVOD.....	10
2. CILJEVI I HIPOTEZE	11
3. METODE	12
4. RESPIRATORNA BOLEST COVID – 19.....	25
4.1. Struktura virusa SARS – CoV – 2	25
4.2. Prijenos virusa SARS – CoV – 2 i mjere zaštite.....	26
4.3. Simptomatologija i klinička slika bolesti COVID – 19.....	27
5. METODE DIJAGNOSTICIRANJA BOLESTI COVID – 19.....	28
5.1. RT – PCR test.....	28
5.2. Kompjutorizirana tomografija (engl. Computer Tomography – CT) toraksa.....	29
6. UMJETNA INTELIGENCIJA – UI (ENGL. ARTIFICIAL INTELLIGENCE – AI).....	31
6.1. Strojno učenje (engl. Machine Learning)	31
6.2. Duboko učenje (engl. Deep Learning)	33
7. PRIMJENA UMJETNE INTELIGENCIJE U DIJAGNOSTICI BOLESTI COVID – 19.....	34
7.1. Algoritmi za klasifikaciju korišteni u dijagnostici bolesti COVID – 19	36
8. ANALIZA ČLANAKA S TEMATIKOM PRIMJENE UMJETNE INTELIGENCIJE U DIJAGNOSTICI BOLESTI COVID – 19 POMOĆU SNIMAKA KOMPJUTORIZIRANE TOMOGRAFIJE TORAKSA	37
8.1. Radiološki znaci COVID – 19 infekcije na kompjutoriziranoj tomografiji i protokoli skeniranja .	37
8.2. Značaj primjene alata umjetne inteligencije u COVID – 19 pneumoniji kod kompjutorizirane tomografije toraksa	39
8.3. Prednosti i ograničenja primjene alata dubokog učenja	40
8.4. Prednosti i ograničenja primjene alata strojnog učenja.....	42
9. ANALIZA ČLANAKA KOJI SE ODOSE NA ETIČKA PITANJA U PRIMJENI UMJETNE INTELIGENCIJE U COVID – 19 PNEUMONIJI	43
10. SMJERNICE ZA DALJNJA ISTRAŽIVANJA ALATA UMJETNE INTELIGENCIJE	45
11. POTVRDA HIPOTEZA	47
12. ZAKLJUČAK	49
LITERATURA.....	50
PRIVITCI	61
KRATAK ŽIVOTOPIS.....	63

POPIS KRATICA

3D – trodimenzionalno

AAPM – Američko udruženje fizičara u medicini (engl. American Association of Physicist in Medicine)

ACR – Američko društvo radiologa (engl. American College of Radiology)

ARDS – akutni respiratorni distress sindrom

CAR – Kanadsko udruženje radiologa (engl. Canadian Association of Radiologists)

CC – CCII – Kineski konzorcij za istraživanje CT snimaka toraksa (engl. China Consortium of Chest CT Image Investigation)

CNN – konvolucijska neuronska mreža (engl. convolutional neural network)

COVID – 19 – bolest uzrokovana koronavirusom 2019 (engl. Coronavirus Disease 2019)

CT – kompjuterizirana tomografija (engl. Computed Tomography)

dCNN – duboka konvolucijska neuronska mreža (engl. deep convolutional neural network)

DICOM – Digitalne slike i komunikacija u medicini (engl. Digital Imaging and Communications in Medicine)

DNA – deoksiribonukleinska kiselina (engl. Deoxyribonucleic Acid)

ESR – Europsko radiološko društvo (engl. European Society of Radiology)

EuSoMII – Europsko društvo za informatiku medicinskog oslikavanja (engl. European Society of Medical Imaging Informatics)

GAN – Generativne suparničke mreže (engl. Generative Adverse Networks)

GDPR – Opća uredba o zaštiti podataka (engl. General Data Protection Regulation)

GGO – opacifikacije zrnatog stakla (engl. ground glass opacities)

HRCT – kompjuterizirana tomografija visoke rezolucije (engl. high resolution computed tomography)

kVp – vršni napon (engl. kilovoltage peak)

MIP – projekcija maksimalnog intenziteta (engl. Maximum Intensity Projection)

MR – magnetska rezonancija (engl. magnetic resonance)

nm – nanometar

PACS – sustav za arhiviranje slika i komunikaciju (engl. Picture Archiving and Communications System)

PCR – lančana reakcija polimerazom (engl. polymerase chain reaction)

RNA – ribonukleinska kiselina (engl. Ribonucleic Acid)

RSNA – Radiološko društvo Sjeverne Amerike (engl. Radiologic Society of North America)

RT – PCR – lančana reakcija polimeraze s reversnom transkripcijom (engl. reverse transcription polymerase chain reaction)

RTG – rendgenska snimka

SARS – CoV – 2 – teški akutni respiratorni sindrom koronavirus 2 (engl. Severe Acute Respiratory Syndrom Coronavirus 2)

SIIM – Društvo za informatiku medicinskog oslikavanja (engl. Society for Imaging Informatics in Medicine)

UI – umjetna inteligencija

UTZ – ultrazvuk

WHO – Svjetska zdravstvena organizacija (engl. World Health Ogranisation)

SAŽETAK

Infekcija COVID – 19 uzrokovana virusom SARS – CoV – 2 pojavila se krajem 2019. godine u Kini te se ubrzo proširila po cijelom svijetu što je dovelo do proglašenja pandemije 11.3.2020. godine. COVID – 19 pneumonija prezentira se kašljem, otežanim disanjem i povišenom tjelesnom temperaturom. Promjene na plućima kod pneumonije se najpreciznije mogu prikazati kompjutoriziranom tomografijom. Stoga je uz radiografiju kao bazičnu radiološku metodu, kompjutorizirana tomografija bila glavna radiološka metoda za dijagnostiku teže oboljelih pacijenata. Kako bi se ubrzao dijagnostički proces, u radiologiju se implementirala tehnologija umjetne inteligencije. Razvili su se modeli dubokog učenja i strojnog učenja koji efikasno dijagnosticiraju COVID – 19 pneumoniju, no njih je potrebno trenirati na velikim bazama podataka. Pri treniranju modela treba obratiti pozornost na zaštitu podataka pacijenata te etičnost primjene umjetne inteligencije. Ovim preglednim radom je analizirano devetnaest članaka s tematikom primjene umjetne inteligencije u dijagnostici bolesti COVID – 19 pomoću kompjutorizirane tomografije te jedanaest članaka vezanih za etičnost primjene umjetne inteligencije u radiologiji. Analiza radova pokazala je da je umjetna inteligencija značajno pomogla u preciznoj i brznoj dijagnostici COVID – 19 pneumonije, ali da je te sustave potrebno dalje razvijati kako bi bili što pouzdaniji u dijagnozi. U člancima etičke tematike ističu se problemi odgovornosti za finalnu dijagnozu te zaštićenosti podataka pacijenata. Autori predlažu sastavljanje univerzalnog etičkog kodeksa kojim bi se točno definirali navedeni problemi.

Ključne riječi: COVID – 19, SARS – CoV – 2, kompjutorizirana tomografija prsnog koša, umjetna inteligencija, duboko učenje, strojno učenje

SUMMARY

The COVID – 19 infection caused by the SARS – CoV – 2 virus appeared at the end of 2019 in China and soon spread throughout the world, which led to the declaration of a pandemic on March 11, 2020. COVID – 19 pneumonia presents with a cough, difficulty breathing and elevated body temperature. Changes in the lungs in pneumonia are shown most precisely by computed tomography. Therefore, along with radiography as the basic radiological method, computed tomography was the main radiological method for the diagnosis of more seriously ill patients. In order to speed up the diagnostic process, artificial intelligence technology was implemented in radiology. Deep learning and machine learning models that effectively diagnose COVID – 19 pneumonia are developed, but they need to be trained on large databases. When training the model, attention should be paid to the protection of patient data and the ethical application of artificial intelligence. In this review paper, nineteen articles on the application of artificial intelligence in computed tomography diagnosis of the disease COVID – 19 and eleven articles related to the ethics of the use of artificial intelligence in radiology have been analyzed. The analysis of the studies showed that artificial intelligence significantly helped in the accurate and fast diagnosis of COVID – 19 pneumonia, but these systems need to be further developed to be more reliable in the diagnostics. In the articles considering ethical topics, the problems of responsibility for the final diagnosis and the protection of patient data are emphasized. The authors propose the creation of a universal code of ethics that would accurately define the above problems.

Keywords: COVID – 19, SARS – CoV – 2, computed tomography of the chest, artificial intelligence, deep learning, machine learning

1. UVOD

Zaključno sa sedmim travnjem 2024. godine Svjetska zdravstvena organizacija (engl. World Health Organisation – WHO) publicirala je izvještaj po kojem je od prosinca 2019. godine u svijetu bilo ukupno 775, 293, 630 zabilježenih slučajeva bolesti COVID – 19 (1). Ova se teška respiratorna bolest od svojeg početka u Wuhanu u Kini brzo proširila globalno što je dovelo do proglašenja pandemije 11. ožujka 2020. godine (1).

Velikom brzinom širenja i rastućim brojem pacijenata stvoren je ogroman pritisak na zdravstveni sustav i njegove djelatnike. Jedna od glavnih zdravstvenih specijalnosti koje su aktivno radile na ranom otkrivanju i kontroli razvoja bolesti COVID – 19 bila je radiologija. Radiološke metode koje su se koristile u dijagnostici bolesti COVID – 19 su: torakalni radiogrami, kompjuterizirana tomografija (engl. Computer Tomography – CT) prsnog koša, ultrazvuk toraksa i magnetska rezonancija (MR); (engl. Magnetic Resonance Imaging – MRI) grudnog koša (2, 3, 4). Obzirom na to da su pacijenti zaraženi bolešću COVID – 19 zahtijevali hitan prijem, dolazilo je do pomicanja dugih lista čekanja za preglede pacijenata nezaraženih COVID – om te dodatnog radnog opterećenja djelatnika radioloških odjela.

Kako bi se što prije i učinkovitije obavili pregledi te došlo do dijagnoze, pojavila se ideja o uvođenju novih sustava i tehnologija u zdravstvo, od kojih je najčešće implementirana umjetna inteligencija (UI); (engl. Artificial Intelligence – AI) (2). U početku pandemije su modeli UI još uvijek bili u razvoju i na samim počecima te je njihova preciznost i točnost bila niska. Kako bi se bolje razvijali bilo je potrebno da se stvore velike baze podataka (engl. Big Data) s brojnim radiološkim snimkama, osobito CT – a, kod pacijenata koji su imali dokazanu bolest PCR testom (engl. Protein Chain Reaction) (5).

Zbog izloženosti zdravstvenih i osobnih podataka modelima UI dolazi do problema etičnosti njihove primjene općenito u medicini pa tako i u radiologiji te do pitanja koliko su podaci zapravo zaštićeni od neželjenih događaja i zlonamjernih napada

2. CILJEVI I HIPOTEZE

Ciljevi:

1. Utvrditi prednosti u primjeni alata umjetne inteligencije – strojnog učenja i dubokog učenja u analizi snimaka bolesnika s COVID – 19 pneumonijom pomoću kompjutorizirane tomografije u usporedbi s analizom snimaka koje su očitali isključivo radiolozi.
2. Analizirati etičke probleme kod primjene alata umjetne inteligencije – strojnog učenja i dubokog učenja u dijagnostici bolesti COVID – 19.

Hipoteze:

1. Primjena alata umjetne inteligencije – strojnog učenja i dubokog učenja u analizi snimaka bolesnika s COVID – 19 pneumonijom pomoću kompjutorizirane tomografije omogućuje bržu i precizniju dijagnostiku u usporedbi s analizom snimaka koje su očitali isključivo radiolozi.
2. Primjena alata umjetne inteligencije – strojnog učenja i dubokog učenja u dijagnostici bolesti COVID – 19 može biti neetična zbog nedovoljne tehničke otpornosti, što dovodi do zlonamjerne upotrebe.

3. METODE

Učinilo se istraživanje baza podataka: Google Scholar, MedRix, IEEE, PubMed i Scopus koristeći sljedeće ključne riječi: artificial intelligence, computed tomography of the chest, COVID – 19, deep learning, machine learning, SARS – CoV – 2.

Kriteriji uključivanja:

- pregledni članci i originalni znanstveni radovi prema navedenim ključnim riječima publicirani od 01.01.2020. godine do 31.12.2023. godine.
- članci na engleskom jeziku

Kriteriji isključivanja:

- članci koji nemaju recenziju (peer review)
- članci koji se dupliciraju
- članci koji obrađuju ostale radiološke dijagnostičke metode osim CT – a (RTG, UTZ, MR)
- prikazi slučajeva (case reports)
- istraživanja koja obuhvaćaju protokole CT – a toraksa s kontrastom

Prilikom analize baza podataka primijenili su se sljedeći filteri: područje istraživanje (biomedicina i zdravstvo), godina publikacije (2020. – 2023.), oblik dokumenta (pregledni članak i originalni znanstveni članak) i jezik (engleski). Izabrani članci, nakon odvajanja članaka prema kriterijima isključenja bili su podijeljeni u pregledne članke i u originalne znanstvene članke (Grafikon 1.). Sljedeći korak bio je grupiranje članaka koji obrađuju upotrebu alata UI kod CT – a toraksa u bolesnika s COVID – 19 pneumonijom po metodi dubokog učenja i po metodi strojnog učenja. Članci izdvojeni u prethodnom koraku bili su pregledani, s fokusom na naslov i sažetak da bi se osigurala relevantnost tematike. Nakon toga, izdvojeni su se članci detaljno u cijelosti analizirali uz procjenu jesu li jasno navedeni ciljevi istraživanja, je li detaljno

elaborirana metodologija istraživanja, jesu li rezultati istraživanja prezentirani u skladu s istraživačkim pitanjem. U posljednjoj fazi filtriranja, u skladu s postavljenim hipotezama, razdvojila su se istraživanja koja su pokazala da primjena alata UI – strojnog učenja i dubokog učenja u dijagnostici bolesti COVID – 19 pomoću CT – a omogućuje brže otkrivanje bolesti u usporedbi sa snimkama koje su očitali isključivo radiolozi i istraživanja koja su pokazala da alati UI nisu doprinijeli bržem i preciznijem otkrivanju bolesti.

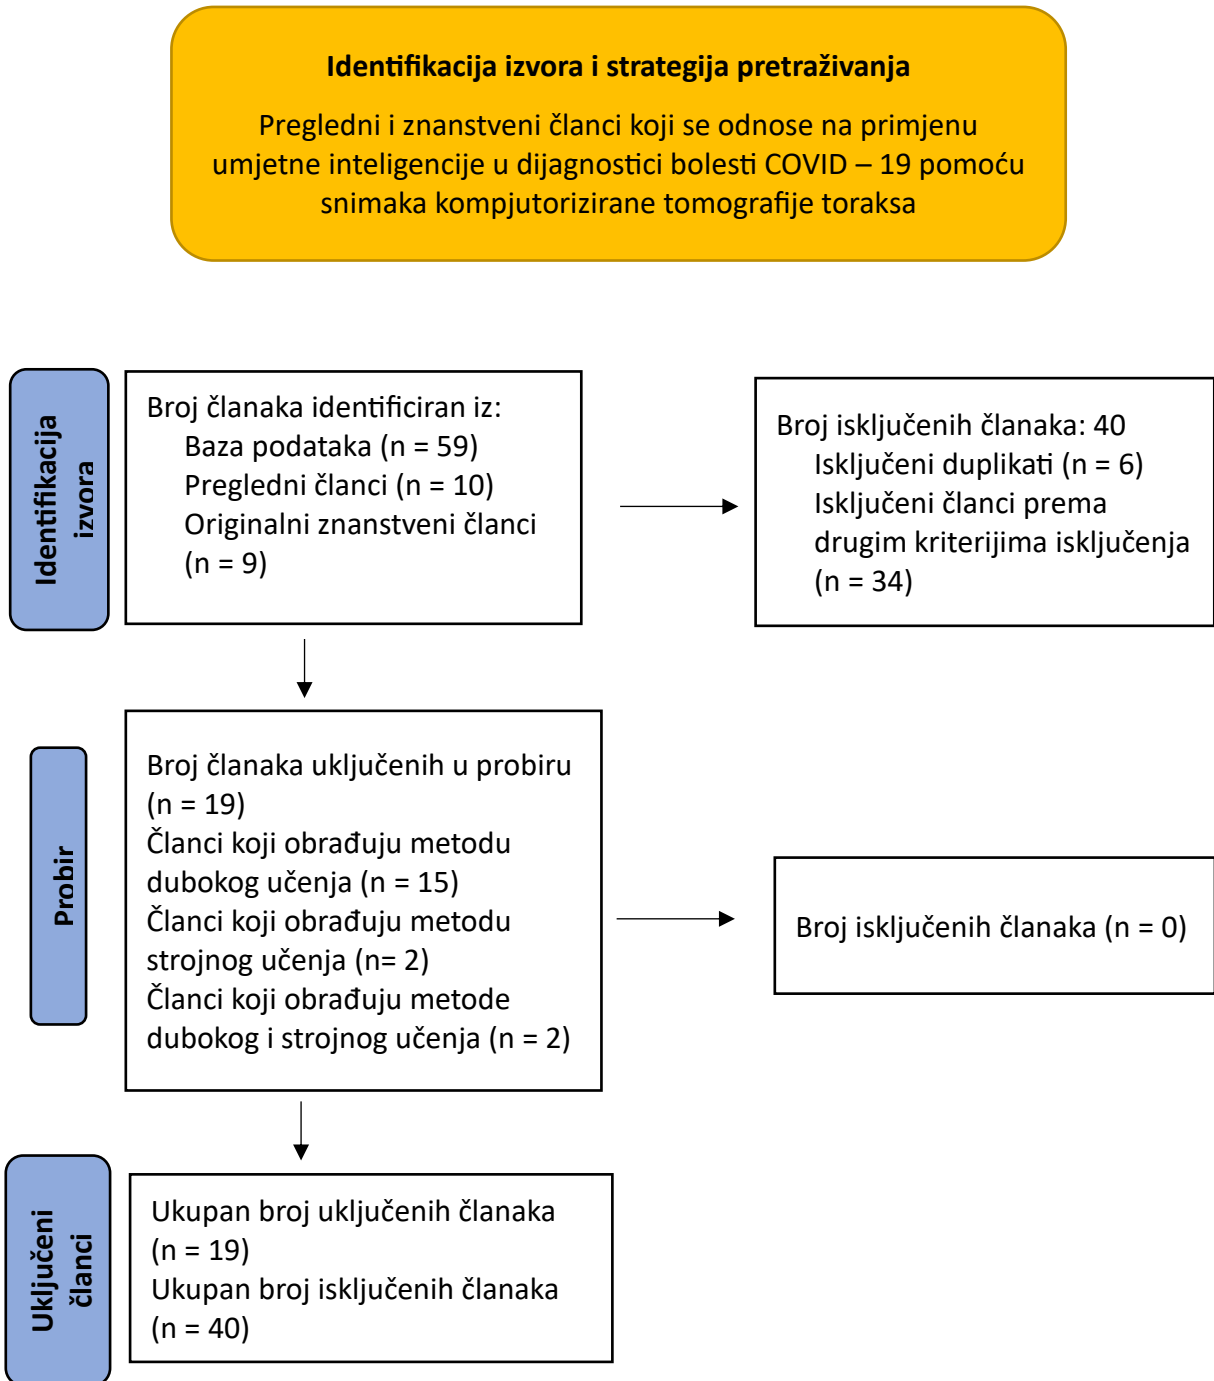
Ukupno je pregledano pedeset devet radova s tematikom primjene umjetne inteligencije u dijagnostici bolesti COVID – 19 pomoću snimaka kompjutorizirane tomografije toraksa. Od pregledanih pedeset devet radova, prema zadanim kriterijima isključeno je četrdeset članaka, a uključeno deset preglednih radova te devet originalnih znanstvenih radova.

Ukupan broj uključenih članaka s temom etičkih problema vezanih za primjenu alata umjetne inteligencije u dijagnostici bolesti COVID – 19 je jedanaest članaka. Nije bilo isključenih članaka niti duplikata.

Rezultati pretrage radova koji su finalno bili analizirani podijelili su se u više tematskih skupina: patofiziologija i epidemiologija COVID – 19 infekcije, protokoli CT – skeniranja, opacifikacije i ostali radiološki znaci COVID – 19 infekcije na CT – u, značaj primjene alata UI u COVID – 19 pneumoniji kod CT – a toraksa, prednosti i ograničenja primjene alata dubokog učenja, prednosti i ograničenja primjene alata strojnog učenja, etička pitanja u primjeni umjetne inteligencije u COVID – 19 pneumoniji, smjernice za daljnja istraživanja alata umjetne inteligencije.

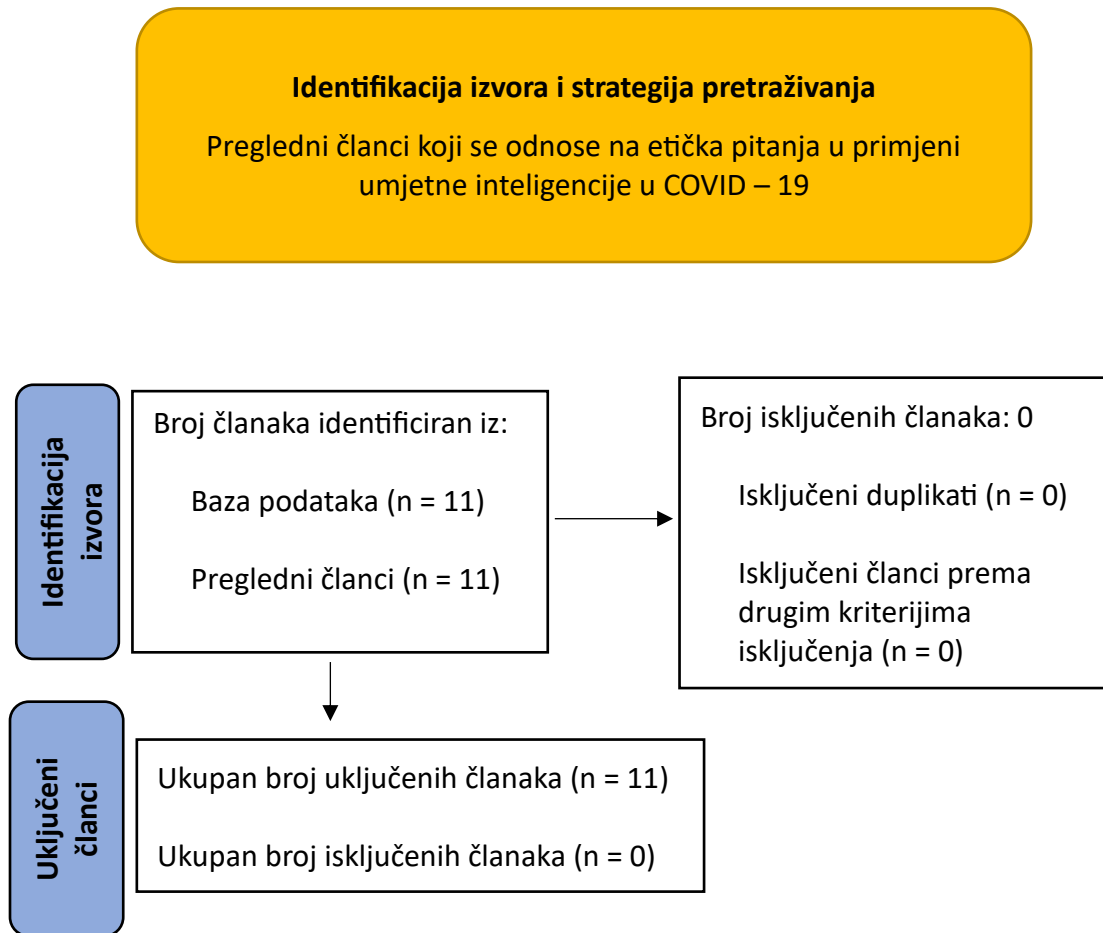
U zasebnom odlomku su elaborirani argumenti koji potvrđuju postavljene hipoteze. Na samom kraju su navedena ograničenja istraživanja, a u zaključku su istaknuti potporni argumenti istraživanja uz sažete ključne dokaze.

Grafikon 1: Grafikon protokola pretraživanja izvora s tematikom primjene umjetne inteligencije u dijagnostici bolesti COVID – 19 pomoću snimaka kompjutorizirane tomografije toraksa



Modificirano prema: Page MJ et al. 2020. (6)

Grafikon 2: Grafikon protokola pretraživanja izvora s tematikom etičkih pitanja u primjeni umjetne inteligencije u COVID – 19 pneumoniji



Modificirano prema: Page MJ et al. 2020. (6)

Tablica 1. Pregledni članci uključeni u analizu s tematikom primjene umjetne inteligencije u dijagnostici bolesti COVID – 19 pomoću snimaka kompjutorizirane tomografije toraksa

Redni broj članka	Ime prvog autora i godina publikacije	Metodologija istraživanja	Slikovna metoda	Ciljevi istraživanja	Rezultati istraživanje	Ograničenja istraživanja
1.	Low W.C.S i sur., 2021. (7)	Duboko učenje	CT i RTG	Pregled tehnika dubokog učenja u oslikavanju pacijenata s COVID – 19 pneumonijom	Razvoj tehnika dubokog učenja je ograničen zbog limitiranog broja baza podataka.	U bazama slikovnog materijala koriste se različiti formati, oblici arhiviranja i kvaliteta te je otežana usporedba.
2.	Fusco R. i sur., 2021. (8)	Strojno učenje i duboko učenje	CT i RTG	Pregled tehnika dubokog učenja i strojnog učenja u dijagnostici i terapiji COVID – 19 pneumonije, usporedba osjetljivosti i specifičnosti CT – a i RTG snimaka	Nije bilo statistički značajne razlike u srednjoj vrijednosti točnosti između RTG – a i CT – a (Hi kvadrat test; p vrijednost > 0,05).	Analiza snimaka nije mogla biti izvršena za pacijente koji su bili u kritičnom stanju, jer nisu mogli biti uključeni u proces oslikavanja.
3.	Alassiri L. i sur., 2022. (9)	Duboko učenje i prijenosno učenje	CT	Retrospektivna analiza algoritama dubokog učenja kako bi se poboljšali rezultati unaprijed treniranih modela sa i bez povećanja podataka	Stopa poboljšanja točnosti unaprijed treniranih modela nakon povećanja podataka iznosila je 3%.	Korišten je mali broj CT studija pacijenata (349, od čega je svega 10% korišteno za validaciju). Klinički podaci o pacijentima nisu uzeti u obzir.

4.	Heidari A. i sur., 2021. (10)	Duboko učenje	CT i RTG	Sustavnim pregledom literature se uspoređuju moderni sustavi koji koriste duboko učenje za detekciju bolesti COVID – 19.	Učinkovitost različitih modela varira.	Nedostupnost članaka koji nisu na engleskom jeziku, te članaka koji su objavljeni od određenih publikacija, nedovoljno jasno opisani korišteni algoritmi.
5.	Roberts M. i sur., 2021. (11)	Strojno učenje	CT i RTG	Usporediti kvalitetu metodologije i mogućnost ponavljanja korištenja metoda različitih modela strojnog učenja za detekciju bolesti COVID – 19	Niti jedan od uključenih modela strojnog učenja nije dovoljno dobar za korištenje u dijagnostici bolesti COVID – 19.	Nedostatak dokumentacije o predloženim algoritamskim pristupima, visok rizik od pristranosti modela zbog obučenosti na malom broju COVID – 19 pozitivnih snimaka
6.	Aggarwal P. i sur., 2022. (12)	Duboko učenje	CT i RTG	Sažeti značajne studije temeljene na dubokom učenju koje mogu pomoći u budućnosti razvijanja modela za brzu i točnu dijagnozu bolesti COVID – 19	Sažetak posljednjih dostignuća (state of art) tehnika dubokog učenja korištenih u tehnologiji CT i RTG. U većini studija korišteni su manji skupovi podataka, te nedostaje usporedba s postojećim istraživanjima, također nisu dostupni kodovi i podaci kojima bi se mogla provjeriti primjena u kliničkim uvjetima.	Nisu istaknuta.

7.	Komolafe T. E. i sur., 2021. (13)	Duboko učenje	CT	Sustavnim pregledom i meta - analizom sažeti sve dostupne dokaze za kvantitativnu procjenu točnosti dijagnostičkog testa (DTA) algoritma dubokog učenja za otkrivanje bolesti COVID-19 na CT snimkama prsnog koša.	3 studije su izvijestile o višoj točnosti dijagnostičkog testa (DTA) algoritma dubokog učenja u usporedbi s interpretacijom radiologa, 4 studije su pokazale da je algoritam dubokog učenja pomogao performansama DTA, 6 studija pokazalo da je veća osjetljivost od specifičnosti, 9 studija pokazalo da je veća specifičnost od osjetljivosti.	Nisu istaknuta.
8.	Ozsahin I. i sur., 2020. (2)	Duboko učenje i strojno učenje	CT	Napraviti pregled studija koje obrađuju korištenje UI u dijagnozi bolesti COVID – 19 pomoću CT – a.	Široko obučene mreže mogu biti vrlo uspješne u svakoj fazi klasifikacije CT snimaka.	Podaci korišteni u studijama mogli su doći iz različitih institucija i različitih uređaja. Nedostatak demografskih i kliničkih informacija pacijenata.
9.	Alzubaidi M. i sur., 2021. (14)	Duboko učenje	CT, RTG i UTZ	Utvrđiti i prikazati ulogu algoritma dubokog učenja tijekom pandemije COVID – 19.	Većina studija je koristila algoritam dubokog učenja za otkrivanje COVID – 19 putem radioloških slika, no nisu koristile algoritam u svrhu praćenja zaraženih slučajeva ili primjene u robotici.	Broj skupova podataka je malen i jednolik. Analizirane studije su bile prijedlozi i nisu empirijski testirane.

10.	Wang Q. i sur., 2022. (15)	Duboko učenje	CT	Analizirati izvedbu modela dubokog učenja u dijagnozi bolesti COVID – 19 iz CT snimaka prsnog koša.	Modeli dubokog učenja imaju veliki potencijal u točnom dijagnosticiranju bolesti COVID – 19 i razlikovanju od ostalih upalnih bolesti pluća.	Izvor podataka iz različitih država i s različitih CT uređaja. Uključen je premalen opseg literature.
-----	-------------------------------	---------------	----	---	--	---

Tablica 2: Originalni znanstveni članci uključeni u analizu s tematikom primjene umjetne inteligencije u dijagnostici bolesti COVID – 19 pomoću snimaka kompjutorizirane tomografije toraksa

Redni broj članka	Ime prvog autora i godina publikacije	Metodologija istraživanja	Slikovna metoda	Ciljevi istraživanja	Rezultati istraživanja	Ograničenja istraživanja
1.	Hamwi W. A. i sur., 2022. (16)	Strojno učenje (konvolucijska neuronska mreža)	CT i RTG	Razviti integrirani model strojnog učenja kako bi se smanjilo pogrešno i kasno dijagnosticiranje bolesti COVID – 19, te usporediti istraživanje s ostalim istraživanjima.	Postignuta je ukupna točnost i F1 rezultat od 99, 73 % primjenjujući mreže u analizi CT snimaka u PNG formatu. Većina snimaka je točno dijagnosticirana.	Nisu istaknuta.
2.	Turk V. i sur., 2022. (17)	Duboko učenje	CT	Usporediti četiri modela algoritma dubokog učenja za klasificiranje pozitivnih i negativnih COVID – 19 nalaza.	Najbolji rezultat i najveću točnost je postigla arhitektura MobileNet.	Ograničen broj COVID – 19 pacijenata, različite veličine i rezolucije CT snimaka.
3.	Vaidyanathan A. i sur., 2022. (18)	Duboko učenje	CT	Predložiti okvir umjetne inteligencije temeljen na trodimenzionalnoj konvolucijskoj neuronskoj mreži namijenjen za klasifikaciju CT snimaka pacijenata s COVID – 19 bolesti, gripom/upalom pluća stečenom u zajednici i bez infekcije.	Ispitani model je pokazao izvrsne rezultate u vanjskom validacijskom sustavu s područjem ispod krivulje od 0.90, 0.92 i 0.92 za bolest COVID – 19, gripu/upalu pluća stečenu u zajednici i bez infekcije.	Prisutnost samo slučajeva upale pluća stečene u zajednici u podjeli za gripu/upalu pluća stečenu u zajednici, podrijetlo snimaka od samo dva različita dobavljača.

4.	Yousefzadeh M. i sur., 2021. (19)	Duboko učenje	CT	Predstaviti i procijeniti dijagnostičku izvedbu modela <i>ai – corone</i> na više baza podataka, te usporediti s nalazima radiologa, RT – PCR – a i druge dvije znanstvene studije.	Model <i>ai – corona</i> je naučio dijagnosticirati bolest COVID - 19, te razlikovati je od ostalih plućnih oboljenja iz CT snimaka. Također je, u usporedbi s ostala dva modela, pokazao bolju uspješnost.	Model se gradio tako da bude što snažniji i točniji, ali na jednostavnijoj bazi podataka. Nisu posebno odvojili ostale tipove upala pluća kako bi model bio što precizniji. Nisu unosili podatke slučajeva koji su bili RT – PCR negativni, a CT pozitivni.
5.	Anwar T. i sur., 2021. (20)	Duboko učenje	CT	Testirati model EfficientNet pomoću strategije peterostruke unakrsne provjere kako bi se provjerila točnost modela i usporedila uspješnost s ostalim člancima.	Dobiven je rezultat točnosti i F1 rezultat od 0.90 na istoj bazi podataka na kojoj su ostali članci dobili rezultat točnosti 0.86 i F1 rezultat 0.85.	Nisu istaknuta.
6.	Chamberlin J. H. i sur., 2022. (21)	Duboko učenje	CT	Procijeniti sposobnost duboke konvolucijske neuronske mreže za predviđanje ishoda bolesti COVID – 19, te analizirati uspješnost algoritma za stupnjevanje uznapređovalosti bolesti.	Ispitani algoritam se pokazao kao precizan i dijagnostički točan alat u procjeni bolesti COVID – 19.	Izvor podataka iz jedne institucije, retrospektivna priroda ove studije koja obuhvaća ponavljane valove bolesti COVID – 19, cjepiva i sojeva, studija nije opsegom obuhvatila trenutnu demografiju i komorbiditete kao faktore rizika.

7.	Chrzan R. i sur., 2022. (22)	Duboko učenje	CT (visoke rezolucije HRCT)	Analizirati uspješnost modela umjetne inteligencije u procjeni stupnja uznapređovalosti bolesti COVID – 19 na snimkama CT – a visoke rezolucije.	Umjetna inteligencija pokazala se kao jednostavan i pouzdan način dijagnosticiranja bolesti COVID – 19, te za predviđanje stupnja uznapređovalosti bolesti.	Retrospektivni dizajn, nije korištena posebna procjena za mjerenje volumena upale stoga model ne može procijeniti volumen upale, nije mogao razlikovati upalne konsolidacije i promjene na plućima uzrokovane bolestima koje nisu COVID – 19.
8.	Gunraj H. i sur., 2022. (23)	Duboko učenje (duboka neuronska mreža)	CT	Predstaviti novi algoritam COVID – Net CT – 2 namijenjen za dijagnostiku bolesti COVID – 19 iz CT snimaka.	Ovaj je algoritam treniran na velikoj, raznolikoj i multinacionalnoj skupini pacijenata te daje precizne i točne kvantitativne rezultate.	Algoritam nije u potpunosti spreman za široku upotrebu, no može ga se koristiti kao osnovu za nova istraživanja.
9.	Nguyen D. i sur., 2021. (24)	Duboko učenje	CT (3D)	Evaluirati klasifikacijske modele dubokog učenja trenirane da identificiraju bolest COVID – 19 na bazi podataka 3D CT – a iz različitih zemalja.	Modeli dubokog učenja s visokom preciznošću korektno identificiraju pacijente koji su COVID – 19 pozitivni, no samo kad je model korišten na bazi podataka na kojoj je treniran.	Modeli nisu uspješni kada se primijene na nepoznatoj bazi podataka (moguća posljedica različitih protokola i metoda prikupljanja podataka iz različitih zemalja, te različite demografije pacijenata), manjak generalizacije pri identifikaciji pacijenata.

Tablica 3: Pregledni članci koji se odnose na analizu etičkih problema u primjeni alata umjetne inteligencije u dijagnostici bolesti COVID-19

Redni broj članka	Ime prvog autora i godina publikacije	Ciljevi istraživanja	Rezultati istraživanja
1.	Brady A. P. i sur., 2020. (25)	Raspraviti o tehnološkim nedostacima umjetne inteligencije, nekima vezanim za etičke probleme, te ponuditi rješenja.	Istaknuti su glavni etički problemi vezani za tehnološke nedostatke umjetne inteligencije te su ponuđena rješenja. Zaključuje se da s razvojem umjetne inteligencije treba paziti na moguće etičke probleme te postaviti etički kodeks vezan za primjenu umjetne inteligencije u radiologiji.
2.	Čartolovni A. i sur., 2022. (26)	Uz etičke i legalne implikacije istaknuti i socijalne implikacije koje su bile zanemarene u dosadašnjim preglednim radovima jer zaslužuju jednaku pozornost u razvojnom stadiju.	Glavne kategorije na koje će primjena umjetne inteligencije u medicini imati su sigurnost pacijenata i njihovih podataka, algoritamska transparentnost, nedostatak odgovarajuće regulative, te utjecaj na odnos između liječnika i pacijenta.
3.	D'Antonoli T. A. i sur., 2020. (27)	Raspraviti o problemima održavanja etičkih i legalnih standarda kako bi se zaštitilo pacijenta pri implementaciji umjetne inteligencije u medicinu.	Umjetnu inteligenciju je potrebno što sigurnije uvesti u sustav kako bi se osigurala što bolja sigurnost za pacijenta. Također je potrebno educirati medicinske stručnjake kako bi ih se prilagodilo na rad s umjetnom inteligencijom.
4.	Franjić D. i sur., 2020. (28)	Objasniti pojam umjetne inteligencije, te proučiti etičke probleme vezane uz primjenu umjetne inteligencije u radiologiji.	Razni problemi kao što su zaštita privatnosti podataka, informirani pristanak pacijenta, sukob interesa i snošenje odgovornosti još nisu riješeni, no svjesnost o tim problemima navodi stručnjake da razvijaju sustav koji je temeljen na zakonima kako bi primjena umjetne inteligencije bila što sigurnija.
5.	Fernandez – Quilez A. i sur., 2022. (29)	Napraviti opsežan sažetak trenutno otvorenih pitanja i istaknuti ključne probleme tijekom razvoja i implementacije modela umjetne inteligencije u zdravstvo, posebno radiologiju.	Stavlja se poseban fokus na proces sakupljanja podataka te kako on utječe na funkcionalnost modela umjetne inteligencije, te etičke probleme koji mogu proizaći iz samog procesa.
6.	Geis J. R. i sur., 2019. (30)	Predstaviti zajednički stav koji se tiče etičkih pitanja vezanih za primjenu umjetne inteligencije u radiologiji, te nadahnuti ljude koji će graditi modele umjetne inteligencije da ih usmjeravaju u humanom pravcu prema pravednim i korisnim ishodima.	Trebali bi se razviti etički kodeksi za primjenu umjetne inteligencije kako bi se promicala dobrobit i minimalizirala šteta.

7.	Goisauf M. i sur., 2022. (31)	Do koje vrste etičkih pitanja dolazi primjenom umjetne inteligencije u medicinskim i biomedicinskim, te kako se te probleme rješava u radiologiji, točnije kod karcinoma dojke.	Rezultati pokazuju da se diskusija vezana za etičnost umjetne inteligencije uglavnom povezivala s medicinom, istaknula su se pitanja funkcioniranja modela umjetne inteligencije kao crne kutije i određenih pristranosti (rodnih pristranosti kod karcinoma dojke).
8.	Martin C. i sur., 2022. (32)	Temeljiti se na etičkim problemima vezanim za primjenu umjetne inteligencije u medicini te liječničkom pristupu prema etici korištenja umjetne inteligencije u kliničkoj praksi	Kako bi se pružila najbolja medicinska usluga, liječnicima moraju biti jasne moguće negativne posljedice koje bi mogle biti rezultat prerane implementacije modela umjetne inteligencije u kliničku praksu.
9.	Mudgal K. S. i sur., 2020. (33)	Pokriti glavne aspekte sigurne i održive implementacije umjetne inteligencije u radiologiju tijekom obuke, integracije i regulacije.	Ako se implementacija umjetne inteligencije provodi uz transparentnost, odgovornost, objašnjivost i pravednost, primjena ove tehnologije može se oblikovati u dobronamjernu.
10.	Neri E. i sur., 2020. (34)	Zaključiti tko i što bi bilo odgovorno za dobrobiti i štetnosti korištenja umjetne inteligencije u medicini.	S obzirom da će vjerojatno od radiologa biti traženo da provjeravaju rezultate koje je dobila umjetna inteligencija, biti će u riziku da sva odgovornost bude na njima. Stoga je potrebno da se kroz zakonodavstvom omogući okvir odgovornosti radiologa s obzirom na pružanje usluge koju daje umjetna inteligencija.
11.	Walsh G. i sur., 2023. (35)	Prikazati glavna načela etične i odgovorne umjetne inteligencije, istaknuti edukativne inicijativne koje su pokrenute za kliničare.	Implementacija umjetne inteligencije u medicinu temelji se na znanju i povjerenju koje su može postići čvrstom etikom, sveobuhvatnom, prilagođenom obukom te suradnjom među zdravstvenim djelatnicima.


4. RESPIRATORNA BOLEST COVID – 19

COVID – 19 spada u upalne bolesti respiratornog sustava uzrokovane virusom teškog akutnog respiratornog sindroma (engl. Severe – Acute – Respiratory – Syndrome – related Coronavirus – SARS – CoV – 2). Ova vrsta virusa u većini slučajeva uzrokuje bolesti kod životinja, no kroz mutacije putem divljih životinja može doći u kontakt s čovjekom te ga može zaraziti. Upravo se na taj način virus SARS – CoV – 2 prenio sa šišmiša na čovjeka čime je nastala nova respiratorna bolest, COVID – 19 (36). Prenosi se aerosolom s osobe na osobu ako su u bliskom kontaktu. Ova se bolest prezentira simptomima kao što su visoka tjelesna temperatura, kašalj i respiratorne poteškoće.

4.1. Struktura virusa SARS – CoV – 2

Virus SARS – CoV – 2 pripada obitelji koronavirusa *Coronaviridae*, rodu betacoronavirusa. Veličina čestica ovog virusa kreće se od 60 do 140 nm, a gradi ga jednolančana ribonukleinska kiselina (engl. Ribonucleic Acid – RNA). Građena je od 14 okvira otvorenog čitanja koji kodiraju 16 nestrukturnih, 9 pomoćnih i 4 strukturalna proteina (37). Nestrukturni proteini sudjeluju u reguliranju replikacije i transkripcije RNA virusa kao enzimi. Pomoćni proteini nisu esencijalni za replikaciju i transkripciju koronavirusa, ali olakšavaju virusu da se prilagodi domaćinu i obrani od imunološkog sustava domaćina. Četiri strukturalna proteina su *spike* protein (S), membranski protein (M), proteini omotača (E) i nukleokapsidni protein (N) (Slika 1) (37) .

Spike protein (S) je površinski protein koji čestici virusa daje specifičan izgled krune, od čega zapravo dolazi naziv *Coronavirus* (37). Ovaj glikoprotein omogućuje virusu vezanje za stanične receptore domaćina i ulaznje u same stanice. Membranski protein u interakciji s ostalim strukturalnim proteinima određuje kakvog će oblika biti virusna ovojnica. Kada se veže s nukleokapsidnim proteinom stabilizira se unutarnja jezgra virusa i nukleokapsid. Interakcijom membranskog proteina s proteinima omotača osigurava se oblik čestice i inicira oslobađanje. Proteini omotača su najmanji strukturalni proteini koji su važni za sastavljanje i pupanje virusa. (37)



Slika 1: Struktura SARS - CoV - 2 virusa (modificirano prema https://encrypted-tbn0.gstatic.com/images?q=tbn:ANd9GcSVwHzdkrd75ihDZ9WFeK_TiqZ50UAWMzJ5LPPfOaF7yg&s)

4.2. Prijenos virusa SARS – CoV – 2 i mjere zaštite

Nakon što je virus dovoljno mutirao da može prijeći sa životinje na čovjeka, postao je visoko infektivan za ljude. Zaražene osobe su najzaraznije prije nego što razviju prve simptome (okvirno 2 dana prije pojave simptoma) i u ranim stadijima bolesti. Bolest uzrokovana ovim virusom može se prenositi među ljudima na različite načine (1).

Najčešće se širi među ljudima koji su u bliskom kontaktu, na malenoj udaljenosti. Virus se prenosi tekućim česticama, tj. aerosolom iz usta ili nosa zaražene osobe kada osoba govori, diše, kašlje ili slično. Osoba se može zaraziti ovim putem ako čestice dođu u doticaj sa sluznicom očiju, usta ili nosa (1). Do zaraze također može doći ako ljudi dodiruju usta, nos ili oči nakon što su dirali kontaminiranu površinu ili predmet. Osoba se može zaraziti i u slabije prozračenim prostorijama ili u zatvorenim prostorima gdje boravi puno ljudi u kojima se aerosol pun infektivnih čestica zadržava duže vrijeme (1).

Za vrijeme pandemije, WHO je dala detaljne smjernice za pridržavanje populacije kako bi se smanjilo širenje bolesti (1). Da bi se reducirala mogućnost zaraze virusom bitno je držati fizičku udaljenost od najmanje jedan metar od ostalih. Poželjno je da se izbjegavaju gužve, no ako je to neizbježno potrebno je pravilno nositi medicinske maske za lice. Čestim pranjem i dezinficiranjem ruku također se smanjuje vjerojatnost prijenosa zaraze.

Preventivno djelovanje se ostvaruje cijepljenjem. Znanstvenici su uz rapidni razvoj bolesti pokušavali razviti cjepiva koja bi bila uspješna u obrani od bolesti. U samom početku bolesti razvijeno je preko 100 vrsta cjepiva na temelju prijašnjeg znanja o *Coronavirusima*. (38) Primjena cjepiva je prvenstveno bila preporuka za starije stanovništvo te osobe s komorbiditetima ili imunokompromitirane, kako bi ih se zaštitilo od zaraze ili ublažilo težinu bolesti ako dođe do zaraze. Danas je preporuka da bi cjelokupno stanovništvo trebalo biti cijepljeno barem jednom dozom cjepiva kako bi se ublažili mogući simptomi i kako bi se smanjila smrtnost (1).

4.3. Simptomatologija i klinička slika bolesti COVID – 19

Inkubacijsko razdoblje bolesti COVID – 19, vremensko razdoblje od izloženosti virusu do manifestacije prvih simptoma, traje 5 do 6 dana u prosjeku, no može trajati čak do 14 dana (39). Ovo razdoblje se još naziva i predsimptomatsko razdoblje, obilježava ga visoka zaraznost osoba koje lako mogu prenijeti virus na ostale zdrave pojedince.

Dobna skupina koju najčešće pogađa ova bolest je od 40 do 70 godina starosti (40). Glavni simptomi kojima se ova bolest prezentira su vrućica, bolovi u tijelu, nedostatak daha, suh kašalj te ponekad se javljaju i gastrointestinalni simptomi kao što su abdominalni bolovi, povraćanje i promjene u stolici. Težina bolesti može varirati od asimptomatske da pacijenti niti ne primijete da su zaraženi, preko blagog oblika do vrlo teške bolesti (40).

U početku, može se raditi o infekciji gornjeg respiratornog sustava, ali se u nekih bolesnika bolest može razviti u teži oblik kao što je upala pluća s otežanim disanjem i nedostatkom zraka te može progredirati u akutni respiratorni distress sindrom (engl. Acute Respiratory Distress Syndrome – ARDS) i u najtežim slučajevima može dovesti do smrti (41). Rizični dio populacije čine osobe starije životne dobi s komorbiditetima, trudnice i nedonošćad, novorođenčad te osobe koje su imunokompromitirane (40).

5. METODE DIJAGNOSTICIRANJA BOLESTI COVID – 19

Pravovremena detekcija virusa SARS – CoV – 2 je bitna da bi se lakše kontroliralo širenje i uznapređevalost bolesti COVID – 19. Zahvaljujući modernim tehnikama molekularne tehnologije, postoji više načina i testova kojima se može detektirati virus SARS – CoV – 2. Jedan od testova koji je postao zlatni standard u dijagnostici bolesti COVID – 19 je RT – PCR (42). Ova se infektivna bolest na plućima također može detektirati radiološkim metodama, od kojih je najpreciznija CT metoda (42).

5.1. RT – PCR test

RT – PCR je najčešće korišten test za utvrđivanje bolesti COVID – 19. Uglavnom se koristi za brzo dijagnosticiranje pacijenata kod kojih su se pojavili simptomi bolesti, ili za probir asimptomatskih pacijenata. Funkcionira na principu visoko osjetljive tehnologije pomoću koje se detektira prisutnost genetičkog materijala virusa u uzorku. Uzorak za analizu se uzima brisom nazalnog ili nazofaringealnog područja (43).

Nakon što se uzme uzorak za analizu, bude tretiran s nekoliko kemijskih otopina kako bi se izdvojila RNA i uklonile ostale tvari kao što su proteini i masti. RNA ekstrahirana ovim putem je mješavina genetskog materijala pacijenta i RNA virusa ako je prisutan (43). U sljedećem se koraku RNA pretvara u DNA postupkom obrnute transkripcije uz pomoć enzima. Zatim se smjesa s DNA stavlja u RT – PCR stroj koji radi na principu zagrijavanja i hlađenja smjese kako bi se pokrenuli kemijski procesi kojima se stvaraju kopije određenih dijelova virusne DNA (43). Uz proces stvaranja kopija virusne DNA na nove se dijelove pričvršćuju oznake markera koje otpuštaju fluorescentnu boju. Računalo mjeri otpuštanje fluorescentne boje i prikazuje rezultat na ekranu (43).

Rezultat je pozitivan, odnosno potvrđuje se prisutnost virusa, kada razina fluorescencije prijeđe određenu mjeru (43). Znanstvenici također prate koliko je ciklusa stvaranja kopija virusne DNA bilo potrebno da bi došlo do fluorescencije jer na taj način utvrđuju ozbiljnost bolesti i koliko je napredovala. Što je manje ciklusa bilo potrebno to znači da je bolest težeg oblika (43).

Ovaj test je u većini slučajeva točan, no može doći i do lažno negativnih i lažno pozitivnih rezultata. Do toga dolazi zbog uzimanja uzoraka u različitom vremenu od pojave simptoma. Optimalno bi bilo da se pacijent testira treći ili četvrti dan od pojave prvih simptoma (43).


5.2. Kompjutorizirana tomografija (engl. Computer Tomography – CT) toraksa

CT je tehnika slojevnog snimanja koja koristi kolimirani rendgenski snop usmjeren okomito na uzdužnu os tijela što rezultira aksijalnim presjekom odabrane debljine sloja. Snimka se dobije na način da detektori mjere intenzitet oslabljene radijacije nakon prolaska kroz tijelo. Ova se radiološka metoda zbog visoke osjetljivosti koristi za potvrdu prisutnosti bolesti COVID – 19 te određivanje stadija uznapređovalosti (3).

Odabrani protokol snimanja pacijenta za kojeg se sumnja da ima bolest COVID – 19 je standardni protokol za snimanje toraksa, no može se snimiti i po protokolu s visokom rezolucijom (engl. High Resolution Computed Tomography – HRCT) (44). Na topogramu se određuje polje gledanja obično od plućnog vrha do baze pluća bez obuhvaćanja nadbubrežnih žlijezda. Za ovaj pregled nije potrebna primjena kontrastnog sredstva zbog toga što su COVID – 19 pneumonije uglavnom lokalizirane u plućima te se ne šire na pleuru i medijastinum. Poželjno je da se snimanje obavlja kada pacijent duboko udahne kako bi bio što bolji prikaz pluća. No, s obzirom da je COVID – 19 plućna bolest koja izaziva kašalj i poteškoće s disanjem, potrebno je da protokol snimanja traje što kraće kako bi se izbjegli artefakti. Zbog toga se predlaže jednofazno snimanje CT – a s bržim vremenom rotacije kućišta (0, 5 s ili manje) i višom vrijednosti *pitcha* (više od 1 : 1) (44).

Radiomorfološki znakovi bolesti COVID – 19 koji se prezentiraju na CT snimkama su konsolidacije, zračni bronhogram, opacifikacije zrnatog stakla (engl. *Ground – Glass Opacities – GGO*), opacifikacije ludog popločenja (engl. *crazy – paving*), obrnuti *halo* znak te perilobularni uzorak (3). Promatrajući navedene radiomorfološke znakove može se okvirno zaključiti u kojem je stadiju razvoja bolest.


U ranoj fazi, koja traje od početka bolesti do četiri dana, na CT snimkama se mogu uočiti GGO (Slika 2). Sljedeća, progresivna faza, koja traje pet do osam dana, se na CT snimkama prezentira opacifikacijama ludog popločenja, GGO i manjim konsolidacijama. Devet do trinaest dana traje vršna faza koja se na CT snimkama očituje konsolidacijama plućnog parenhima okruženim znakom *halo* ili GGO (Slika 3.). Posljednja ili apsorpcijska faza nastaje nakon četrnaestog dana bolesti kada se parenhim pluća počinje oporavljati, što se na CT snimkama vidi kao GGO i linearne konsolidacije (45).



Slika 2: CT toraksa kod bolesnika s COVID – 19 pneumonijom u trećem danu bolesti. Vidljive su periferno smještene opacifikacije zrnatog stakla (engl. Ground – Glass Opacities – GGO) (označene crvenim strelicama), (Arhiva Klinike za infektivne bolesti „Dr. Fran Mihaljević“ u Zagrebu).

Najčešći znak COVID – 19 pneumonije su multifokalne GGO opacifikacije koje budu smještene bilateralno. Lezije su najčešće smještene u bazalnim, perifernim i posteriornim dijelovima pluća. Znakovi bolesti COVID – 19 koji se prezentiraju na snimkama CT – a mogu biti dosta slični znakovima drugih virusnih upala pluća. Ono što razlikuje COVID – 19 od nekih virusnih upala pluća (npr. uzrokovanih adenovirusom ili virusom influence) je periferna lokalizacija lezija, prožetost svih pet plućnih režnjeva te prisutnost uskih retikulacija i peribronhovaskularnih zadebljanja (46).

Također je moguće da COVID – 19 pneumonija bude atipično prezentirana na snimkama CT – a. U tom se slučaju na snimkama mogu vidjeti pseudonodularne konsolidacije, te obrnuti *halo* znak. Ako je bolest u ranom stadiju, tj. nije došlo do zahvaćanja oba plućna krila, znakovi mogu biti vidljivi samo unilateralno (obično prva četiri dana od početka simptoma). Može se istaknuti i lokalizacija patoloških uzoraka u plućnim vrhovima ili peribronhovaskularno (47).



Slika 3: CT toraksa kod bolesnika s COVID – 19 pneumonijom u desetom danu bolesti. Vidljive su GGO opacifikacije (plavi trokut) i periferne konsolidacije u plućnom parenhimu desnog plućnog krila (crvena strelica). (Arhiva Klinike za infektivne bolesti „Dr. Fran Mihaljević“ u Zagrebu).

6. UMJETNA INTELIGENCIJA – UI (ENGL. ARTIFICIAL INTELLIGENCE – AI)

UI je polje znanosti koje se klasificira kao grana računalnih znanosti kojoj je cilj imitirati ljudsko ponašanje na način da kopira ljudsko razmišljanje, inteligenciju te da na taj način rješava zahtjevne zadatke (48). Ova domena računalnih znanosti gradi sustave koji imaju sposobnost primati, analizirati i reagirati na razne podražaje koji im se predstavljaju u obliku podataka. Na temelju unesenih podataka, program baziran na tehnologiji UI može učiti iz danih podataka i samostalno djelovati. Dva glavna alata pomoću kojih program utemeljen na tehnologiji UI može obnavljati svoju bazu podataka su strojno i duboko učenje (48).

6.1. Strojno učenje (engl. Machine Learning)

Na sličan način kao ljudi, sustavi UI mogu učiti iz prošlih iskustava i na taj se način poboljšati. To im omogućuje koncept rada nazvan strojno učenje. Naime, strojno je učenje domena umjetne inteligencije koja se bavi izgradnjom algoritama pomoću kojih računalo

samostalno proučava dane baze podataka te iz njih uči i gradi iskustvo (48). Ovom metodom računalo proučava dostupnu bazu podataka (obično bazu podataka za obuku) te ju pomoću danih algoritama analizira i odlučuje koji bi mogao biti ishod. Točnost predviđanja i bolje performanse samog računala su rezultat treninga na što većim bazama podataka (48). Ovaj je model povoljan u djelatnostima koje se bave obradom velikog broja kompleksnih podataka, zbog toga što olakšava posao ljudima te skraćuje potrebno vrijeme za obradu podataka (48).

Strojno se učenje može podijeliti u tri glavne kategorije ovisno o tome kakav je signal za učenje ili odgovor računalo dobilo (48). Kategorije su nadzirano, nenadzirano i podržano učenje (48).

Nadzirano učenje (engl. Supervised Learning) funkcionira na način da se algoritmi uvježbavaju pomoću označenih podataka (48). Ovim se pristupom sustavu daje baza podataka koja sadrži poznat i ulazni i izlazni skup podataka te se analizom trenira model za predviđanje. Algoritam na ovaj način uspoređuje svoj stvarni izlaz s danim točnim izlazima te se na taj način aktualizira kako bi postigao dovoljno dobre rezultate. Prema ovom načinu učenja algoritme se može podijeliti u dvije kategorije, na regresiju i klasifikaciju (48).

Nenadzirano učenje (engl. Unsupervised Learning) je metoda u kojoj se računalo trenira samostalno bez nadzornika (48). Sustavu se daje baza podataka koji nisu označeni niti klasificirani. Algoritam mora samostalno analizirati podatke i odrediti stupanj sličnosti među njima kako bi mogao zaključiti i dovesti do točnog izlaza za zadani problem. U ovom načinu učenja algoritmi mogu koristiti dvije tehnike, grupiranje i asociranje (48).


Podržano učenje (engl. Reinforcement Learning) je metoda učenja koja se bazira na povratnim informacijama koje algoritam dobije nakon što riješi zadani problem (48). Funkcionira pomoću analiziranja prethodnih izvedbi. Za svaki ispravan rezultat računalo dobije nagradu, a za svaki neispravan rezultat bude kažnjeno. Algoritmu se na taj način postavi cilj da skupi što više nagrada, a time i poboljša ispravnost (48).

Glavna prednost ove metode je sposobnost ponavljanja procesa dok ne pronađe točan izlaz te se time i samostalno nadograđuje. No, s druge strane problem metode strojnog učenja je taj što je za treniranje i usavršavanje potrebna heterogena baza s velikim brojem podataka (48).

Algoritmi koji se nadograđuju i uče metodom strojnog učenja imaju široku primjenu, najčešće u medicinskoj dijagnostici, obradi fotografija, u marketinškom i financijskom sektoru te mnogim drugima.

6.2. Duboko učenje (engl. Deep Learning)

Duboko učenje se kategorizira kao podskupina strojnog učenja koja je naprednija od ostalih jer je sustav na temelju kojeg radi sličan ljudskom živčanom sustavu te pokušava imitirati rad neurona (48). Ovaj model radi na temelju arhitekture neuronskih mreža koje su inspirirane ljudskim mozgom. Neuronske se mreže sastoje od mnogobrojnih čvorova koji se nalaze u skrivenim slojevima čiji je zadatak povezati ulazne i izlazne slojeve (48). Broj skrivenih slojeva varira od mreže do mreže te zbog njihovog broja koji je obično velik dolazi naziv duboko učenje (Slika 4.). Što je mreža „dublja“, tj. što ima više skrivenih slojeva, to ima veću mogućnost boljeg prikaza i obrade podataka. Proces dubokog učenja započinje tako da računalo razumije zadani problem te identificira podatke i odabire pravilan algoritam nakon čega kreće obuka i testiranje modela (48).



Slika 4: Struktura umjetne neuronske mreže (modificirano prema <https://media.geeksforgeeks.org/wp-content/cdn-uploads/20230602113310/Neural-Networks-Architecture.png>)

Prednost ovog modela učenja je ta što može učiti i bez prethodno definiranih podataka te ne zahtijeva detaljno programiranje kao strojno učenje. Najveći izazov s kojim se susreće ovaj model je prikupljanje velike količine podataka i njihova točna klasifikacija (48).

UI je našla primjenu u medicini u raznim dijelovima zdravstvenog sustava, od pohrane podataka do pomoći u dijagnosticiranju. Grana medicine koja je oduvijek vodila u digitalizaciji medicine bila je radiologija. Radiologija je i danas jedan o vodećih pokretača u uvođenju UI u zdravstveni sustav kako bi se poradilo na preciznosti i brzini u dijagnosticiranju.

Svake se godine obavlja sve više radioloških pretraga čime se stvara veliko radno opterećenje za radiologe. Bez obzira na opseg znanja i iskustva radiologa, uz toliko opterećenje može doći do neizbježnih grešaka prilikom dijagnosticiranja. Stoga se, kako bi se pomoglo radiolozima te im se smanjio opseg posla, počela uvoditi tehnologija UI u radiologiju. Posebno je došla do izražaja primjena UI u doba pandemije COVID – 19 kada je već i tada širok opseg posla postao izrazito velik (48).

7. PRIMJENA UMJETNE INTELIGENCIJE U DIJAGNOSTICI BOLESTI COVID – 19


Pojavom pandemije COVID – 19 pojavili su se razni novi izazovi za zdravstveni sustav. Došlo je do poteškoća s pravovremenim dijagnosticiranjem zbog toga što su testovi znali biti nedostupni i slabije kvalitete što bi dovodilo do lažnih rezultata. Također, zbog velike brzine širenja bolesti, puno je ljudi bilo istovremeno zaraženo što je rezultiralo kašnjenjem u obradi uzoraka. Zbog same prirode bolesti bilo je potrebno da se bolest COVID – 19 točno i brzo dijagnosticira.

Kako bi se riješilo navedene izazove koje je donijela pandemija COVID – 19, počela se implementirati tehnologija UI u zdravstveni sustav. Korist UI se posebno istaknula primjenom u dijagnostičkoj radiologiji pri očitavanju radioloških snimaka kao što su snimke CT – a i digitalni torakalni radiogrami. Na ovaj je način povećana točnost i brzina vremena potrebnog za obradu snimke. Studije su pokazale da su današnji modeli umjetne inteligencije jako uspješni u dijagnostici bolesti COVID – 19, te da im je točnost predviđanja dijagnoze u razini s radiolozima i u nekim slučajevima čak i preciznija (49).

Zdravstveni djelatnici koriste tehnologiju UI kako bi što brže i preciznije analizirali radiološke snimke te došli do dijagnoze bez potrebe za dugotrajnim analiziranjem snimaka. Također kod pregledavanja velikog broja snimaka može doći do zamora radiologa te povećanja subjektivnosti u interpretiranju nalaza, što može rezultirati greškama u dijagnozi (49).

Kako bi se stopa dijagnostičkih grešaka smanjila, koriste se modeli dubokog učenja s ciljem da se razviju alati za analizu snimaka koji rade na principu automatizma (Slika 5.). Ovim se alatima brže dolazi do preciznijih rezultata i dijagnoza te naposljetku se smanjuje opterećenje radiologa. Svojevremeno za modele dubokog učenja je da identificirajući pojedine strukture i dijelove mogu učiti iz radioloških snimaka i na taj način nadograđivati neuronsku mrežu i širiti bazu podataka (50).

Za izgradnju softvera za dijagnostiku bolesti COVID – 19, u većini slučajeva su korišteni modeli dubokog učenja koji funkcioniraju pomoću metode prenesenog učenja (engl. Transfer Learning) (50). Ovom kombinacijom postigla se visoka preciznost i točnost modela pri raspoznavanju bolesti COVID – 19 od ostalih plućnih bolesti (50). Nekoliko algoritama za klasifikaciju je imalo važnu ulogu u klasificiranju pri istraživanju vezanom za dijagnozu bolesti COVID – 19 (50). Neki od njih su neuronske mreže, vektorski strojevi za podršku, algoritam slučajne šume i stabla odlučivanja (50). Ovi su algoritmi pokazali visoku uspješnost u obavljanju zadataka, no potrebno ih je još optimizirati (50).



Slika 5: Prikaz alata za označavanje lezija karakterističnih za COVID – 19 pneumoniju na snimkama CT toraksa. (Arhiva Klinike za infektivne bolesti „Dr. Fran Mihaljević“ u Zagrebu).

7.1. Algoritmi za klasifikaciju korišteni u dijagnostici bolesti COVID – 19


Neuronske mreže su sustavi utemeljeni na radu ljudskog mozga koji se sastoje od međusobno povezanih elemenata nazvanih umjetni neuroni. Ulazne vrijednosti koje se unose u algoritam množe se s težinskim faktorom te onda zbrajaju čime se dobije ulazna vrijednost prijenosne funkcije neurona (51). Rezultat prijenosne funkcije čini zapravo izlaznu vrijednost neurona koja je dalje ulazna vrijednost drugog neurona. Na taj se način pravilno gradi i povezuje cijela struktura neuronske mreže (51). Ovisno o vrsti primjene, ulazne i izlazne vrijednosti mogu biti interpretirane na razne načine, npr. kao binarni vektori, cijeli ili realni brojevi (51). Ova vrsta algoritma se najčešće primjenjuje u nekim zadacima koje obična računala ne mogu dovoljno dobro obaviti (npr. prepoznavanje oblika, govora ili tekstova pisanih rukom) (Slika 6.).

Vektorski strojevi za podršku spadaju pod klasifikatore strojnog učenja koji su našli primjenu uglavnom u rješavanju numeričkih problema predviđanja, prepoznavanju uzoraka i klasificiranju podataka (51). Najčešće se koriste za klasificiranje tekstova. U ovom algoritmu se crta svaka podatkovna stavka kao točku u n – dimenzionalnom prostoru (gdje je n broj poznatih značajki), a vrijednost svake značajke je vrijednost određene koordinate (51). Zatim se provodi klasifikaciju tako da se pronađe optimalna hiper – ravnina koja vrlo dobro razlikuje dvije klase. Cilj korištenja ovog algoritma je crtanje hiper – ravnine odvojenih podatkovnih točaka s najvećom marginom ili s najvećim razmakom između linije razdvajanja i bilo koje dane podatkovne točke kako bi se postigla uravnotežena margina između dviju različitih klasa (51).

Stablo odluke je algoritam koji spada pod nadzirano strojno učenje. Ovo je jedna od najpraktičnijih metoda nadziranog učenja koja se koristi za klasifikaciju i regresiju. Svako stablo sadrži čvorove, grane i listove (51). Čvorovi predstavljaju po jednu značajku problema koji se rješava. Na čvorove se nastavljaju grane koje prikazuju svaku vrijednost koju taj čvor može poprimiti. Ovisno o tome koju će vrijednost atribut dobiti za određeni ispitni slučaj, putuje se kroz stablo prateći određenu granu. Na kraju svake grane se nalaze listovi koji su reprezentacija razreda u koje se dijele i slažu ulazni podaci (51).

Za algoritam slučajnih šuma može se ugrubo reći da se sastoji od više stabala odluke. U ovom se algoritmu koristi odvajajuću (engl. bagging) metodu kojom se za izgradnju stabala odluke uzima nasumičan podskup uzoraka iz skupa podataka za treniranje (51). Svako stablo

predstavlja glas te algoritam očitava najmnogobrojniji glas. Ne uzimaju se svi uzorci i atributi kako bi se istrenirala pojedina stabla, već se uzima određen broj nasumično odabranih atributa i uzoraka (51).



Slika 6: U gornjem redu vide se neznačajne snimke CT – a kod bolesnika s COVID – 19 pneumonijom, a u donjem redu su „toplinske mape“ s označenim karakterističnim lezijama za COVID – 19 pneumoniju koje označava algoritam umjetne inteligencije. (Arhiva Klinike za infektivne bolesti „Dr. Fran Mihaljević“ u Zagrebu).

8. ANALIZA ČLANAKA S TEMATIKOM PRIMJENE UMJETNE INTELIGENCIJE U DIJAGNOSTICI BOLESTI COVID – 19 POMOĆU SNIMAKA KOMPJUTORIZIRANE TOMOGRAFIJE TORAKSA

8.1. Radiološki znaci COVID – 19 infekcije na kompjutoriziranoj tomografiji i protokoli skeniranja

Autori svih analiziranih radova, kako preglednih tako i originalnih, navedenih u Tablicama 1. i 2., jedinstveni su u korištenju i klasifikaciji radioloških znakova koji se javljaju na CT – u kod bolesnika s COVID – 19 pneumonijom. U akutnoj fazi najčešće se javljaju opacifikacije poput zrnatog stakla (GGO), konsolidacije plućnog parenhima ili kombinacija (7). Terminologija je standardizirana i definirana po rječniku Fleischner Society (46).

Duboke konvolucijske mreže se temelje na biološkom procesu humanog vizualnog korteksa u mozgu. CNN se sastoji od više slojeva gdje je viši sloj povezan s nižim slojem kako bi

analizirao apstraktne značajke slika uzimajući u obzir prostorne odnose između receptivnih polja. To omogućuje CNN – u prepoznavanje uzoraka i identificiranje uzoraka unutar slojeva slika. Različiti modeli CNN – a primjenjuju različite slojeve, broj neurona i receptivna polja u odgovarajućim slojevima i različite algoritme.

Od navedenih jedanaest originalnih znanstvenih radova (Tablica 2.), samo su četiri skupine autora navele detaljan protokol skeniranja pacijenata (18, 22, 41, 46). Ti su protokoli bili učinjeni na 64 ili 128 slojnim CT – ima, u inspiratornoj fazi, bez primjene intravenoznog kontrastnog sredstva, tijekom jednog zadržavanja daha. Debljina slojeva se kretala od 0,5 do 2 mm, a fiksni napon cijevi postavljen je na 120 kVp s automatskom modulacijom cijevi. Iz sirovih podataka, CT slike su rekonstruirane matricom 512x512 u aksijalnom presjeku, s iterativnom rekonstrukcijom. Podaci su zatim arhivirani u digitalnom sustavu za arhiviranje i komunikaciju (Picture Archiving and Communications System – PACS) i preneseni na sučelja za različite algoritme korištenja alata UI.

Autori ostalih analiziranih znanstvenih radova iz Tablice 2. (4, 16, 17, 19, 20, 23, 24) nisu precizno naveli protokole snimanja. Neki su koristili globalno javno dostupne baze podataka koje su imenovali i definirali. Na primjer Nguyen i sur. koristili su tri baze: China Consortium of Chest CT Image Investigation (CC – CCII) Dataset (China), 2) COVID – CTset (Iran) i 3) MosMedDat (Rusija) (24). Ostali autori nisu precizirali imena baza, već su samo naveli da se radi o javno dostupnim bazama podataka (17) ili o podacima prikupljenim unutar njihovih bolnica (19).

Činjenica da se u različitim istraživanjima koriste različite baze slikovnih podataka i nepoznati ili neujednačeni protokoli skeniranja upućuje na jedan od većih problema u razvoju i integraciji UI u proces analize CT snimaka kod COVID – 19 pacijenata, a to je nedostatak standardizacije podataka. Samim time je i usporedba rezultata otežana.

Trening algoritma na visokokvalitetnim podacima koji su reprezentativni za ciljanu populaciju, uz eksternu validaciju, daje najbolju procjenu performansi modela (36).

Da bi prikupili kvalitetne slikovne podatke, istraživači moraju biti upoznati s lokalnim smjernicama vezanim uz upotrebu i distribuciju podataka o pacijentima, a ključni su i protokoli za anonimiziranje i sigurno pohranjivanje podataka u PACS – u. Dobivanje velikih količina CT – a s kvalitetnim snimkama i označenim lezijama koje su markirali iskusni torakalni radiolozi je

teško, posebno kada se radi o malim bazama podataka. Postoje diskrepancije između standarda istraživanja u medicini i strojnom učenju. Istraživači iz područja strojnog učenja trebaju biti upoznati sa standardnim propisima za procjenu značajki modela. S druge strane, medicinski standardi moraju se ažurirati kako bi podržavali pravila dubokog učenja.

8.2. Značaj primjene alata umjetne inteligencije u COVID – 19 pneumoniji kod kompjutorizirane tomografije toraksa

Tijekom pandemije COVID – 19 infekcije brojnim je studijama dokazano da je CT primarni modalitet oslikavanja i „zlatni standard“ kod pacijenata sa sumnjom na infekciju (9, 20, 22). CT snimke imaju značajno bolju prostornu rezoluciju u usporedbi s rendgenskim snimkama i detaljnije pokazuju distribuciju opacifikacija i njihove oblike. Osobito je važna visoka prostorna rezolucija u trodimenzionalnom prikazu, što omogućuje preciznu kvantifikaciju opacifikacija (9). S obzirom na veliki broj pacijenata s kojima su se suočavale bolnice diljem svijeta tijekom pandemije, ograničen broj radiologa i vremena koje se moglo posvetiti očitavanju, stručnjaci za UI uložili su velike napore u razvoju alata i njihovu implementaciju kako bi se automatizirao proces dijagnostike i ubrao proces izvještavanja, koji bi po kvaliteti i pouzdanosti bio istovjetan nalazu iskusnog radiologa.

Radiološko društvo Sjeverne Amerike (Radiologic Society of North America – RSNA) i Inicijativa za primjenu umjetne inteligencije u slikovnim metodama za analizu COVID-19 u Europi (Imaging COVID-19 AI Initiative in Europe) omogućili su javni pristup bazama podataka sa slikovnim materijalima, kako bi se omogućilo treniranje alata dubokog učenja na provjerenim i dokazanim slučajevima (7). Ukoliko nema dovoljno slikovnih podataka, modeli ne mogu biti dovoljno generalizirani. Kako bi se taj nedostatak otklonio, uvedena je metoda augmentacije podataka, koja je učinkovita u treniranju diskriminativnih modela dubokog učenja (3). Primjeri tehnika augmentacije podataka uključuju rotiranje, fluktuaciju boje, nasumično obrezivanje, elastične distorzije i generativne kontradiktorne mreže (engl. Generative Adverse Networks – GAN) za generiranje sintetskih podataka (3, 52). One se sastoje od dviju mreža koje se međusobno sukobljavaju. Prva se naziva generator, a druga diskriminator. Tradicionalne metode augmentacije koje vrše jednostavne promjene slike manje su učinkovite od naprednih (3). U prevladavanju nedostataka podataka GAN se koristi kako bi se razvile učinkovite strategije augmentacije podataka za slikovno prepoznavanje (3). To se

odnosi na složene i specijalizirane algoritme i sisteme dubokog učenja koji prema predikcijama i transformaciji podataka iz jednog u drugi sustav proizvode dinamične slikovne podatke (7)

Dio preglednih i originalnih istraživanja navedenih u Tablici 1. i 2. pokazao je visoku točnost metoda dubokog učenja u analizi CT snimaka kod bolesnika s COVID – 19 pneumonijom (9, 13, 17, 18, 19). Većina navedenih istraživanja podijelila je skup podataka na 70 – 80% za trening i 30 – 20% za testiranje, dok su druge studije podijelile skup podataka na 50% za trening i 50% za testiranje (14). Studija koja je podijelila skup podataka na 40% za trening i 60% za testiranje postigla je visoku osjetljivost i najbolje rezultate (14).

Ortiz i suradnici razvili su dva načina za automatsko ekstrahiranje klinički relevantnih značajki iz CT – a toraksa u okviru ograničenih podataka i kombinirali te značajke s demografskim podacima kako bi razvili model prognoze za ishode COVID – 19. Pomoću MIP rekonstrukcija (engl. Maximum Intensity Projection) stvorili su 3D CT volumne mape, koje se mogu koristiti u COVID – 19 dijagnostičkom modelu bez potrebe za segmentacijom lezija. Zatim je model identificirao četiri plućne lezije specifične za COVID – 19 infekciju i izračunao lokaciju i obim svake vrste lezije. Ovakav pristup omogućio je identificiranje 3D patoloških slikovnih podataka koji se mogu kombinirati s drugim kliničkim podacima. Na taj su način autori stvorili prognostički pristup koji je analizirao najrelevantnije nalaze CT – a u kombinaciji s demografskim podacima kako bi se precizno prognozirali ishodi u komparaciji s modelima koji su temeljeni samo na mapiranju intenziteta ili segmentiranim značajkama (53).

8.3. Prednosti i ograničenja primjene alata dubokog učenja

8.3.1. Setovi podataka

Za implementaciju konvolucijskih neuronskih mreža potrebno je uvesti skup podataka i potrebne biblioteke, pripremiti podatke, izgraditi CNN, trenirati je i dobiti konačnu predikciju. Prednost velikih, javno dostupnih baza podataka je mogućnost da ih brojni istraživači mogu neograničeno koristiti u stvaranju i testiranju alata dubokog učenja. Međutim, potrebno je uzeti u obzir da većina skupova podataka ima ograničen broj kliničkih slučajeva infekcije COVID – 19. Prije nego što se podaci analiziraju alatom dubokog učenja, većina dostupnih skupova podataka zahtijeva „predobradu“, poput promjene veličine, usklađivanja formata slika i segmentacije slike plućnog parenhima od ostalih dijelova tijela (17). Zbog problema s

„nečistim” sirovim podacima, kao što su ponavljajuće i nesegmentirane slike pluća, odabir najbolje slike za model je često vrlo izazovan (17).

Mogućnost „pročišćavanja” setova podataka omogućuje odstranjivanje ponavljajućih slika iz setova podataka (17). Na taj način osigurano je da nema ponavljajućih slika prije nego što se skup podataka preda modelu. Ponavljajuće slike će generirati netočne rezultate ukoliko se pojave u skupovima podataka koji služe i za trening i za testiranje. Testni skup ne smije prethodno „vidjeti” podatke, kako bi se ispitala učinkovitost modela (17). Podjelom podataka u tri kategorije skupova: za trening, test i validaciju na temelju demografskih podataka pacijenata sprječava pojavljivanje istog pacijenta u dva skupa (17).

8.3.2 Metoda segmentacije

Segmentacija pluća predstavlja razdvajanje slika dijelova pluća od drugih dijelova grudnog koša. Ovaj početni korak je potreban za analizu CT snimaka pluća i igra ključnu ulogu u performansama klasifikacijskog modela (7). „Sirove” CT snimke sadrže šum i razlikuju se, ovisno o vrstama uređaja i varijacijama u konstituciji pacijenata. Segmentacija također rješava heterogenost podataka među različitim podskupovima podataka, ukoliko se kombiniraju u jedan skup. Segmentacija omogućuje modelu da se fokusira na karakteristične COVID – 19 opacifikacije ulazne slike. Najčešća i najšire prihvaćena metoda je označavanje granica pluća koja ih dijeli od okolnih organa, korištenjem posebnih alata (10).

Rezultati segmentacije se anotiraju, a rezultate kontroliraju najmanje dva iskusna torakalna radiologa. U usporedbi s anotacijama opacifikacija koje napravi radiolog, segmentacijske mreže postižu bolje rezultate u smislu dobivanja visoke točnosti te oštrijih i jasnijih granica razdvajanja lezija (10).

8.3.3. Pred – trenirani modeli dubokog učenja

Pred – trenirani modeli dubokog učenja pokazali su obećavajuće rezultate u rješavanju mnogih problema u različitim istraživačkim područjima, poput računalnog vida, prepoznavanja uzoraka, obrade prirodnog jezika i klasifikacije medicinskih slika. Superiorne sposobnosti pred-treniranih mreža proizlaze iz njihove opsežne obuke na velikim skupovima podataka.. Kako bi

se poboljšale dijagnostičke sposobnosti modela klasifikacije COVID – 19, neki istraživači izvodili su pred – treniranje korištenjem vanjskog skupa podataka CT snimaka na velikom javnom skupu podataka (36). Mnogi modeli konvolucijskih neuronskih mreža trenirani su na ImageNet skupu podataka.

8.3.4. Razlikovanje COVID – 19 od ostalih virusnih pneumonija

Opacifikacije koje se javljaju na CT – u kod pacijenata s COVID – 19 pneumonijom su slične različitim oblicima pneumonije uzrokovane drugim virusima, kao što je influenza, adenovirus, sincicijski respiratorni virus i sl. Stoga je razlikovanje COVID – 19 od drugih virusnih pneumonija ključni izazov u studijama višeklasne klasifikacije u usporedbi sa studijama binarne klasifikacije. Višeklasni model klasifikacije koristi se za razlikovanje urednog nalaza pluća od COVID – 19 pneumonije i upale pluća iz opće populacije (36).

8.4. Prednosti i ograničenja primjene alata strojnog učenja

Proces strojnog učenja u detekciji COVID – 19 pneumonije na CT snimkama pluća sastoji se od prikupljanja podataka, pripreme podataka, odabira modela, treniranja modela, procjene, podešavanja parametara i predikcije ili zaključivanja (36).

CapsNet je sustav strojnog učenja koji predstavlja jednu vrstu umjetne neuronske mreže koja se može koristiti za bolje modeliranje hijerarhijskih odnosa (7). Ona imitira biološku neuronsku organizaciju. U konvolucijsku neuronsku mrežu se dodaju „kapsule” i zatim se koristi izlaz iz nekoliko „kapsula” kako bi se formirali stabilniji prikazi (7).

Korištenje CapsNet – a je jedno je od praktičnih rješenja za ograničene setove COVID – 19 podataka, jer može rukovati malim skupovima podataka. Alaufi i sur. su koristili CapsNet bez primjene bilo kakvih metoda za augmentaciju skupova podataka ili prethodno treniranje modela (36). Postigli su 95,7% točnosti, 95,8% specifičnosti, 90% osjetljivosti i 97% AUC – a (36). Modificirali su funkciju gubitka kako bi se istaknuo problem neuravnoteženih klasa zbog nedostatka dostupnih slika COVID – 19.

9. ANALIZA ČLANAKA KOJI SE ODOSE NA ETIČKA PITANJA U PRIMJENI UMJETNE INTELIGENCIJE U COVID – 19 PNEUMONIJI

Složenost UI donosi etička pitanja o tome kako su algoritmi umjetne inteligencije razvijeni i kako se koriste. Godine 2019. međunarodna radiološka stručna tijela (engl. European Society of Radiology – ESR; AMERICAN College of Radiology – ACR; Radiologic Society of North America – RSNA; Canadian Association of Radiologists – CAR; Society for Imaging Informatics in Medicine – SIIM; European Society of Imaging Medical Imaging Informatics – EuSoMII; American Association of Physicist in Medicine – AAPM), objavila su zajedničku izjavu o etici UI u radiologiji i publicirali je na mrežnim stranicama društva i u četiri vodeća radiološka časopisa (Insights into Imaging, Journal of American College of Radiology, Radiology; Canadian Association of Radiologist Journal) (25). Godinu dana kasnije (2020. godine), međunarodno društvo radioloških tehnologa (The Society and College of Radiographers) izdalo je svoju izjavu o primjeni UI u radiološkoj tehnologiji (54).

Algoritmi dubokog učenja za analizu CT snimaka kod bolesnika s COVID – 19 pneumonijom moraju imati dostupne velike baze podataka, zbog učenja, testiranja i validacije. Podaci moraju biti precizni, a odgovarajuće opacifikacije na snimkama CT – a pluća moraju označiti iskusni radiolozi. Postavlja se pitanje tko je vlasnik navedenih podataka, na koji način se ti podaci koriste i kako su zaštićeni od zloupotrebe (29). U skladu s europskom Općom uredbom za zaštitu podataka (engl. General Data Protection Regulation – GDPR), što se odnosi i na Republiku Hrvatsku, pacijenti su vlasnici svojih podataka i moraju dati eksplicitni konsenzus za njihovu pohranu, korištenje i eventualno dijeljenje, uključujući treniranje UI alata (25). Ukoliko su uključeni u bilo koje istraživanje u kojem se koriste njihovi slikovni podaci, bez obzira što su u potpunosti anonimizirani, svaki pacijent mora dati svoj obavješteni pristanak (engl. Informed Consent) i suglasnost za sudjelovanje u istraživanju. Istraživači moraju na jednostavan, razumljiv i pristupačan način dati potpunu informaciju pacijentima kako će se prikupljati podaci s njihovim demografskim i kliničkim karakteristikama te CT studije u odgovarajućem formatu (najčešće engl. Digital Imaging and Communications in Medicine – DICOM), kako će se podaci kodirati i pohranjivati i tko će biti upućen u njihov identitet (30). Prije početka istraživanja etička povjerenstva zdravstvenih ustanova u kojima će se istraživanje provoditi moraju dati svoj pristanak (30). Zloupotreba informacija koje se mogu detektirati na

CT snimkama toraksa kod bolesnika s COVID – 19 pneumonijom može dovesti do ponižavanja i diskriminacije pacijenata te ugrožavanja njihovih ljudskih prava.

Isto tako, ukoliko se radi o komercijalnim alatima UI koji su već kreirani i koriste se u pomoći radiologa kod očitavanja snimaka CT – a kod bolesnika s COVID – 19 pneumonijom, potrebno je pacijenta obavijestiti da će njegove snimke biti pregledane i interpretirane od strane UI alata. Neki autori smatraju da svaki pacijent i u ovakvim situacijama mora biti adekvatno obavješten i dati svoju suglasnost za primjenu alata UI (25, 33).

Jedan od problema koji se odnosi na kodiranje i označavanje snimaka CT toraksa je i nehotična pristranost radiologa koja se odražava i u samom algoritmu UI (33). Naime, jedan od najvećih benefita UI je sposobnost prepoznavanja kompleksnih uzoraka opacifikacija na CT – u toraksa u velikoj bazi podataka koje radiolog može previdjeti (34).

Prema nekim autorima, UI se kvalificira kao „crnakutija”, tj. sustav kod kojeg su matematički procesi poznati i razumljivi, ali nije jasno kako nastaje transformacija podataka nakon obrade CNN – om (34, 35). To bi u praksi značilo da UI donosi neke nove informacije koje radiolozi, kao ljudska bića, ne mogu detektirati niti analizirati. Tipičan primjer su radiomiksi, koje ljudsko biće ne može detektirati niti kvantificirati. U tom slučaju postoji dilema kako radiolozi mogu kontrolirati i monitorirati te validirati sustav kojeg ne razumiju, a snose odgovornost za konačan rezultat interpretacije i zaključak o nalazu pacijentovog CT – a (34).

Jedan od mogućih etičkih problema u primjeni UI u radiologiji je pristranost automatizacije (55). Ona se odnosi na neke radiologe koji će dati prednost i više vjerovati automatiziranom zaključku alata UI pred zaključkom kojeg donosi ljudsko promišljanje u interpretaciji snimaka i odluci za terapijski postupak (34, 55). U slučaju COVID – 19 pneumonije takav pristup može imati ozbiljne posljedice na progresiju bolesti i razvoj komplikacija kao što je ARDS (55). Nasuprot tome postoji tzv. averzija prema algoritmima kod nekih radiologa, što je najčešće posljedica nedovoljne informiranosti i educiranosti te nepoznavanja same suštine UI algoritma. U ovim slučajevima postoji opasnost od ignoriranja ozbiljnih zaključaka koje UI algoritmi kreiraju i pogoršanje težine bolesti (34, 55).

Obzirom na značajan razvoj alata UI za analizu snimaka pacijenata s COVID – 19 pneumonijom tijekom pandemije i potrebe da se dijagnoza postavi brzo, neki su znanstvenici kao što su Geoffrey Hinton i njegovi suradnici, iznijeli predviđanje da će UI u budućnosti

zamijeniti radiologe (28). Ovakve teorije mogu dovesti do gubitka motivacije i želje za tom specijalizacijom kod mladih liječnika i do još većeg nedostatka radiologa na globalnoj razini (28).

Dodatan rizik za specijalizante radiologije je slabija edukacija od dosadašnjih edukacijskih sustava i programa, zbog toga što se korištenjem alata UI skraćuje vrijeme očitavanja i reducira ukupan broj radioloških slikovnih studija koje je potrebno očitati (34). Na taj način nastaje paradoksalna situacija da će se još više povećavati broj novih algoritama i njihovo korištenje, zbog dodatnog nedostatka radiologa (32).

10. SMJERNICE ZA DALJNJA ISTRAŽIVANJA ALATA UMJETNE INTELIGENCIJE

Napredni algoritmi UI i dalje se moraju razvijati, osobito u detekciji, segmentaciji i klasifikaciji lezija kod dijagnostike COVID – 19 pneumonije CT – om. Analizom originalnih i preglednih znanstvenih radova navedenih u Tablici 1. i 2. mogu se istaknuti sljedeće smjernice za daljnja istraživanja alata umjetne inteligencije u analizi snimaka CT toraksa kod bolesnika s COVID – 19 pneumonijom.

Anwar i sur. koji su koristili algoritam dubokog učenja (EfficientNet) na setu od 253 CT skena pacijenta s COVID – 19 pneumonijom i 291 skenom kod pacijenata koji nisu imali COVID – 19 pneumoniju, smatraju da će se njegov daljnji razvoj postići testiranjem modela na drugom setu podataka, obzirom da u ovom istraživanju nisu koristili odvojeni validacijski set podataka (20).

Alaufi i sur. smatraju da je binarna klasifikacija dosegla visoku performansu , ali je potrebno unaprijediti model višeklasne klasifikacije CT snimaka kod COVID – 19 pneumonije kreiranjem matrica visoke performanse (36). Modeli dubokog učenja moći će se primijeniti u kategorizaciji različitih stadija COVID – 19 infekcije, kao što su pred – simptomatski, asimptomatski, blagi i teški (36).

Chamberlain i sur. koji su testirali algoritam duboke konvolucijske mreže (dCNN) u kategorizaciji opacifikacija na CT – u kod bolesnika s COVID – 19 pneumonijom i kao zlatni standard koristili bodovni sustav temeljen na ekspertnoj procjeni triju torakalnih radiologa,

smatraju da se buduća istraživanja moraju više fokusirati na ishode multivarijatne prediktivne analize nego na usuglašavanje među radiolozima (21).

Gunray i sur. koristili su pojačane duboke neuronske mreže za detekciju COVID – 19 pneumonije na dvjema različitim, velikim međunarodnim kohortama od 4500 ispitanika iz 16 zemalja (23). Zaključili su da buduća istraživanja trebaju biti usmjerena na korištenje prethodno treniranih mreža za zadatke kao što su predikcija plućne funkcije, procjena težine bolesti i stvaranje personaliziranih tretmana za pacijente oboljele od COVID – 19 pneumonije (23).

U istraživanju Pana – a i sur. evaluacija novih metoda dubokog učenja za kvantifikaciju COVID-19 opacifikacija pokazala je dobru korelaciju s konvencionalnim CT bodovanjem (46). Smatraju da će u budućnosti kvantifikacija opacifikacija bazirana na metodama dubokog učenja u procjeni težine COVID – 19 pneumonije biti primjenjiva i kod ostalih oblika virusnih pneumonija (46).

Turk i sur. su evaluirali četiri različite arhitekture algoritama dubokog učenja koristeći javno dostupnu bazu podataka na ukupnom broju od 360 snimaka COVID – pozitivnih pacijenata, pri čemu su utvrdili da je najveću preciznost imao MobilNet algoritam (17). Smatraju da za razvoj algoritama dubokog učenja u budućnosti moraju biti javno dostupne puno veće baze podataka (17).

Vaydiyanathan i sur. su pokazali izvrsnu performansu algoritma dubokog učenja u razlikovanju opacifikacija kod COVID – 19 pneumonije od influenza pneumonije u vanjskoj validaciji na setu podataka iz druge zdravstvene ustanove (18). Smatraju da će takav algoritam biti vrlo koristan u kliničkoj praksi u bliskoj budućnosti i da će moći razdvojiti relevantne slojeve CT snimaka koji sadrže abnormalnosti i koji su važni za bolest koja se istražuje. Za takav razvoj potrebna je intenzivnija suradnja kliničara s informatičarima koji su specijalizirani za UI (18).

Verma i suradnici testirali su mobilnu aplikaciju algoritma koji ima visoku preciznost (99,58%) i specifičnost (99,46%) u označavanju opacifikacija kod pacijenata s COVID – 19 pneumonijom (52). Smatraju da će se razvoj mobilnih aplikacija značajno ubrzati, zato jer su dostupnije radiolozima, osobito u dijelovima svijeta sa slabije razvijenom zdravstvenom zaštitom i omogućiti će procjenu težine bolesti, a samim time i adekvatno liječenje kod puno većeg broja pacijenata (52).

Yousefzadeh i suradnici su zaključili da će u budućnosti algoritmi UI koji objedinjuju kliničke informacije, laboratorijske nalaze uključujući PCR i dijagnozu temeljenu na CT – u imati najprecizniju dijagnozu COVID – 19 pneumonije (19).

11. POTVRDA HIPOTEZA

Prva hipoteza koju smo postavili u istraživanju, a koja glasi: „Primjena alata UI – strojnog učenja i dubokog učenja u analizi snimaka bolesnika s COVID – 19 pneumonijom pomoću CT – a omogućuje bržu i precizniju dijagnostiku u usporedbi s analizom snimaka koje su očitali isključivo radiolozi” potvrđena je u petnaest od ukupno devetnaest analiziranih radova koji su zadovoljili kriterije uključenja (3, 4, 9, 11, 13, 14, 16, 17, 18, 19, 20, 21, 22, 23, 24).

Ostali autori su donijeli sljedeće zaključke:

Low i suradnici su konstatairali da su skupovi podataka pacijenata s COVID – 19 pneumonijom pohranjeni u različitim formatima, standardima, veličinama i kvaliteti, što su moguće prepreke u brzom razvoju alata UI (7).

Fusco i suradnici smatraju da je jedno od vodećih ograničenja u istraživanjima efikasnosti UI što su modeli istraživanja eksperimentalni i što se u bazama podataka ne nalaze snimke kritično oboljelih pacijenata s COVID – 19 pneumonijom, zato što ti pacijenti nisu bili u mogućnosti učiniti CT snimanja zbog težine zdravstvenog stanja, odnosno vezanosti za respiratore ili druge uređaje i nemogućnost transporta (8).

Heidari i skupina autora smatraju, prema analizi članaka temeljenih na kvalitativnim karakteristikama, da je većina autora ocijenila alate UI temeljem procjene točnosti, kašnjenja, robusnosti i mogućnosti nadogradnje. Međutim, neke značajke, poput sigurnosti i vremena konvergencije nisu uzete u obzir. Osim toga, različiti programski jezici koristili su se za evaluaciju i implementaciju predloženih mehanizama, što može također biti uzrok pristranosti u analizi (10).

Aggarwal i koautori su u svom preglednom radu razmatrali izazove povezane s pristupima dubokom učenju za dijagnozu COVID – 19 pneumonije na CT snimkama. Važno je napomenuti da je svaka studija u literaturi pokazala potencijal u automatskom otkrivanju

COVID – 19 pneumonije, ali se istovremeno suočila s izazovima ili nedostacima analize i evaluacije predloženih rješenja s različitih gledišta. Većina studija koristila je manje skupove podataka i nedostajala je usporedna analiza. Slično Low i suradnicima, konstatirali su da je potrebno uložiti napore kako bi se konsolidirali veći javno dostupni, sveobuhvatni i raznoliki skupovi s multimodalnim podacima o karakteristikama bolesti COVID – 19 prikupljenima iz brojnih zdravstvenih ustanova u svijetu. To bi omogućilo istraživačima da razviju pouzdanije metode i međusobno ih usporede (12).

Druga postavljena hipoteza glasi: „Primjena alata UI – strojnog učenja i dubokog učenja u dijagnostici bolesti COVID – 19 može biti neetična zbog nedovoljne tehničke otpornosti, što dovodi do zlonamjerne upotrebe.”

Autori svih jedanaest preglednih članaka koji su analizirali etičnost primjene alata umjetne inteligencije složili su se da postoje brojni, još uvijek neriješeni etički problemi koji otežavaju njezinu implementaciju. Pojam tehničke otpornosti sustava UI odnosi se na sposobnost sprječavanja nastanka štete, tj. očuvanja od zlonamjernih napada. Pri tome je potrebno poduzeti preventivne radnje da se reduciraju rizici. Zlonamjerni napadi mogu biti usmjereni na sam model (npr. algoritam analize CT snimaka pacijenata s COVID – 19 pneumonijom zbog „curenja” podataka) ili može doći do „onečišćenja” podataka što ih može promijeniti ili isključiti pa će sustav donijeti pogrešne odluke. Posebno je potrebno istaknuti pregledni članak Martina i suradnika koji su opisali situaciju vezanu uz pandemiju COVID – 19 kao hitnu potrebu za primjenom alata UI zbog velikog broja teško oboljelih i nedovoljnog broja raspoloživih radiologa.

Li i suradnici su tada stvorili duboku neuronsku mrežu (COVNet) za izdvajanje COVID – 19 opacifikacija iz volumetrijskih CT pregleda toraksa, iako model nije bio vrlo interpretabilan niti transparentan (32, 56). Međutim, istovremeno Talijansko društvo za medicinsku i intervencijsku radiologiju objavilo je istraživanje o primjeni UI u prognoziranju i predviđanja ishoda bolesti, pri čemu nisu preporučili upotrebu CT – a kao dijagnostičke metode za probir (57). Njihove smjernice napominju da CT prsnog koša općenito ne može zamijeniti PCR test, jer CT ima nisku specifičnost za COVID – 19 (32, 57). S obzirom na nedostatak transparentnosti u pojedinim UI algoritmima i neusklađenosti u kliničkim interpretacijama, još uvijek se postavlja mnoštvo etičkih pitanja prije njihove široko prihvaćene kliničke primjene.

12. ZAKLJUČAK

UI danas preuzima vodeću ulogu u gotovo svim aspektima modernog života, stoga je potrebno ovu tehnologiju primijeniti u najbolje moguće svrhe. Primjena u medicini, tj. radiologiji, uvelike može pomoći i olakšati radiolozima pogotovo u kriznim situacijama poput pandemije COVID – 19. Pojava pandemije stvorila je nužnu potrebu za razvojem modela UI koji bi pomogli detektirati COVID – 19 pneumoniju na snimkama CT – a.

Veću preciznost u detekciji pneumonije COVID – 19 pokazuju modeli dubokog učenja bazirani na konvolucijskim neuronskim mrežama. Ovi modeli su od značajne važnosti za dijagnosticiranje i praćenje napretka bolesti te omogućuju radiolozima brže otkrivanje infekcije. Osim prednosti u primjeni alata UI, postoje i određena ograničenja. Za razvoj modela potrebne su velike baze podataka na kojima algoritmi treniraju. Zbog neujednačenosti veličine javno dostupnih baza dolazi do varijacija u uspješnosti modela. Skupovi podataka mogu biti u različitim formatima, standardima i različite kvalitete, što otežava komparaciju rezultata. Neki istraživački modeli bili su samo eksperimentalni, a u bazama podataka nedostajale su CT snimke kritično oboljelih pacijenata s COVID – 19 pneumonijom, zbog težine zdravstvenog stanja i nemogućnosti transporta uslijed povezanosti na različite uređaje neophodne za održavanje života.

U uspješnoj i rutinskoj implementaciji alata UI u analizi snimaka pacijenata s COVID – 19 pneumonijom učinjenih CT – om postoje još brojna neriješena etička pitanja. Odnose se na tehničku otpornost sustava UI tj. sprječavanje nastanka štete i očuvanja od zlonamjernih napada, koji mogu biti usmjereni na sam model ili na „onečišćenje” podataka. Kao posljedica može nastati promjena ili isključenje pojedinih podataka. Također je potrebno razriješiti nedostatak transparentnosti i neusklađenost s kliničkim interpretacijama pojedinih zaključaka UI algoritama.

Prevladavanjem ograničenja, alati UI će se u skoroj budućnosti sve više usavršavati u preciznosti, brzini i kliničkoj primjenjivosti te će biti izvrsno sredstvo za analizu CT – a toraksa kod bolesnika s COVID – 19 infekcijom i na taj način ubrzati i olakšati rad radiologa.

LITERATURA

1. World Health Organization. Coronavirus Disease (COVID-19) Pandemic [Internet]. World Health Organization. 2020 [cited 2024 Apr 25]. Available from: <https://www.who.int/emergencies/diseases/novel-coronavirus-2019>
2. Khanna VV, Chadaga K, Sampathila N, Prabhu S, Chadaga R, Umakanth S. Diagnosing COVID-19 using artificial intelligence: a comprehensive review. Network Modeling Analysis in Health Informatics and Bioinformatics. [Internet] 2022 Dec [cited 2024 Apr 25] ;1(1):25. Available from: https://www.researchgate.net/publication/361945111_Diagnosing_COVID-19_using_artificial_intelligence_a_comprehensive_review . doi: 10.1007/s13721-022-00367-1
3. Ozsahin I, Sekeroglu B, Musa MS, Mustapha MT, Uzun Ozsahin D. Review on Diagnosis of COVID-19 from Chest CT Images Using Artificial Intelligence. Comput Math Methods Med. [Internet] 2020 Sep 26 [cited 2024 Apr 25];2020:9756518. Available from: <https://pubmed.ncbi.nlm.nih.gov/33014121/> . doi: 10.1155/2020/9756518. PMID: 33014121; PMCID: PMC7519983.
4. Wang Q, Ma J, Zhang L, Xie L. Diagnostic performance of corona virus disease 2019 chest computer tomography image recognition based on deep learning: Systematic review and meta-analysis. Medicine (Baltimore). [Internet] 2022 Oct 21[cited 2024 Apr 25];101(42):e31346. Available from: <https://pubmed.ncbi.nlm.nih.gov/36281129/> . doi: 10.1097/MD.00000000000031346. PMID: 36281129; PMCID: PMC9592148.
5. Harmon SA, Sanford TH, Xu S, Turkbey EB, Roth H, Xu Z, Yang D, Myronenko A, Anderson V, Amalou A, Blain M, Kassin M, Long D, Varble N, Walker SM, Bagci U, Ierardi AM, Stellato E, Plensich GG, Franceschelli G, Girlando C, Irmici G, Labella D, Hammoud D, Malayeri A, Jones E, Summers RM, Choyke PL, Xu D, Flores M, Tamura K, Obinata H, Mori H, Patella F, Cariati M, Carrafiello G, An P, Wood BJ, Turkbey B. Artificial intelligence for the detection of COVID-19 pneumonia on chest CT using multinational datasets. Nat Commun. [Internet] 2020 Aug 14 [cited 2024 Apr 25];11(1):4080. Available from: <https://pubmed.ncbi.nlm.nih.gov/32796848/> . doi: 10.1038/s41467-020-17971-2. PMID: 32796848; PMCID: PMC7429815.

6. Page MJ, McKenzie JE, Bossuyt PM, Boutron I, Hoffmann TC, Mulrow CD, Shamseer L, Tetzlaff JM, Akl EA, Brennan SE, Chou R, Glanville J, Grimshaw JM, Hróbjartsson A, Lalu MM, Li T, Loder EW, Mayo-Wilson E, McDonald S, McGuinness LA, Stewart LA, Thomas J, Tricco AC, Welch VA, Whiting P, Moher D. The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *BMJ*. [Internet] 2021 Mar 29 [cited 2024 May 9];372:n71. Available from: <https://pubmed.ncbi.nlm.nih.gov/33782057/> . doi: 10.1136/bmj.n71. PMID: 33782057; PMCID: PMC8005924.
7. Serena Low WC, Chuah JH, Tee CATH, Anis S, Shoaib MA, Faisal A, Khalil A, Lai KW. An Overview of Deep Learning Techniques on Chest X-Ray and CT Scan Identification of COVID-19. *Comput Math Methods Med*. [Internet] 2021 Jun [cited 2024 Feb 29]; 4;2021:5528144. Available from: <https://pubmed.ncbi.nlm.nih.gov/34194535/> . doi: 10.1155/2021/5528144. PMID: 34194535; PMCID: PMC8184329.
8. Fusco R, Grassi R, Granata V, Setola SV, Grassi F, Cozzi D, Pecori B, Izzo F, Petrillo A. Artificial Intelligence and COVID-19 Using Chest CT Scan and Chest X-ray Images: Machine Learning and Deep Learning Approaches for Diagnosis and Treatment. *J Pers Med*. [Internet] 2021 Sep 30 [cited 2024 Feb 29];11(10):993. Available from: <https://pubmed.ncbi.nlm.nih.gov/34683133/> . doi: 10.3390/jpm11100993. PMID: 34683133; PMCID: PMC8540782.
9. Alassiri R., Abukhodair F., Kalkatawi M., Khashoggi K., Alotaibi R. COVID-19 diagnosis from chest CT scan images using deep learning. *Revista română de informatică și automatică*. [Internet] 2022 Sep [cited 2024 Feb 29]; 30;32(3):65–72. Available from: https://www.researchgate.net/publication/364069320_COVID-19_diagnosis_from_chest_CT_scan_images_using_deep_learning. doi:10.33436/v32i3y202205.
10. Heidari A, Jafari Navimipour N, Unal M, Toumaj S. The COVID-19 epidemic analysis and diagnosis using deep learning: A systematic literature review and future directions. *Comput Biol Med*. [Internet] 2022 Feb [cited 2024 Feb 29];141:105141. Available from: <https://pubmed.ncbi.nlm.nih.gov/34929464/> . doi: 10.1016/j.compbiomed.2021.105141. Epub 2021 Dec 14. PMID: 34929464; PMCID: PMC8668784.

11. Roberts M, Driggs D, Thorpe M, Gilbey J, Yeung M, Ursprung S, et al. Common pitfalls and recommendations for using machine learning to detect and prognosticate for COVID-19 using chest radiographs and CT scans. *Nature Machine Intelligence* [Internet]. 2021 Mar 1 [cited 2024 Feb 29]; 3(3):199–217. Available from: https://www.researchgate.net/publication/351064521_Common_Pitfalls_and_Recommendations_for_Using_Machine_Learning_to_Detect_and_Prognosticate_for_COVID-19_Using_Chest_Radiographs_and_CT_Scans
12. Aggarwal P, Mishra NK, Fatimah B, Singh P, Gupta A, Joshi SD. COVID-19 image classification using deep learning: Advances, challenges and opportunities. *Comput Biol Med.* [Internet] 2022 May [cited 2024 Mar 3];144:105350. Available from: <https://pubmed.ncbi.nlm.nih.gov/35305501/> . doi: 10.1016/j.compbimed.2022.105350. Epub 2022 Mar 3. PMID: 35305501; PMCID: PMC8890789.
13. Komolafe TE, Cao Y, Nguchu BA, Monkam P, Olaniyi EO, Sun H, Zheng J, Yang X. Diagnostic Test Accuracy of Deep Learning Detection of COVID-19: A Systematic Review and Meta-Analysis. *Acad Radiol.* [Internet] 2021 Nov [cited 2024 Mar 3]; 28(11):1507-1523. Available from: <https://pubmed.ncbi.nlm.nih.gov/34649779/> . doi: 10.1016/j.acra.2021.08.008. Epub 2021 Sep 17. PMID: 34649779; PMCID: PMC8445811.
14. Alzubaidi M, Zubaydi HD, Bin-Salem AA, Abd-Alrazaq AA, Ahmed A, Househ M. Role of deep learning in early detection of COVID-19: Scoping review. *Comput Methods Programs Biomed Update.* [Internet] 2021 [cited 2024 Mar 3]; 1:100025. Available from: <https://pubmed.ncbi.nlm.nih.gov/34345877/> . doi: 10.1016/j.cmpbup.2021.100025. Epub 2021 Jul 30. PMID: 34345877; PMCID: PMC8321699.
15. Wang Q, Ma J, Zhang L, Xie L. Diagnostic performance of corona virus disease 2019 chest computer tomography image recognition based on deep learning: Systematic review and meta-analysis. *Medicine (Baltimore).* [Internet] 2022 Oct 21 [cited 2024 Mar 3]; 101(42):e31346. Available from: <https://pubmed.ncbi.nlm.nih.gov/36281129/> . doi: 10.1097/MD.00000000000031346. PMID: 36281129; PMCID: PMC9592148.
16. Abdulsalam Hamwi W, Almustafa MM. Development and integration of VGG and dense transfer-learning systems supported with diverse lung images for discovery of the Coronavirus identity. *Inform Med Unlocked.* [Internet] 2022 [cited 2024 Mar 3]; 32:101004. Available from:

<https://pubmed.ncbi.nlm.nih.gov/35822170/> . doi: 10.1016/j.imu.2022.101004. Epub 2022 Jul 8. PMID: 35822170; PMCID: PMC9263684.

17. Turk V, Çatal Reis H, Kaya S. Automatic prediction of covid-19 from chest- computed tomography (CT) images using deep learning architectures. Gümüşhane Üniversitesi Fen Bilimleri Enstitüsü Dergisi. [Internet] 2022 Sep 3 [cited 2024 Mar 3]; Available from: [https://www.researchgate.net/publication/355427287 Automatic prediction of COVID-19 from chest-CT images using deep learning architectures](https://www.researchgate.net/publication/355427287_Automatic_prediction_of_COVID-19_from_chest-CT_images_using_deep_learning_architectures) . doi: 10.17714/gumusfenbil.1002738

18. Vaidyanathan A, Guiot J, Zerka F, Belmans F, Van Peufflik I, Deprez L, Danthine D, Canivet G, Lambin P, Walsh S, Occhipinti M, Meunier P, Vos W, Lovinfosse P, Leijenaar RTH. An externally validated fully automated deep learning algorithm to classify COVID-19 and other pneumonias on chest computed tomography. ERJ Open Res. [Internet] 2022 May 3 [cited 2024 Mar 3]; 8(2):00579-2021. Available from: <https://pubmed.ncbi.nlm.nih.gov/35509437/> . doi: 10.1183/23120541.00579-2021. PMID: 35509437; PMCID: PMC8958945.

19. Yousefzadeh M, Esfahanian P, Movahed SMS, Gorgin S, Rahmati D, Abedini A, Nadji SA, Haseli S, Bakhshayesh Karam M, Kiani A, Hoseinyazdi M, Roshandel J, Lashgari R. ai-corona: Radiologist-assistant deep learning framework for COVID-19 diagnosis in chest CT scans. PLoS One. [Internet] 2021 May 7 [cited 2024 Mar 6]; 16(5):e0250952. doi: 10.1371/journal.pone.0250952. Erratum in: PLoS One. 2021 Sep 1;16(9):e0257119. Available from: <https://pubmed.ncbi.nlm.nih.gov/33961635/> . doi: 10.1371/journal.pone.0257119. PMID: 33961635; PMCID: PMC8104381.

20. Anwar T, Zakir S. Deep learning based diagnosis of COVID-19 using chest CT-scan images. 2020 IEEE 23rd International Multitopic Conference (INMIC). [Internet] 2020 Nov 5 [cited 2024 Mar 6]; 978-1-7281-9893-4/20; Available from: [https://www.researchgate.net/publication/348644621 Deep learning based diagnosis of COVID-19 using chest CT-scan images](https://www.researchgate.net/publication/348644621_Deep_learning_based_diagnosis_of_COVID-19_using_chest_CT-scan_images) . doi: 10.1109/INMIC50486.2020.9318212

21. Chamberlin JH, Aquino G, Schoepf UJ, Nance S, Godoy F, Carson L, Giovagnoli VM, Gill CE, McGill LJ, O'Doherty J, Emrich T, Burt JR, Baruah D, Varga-Szemes A, Kabakus IM. An Interpretable Chest CT Deep Learning Algorithm for Quantification of COVID-19 Lung Disease and Prediction of Inpatient Morbidity and Mortality. Acad Radiol. [Internet] 2022 Aug [cited

2024 Mar 6]; 29(8):1178-1188. Available from: <https://pubmed.ncbi.nlm.nih.gov/35610114/>
doi: 10.1016/j.acra.2022.03.023. Epub 2022 Apr 4. PMID: 35610114; PMCID: PMC8977389.

22. Chrzan R, Wojciechowska W, Terlecki M, Klocek M, Rajzer M, Popiela T. The role of artificial intelligence technology analysis of high-resolution computed tomography images in predicting the severity of COVID-19 pneumonia. *Pol Arch Intern Med*. [Internet] 2022 Dec 21 [cited 2024 Mar 6]; 132(12):16332. Available from: <https://pubmed.ncbi.nlm.nih.gov/36026617/> . doi: 10.20452/pamw.16332. Epub 2022 Aug 26. PMID: 36026617.

23. Gunraj H, Sabri A, Koff D, Wong A. COVID-Net CT-2: Enhanced Deep Neural Networks for Detection of COVID-19 From Chest CT Images Through Bigger, More Diverse Learning. *Front Med (Lausanne)*. [Internet] 2022 Mar 10 [cited 2024 Mar 8] ;8:729287. Available from: <https://pubmed.ncbi.nlm.nih.gov/35360446/> . doi: 10.3389/fmed.2021.729287. PMID: 35360446; PMCID: PMC8960961.

24. Nguyen D, Kay F, Tan J, Yan Y, Ng YS, Iyengar P, Peshock R, Jiang S. Deep Learning-Based COVID-19 Pneumonia Classification Using Chest CT Images: Model Generalizability. *Front Artif Intell*. [Internet] 2021 Jun 29 [cited 2024 Mar 8]; 4:694875. Available from: <https://pubmed.ncbi.nlm.nih.gov/34268489/> . doi: 10.3389/frai.2021.694875. PMID: 34268489; PMCID: PMC8275994.

25. Brady AP, Neri E. Artificial Intelligence in Radiology-Ethical Considerations. *Diagnostics (Basel)*. [Internet] 2020 Apr 17 [cited 2024 Mar 25]; 10(4):231. Available from: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7235856/> . doi: 10.3390/diagnostics10040231. PMID: 32316503; PMCID: PMC7235856.

26. Čartolovni A, Tomičić A, Lazić Mosler E. Ethical, legal, and social considerations of AI-based medical decision-support tools: A scoping review. *Int J Med Inform*. [Internet] 2022 May [cited 2024 Mar 25]; 161:104738. Available from: <https://pubmed.ncbi.nlm.nih.gov/35299098/> . doi: 10.1016/j.ijmedinf.2022.104738. Epub 2022 Mar 14. PMID: 35299098.

27. Akinci D'Antonoli T. Ethical considerations for artificial intelligence: an overview of the current radiology landscape. *Diagn Interv Radiol*. [Internet] 2020 Sep [cited 2024 Mar 25];

26(5):504-511. Available from: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7490024/> .
doi: 10.5152/dir.2020.19279. PMID: 32755879; PMCID: PMC7490024.

28. Franjić D, Miljko M. UMJETNA INTELIGENCIJA U RADIOLOGIJI: ETIČKI PROBLEMI. Zdravstveni glasnik. [Internet] 2020 Nov 30 [cited 2024 Mar 25]; (12):61–8. Available from: https://www.researchgate.net/publication/346470290_UMJETNA_INTELIGENCIJA_U_RADIOLOGIJI_ETICKI_PROBLEMI . doi: 10.47960/2303-8616.2020.12.61

29. Fernandez-Quilez A. Deep learning in radiology: ethics of data and on the value of algorithm transparency, interpretability and explainability. AI and Ethics. [Internet] 2022 Apr 28 [cited 2024 Mar 29]; 3:257–265. Available from: https://www.researchgate.net/publication/360249785_Deep_learning_in_radiology_ethics_of_data_and_on_the_value_of_algorithm_transparency_interpretability_and_explainability . doi: 10.1007/s43681-022-00161-9

30. Geis JR, Brady AP, Wu CC, Spencer J, Ranschaert E, Jaremko JL, Langer SG, Kitts AB, Birch J, Shields WF, van den Hoven van Genderen R, Kotter E, Gichoya JW, Cook TS, Morgan MB, Tang A, Safdar NM, Kohli M. Ethics of Artificial Intelligence in Radiology: Summary of the Joint European and North American Multisociety Statement. J Am Coll Radiol. [Internet] 2019 Nov [cited 2024 Mar 29] ;16(11):1516-1521. Available from: <https://pubmed.ncbi.nlm.nih.gov/31585696/> . doi: 10.1016/j.jacr.2019.07.028. Epub 2019 Oct 1. PMID: 31585696.

31. Goisauf M, Cano Abadía M. Ethics of AI in Radiology: A Review of Ethical and Societal Implications. Front Big Data. [Internet] 2022 Jul [cited 2024 Mar 29]; 14;5:850383. Available from: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC9329694/> . doi: 10.3389/fdata.2022.850383. PMID: 35910490; PMCID: PMC9329694.

32. Martin C, DeStefano K, Haran H, Zink S, Dai J, Ahmed D, et al. The ethical considerations including inclusion and biases, data protection, and proper implementation among AI in radiology and potential implications. Intelligence-Based Medicine [Internet]. 2022 Jan 1 [cited 2024 Mar 29]; 6:100073. Available from: https://www.researchgate.net/publication/363385919_The_ethical_considerations_including_inclusion_and_biases_data_protection_and_proper_implementation_among_AI_in_radiology_and_potential_implications . doi: 10.1016/j.ibmed.2022.100073

33. Mudgal KS, Das N. The ethical adoption of artificial intelligence in radiology. *BJR Open*. [Internet] 2020 Jan 1 [cited 2024 Mar 29]; 2(1):20190020. Available from: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7605209/> . doi: 10.1259/bjro.20190020. PMID: 33178959; PMCID: PMC7605209.
34. Neri E, Coppola F, Miele V, Bibbolino C, Grassi R. Artificial intelligence: Who is responsible for the diagnosis? *Radiol Med*. [Internet] 2020 Jun [cited 2024 Mar 29]; 125(6):517-521. Available from: <https://pubmed.ncbi.nlm.nih.gov/32006241/> . doi: 10.1007/s11547-020-01135-9. Epub 2020 Jan 31. PMID: 32006241.
35. Walsh G, Nikolaos Stogiannos, van, Rainey C, Tam W, McFadden S, et al. Responsible AI practice and AI education are central to AI implementation: a rapid review for all medical imaging professionals in Europe. *BJR|open*. [Internet] 2023 Jun [cited 2024 Mar 29]; 5(1). Available from: https://www.researchgate.net/publication/372009982_Responsible_AI_practice_and_AI_education_are_central_to_AI_implementation_a_rapid_review_for_all_medical_imaging_professionals_in_Europe . doi: 10.1259/bjro.20230033
36. Rawan Alaufi, Manal Kalkatawi, Felwa Abukhodair. Challenges of deep learning diagnosis for COVID-19 from chest imaging. *Multimedia Tools and Applications*. [Internet] 2023 Jul 10 [cited 2024 May 2]; 83: 1 – 25. Available from: https://www.researchgate.net/publication/372247327_Challenges_of_deep_learning_diagnosis_for_COVID-19_from_chest_imaging . doi: 10.1007/s11042-023-16017-1
37. Bai Y, Ning K. How does severe acute respiratory syndrome coronavirus 2 (SARS-CoV-2) achieve immune evasion?: A narrative review. *Medicine (Baltimore)*. [Internet] 2024 Apr 19 [cited 2024 May 2]; 103(16):e37780. Available from: <https://pubmed.ncbi.nlm.nih.gov/38640329/> . doi: 10.1097/MD.00000000000037780. PMID: 38640329; PMCID: PMC11030025.
38. Ndwandwe D, Wiysonge CS. COVID-19 vaccines. *Curr Opin Immunol*. [Internet] 2021 Aug [cited 2024 May 2]; 71:111-116. Available from: <https://pubmed.ncbi.nlm.nih.gov/34330017/> . doi: 10.1016/j.coi.2021.07.003. Epub 2021 Jul 12. PMID: 34330017; PMCID: PMC8272971.

39. Cha Y, Jung W, Seo M, Rahmati M. The emerging pandemic recent: SARS-CoV-2. Life Cycle. [Internet] 2023 Jan 22 [cited 2024 May 2]; 3. Available from: https://www.researchgate.net/publication/369308028_The_emerging_pandemic_recent_SA_RS-CoV-2 . doi: 10.54724/lc.2023.e2
40. Tsai PH, Lai WY, Lin YY, Luo YH, Lin YT, Chen HK, Chen YM, Lai YC, Kuo LC, Chen SD, Chang KJ, Liu CH, Chang SC, Wang FD, Yang YP. Clinical manifestation and disease progression in COVID-19 infection. J Chin Med Assoc. [Internet] 2021 Jan 1 [cited 2024 May 2]; 84(1):3-8. Available from: <https://pubmed.ncbi.nlm.nih.gov/33230062/> . doi: 10.1097/JCMA.0000000000000463. PMID: 33230062.
41. Keni R, Alexander A, Nayak PG, Mudgal J, Nandakumar K. COVID-19: Emergence, Spread, Possible Treatments, and Global Burden. Front Public Health. [Internet] 2020 May 28 [cited 2024 May 2];8:216. Available from: <https://pubmed.ncbi.nlm.nih.gov/32574299/> . doi: 10.3389/fpubh.2020.00216. PMID: 32574299; PMCID: PMC7270802.
42. Long C, Xu H, Shen Q, Zhang X, Fan B, Wang C, Zeng B, Li Z, Li X, Li H. Diagnosis of the Coronavirus disease (COVID-19): rRT-PCR or CT? Eur J Radiol. [Internet] 2020 May [cited 2024 May 7];126:108961. Available from: <https://pubmed.ncbi.nlm.nih.gov/32229322/> . doi: 10.1016/j.ejrad.2020.108961. Epub 2020 Mar 25. PMID: 32229322; PMCID: PMC7102545.
43. Teymouri M, Mollazadeh S, Mortazavi H, Naderi Ghale-Noie Z, Keyvani V, Aghababaei F, Hamblin MR, Abbaszadeh-Goudarzi G, Pourghadamyari H, Hashemian SMR, Mirzaei H. Recent advances and challenges of RT-PCR tests for the diagnosis of COVID-19. Pathol Res Pract. [Internet] 2021 May [cited 2024 May 7];221:153443. Available from: <https://pubmed.ncbi.nlm.nih.gov/33930607/> . doi: 10.1016/j.prp.2021.153443. Epub 2021 Apr 14. PMID: 33930607; PMCID: PMC8045416.
44. Kalra MK, Homayounieh F, Arru C, Holmberg O, Vassileva J. Chest CT practice and protocols for COVID-19 from radiation dose management perspective. Eur Radiol. [Internet] 2020 Dec [cited 2024 May 7];30(12):6554-6560. Available from: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7332743/> . doi: 10.1007/s00330-020-07034-x. Epub 2020 Jul 3. PMID: 32621238; PMCID: PMC7332743.

45. Vince A., Papić N., Židovec Lepej S., Kutleša M., Stemberger Marić L., Tešović G., Višković K. Molekularna biologija SARS - CoV - 2, patogeneza, klinička slika, liječenje i profilaksa bolesti. Zagreb: Medicinski fakultet Sveučilišta u Zagrebu; 2023.
46. Pan F, Ye T, Sun P, Gui S, Liang B, Li L, Zheng D, Wang J, Hesketh RL, Yang L, Zheng C. Time Course of Lung Changes at Chest CT during Recovery from Coronavirus Disease 2019 (COVID-19). *Radiology*. [Internet] 2020 Jun [cited 2024 May 9]; 295(3):715-721. Available from: <https://pubmed.ncbi.nlm.nih.gov/32053470/> . doi: 10.1148/radiol.2020200370. Epub 2020 Feb 13. PMID: 32053470; PMCID: PMC7233367.
47. Jalaber C, Lapotre T, Morcet-Delattre T, Ribet F, Jouneau S, Lederlin M. Chest CT in COVID-19 pneumonia: A review of current knowledge. *Diagn Interv Imaging*. [Internet] 2020 Jul-Aug [cited 2024 May 9]; 101(7-8):431-437. Available from: <https://pubmed.ncbi.nlm.nih.gov/32571748/> . doi: 10.1016/j.diii.2020.06.001. Epub 2020 Jun 11. PMID: 32571748; PMCID: PMC7287482.
48. Ghosh M, Thirugnanam A. Introduction to Artificial Intelligence. *Studies in Big Data*. [Internet] 2021 [cited 2024 May 9];23–44. Available from: https://www.researchgate.net/publication/351758474_Introduction_to_Artificial_Intelligenc_e . doi: 10.1007/978-981-16-0415-7_2
49. Althinyan Albatoul, Abdulrahman M, Sherin A, Nouh Thamer, Mahboub Bassam, Salameh Laila, et al. COVID-19 detection and classification: key AI challenges and recommendations for the way forward. *Journal of pulmonology and respiratory research*. [Internet] 2023 May 25 [cited 2024 May 14];7(1):010–4. Available from: https://www.researchgate.net/publication/379588789_COVID-19_detection_and_classification_key_AI_challenges_and_recommendations_for_the_way_forward . doi: 10.29328/journal.jprr.1001044
50. El-Bouzaidi YEI, Abdoun O. Advances in Artificial Intelligence for Accurate and Timely Diagnosis of COVID-19: A Comprehensive Review of Medical Imaging Analysis. *Scientific African* [Internet]. 2023 Nov 4 [cited 2024 May 14];e01961. Available from: <https://www.sciencedirect.com/science/article/pii/S2468227623004167>
51. Bansal M, Goyal A, Choudhary A. A comparative analysis of K-Nearest Neighbor, Genetic, Support Vector Machine, Decision Tree, and Long Short Term Memory algorithms in

machine learning. Decision Analytics Journal. [Internet] 2022 Jun [cited 2024 May 14];3:100071. Available from:

<https://www.researchgate.net/publication/360906575> A comparative analysis of K-Nearest Neighbor Genetic Support Vector Machine Decision Tree and Long Short Term Memory algorithms in machine learning . doi: 10.1016/j.dajour.2022.100071

52. Verma A, Amin SB, Naeem M, Saha M. Detecting COVID-19 from chest computed tomography scans using AI-driven android application. Comput Biol Med. [Internet] 2022 Apr [cited 2024 May 14];143:105298. Available from:

<https://pubmed.ncbi.nlm.nih.gov/35220076/> . doi: 10.1016/j.compbio.2022.105298. Epub 2022 Feb 20. PMID: 35220076; PMCID: PMC8858433.

53. Ortiz A, Trivedi A, Desbiens J, Blazes M, Robinson C, Gupta S, Dodhia R, Bhatraju PK, Liles WC, Lee A, Ferres JML. Effective deep learning approaches for predicting COVID-19 outcomes from chest computed tomography volumes. Sci Rep. [Internet] 2022 Feb 2 [cited 2024 May 14];12(1):1716. Available from: <https://pubmed.ncbi.nlm.nih.gov/35110593/> . doi: 10.1038/s41598-022-05532-0. PMID: 35110593; PMCID: PMC8810911.

54. The Society and College of Radiographers policy statement: Artificial Intelligence [Internet]. SoR. [cited 2024 May 14]. Available from: <https://www.sor.org/learning-advice/professional-body-guidance-and-publications/documents-and-publications/policy-guidance-document-library/the-society-and-college-of-radiographers-policy-st>

55. Kulikowski C, Maojo VM. COVID-19 pandemic and artificial intelligence: challenges of ethical bias and trustworthy reliable reproducibility? BMJ Health Care Inform. [Internet] 2021 Oct [cited 2024 May 14];28(1):e100438. Available from: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC8495685/> . doi: 10.1136/bmjhci-2021-100438. PMID: 34615665; PMCID: PMC8495685.

56. Li L, Qin L, Xu Z, Yin Y, Wang X, Kong B, Bai J, Lu Y, Fang Z, Song Q, Cao K, Liu D, Wang G, Xu Q, Fang X, Zhang S, Xia J, Xia J. Using Artificial Intelligence to Detect COVID-19 and Community-acquired Pneumonia Based on Pulmonary CT: Evaluation of the Diagnostic Accuracy. Radiology. [Internet] 2020 Aug [cited 2024 Apr 15]; 296(2):E65-E71. Available from: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7233473/> . doi: 10.1148/radiol.2020200905. Epub 2020 Mar 19. PMID: 32191588; PMCID: PMC7233473.

57. Neri E, Miele V, Coppola F, Grassi R. Use of CT and artificial intelligence in suspected or COVID-19 positive patients: statement of the Italian Society of Medical and Interventional Radiology. *Radiol Med.* [Internet] 2020 May [cited 2024 Apr 15];125(5):505-508. Available from: <https://pubmed.ncbi.nlm.nih.gov/32350794/>. doi: 10.1007/s11547-020-01197-9. Epub 2020 Apr 29. PMID: 32350794; PMCID: PMC7189175.

PRIVITCI

Grafikoni:

Grafikon 1: Grafikon protokola pretraživanja izvora s tematikom primjene umjetne inteligencije u dijagnostici bolesti COVID – 19 pomoću snimaka kompjutorizirane tomografije toraksa.....12

Grafikon 2: Grafikon protokola pretraživanja izvora s tematikom etičkih pitanja u primjeni umjetne inteligencije u COVID – 19 pneumoniji.....13

Tablice:

Tablica 1. Pregledni članci uključeni u analizu s tematikom primjene umjetne inteligencije u dijagnostici bolesti COVID – 19 pomoću snimaka kompjutorizirane tomografije toraksa.....14

Tablica 2: Originalni znanstveni članci uključeni u analizu s tematikom primjene umjetne inteligencije u dijagnostici bolesti COVID – 19 pomoću snimaka kompjutorizirane tomografije toraksa.....18

Tablica 3: Pregledni članci koji se odnose na analizu etičkih problema u primjeni alata umjetne inteligencije u dijagnostici bolesti COVID-19.....21

Slike:

Slika 1 : Struktura SARS - CoV - 2 virusa (modificirano prema https://encrypted-tbn0.gstatic.com/images?q=tbn:ANd9GcSVwHzdkrd75ihDZ9WFeK_TiqZ50UAWMzJ5LPFbOaF7yg&s).....24

Slika 2 : CT toraksa kod bolesnika s COVID – 19 pneumonijom u trećem danu bolesti. Vidljive su periferno smještene opacifikacije zrnatog stakla (engl. Ground – Glass Opacities – GGO) (označene crvenim strelicama), (Arhiva Klinike za infektivne bolesti „Dr. Fran Mihaljević“ u Zagrebu).....28

Slika 3: CT toraksa kod bolesnika s COVID – 19 pneumonijom u desetom danu bolesti. Vidljive su GGO opacifikacije (plavi trokut) i periferne konsolidacije u plućnom parenhimu desnog plućnog krila (crvena strelica). (Arhiva Klinike za infektivne bolesti „Dr. Fran Mihaljević“ u Zagrebu).....29

Slika 4 : Struktura umjetne neuronske mreže (modificirano prema https://media.geeksforgeeks.org/wp-content/cdn-uploads/20230602113310/Neural-Networks-Architecture.png).....	31
Slika 5 : Prikaz alata za označavanje lezija karakterističnih za COVID – 19 pneumoniju na snimkama CT toraksa. (Arhiva Klinike za infektivne bolesti „Dr. Fran Mihaljević“ u Zagrebu)...	33
Slika 6: U gornjem redu vide se neoznačene snimke CT – a kod bolesnika s COVID – 19 pneumonijom, a u donjem redu su „toplinske mape“ s označenim karakterističnim lezijama za COVID – 19 pneumoniju koje označava algoritam umjetne inteligencije. (Arhiva Klinike za infektivne bolesti „Dr. Fran Mihaljević“ u Zagrebu).....	35

KRATAK ŽIVOTOPIS

Nina Mrvoš rođena je 22.11.2002. godine u Ogulinu. Od 2009. godine do 2017. godine pohađala je Prvu osnovnu školu u Ogulinu. Kroz svoje osnovnoškolsko školovanje sudjelovala je na raznim natjecanjima, od kojih je postigla značajan uspjeh na natjecanju Crvenog križa iz prve pomoći. Zatim je 2017. godine upisala gimnazijski program u Gimnaziji i strukovnoj školi Bernardina Frankopana, također u Ogulinu te maturirala 2021. godine. Uz osnovnoškolsko i srednjoškolsko obrazovanje pohađala je tečaj engleskog jezika u Jezičnoj školi Koala u Ogulinu. Nakon završetka srednje škole, upisala je Prijediplomski stručni studij radiološke tehnologije na Fakultetu zdravstvenih studija u Rijeci.