

PRIMJENA UMJETNE INTELIGENCIJE U RADIOLOGIJI

Ivanišević, Dejan

Undergraduate thesis / Završni rad

2021

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

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:184:084966>

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

Download date / Datum preuzimanja: **2025-03-05**

Repository / Repozitorij:

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



SVEUČILIŠTE U RIJECI
FAKULTET ZDRAVSTVENIH STUDIJA
PREDDIPLOMSKI STRUČNI STUDIJ
RADIOLOŠKA TEHNOLOGIJA

Dejan Ivanišević

PRIMJENA UMJETNE INTELIGENCIJE U RADIOLOGIJI

Završni rad

Rijeka, 2021.

UNIVERSITY OF RIJEKA
FACULTY OF HEALTH STUDIES
UNDERGRADUATE STUDY OF
RADIOLOGICAL TECHNOLOGY

Dejan Ivanišević

APPLICATION OF ARTIFICIAL INTELLIGENCE IN RADIOLOGY

Final work

Rijeka, 2021.

Mentor rada: Doc. dr.sc. Ksenija Baždarić, dipl.psih.-prof. , Katedra za medicinsku informatiku, Medicinski fakultet u Rijeci

Pregledni rad obranjen je dana 16.9.2021. na Fakultetu zdravstvenih studija u Rijeci pred povjerenstvom u sastavu:

1. dr.sc. Robert Doričić, magistar organizacije, planiranja i upravljanja u zdravstvu
2. Boris Bezak, dr.med., spec. radiologije
3. Doc. dr.sc. Ksenija Baždarić, dipl. psih.-prof.

Zahvala

Zahvaljujem se obitelji koja me podržala skroz do kraja svoga školovanja. Također zahvaljujem svojoj mentorici doc. dr.sc. Kseniji Baždarić, dipl. psih.-prof. na stručnoj pomoći i savjetima tijekom izrade završnog rada. Zahvaljujem se svim radiološkim tehnolozima, radiolozima i ostalim djelatnicima na dobivenom znanju te kod obavljanja stručne prakse.

Sadržaj

1. UVOD	6
2. EKSPERTNI SUSTAVI.....	8
2.1. Građa ekspertnog sustava	9
2.2. Zaključivanje ekspertnog sustava	10
2.3. Prednosti i nedostaci ekspertnih sustava	11
3. UMJETNE NEURONSKE MREŽE.....	12
3.1. Primjena umjetnih neuronskih mreža.....	13
3.2. Učenje neuronske mreže.....	14
3.3. Umjetni neuron – TLU perceptron	15
3.4. Višeslojne umjetne neuronske mreže	16
4. KONVOLUCIJSKE NEURONSKE MREŽE	18
4.1. Učenje konvolucijskih neuronskih mreža	19
4.2. Primjena konvolucijskih neuronskih mreža u radiologiji.....	20
5. UMJETNA INTELIGENCIJA U RADIOLOGIJI	22
5.1. Metode UI u onkologiji.....	23
5.2. Metode UI u nuklearnoj medicini.....	25
5.3. Primjena UI u hepatologiji i gastroenterologiji.....	26
5.3.1. Umjetna inteligencija kod bolesti jetre.....	27
5.3.2 Umjetna inteligencija kod bolesti gušterače	29
5.4. Primjena UI u kardiovaskularnoj radiologiji.....	30
6. RAČUNALNO POTPOMOĞNUTA DETEKCIJA.....	32
6.1. Primjena CAD-a kod mamografije.....	32
6.2. Primjena CAD-a kod radiografije prsnog koša	33
6.3. Primjena CAD-a kod višeparametarskog MR snimanja	35
6.4. Procjena CAD sustava	37
ZAKLJUČAK	38
LITERATURA.....	39
PRIVITCI.....	41

SAŽETAK

Umjetna inteligencija je grana računarske znanosti koja se bavi proučavanjem i izgradnjom računalnih sustava koji pokazuju neki oblik inteligencije. Takvi sustavi se dizajniraju da mogu učiti, donositi zaključke te obavljati druge vrste vještina kojima je potrebna i zahtijevaju ljudsku inteligenciju. Cilj primjene umjetne inteligencije u medicini, odnosno u radiologiji je povećanje dijagnostičke i terapijske točnosti. Neke od grana umjetne inteligencije koje imaju primjenu u radiologiji su: ekspertni sustavi, strojno učenje i duboko učenje te neuronske mreže. Metode umjetne inteligencije služe kao potpora radiologu pri dijagnosticiranju i interpretaciji nalaza te olakšavaju radiologu posao tako što smanjuju vrijeme potrebno za dijagnostiku. Podatci dobiveni u radu su iz stručnih članaka i raznih istraživanja provedenim u bolnicama, klinikama i sličnim ustanovama te rezultata dobivenih u ne kliničkim uvjetima. Ustanovljeno je da za dobivanje kvalitetnijih umjetnih neuronskih mreža i njihov bolji rad je potrebno da su uvjeti snimanja i protokoli što sličniji, vanjske karakteristike pacijenata što sličnije, edukacija osoblja da pravilno koriste programe umjetne inteligencije te računalna oprema da je što kvalitetnija i modernija. Također je ustanovljeno da umjetna inteligencija i umjetne neuronske mreže imaju veliki potencijal u njihovoj primjeni u radiologiji, olakšavaju rad radiologa te postaju sve sigurnije i točnije poboljšanjem tehnologije. Njihova ograničenja su u još ne sigurnosti u radu, strah radiologa i pacijenata u njihovu efikasnost i rad te problem kod prikupljanja podataka za treniranje neuronskih mreži zbog moralnih i etičkih razloga.

Ključne riječi: duboko učenje, ekspertni sustavi, računalno potpomognuta detekcija, radiologija, strojno učenje, umjetna inteligencija, umjetne neuronske mreže

ABSTRACT

Artificial intelligence is a branch of computer science that deals with the study and construction of computer systems that show some form of intelligence. Such systems are designed to be able to learn, draw conclusions and perform other tasks that require and demand human intelligence. The goal of the application of artificial intelligence in medicine, particularly in radiology is to increase diagnostic and therapeutic accuracy. Some of the branches of artificial intelligence that have application use in radiology are: expert systems, machine learning and deep learning as well as neural networks. Artificial intelligence methods serve to support the radiologist in diagnosing and interpreting the findings as well as making the radiologist's job easier by reducing the time required for diagnosis. The data obtained in this paper are from scientific articles - various studies conducted in hospitals, clinics and similar institutions as well as results obtained in non-clinical conditions. It has been established that in order to obtain better quality artificial neural networks, it is necessary that the imaging conditions and protocols are as similar as possible, the external characteristics of patients are as similar as possible, staff training to use artificial intelligence programs and that computer equipment is modern and has high quality. It is also established that artificial intelligence and artificial neural networks have great potential in their application in radiology, facilitate the work of radiologists as well as becoming safer and more accurate with the improvement of technology. Limitations of artificial intelligence are that they are not yet fully certain while working, fear of radiologists and patients in their efficiency and operation, and the problem of collecting data for neural network training because of moral and ethical reasons.

Key words: artificial intelligence, artificial neural network, computer aided detection, deep learning, expert systems, machine learning, radiology,

1. UVOD

U današnje vrijeme medicinu ne bi mogli ni zamisliti bez visoko razvijene računalne opreme. Pošto kvalitetna računalna oprema postaje sve dostupnija zdravstvenim ustanovama, zajedno sa količinom informacija dobivenih raznim medicinskim pregledima, umjetna inteligencija ima velik potencijal tog korištenja u svrhu povećane efikasnosti i učinkovitosti u zdravstvenoj skrbi. Veliki razvoj radiološke opreme, dovodi do bržeg i kvalitetnijeg rada zdravstvenih djelatnika, no ujedno povećava količinu informacija i nalaza koje radiolozi moraju interpretirati. Sada se radiolozi više ne moraju samo vizualno oslanjati kako bi očitali nalaz, nego imaju širok raspon seta alata i računalnih programa koji pomaže pri radu. Također neke manje promjene na slikama kod slikovnih metoda radiolozi ih mogu preskočiti i ne vidjeti. Iz tih razloga se grade sustavi umjetne inteligencije. Pošto sustavi umjetne inteligencije mogu superiorno kvantificirati podatke dobivene na radiološkim slikama, započeto je razmišljanje o njihovom uvođenju u svakodnevne kliničke svrhe.

Razvoj umjetnih neuronskih mreža moguće je kroz povijest pratiti još od sredine 20. stoljeća. 1940-tih godina Warren McCulloch i Walter Pitts objavljuju rad u kojem predlažu korištenje neuronske mreže kao način imitacije ljudskog mozga. 1950-tih godina Minsky i Dean Edmonds proizvode stohastički neuronski kalkulator koji se prepoznaje kao prva neuronska mreža u povijesti. Par godina nakon, proizvode se i prvi programi umjetne inteligencije. Krajem 1950-tih godina Arthur Samuel ubrzao je razvoj umjetne inteligencije uvođenjem koncepta strojnog učenja. 1960-tih godina provode se istraživanja prema kojim bi se ukazali temeljni problemi umjetne inteligencije. Joseph Weizenbaum također razvija program umjetne inteligencije pod imenom ELIZA. ELIZA je omogućila ljudima da komuniciraju sa strojevima na engleskom jeziku te je kroz svoj rad pokazala da je stroj u mogućnosti komunicirati sa ljudima na površnoj razini bez samosvijesti ili dubokog razumijevanja osobe unutar komunikacije(1).


Cilj sustava umjetne inteligencije u radiologiji je pomoć radiolozima u interpretaciji nalaza odnosno bržoj i kvalitetnijoj dijagnostici. U ovom radu navodim moguću korisnost sustava umjetne inteligencije i njene primjene u kliničkim uvjetima odnosno radiologiji. U prvom dijelu rada se definiraju osnovni tipovi strojnog učenja koji se najčešće koriste za istraživanja i u implementaciji u radiologiji. U drugom dijelu rada se gleda na koje sve grane medicine oni nalaze korisnost te na koji način bi oni radili. Zatim se definira i razmatra učinkovitost programa računalne potpomognute detekcije, njene primjene u radiologiji i na koji način se mogu

provjeravati sustavi umjetne inteligencije, odnosno njihova točnost u interpretaciji nalaza. U radu je korištena literatura informacije iz znanstvenih članaka, knjiga i raznih istraživanja u bolničkim ustanovama i kliničkim uvjetima kao i istraživanja u ne kliničkim uvjetima. Pregledani su svi izvori koji uključuju jedan od osnovnih tipova strojnog učenja i jednu od problematika koju mogu riješiti na području radiologije. Također ključne riječi koje su korištenje prilikom pretraživanja izvora također uključuju neki od tipova strojnog učenja te granu medicine koja koristi radiologiju kao glavni tip dijagnostike.

2. EKSPERTNI SUSTAVI

“Ekspertni sustavi su oni koji sadrže znanje i mehanizme za rješavanje problema koji zahtijevaju ljudsku inteligenciju“(2). To su sustavi koji pomažu ljudima u rješavanju zadataka, a rade na način na koji bi i ljudski eksperti donosili odluke u rješavanju zadataka.

Ekspertni sustavi su nastali kao pokušaj da se izgradi računalni sustav koji pokazuje određen stupanj inteligencije. Ideja je da ekspertni sustavi iskazuju svojstva inteligencije te ju primjenjuju na širok raspon problema i zadataka. Međutim takvi sustavi su teški za napraviti i dan danas, ali se sve više nadograđuju. Osnovna struktura građe ekspertnog sustava sastoji se od baze znanja te stroja za zaključivanje (Slika 1.). Korisnik postavlja upite ili činjenice u bazu znanja te nakon toga stroj za zaključivanje (pravila) daje odgovor ili objašnjenje nazad korisniku.



Slika 1. Osnovna struktura građe ekspertnog sustava.

Primjer uspješnog ekspertnog sustava u medicini je MYCIN sustav. Korišten je za dijagnozu i preporučanu terapiju krvnih infekcija. MYCIN sustav koristi skup pravila koji imaju čimbenike koji govore kolika je sigurnost sustava na postavljenu dijagnozu i time provjeravaju njegovo kliničko znanje. Pravila u sustavu su sastavljena nakon razgovora sa brojnim stručnjacima i njihovim izjavama iz vlastitih iskustava. Zbog toga su pravila djelomično imala nesigurnosti u medicinskim dijagnozama.(3)

Kako bi se olakšala implementacija ekspertnih sustava unutar različitih djelatnosti, osmišljen je način izgradnje ljusaka ekspertnih sustava. Ljuska ekspertnog sustava je ekspertni sustav bez

baze znanja. Baza znanja se puni kada se odredi specijalizacija za određenu problemsku domenu. Priprema baze znanja često predstavlja prepreku jer uporaba računala i računalnog znanja nije bila mnogo raširena ljudska djelatnost. Stoga taj posao uobičajeno radi inženjer baze znanja koji zajedno kroz razgovor i interakciju s ekspertom prikuplja relevantno znanje te ga oblikuje i upisuje u bazu znanja. Ekspert uvidom u stanje baze znanja kroz interakciju s inženjerom baze znanja doprinosi u razvoju ekspertnog sustava koji se na kraju primjenjuje za problemsku domenu.(2,4,5)

2.1. Građa ekspertnog sustava

Ekspertni sustavi se dijele na sustave *temeljene na pravilima* te sustave koji su *temeljeni na učenju*. Postoje i *mješoviti sustavi* koji dio znanja dobivaju putem pravila, a dio učeći na primjerima. Najčešće pravilo koje se koristi je pravilo AKO-ONDA.

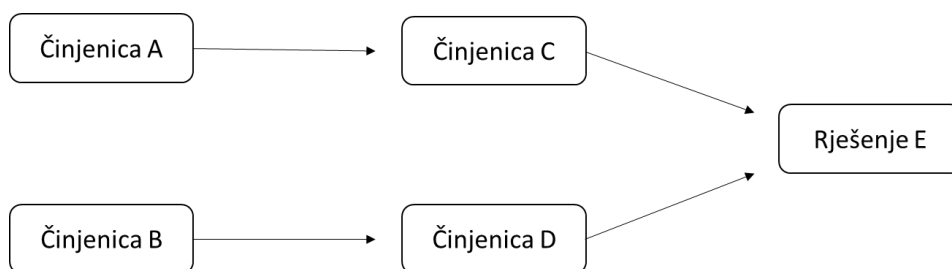
Ekspertni sustavi koji su temeljeni na pravilu AKO-ONDA se nazivaju *produkcijски ekspertni sustavi*. Jednostavan primjer pravila AKO-ONDA bi bilo “AKO kašalj ONDA gripa“. Moguće je i da nekoliko uvjeta treba biti ispunjeno kako bi se ostvarilo pravilo. Na primjer “AKO kašalj i kihanje ili glavobolja ONDA gripa“. Produkcijски ekspertni sustavi sadrže *činjenično znanje i uvjetno znanje*.

Činjenično znanje se nalazi u radnoj memoriji dok uvjetno znanje se nalazi u bazi pravila. Baza pravila sadržava skup svih produkcijskih pravila, a u radnoj memoriji se nalaze sve činjenice koje su prikupljene od korisnika ili izvedene procesom zaključivanja. Baza znanja produkcijskog ekspertnog sustava se sastoji od radne memorije i baze pravila. Produkcijски ekspertni sustav zaključuje na princip upravljačkog mehanizma. Pronalazi sva pravila koja su u skladu s činjenicama u bazu te izabire jedno od pravila te izvršava prema njemu. (2,4,5)

2.2. Zaključivanje ekspertnog sustava

Zadaća je ekspertnog sustava koji je temeljen na činjenicama i niza pojedinih pravila koje je dao korisnik doći do rješenja i odgovora koje je postavio korisnik. Ekspertni sustav gradi lanac činjenica i zaključaka kojim od početnih činjenica dolazi do zaključka. Ekspertni sustav temeljen na pravilima na korisnikova pitanja može odgovoriti na dva suprotna načina. Odgovara *zaključivanjem unaprijed* i *zaključivanjem unatrag*, odnosno *heuristički ulančavanjem unaprijed ili unatrag*.

Heuristika je “splet intuicija, asocijacija i procjena koje kombinirane s činjeničnim znanjem mogu ubrzati postizanje cilja“(2). *Zaključivanje unaprijed* počinje od početnog skupa činjenica. Traže se sva pravila koja s obzirom na trenutno stanje činjenica imaju u radnoj memoriji. Ta se pravila izvršavaju i nove činjenice se dodaju u bazu činjenica. Proces se ponavlja ili staje skroz dok se ne izvede vrijednost za činjenicu koju je korisnik tražio ili ako se više ništa novo ne može izvesti. *Zaključivanje unatrag* je postupak zaključivanja koji kreće od ciljne činjenice. Korisnik ne treba zadati ništa više od krajnje činjenice. Za činjenice koje nisu poznate će sustav potražiti pravila koja do njih dolaze. Ako postoji činjenica za koju nema pravilo kako dolazi do nje, sustav pita korisnika da unese vrijednosti za te činjenice. Primjer jednog jednostavnog ekspertnog sustava bi išao: AKO „A“ ONDA „C“ ; AKO „B“ ONDA „D“ ; AKO „C i D“ ONDA „E“. Ulančavanjem unaprijed da bi ovaj sustav došao do rješenja E, moraju se postaviti činjenice da su A i B točni. Sustav gleda prvo pravilo AKO „A“ ONDA „C“ i provjerava ako se ono može izvesti. Pošto je moguće izvesti, sustav gleda činjenicu C kao točnu. Prelazi na sljedeće pravilo AKO „B“ ONDA „D“ koje se također može izvesti u kojoj je činjenica D točna. Prelazi na posljednje pravilo AKO „C i D“ ONDA „E“. pošto su C i D oboje točni, ovaj sustav zaključuje da je rješenje E točno (Slika 2.). Ulančavanje unatrag koristi malo drugačiji pristup. Sustav polazi odmah od rješenja E te unatrag provjerava ako je ono točno. Rješenje E je točno ako su činjenice C i D točne. Sustav zatim provjerava kako može doći do činjenice C ili D te gleda ako postoje pravila koje ih čine. Pošto je činjenica C točna ako je činjenica A točna, sustav provjerava kako doći do činjenice A. Pošto ne postoji pravilo koje tvori činjenicu A, sustav pita korisnika ako je činjenica A točna. Na isti način se dobiva i činjenica D tako da sustav pita korisnika za činjenicu B. Ukoliko su činjenice A i B točne, sustav zaključuje da je rješenje E također točno. (2,4,5)




Slika 2. Jednostavan primjer ekspertnog sustava koji koristi ulančavanje unaprijed

2.3. Prednosti i nedostatci ekspertnih sustava

Prednosti ekspertnih sustava su što mogu rješavati složene zadatke i probleme kao što to i stručnjaci mogu. Rješavaju probleme i zadatke heuristički, odnosno prave postupak koji vodi prema njemu ili ga potiču. Mogu komunicirati s korisnikom te objašnjavaju zašto postavljaju pitanja ili dovedene zaključke. Također su superiorniji u načinu pohranjivanja podataka i znanja od konvencionalnih metoda. Omogućuju interaktivno i potpomognuto učenje te ga na taj način ubrzavaju od metoda koji dovode do samostalnog razmišljanja i donošenja zaključka. Nedostatci ekspertnih sustava u usporedbi sa sustavima koji koriste neuronske mreže što ne mogu doći do rješenja ili zaključka ako nemaju potpune i točno definirane informacije. Ne mogu imati široko područje primjene zbog kompleksnosti u izgradnji baze podataka te limitiranosti brojem pravila. Točnost dobivenih zaključaka i rješenja ovisi o pravilnoj izgradnji ekspertnog sustava te točnih činjenica dobivenih od stručnjaka. Ekspertni sustav prema tome ne mora uvijek davati odgovore točno. Ne mogu obavljati kreativne zadatke ili zadatke koje uključuju moral jer se oni ne mogu predočiti pravilima. Također izgradnja ekspertnih sustava je skup proces i zahtjeva određen vremenski period uhodavanja korisnika.(2,4,5)

3. UMJETNE NEURONSKE MREŽE

Umjetne neuronske mreže su vrste računarskih mreža koje grade svoje sustave slične arhitekture kao središnji živčani sustav u namjeni rješavanja zadataka i problema. Spadaju u granu računarstva koji se zove neuro-računarstvo. Umjetne neuronske mreže se sastoje od umjetnog neurona sa svojim težinama te veza koji ih povezuju zajedno. Moraju imati ulazni sloj od kojeg mreža dobiva podatke za obradu te završni sloj u kojem mreža daje izračunati rezultat (Slika 3.). (1)



Slika 3. Višeslojna unaprijedna umjetna neuronska mreža konfiguracije 2x3x3x2.

Postoje dva tipa obrade podataka za rješavanje problema i zadataka: simbolički i konektivistički način obrade podataka. Simbolički pristup obrade podataka obično vrši serijsku obradu podataka. Kod simboličke obrade najčešće se koristi Von Neumannova arhitektura rješavanja algoritama. Kod Von Neumannove arhitekture problem koji treba riješiti se mora definirati unaprijed razložen na niz koraka. Svi podatci moraju biti točni, u situaciji kod koje nekoj varijabli dajemo vrijednost „točno“, a nakon toga pročitamo vrijednost „netočno“ karakterizira se kao pogrešan rad sustava. Zbog toga algoritam nije u mogućnosti ispravno obrađivati podatke. Također podatci moraju biti precizni inače se ne mogu koristiti kao ulaz algoritama. Svaka varijabla se točno zna što u programu predstavlja i gdje je smještena u memoriji.(5)

Drugi pristup je konektivistički pristup koji koristi umjetne neuronske mreže za masovno raspodijeljeno i paralelno računanje. Umjetna neuronska mreža sasvim drugačije obrađuje podatke. Nije potrebno definirati način na koji će mreža obraditi podatke zato što će mreža učiti na temelju dobivenih podataka. Podatci ne moraju biti precizni ni točni koji se dovode na ulaz umjetne neuronske mreže. Prilikom učenja umjetne neuronske mreže, razviti će sposobnost razlikovanja u podacima i generalizacije te će raditi i u situacijama kada su ulazni podatci nejasni, odnosno prožeti sa šumom. Obrada podataka se odvija raspodijeljeno pa točan rezultat nije ovisan samo o jednom neuronu. Zbog toga umjetna neuronska mreža je sposobna obrađivati podatke relativno dobro iako postoji određena razina kvarova u mreži. (Slika 3.).(5,6)

3.1. Primjena umjetnih neuronskih mreža

Najčešću primjenu umjetne neuronske mreže pronalaze na područjima klasifikacije i funkcijske regresije. Klasifikacija je postupak određivanja razreda ili klase u kojoj ulazni uzorak pripada. Funkcijska regresija je postupak pri kojem se na temelju podataka pokušava napraviti aproksimacija funkcije.(5) Cilj je da se izgradi model na temelju kojeg će sustav koji obavlja funkciju regresije moći i za prethodno neviđene ulazne uzorke na izlazu dati vrijednost na temelju danih podataka.

Konkretni primjeri primjene umjetnih neuronskih mreža su obrada jezika, prepoznavanje pisanih znakova, kompresije slika, prepoznavanje uzoraka, obrada signala, financije te upravljanje strojevima. Kod obrade jezika uključuju se sustavi koji pretvaraju teksta u govor i govor u tekst, sustave kojima se može upravljati govorom te sustave za automatsku transkripciju. Prepoznavanje pisanih znakova uključuje primjenu sustava koji može detektirati tekst, retke, riječi ili slova. Kompresija slike uključuje sustave koji u stvarnom vremenu obavljaju kompresiju i dekompresiju podataka. Prepoznavanje uzoraka uključuje primjenu sustava koji na temelju snimaka mogu detektirati razne predmete te ima niz primjena u medicini. (5,6)

3.2. Učenje neuronske mreže

Faza učenja podrazumijeva da se neuronskoj mreži predočavaju uzorci iz skupa uzoraka za učenje. Usljed toga, dolazi do promjena u jakosti veza (težinama) između neurona koji čine neuronsku mrežu čime se mreža prilagođava viđenim podacima. Neuronska mreža svoje težine može podešavati nakon svakog viđenog uzorka odnosno iteracije ili nakon što prođe sve uzorke odnosno epohe. Neuronska mreža može učiti nakon svakog viđenog uzorka ili može učiti tek kada vidi cijeli skup uzoraka. Učenje nakon svakog viđenog uzorka naziva se pojedinačno učenje, a nakon cijelog skupa uzoraka naziva se grupno učenje(5).


Druga podjela načina učenja je da neuronska mreža može učiti s učiteljem, podržano i bez učitelja. Kod učenja s učiteljem neuronskoj se mreži predočavaju uzorci oblika, a zadaća mreže je naučiti klasificirati ili funkcijsku regresiju.

Kod učenja bez učitelja cilj neuronske mreže je da obavlja zadaću grupiranja podataka. Pri radu s neuronskim mrežama složenost modela ovisi o broju neurona od koje se mreža sastoji, njihovom funkcijom i načinom na koji su povezani. Kod ulaznih podataka koje imaju šum, neuronska mreža za vrijeme učenja može se početi prilagođavati tako da napamet uči s čime gubi sposobnost generalizacije umjesto da se prilagodi općim svojstvima prisutnim u podacima. Zbog toga je bitno pratiti postupak učenja mreže te mrežu pustiti da uči tako dugo dok joj se sposobnost generalizacije popravlja. Treba biti u stanju detektirati kada mreža gubi svojstvo generalizacije, kada se počne prilagođavati prisutnim šumom u podacima. Tada se prekida učenje. Čitav skup uzoraka se dijeli u tri podskupine: skup za učenje (60%), skup za provjeru (20%), skup za testiranje (20%). Tijekom učenja neuronske mreže, ona uči na skupu za učenje. Predočavaju joj se uzorci te se mreža prilagođava njima. Rad neuronske mreže se povremeno kontrolira, obično nakon jedne epohe, na skupu za provjeru. Pri provjeri učenje mreže se obustavlja odnosno drži se fiksnom da se ne prilagođava na podatke iz skupa za provjeru. U ranim fazama učenja, neuronska će se mreža prilagođavati globalnim svojstvima prisutnim u podacima pa će tako pogreška koju mreža ostvaruje i nad skupom za učenje i nad skupom za provjeru padati“. Naime u jednom se trenutku neuronska mreža počne prilagođavati specifičnim podacima i šumu na skupu za učenje gdje počinje odstupati od globalnih svojstava u podacima. Kao posljedica toga greška u skupu za učenje će nastaviti padati, no istovremeno će pogreška neuronske mreže na skupu za provjeru početi rasti. Zbog toga je vrlo važno pratiti rad neuronske mreže na skupu za učenje i skupu za provjeru te se tako i tada može detektirati trenutak kada treba prekinuti učenje. Kada je cijeli postupak učenja gotov, konačnu kvalitetu

rada se provjerava na skupu za testiranje. Ta se provjera obavlja samo jednom. Pretreniranost je stanje neuronske mreže u kojem je izgubila sposobnost generalizacije te je postala stručnjak za podatke iz skupa za učenje.(5,6)


3.3. Umjetni neuron – TLU perceptron

TLU perceptron je vrsta umjetnog neurona koji težinsku sumu propušta kroz funkciju skoka i time određuje izlaznu vrijednost. Ulazi umjetnog neurona označuju se x_1, x_2, \dots, x_i . U kojoj mjeri signal primljen kroz ulaz x_i utječe na neuron, karakterizirano je težinom w_i . Signal koji dolazi na ulaz x_i množi se težinom w_i te je njihovo djelovanje određeno umnoškom $x_i * w_i$. Tijelo umjetnog neurona modelira integriranje svih primljenih podataka u jednu zajedničku sumu. Generirana suma na izlazu se označava kao *net*. Izlaz umjetnog neurona prikazan je kao prienosna funkcija te ona određuje konačni izlaz *o* umjetnog neurona (Slika 3.).



Slika 4. Izgled i građa TLU perceptrona.

Kod funkcije skoka gleda se predznak težinske sume. Ako je težinska suma negativna, izlaz na umjetnom neuronu će biti 0, no ako je težinska suma 0 ili pozitivna, izlaz na umjetnom neuronu će biti 1. U dvodimenzionalnom prostoru parovi svih točaka koji zadovoljavaju uvjet $net = 0$, tvore liniju (pravac) koja se naziva decizijska granica (Slika 4.). To je linija koja odvaja sve pozitivne od svih negativnih izlaza na umjetnom neuronu. Decizijska granica na TLU perceptronu može biti samo linijska. Uobičajena primjena TLU perceptrona je u klasifikaciji kada u najjednostavnijem slučaju treba uzorke razvrstati u dva razreda. Ovisno o zadatku perceptrona on ne daje sva moguća rješenja u zadacima već samo jednu od mogućih rješenja. TLU perceptron se također ne može koristiti kod zadataka u kojem rješenje nije linearno razdvojivo.



Slika 5. Primjer mogućeg izgleda decizijske granice.

Težine TLU perceptrona uče iz podataka načinom algoritma učenja perceptrona. Algoritam učenja perceptrona se formuliraju na način da ciklički prolaze kroz svaki uzorak za učenje jedan po jedan te ako se klasificiraju korektno ne trebaju se promijeniti težine. Također ako prođe ciklički kroz sve (N) uzorke i vrati se na početni, prekida se učenje jer perceptron klasificira sve ispravno. U suprotnom ako perceptron ne klasificira uzorak korektno primjenjuje se algoritam za korigiranje težine perceptrona. Formula odnosno algoritam kojim TLU perceptron uči, odnosno korigira svoju težinu glasi: $w_i(k+1) \leftarrow w_i(k) + \eta \cdot (t - o) \cdot x_i$ (5,6)

3.4. Višeslojne umjetne neuronske mreže


Višeslojne umjetne neuronske mreže su građene od više umjetnih neurona (Slika 3.). Neuroni su grupirani u jasno definirane slojeve te svaki neuron dobiva podražaj iz svih neurona prije njega ili ulaznih podataka. Ulazni sloj čine N broj neurona te se kroz njih dobivaju ulazni podatci. Nemaju funkciju već služe da prenesu informaciju dobivene izvana na obradu u mreži. Drugi sloj (skriveni slojevi) koji se sastoji od N broja neurona dobiva ulaze na svakom neuronu

od neurona ulaznog sloja. Neuron u skrivenom sloju obavlja obradu podataka na način da računaju težinsku sumu ulaznih podataka, propuštaju ju kroz prijenosnu funkciju te tako obrađeni podatak stave kao svoj izlaz(5). Svaki neuron u 1. skrivenom sloju ima N broj težina. Težine koje određuju utjecaje ulaznih neurona te težinu koja predstavlja konstantan otklon (engl. *bias*). Težine se ne dijele među neuronima, nego svaka ima svoju vlastitu težinu s kojom raspolaže te se može podešavati. Sljedeći slojevi (skriveni slojevi) se također sastoje od neurona koji su spojeni sa izlazima prethodnog sloja. Također imaju svoje težine koje se mogu podešavati. Izlazni sloj koji se sastoji od N broja neurona koji su spojeni sa zadnjim skrivenim slojem. Određuju konačni izlaz umjetne neuronske mreže.

Neuronske mreže mogu obavljati zadaću složenijih funkcijskih regresija i klasifikacija u odnosu na TLU perceptron. Osnovni algoritam učenja unaprijednih neuronskih mreža je algoritam propagacije pogreške unatrag. Najprije treba odrediti izlaz mreže. Potom se računa pogreška neurona izlaznog spoja. Na temelju pogrešaka izlaznog sloja se računaju pogreške neurona sljedećeg spoja (predzadnjeg). Pogreške se računaju redom sve do prvoga skrivenog sloja. Pogreška se propagira od kraja mreže prema početku mreže. Umjetne neuronske mreže uče na način da se svim težinama postave slučajne vrijednosti, postavljaju se podaci na ulaz mreže, izračunaju se izlazi svih neurona iz svih slojeva te se odredi konačni izlaz neuronske mreže, odredi se pogreška neurona izlaznih slojeva te se računa pogreška sloj po sloj prema početku mreže te se korigiraju sve težine. (5,6)

4. KONVOLUCIJSKE NEURONSKE MREŽE


Konvolucijske neuronske mreže su vrste modela dubokog učenja koji ima mrežnu strukturu poput slike. Dizajnirane su za automatsko i prilagodljivo učenje prostornih značajki. Sastoji se od obično tri sloja: konvolucijskog sloja, sloja sažimanja te potpuno povezanih slojeva. Konvolucijski sloj je temeljna komponenta mreže koja vrši izvlačenje značajki. Sloj funkcionira na način da se mali niz brojeva (engl. *kernel*) primjeni na ulazu koji se također sastoji od niza brojeva koji se naziva *tenzor*. Tenzor bi na radiološkim slikama podrazumijevao brojčanu vrijednost piksela. Pri tome se izračunava vrijednost između kernela i tenzora, a dobivena se vrijednost postavlja u svoje odgovarajuće mjesto na mapi značajki (Slika 6.). Postupak se ponavlja kako bi se formirao proizvoljan broj mapa koje predstavljaju različite karakteristike ulaznih jedinica. Ključna značajka konvolucijskog sloja je dijeljenje težine odnosno podjela kernela na svim dijelovima slike.



Slika 6. Računanje vrijednosti kernela i tenzora te postavljanje dobivene vrijednosti u mapu značajki. (Izvor: Yamashita R, Nishio M, Do RKG, Togashi K. Convolutional neural networks: an overview and application in radiology. Insights Imaging. 2018.;9(4):611–29)

Sloj sažimanja smanjuje dimenziju u mapi značajki kako bi dovelo do nepromjenjivosti prema malim pomacima unutar parametara. Koriste se dva načina sažimanja. Maksimalno sažimanje izvlači najveću vrijednost unutar mape značajki, a ostale vrijednosti odbacuje. Najčešće se primjenjuje filter veličine 2x2 te umanjuju dimenziju mape značajki (Slika 7.). Drugi način sažimanja je putem srednje vrijednosti svih značajki. Koristi ekstremnu vrstu smanjenja uzorkovanja, gdje se mapa značajki određene veličine smanji na veličinu 1x1 uzimanjem

prosjeaka svih elemenata na mapi značajki. To se sažimanje obično primjenjuje prije potpuno povezanih slojeva.



Slika 7. Maksimalno sažimanje koji primjenjuje filter veličine 2x2 i umanjuje dimenziju mape. (Izvor: Yamashita R, Nishio M, Do RKG, Togashi K. Convolutional neural networks: an overview and application in radiology. Insights Imaging. 2018.;9(4):611–29)

Izlazna vrijednost od mape značajki završnog konvolucijskog sloja ili sloja sažimanja se pretvaraju u jednodimenzionalni niz brojeva koji su povezani s jednim ili više potpuno povezanih slojeva. Potpuno povezani slojevi tada daju vjerojatnost za svaku klasu u zadatcima klasifikacije.(7,8)


4.1. Učenje konvolucijskih neuronskih mreža

Treniranje mreže je postupak u kojemu se pronalazi optimalni kerneli u konvolucijskim slojevima i težine u potpuno povezanim slojevima. Na taj se način povećava točnost u predviđanju rezultata na mreži. Pažljivo prikupljanje podataka i točno interpretiranih nalaza pomoću kojih se trenira i testira neuronska mreža obavezna je komponenta za duboko učenje. Dobivanje visokokvalitetnih i točnih podataka je najčešće dugotrajan proces. Iako skupovi podataka o radiološkim slikama mogu biti javno dostupni, i dalje treba dati posebnu pozornost njihovoj kvaliteti odnosno točnosti. Kao i ostale umjetne neuronske mreže podatci su podijeljeni u tri skupa: skup za učenje neuronske mreže, skup za provjeru te skup za testiranje

mreže. Skup za učenje služi da ažurira parametre koji uče, skup za provjeru služi da na mreži ne bi došlo do pretreniranosti ili ako treba promijeniti neki od parametara, a skup za testiranje se koristi jednom da bi se utvrdilo koliko dobro umjetna neuronska mreža radi.(7,8)

4.2. Primjena konvolucijskih neuronskih mreža u radiologiji

U analizi radioloških slika, klasifikacija se obično koristi za ciljani prikaz lezija na slici. Na primjer, metode dubokog učenja se koriste za klasifikaciju plućnih čvorova na CT slici te ih klasificira kao benigne ili maligne. Potrebno je pripremiti veliku količinu podataka koje imaju odgovarajuće oznake za učinkovito klasificiranje. Kod klasifikacije plućnih čvorova, za treniranje se koriste CT slike plućnih čvorova i njihove oznake ako su benigne, odnosno maligne (Slika 8.).



Slika 8. Učenje i klasifikacija konvolucijske neuronske mreže kod benignih ili malignih lezija na CT slikama. (Izvor: Yamashita R, Nishio M, Do RKG, Togashi K. Convolutional neural networks: an overview and application in radiology. Insights Imaging. 2018.;9(4):611–29)

Nakon treniranja neuronske mreže, može se implementirati u sustave za potporu u odlučivanju radi otkrivanja ciljanih lezija na radiološkim slikama. Segmentacija organa ili anatomskih struktura je temeljna tehnika obrade radioloških slika. Najčešće koristi kvantitativne parametre poput volumena i oblika organa. Klasifikacija je ovisna o dobroj segmentaciji organa, odnosno leziji od interesa. Sustav za segmentaciju najčešće prima izravno cijelu sliku te prikazuje rezultat segmentacije. Podatci za trening sustava segmentacije se sastoje od radioloških slika koji sadrže organ ili strukturu od interesa i završni rezultat segmentacije. Rezultati segmentacije se uglavnom dobivaju prethodno provedenim ručnim segmentacijama. Pošto se u sustav segmentacije unosi cijela slika, sustav mora obuhvatiti cjelokupnu prostornu povezanost na slici radi učinkovitije segmentacije. Segmentirati se može upotrebom klasifikatora, konvolucijske mreže za izračunavanje vjerojatnosti organa ili atomske strukture. U tom pristupu postupak segmentacije se dijeli na dva koraka. Prvi korak izgrađuje mapu vjerojatnosti organa ili atomske strukture pomoću konvolucijske mreže i slojeva slika. Drugi korak koristi usavršenje izgradnje mape gdje se upotrebljavaju i spajaju sadržaj sa slike i mapa vjerojatnosti struktura. Jedno prethodno istraživanje je koristilo klasifikator konvolucijske mreže za segmentaciju jetre na CT slikama. Kao ulaz za konvolucijsku mrežu se koristio sloj slika prikupljenih od cijelih CT slika. Konvolucijska mreža je računala vjerojatnost na kojoj se nalazi jetra iz slojeva slika. Izračunavanjem vjerojatnosti prisutnosti jetre na slikama, dobivena je 3D mapa za vjerojatnost jetre. Rezultati otkrivaju da je pristup učinkovit i precizan za procjenu volumena jetre u radnim uvjetima(9). Visoka korelacija između automatske i ručne interpretacije ukazuje da metoda može biti dovoljno dobra za moguću implementaciju u sustav.(7–9)

5. UMJETNA INTELIGENCIJA U RADIOLOGIJI

Umjetna inteligencija se sve više razvija što dozvoljava strojevima da bolje predstavljaju i protumače složene podatke. To je dovelo do velikih napredaka u primjeni umjetne inteligencije te je omogućilo rješavanje zadataka koje je ranije samo čovjek mogao riješiti. Duboko učenje je podskup strojnog učenja koje se temelji na strukturi neuronske mreže inspiriranom ljudskim mozgom(10). Takve strukture automatski uče diskriminacijske značajke iz podataka dajući im mogućnost aproksimacije vrlo složenih nelinearnih odnosa. Većina prijašnjih metoda umjetne inteligencije su dovele do slabijih rezultata i učinaka. Najnoviji algoritmi dubokog učenja u stanju su se podudarati i čak nadmašiti ljude u primjenama specifičnih zadataka. To je zahvaljujući nedavnom napretku u istraživanju umjetne inteligencije, ogromnim količinama digitalnih podataka sada dostupnih za obuku algoritama te modernog i moćnog računalnog hardvera.

Osnovni pokretač nastanka UI u medicinskom slikanju je želja za većom efikasnosti i učinkovitošću u kliničkoj skrbi. Podaci radiološkog snimanja rastu velikom brzinom i povećavaju potrebu za brojem dostupnih obučenih radiologa. Pružatelji zdravstvenih usluga su prisiljeni to nadoknaditi povećanjem produktivnosti. Ti su čimbenici pridonijeli dramatičnom povećanju opterećenja radiologa. Integrirana komponenta UI unutar slikovnog tijeka rada povećala bi učinkovitost, smanjila pogreške i postigla ciljeve uz minimalni ručni unos pružajući obučenim radiolozima unaprijed prikazane slike i identificirane značajke. Gotovo svi radiološki zadaci temeljeni na slici ovise o kvantifikaciji i procjeni radiografskih karakteristika sa slika. Te karakteristike mogu biti važne za klinički zadatak, odnosno za otkrivanje, karakterizaciju ili praćenje bolesti.

Uspješan projekt strojnog učenja i njegova implementacija u radiologiji je gotovo uvijek multidisciplinarna i najčešće se promatra kao proces s četiri koraka. Prvo se iz medicinske domene treba identificirati problem. Zatim se pomoću znanja programera procjenjuje ako je identificirani problem tehnički rješiv uz pomoć sustava umjetne inteligencije. Također se treba ispitati ako je umjetna inteligencija najbolja opcija za rješavanje ili postoji neka druga manje složenija metoda. Nakon što se identificira problem, drugi korak podrazumijeva pravljenje i razvoj algoritma. To počinje odabirom podataka i utvrđivanjem temeljne istine, odnosno koji podatci se mogu smatrati točnima. Važno je da podatci budu točni kako bi za vrijeme treniranja algoritma njegova performansa bila što bolja. Treći korak podrazumijeva evaluaciju umjetne mreže. Kao primjer najjednostavnijih testova koji se mogu koristiti su testovi osjetljivosti,

specifičnosti i točnosti. Radiolog je odgovoran za to da odabrana metoda evaluacije odražava klinički važne značajke, odnosno da vizualno provjeri valjanost podataka. Nadalje umjetna mreža mora služiti namijenjenoj kliničkoj uporabi za koju je dizajnirana. Ako se ocijeni da umjetna mreža učinkovito rješava klinički problem, u zadnjem se koraku pokušava implementirati u kliničku praksu. Iako je pravljenje namijenjenog softverskog paketa najčešća opcija, kao zlatni standard se koristi izravna integracija algoritma u postojeće sustave. Rezultira glatkim tijekom rada te se osigurava prihvaćanje i angažiranost njegovih korisnika.(11)

Postoje dvije vrste metoda UI koje su u širokoj uporabi. Prva koristi tradicionalne metode umjetne inteligencije koje se oslanjaju na unaprijed definirane algoritme s eksplicitnim parametrima koji se temelje na stručnom znanju. Te se značajke koriste kao ulazne jedinice koji su osposobljeni da klasificiraju pacijente na način gdje podržavaju kliničko odlučivanje. Iako se takve značajke smatraju diskriminativne, oslanjaju se na stručnu definiciju i stoga ne predstavljaju najoptimalniji pristup za predmetni zadatak diskriminacije. Takve su značajke dizajnirane za mjerenje određenih radioloških karakteristika, poput 3D oblika tumora, teksture unutra tumora i raspodjele intenziteta piksela. Unaprijed definirane značajke se često ne mogu prilagoditi varijacijama u modalitetima snimanja, poput CT-a, PET-a i MR-a te njihovim karakteristikama SNR-a. Nedeterministički algoritmi dubokog učenja koji ne zahtijevaju eksplicitnu definiciju značajki što predstavljaju temeljno drugačiji primjer strojnog učenja. Bez unaprijed definiranih obilježja, algoritmi izravno uče kretanjem kroz prostor podataka što im pruža mogućnost superiornog rješavanja problema. Iako postoje razne strukture mreža dubokog učenja za rješavanje zadataka, danas se u medicinskom oslikavanju najčešće koriste konvolucijske neuronske mreže. Druge strukture poput dubokih autodekoda i generativnih kontradiktornih mreža su više namijenjene za učenje na neobilježenim podacima. (10,12)

5.1. Metode UI u onkologiji

Veliki tehnički razvoj tijekom godina podupire stajalište da računalni programi koji su temeljeni na modelima koji su obučeni na digitaliziranim medicinskim podacima mogu izvoditi mnogo koraka kao što to može i čovjek. Zbog velike važnosti medicinskog slikanja za planiranje radioterapije, isporuku zračenja i procjenu ishoda, radioterapijska onkologija je posebno prikladna za primjenu automatiziranih metoda. Glavni klinički radiološki zadatci koji se odnose

na onkologiju su otkrivanje abnormalnosti, karakterizacija te naknadno praćenje promjena. Ti zadatci zahtijevaju medicinske vještine u smislu dijagnoze bolesti i skrbi te tehničkih za hvatanje i obradu radiografskih slika. Kod ručnog otkrivanja radiolozi vizualno pregledavaju veliku količinu slika dok povremeno prilagođavaju ravnine gledanja i postavke širine i razine prozora. Oslanjajući se na obrazovanje, iskustvo i razumijevanje normalne radiografije, radiolozi su obučeni za prepoznavanje abnormalnosti na temelju promjena u intenzitetu snimanja ili pojave neobičnih uzoraka. Kako se razvijala informacijsko-komunikacijska tehnologija, automatizirane metode za identifikaciju i obradu unaprijed definiranih značajki predlažu se i povremeno se koriste u klinici. Radiolozi definiraju kriterije za prepoznavanje uzoraka kojim će algoritam računalnog vida istaknuti i izraziti definirane objekte na slikama.(10) Algoritmi su često specifični za zadatak i ne generaliziraju bolesti i modalitete snimanja. Točnost tradicionalnih unaprijed definiranih CAD sustava temeljenih na značajkama je relativno upitna, no korištenjem konvolucijskih neuronskih mreža moguće je poboljšati otkrivanje abnormalnosti.

Karakterizacija je pojam koji se odnosi na segmentaciju, dijagnozu i stadij bolesti. Ti se zadatci postižu kvantificiranjem radioloških karakteristika abnormalnosti kao što su veličina, opseg i unutarnja tekstura. Ljudi nisu sposobni interpretirati više od nekoliko kvalitativnih obilježja dok se bave rutinskim zadacima očitavanja medicinskih slika. Automatizacija putem umjetne inteligencije može, u pravilu, uzeti u obzir veliki broj kvantitativnih značajki te stupanj njihove relevantnosti i svaki put izvoditi zadatak na ponovljiv način. Unutar početnog koraka segmentacije, dok se zdravi organi mogu segmentirati s relativnom lakoćom, identificiranje opsega bolesnog tkiva je mnogo izazovnije. Uobičajeni postupci segmentacije tumora u kliničkoj radiologiji su često ograničeni na metrike visoke razine kao što je najveći promjer ravnine.(13) U drugim kliničkim slučajevima je potrebna i nužna veća osjetljivost i preciznost. Kod radioterapije opseg tumorskih i ne tumorskih tkiva mora biti precizno segmentirana za planiranje liječenja zračenjem. Višestruke radiografske karakteristike se također koriste u zadacima dijagnoze. Presudne su za utvrđivanje abnormalnosti čvrstih struktura ili ako također sadrže mekana područja. Radiografske karakteristike tumora uključuju podatke o veličini, maksimalnom promjeru, okruglosti, unutarnjoj teksturi te rubove. Logika dijagnoze se često temelji na tim subjektivnim karakteristikama što omogućuju dijeljenje u razrede koji ukazuju da su benigne ili maligne tvorbe. Stadij bolesti se općenito malo ili nimalo automatizira. Oslanja se na kvalitativne opise koje je često teško kvantitativno izmjeriti. Automatsko postavljanje stadija veličine primarnog tumora, obližnjih limfnih čvorova te udaljenih metastaza zahtjeva

različite skupove značajki i pristupa. Praćenje bolesti ključno je za dijagnozu, kao i za procjenu odgovora na liječenje. Uključuje obradu slike gdje se oboljelo tkivo poravnava na više snimaka. Nakon toga slijedi procjena jednostavnih mjernih podataka pomoću unaprijed definiranih protokola koje se koriste za kvantificiranje promjene. Početni pokušaji u automatizaciji tijeka praćenja bolesti i promjena oslanjali su se na automatiziranu primjenu više slika praćenu oduzimanjem jedne od druge, nakon čega su se promijenjeni pikseli istaknuli i predstavljali čitatelju. Druge metode izvode klasifikaciju po pikselima. Koriste unaprijed definirana obilježja kako bi identificirali promijenjene i tako stvorile sažetiju kartu promjena. Primjeri gdje se umjetna inteligencija može primijeniti u onkologiji su kod snimanja prsnog koša, snimanja abdomena i zdjelice, kolonoskopije, mamografije, snimanja mozga, radioterapija te dermatologija i patologija.(10,13)

5.2. Metode UI u nuklearnoj medicini

Nuklearna medicina već neko vrijeme koristi umjetnu inteligenciju. Implementacija strojnog učenja provedena je u nekoliko područja nuklearne medicine. Ponajviše uključuju nuklearnu kardiologiju, onkologiju i neurologiju. Postignut je uspjeh s automatskim otkrivanjem rubova, ocrtavanjem volumena tumora te automatskim otkrivanjem anatomije i plućnih čvorova na PET/CT uređaju. Poboljšana dijagnostika, određivanje stadija i procjena odgovora na terapiju pomoću PET/CT uređaja postigla je određeni uspjeh, a teksturna analiza pomaže u razlikovanju benigne od maligne bolesti. Otkrivanje ishemijske i poboljšana dijagnostika Parkinsonove bolesti mogućnosti su za buduću kliničku primjenu. Umjetna inteligencija poboljšava i dijelove nuklearne medicine koji su povezani sa dozom zračenja. Omogućava poboljšanje metoda praćenja doza, usklađenost i poštivanje ograničenja doze te algoritmi koji vode do smanjenja doze. Jedno od problema istaknuto s umjetnom inteligencijom je potreba za točnim unosom podataka te njihova konzistencija. Stopa pogrešaka pri unosu podataka može biti velika i slični se sustavi ne koriste uvijek na isti način na svim lokacijama. Mogućnost korištenja umjetne inteligencije također se može koristiti u tipičnom tijeku medicinskog slikanja. Prije nego što se izvrši pregled na pacijentu, treba utvrditi je li planirani postupak medicinski indiciran. Što je pregled neugodniji, rizičniji ili skuplji to se više primjenjuju smjernice za umjetnu inteligenciju. Veliki izazov u zakazivanju liječničkih pregleda je nedolazak. Taj je izazov posebno

problematičan u nuklearnoj medicini zbog dostupnosti, raspadanja i troškova radiofarmaka. Istraživanje iz opće bolnice Massachusetts(14) je pokazalo da izvedivost predviđanja nedolaska na odjel za snimanje moguće pomoću relativno jednostavnih algoritama strojnog učenja i regresije. Korišteno je 16 podatkovnih elemenata iz medicinske elektroničke evidencije grupirane prema povijesti nedolaska, faktorima specifičnim za dogovoreni dolazak te sociodemografske čimbenike. Model je imao veliki stupanj predviđanja nedolaska na zakazani radiološki pregled. Pretpostavlja se da će ručno istraživanje podataka o pacijentu obavljati umjetni inteligentni asistenti i prezentirati ga liječniku u obliku sažetih ploča za pojedine slučajeve te obogatiti informacije sa dodatnim objašnjenjem. U nuklearnoj medicini atenuacijske mape i korekcije raspršenja za PET i SPECT snimanja predmeti su intenzivnog istraživanja umjetne inteligencije. Sljedeća tema istraživanja se odnosi na poboljšanje kvalitete slike. Poboljšanje u rekonstrukciji kvalitete slike također može smanjiti dozu zračenja. Kao rezultat dolazi do kraćeg vremena akvizicije i rezultira većim protokom pacijenata.(14,15)


5.3. Primjena UI u hepatologiji i gastroenterologiji

Umjetna inteligencija dobiva sve veću pažnju u dijagnozi, liječenju i prognozi različitih bolesti u području gastroenterologije i hepatologije. Razlog tome je heterogena razina stručnosti liječnika, dugotrajni postupci i velika opterećenost liječnika. Liječnici procjenjuju radiološke slike kako bi otkrili i dijagnosticirali bolest na temelju stečenog znanja i osobnog iskustva, no taj oblik troši mnogo vremena. Kao najprikladniji pristup za analizu radioloških slika se koriste modeli dubokog učenja. Oni ne zahtijevaju oblikovana i označena područja od interesa na slikama kako bi se izvršila selekcija i ekstrakcija značajki.(16)

5.3.1. Umjetna inteligencija kod bolesti jetre


Umjetna inteligencija se može primijeniti na slike ultrazvuka abdomena za procjenu bolesti jetre. Razvijaju se potporni vektorski strojevi za otkrivanje i klasifikaciju kronične bolesti jetre na temelju ultrazvuka. Taj model ima jako dobre rezultate, odnosno točnost, specifičnost i osjetljivost preko 85% što poboljšava dijagnostiku i klasifikaciju kronične bolesti jetre. Konvolucijske neuronske mreže služe za identificiranje i izoliranje područja različite gustoće pod ultrazvukom kako bi se istražio utjecaj na dijagnozu kronične bolesti jetre. Algoritam otkrivanja povećao je točnost na 95% nakon što je isključio nepouzdana područja. Otkrivanje i klasificiranje lezija, odnosno benignih ili malignih jetrenih masa je također važno. Schmauch i suradnici(16) konstruirali su model dubokog učenja za otkrivanje i karakterizaciju lezija. Rezultirajući algoritam je imao visoku krivulju točnosti u otkrivanju lezija. Iako model može povećati dijagnostičku točnost i otkriti potencijalne lezije na jetri, treba se još dodatno potvrditi i ustanoviti njegovu sigurnost. Bolesti jetre su često neodređeno karakterizirane na CT abdomena.

Konstruiran je model konvolucijske neuronske mreže za dijagnozu pacijenata sa fibrozom jetre. Sustav je imao visoku točnost u klasifikaciji stadija fibroze jetre od 80%, a veliki postotak koji nije bio potpuno točan sustav je napravio grešku unutar jedne faze razlike od stadija fibroze. Za pacijente kojima je dijagnosticiran tumor jetre, ključno je napraviti segmentaciju kako bi se procijenile lezije i izradio idealan plan liječenja. Predložen tip segmentacije se sastoji od 3 glavna koraka. Prvo se primjenjuje za segmentaciju jetre (Slika 9.) pa onda za segmentaciju jetrene lezije (Slika 10.). Prvi korak koristi predobradu slike, pojačavanje kontrasta te filtriranje podataka koji se primjenjuju na skupovima podataka za segmentaciju jetre i tumora. U drugom koraku se izrađuje i trenira jedna mreža za segmentaciju jetre, a druga mreža za segmentiranje lezije unutar područja od interesa jetre. U trećem koraku se primjenjuje daljnje poboljšanje kako bi se dobila konačna segmentacija jetre i lezija. Dobiveni sustav ima vrlo visoku točnost segmentacije jetre, a nešto manju točnost za segmentaciju lezija(17).



Slika 9. Segmentacija jetre od ostalih struktura.

Izvor: Alirri OI. Deep learning and level set approach for liver and tumor segmentation from CT scans. J Appl Clin Med Phys. 10. kolovoz 2020.;21(10):200–9.



Slika 10. Segmentacija mogućih lezija unutar jetre.


Izvor: Alirri OI. Deep learning and level set approach for liver and tumor segmentation from CT scans. J Appl Clin Med Phys. 10. kolovoz 2020.;21(10):200–9.

Umjetna inteligencija se može koristiti i za segmentaciju jetrenih krvnih žila. Segmentacija krvnih žila se provodi postupcima poboljšavanja i pojačavanja konture krvnih žila te postupcima strojnog učenja. Poboljšavanje konture krvnih žila se provodi poboljšanjem kontrasta krvnih žila te njihovim olakšavanjem da se izdvoje sa slike. Nakon toga se provodi naknadna obrada u kojoj se smanjuje šum i smanjuju artefakti koji ne odgovaraju krvnim žilama. Povezuju se odjeljci na krvnim žilama koji su nepotpuni na slici kao rezultat izvršene njihove segmentacije. Dvije skupine metoda strojnog učenja se može koristiti. Nadzirano učenje i nenadzirano učenje. Nadzirano učenje koristi skup podataka koji sadrži točne i očekivane odgovore. Za segmentaciju, to su spremni referentni primjeri koji se pružaju neuronskoj mreži za njeno učenje i osposobljavanje. Kod nenadgledanog učenja ne daju se primjeri i odgovori, već samo skup podataka. Pristup nenadgledanog učenja je koristan ako javni skupovi podataka koji uključuju segmentaciju nisu dostupni ili ako se takvi podatci uopće

ne koriste. Obje skupine koriste konvolucijske neuronske mreže kako bi vršile segmentaciju krvnih žila. Metode nadziranog učenja imaju bolje rezultate u segmentaciji od nenadziranog ako je skup podataka na kojem uče točno segmentiran.(16–18)

5.3.2 Umjetna inteligencija kod bolesti gušterače

Umjetne neuronske mreže se mogu koristiti kod osoba sa karcinomom gušterače u svrhu segmentacije i procjene lezija. Segmentacija gušterače je izazovan zadatak kod analize radiološke slike zbog loše kontrastnosti i nejasnih granica. Također postoje razlike u teksturi, položaju, obliku i veličini gušterače što dodatno otežava njenu procjenu. Konvolucijske neuronske mreže otvaraju mogućnost bolje segmentacije i razlikovanja kanceroznog tkiva od nekanceroznog tkiva gušterače (Slika 11.). Sve radiološke slike radiolozi ručno označuju kako bi se neuronska mreža mogla trenirati i provjeriti. Kao regija od interesa se uzima cijela gušterača zajedno s tumorskim tkivom. Parametri snimanja također moraju biti što sličniji mogu radi ispravnijeg i boljeg treniranja mreže. Konvolucijska mreža je rezultirala relativnom visokom preciznošću. Iako postoji velika mogućnost primjene umjetnih neuronskih mreža za pomoć pri dijagnosticiranju bolesti gušterače, to područje nije još dovoljno istraženo.(19,20)



Slika 11. Segmentacija gušterače i predviđanje lokacije tumora modelom konvolucijske mreže


Izvor: Liu K-L, Wu T, Chen P-T, Tsai YM, Roth H, Wu M-S, i ostali. Deep learning to distinguish pancreatic cancer tissue from non-cancerous pancreatic tissue: a retrospective study with cross-racial external validation. Lancet Digit Health. 01. lipanj 2020.;2(6):e303–13.

5.4. Primjena UI u kardiovaskularnoj radiologiji

Strojno učenje nudi velike mogućnosti za pojednostavljenje i poboljšanje kliničke njege za kardiovaskularne radiologe i pacijente. Europsko društvo za kardiovaskularnu radiologiju su posvećeni unapređenju kardiovaskularne radiologije te položaju upotrebe strojnog učenja u snimanju kardiovaskularnog sustava. Pružaju smjernice o zahtjevima za uspješan razvoj i primjenu strojnog učenja, daju preporuke kako najbolje dizajnirati studiju strojnog učenja te kako se izvještavaju i tumače njihovi rezultati.(11)

Primjena umjetne inteligencije u kardiovaskularnoj radiologiji se može klasificirati u 5 kategorija: akviziciju slike i predobradu, detekciju, segmentaciju, dijagnozu te za predviđanje. Konvolucijska neuronska mreža se može koristiti za smanjenje šuma na slikama CT angiografije te u poboljšanju kvalitete same slike. To izvodi tehnikom obnove slike temeljenom na dubokom učenju. Tehnika također može omogućiti i doprinijeti smanjenju izloženosti zračenju. Neuronske mreže mogu služiti za detekciju i identifikaciju srčanih pacemakera i defibrilatora na radiografskim snimkama prsnog koša. Detekciju i identifikaciju čine s velikom točnošću te također mogu klasificirati i određene modele uređaja.

Kao primjer za analizu i dijagnozu, konstruirana je i testirana konvolucijska neuronska mreža za automatsko bodovanje kalcija na CT-u bez kontrasta (Slika 12.). Istraživanje je pokazalo da daje vrlo uspješne rezultate za koronarne arterije i prsnu aortu, nešto lošije rezultate za aortni zalistak te najslabije rezultate za kalcifikacije mitralnog zaliska. Umjetne neuronske mreže se mogu koristiti za predviđanje značajnih hemodinamskih stenoza koronarnih arterija.(11,21,22)



Slika 12. Otkrivanje i kvantificiranje kalcifikata na CT-u bez kontrasta.

Izvor: Weikert T, Francone M, Abbara S, Baessler B, Choi BW, Gutberlet M, i ostali. Machine learning in cardiovascular radiology: ESCR position statement on design requirements, quality assessment, current applications, opportunities, and challenges. Eur Radiol. 2021.;31(6):3909–22.


Korištenje umjetne inteligencije u kardiovaskularnoj radiologiji daje mogućnost da se izbjegnu bespotrebne dodatne slikovne metode, mogućnost smanjenja doze zračenja te omogućava pomoć radiologu u interpretaciji nalaza. S druge strane, metode umjetne inteligencije se suočavaju s specifičnim izazovima u kardiovaskularnoj radiologiji. Problemi se javljaju zbog osobitosti podataka povezanih sa zdravljem, raspršenosti kod pohrane podataka te problema sa privatnošću podataka.(11)

6. RAČUNALNO POTPOMOGNUTA DETEKCIJA

CAD se odnosi na računalni program za prepoznavanje uzoraka koji prepoznaje sumnjive značajke na slici i dovodi pozornosti radiologa kako bi se smanjilo lažno negativna očitavanja. Radiolog prvo pregledava sliku, zatim aktivira CAD softver i ponovno procjenjuje područja koja su označena CAD-om prije iznošenja konačne odluke. Brojne studije su pokazale da se radiografske abnormalnosti ne detektiraju na slikama unatoč njihovoj prisutnosti. Problem se rješava tako što se selektivno koriste strategije poput dvostrukog očitavanja (najčešće kod probirne mamografije) koje pridonose povećanje stopa otkrivanja raka. Vrlo je radno intenzivno i stoga se ne koristi široko. Cilj CAD sustava je smanjiti i spriječiti lažno negativne nalaze odnosno povećati otkrivanje bolesti zbog propusta u opažanju. Prednost korištenja računala je što ne povećava zahtjeve odnosno opterećenost radiologa. CAD algoritmi su napravljeni da traže iste značajke koje radiolog traži tijekom pregleda slučaja. CAD sustavi su većinom podijeljeni na obradu slike, izdvajanje regije od interesa, izdvajanje značajki regije od interesa te klasifikaciju bolesti prema značajkama. Metode umjetne inteligencije uključuju plitko učenje i duboko učenje. Plitke metode učenja se koriste kao klasifikatori za otkrivanje bolesti, no njihov učinak ovisi o ručno izrađenim značajkama. (23,24)

6.1. Primjena CAD-a kod mamografije

Kod karcinoma dojke na mamografima, algoritmi traže mikrokalCIFIKATE, mase te asimetrije. CAD na mamografima označava sumnjiva područja za daljnju evaluaciju radiologa (Slika 13.). Najčešći algoritmi za prepoznavanje područje od interesa su metode temeljene na pikselima i regijama. Iako se metode razlikuju u različitim sistema, procjena CAD-a obuhvaća slične korake. Prvi korak je odvajanje regije dojke od okolnih regija nakon čega slijedi obrada koja pojačava kontrast između sumnjivog i normalnog tkiva. Nakon toga se izdvajaju značajke poput oblika i veličine lezije te se koriste kao ulaz za razlikovanje sumnjivih i nesumnjivih nalaza. CAD sistemi pružaju mogućnost podešavanja pragova osjetljivosti i specifičnosti, a s time regulira broj lažno pozitivnih nalaza. Postavka visoke osjetljivosti rezultira s većim lažno pozitivnim navođenjem i nižom specifičnošću. U mamografiji, CAD ima veću osjetljivost na karcinome *in situ* u usporedbi s invazivnim karcinomima. Različite mamografske karakteristike tumora pokazuju da CAD bolje otkriva mikrokalCIFIKATE od mamografskih masa. (25,26)



Slika 13. Korištenje CAD sustava kod probirne mamografije.


Izvor: Brem RF, Baum J, Lechner M, Kaplan S, Souders S, Naul LG, i ostali. Improvement in Sensitivity of Screening Mammography with Computer-Aided Detection: A Multiinstitutional Trial. *Am J Roentgenol.* 01. rujan 2003.;181(3):687–93.

6.2. Primjena CAD-a kod radiografije prsnog koša

Radiografija prsnog koša ima važnu kliničku vrijednost u dijagnozi bolesti s obzirom da je jedna od najčešćih pregleda u medicinskoj praksi. Radiografija prsnog koša sadrži veliku količinu informacija o pacijentovom zdravlju, no ispravno interpretiranje informacija je glavni izazov za radiologe. Razvoj umjetne inteligencije u kombinaciji sa gomilanjem velike količine medicinskih slika otvara nove mogućnosti za izgradnju CAD sustava. Preklapanje tkivnih struktura na rendgenu prsnog koša povećava složenost interpretacije. Otkrivanje lezije je izazovno kada je kontrast između okolnog tkiva i lezije nizak ili kada je lezija prekrivena primjerice rebrima ili velikim krvnim žilama. Stoga će na rendgenu prsnog koša postojati određen stupanj propuštenog otkrivanja plućnih bolesti. Široka primjena rendgena prsnog koša i kompleksnost očitavanja čine CAD sustave temom istraživanja. Sustav može pomoći liječnicima u otkrivanju propuštenih sumnjivih lezija čime se poboljšava točnost njihova otkrivanja.

Za složene rendgenske snimke prsnog koša potrebno je dugo vremena da se pronađe dobar skup značajki koje će biti korisne za izvođenje CAD-a. Duboko učenje uglavnom zamjenjuje postupak izvlačenja značajki i klasifikacije bolesti od tradicionalnih CAD sustava. Zbog opsežne i uspješne primjene dubokog učenja pri zadatcima prepoznavanja slike, potaknut je interes za većom primjenom dubokog učenja na medicinske slike. Treniranje, provjera

valjanosti, testiranje te usporedba učinka CAD sustava zahtijevaju mnoge radiografije prsnog koša. Neke od najčešćih vrsta bolesti na radiografiji prsnog koša su infiltracije, atelektaze, hipertrofija srca, izljevi, čvorići, pneumonia te pneumotoraks.(24) CAD sustavi obično uzimaju ulazne slike za niz koraka obrade. Glavna svrha obrade je povećati kvalitetu slike i napraviti regiju od interesa jasnom. Tipične tehnike koje se koriste uključuju povećanje kvalitete slike, segmentaciju slike te supresiju kostiju za specifične primjene kod snimaka prsnog koša. Povećanje kvalitete slike uključuje pojačavanje kontrasta, smanjenje šuma, izoštravanje rubova te filtriranje. Pojačavanje kontrasta je postupak povećanja raspona vrijednosti svjetline, koji poboljšava ukupni ili lokalni kontrast slike i čini je jasnom. Smanjenje šuma je postupak u kojem se na slici smanjuje šum dok se istovremeno očuvaju detalji slike. Oštrenje slike nadoknađuje konturu slike, poboljšava rubove slike i dio sive skale, odnosno poboljšava informacije o detaljima slike. Također kod poboljšanja slike filtriranje se može koristiti. Može se provesti u stvarnoj ili frekvencionalnoj domeni. Zbog različitih zadataka u radiografiji prsnog koša postoji mnogo različitih vrsta segmentacije. Neke od segmentacija su segmentacija plućnog polja, detektiranje kontura plućnih polja ili rebara, detektiranje dijafragme ili frenikokostalnih sinusa. Segmentacija plućnog polja ne najbitnija jer točno određuje regiju od interesa. Supresija kostiju je jedinstvena tehnika obrade i važan je korak obrade u segmentaciji pluća i izvlačenju značajki. Rebra i ključna kost mogu blokirati abnormalnosti na radiogramu pluća što komplicira fazu izvlačenja značajki CAD sustava. Zbog toga postoji potreba uklanjanja koštanih struktura kako bi se povećala vidljivost gustoće mekih tkiva. Korištenje CAD sustava kod radiografije prsnog koša uvelike pomaže u detekciji abnormalnosti na slikama (Slika 14.)



Slika 14. CAD sustav označuje regije od interesa sa mogućim malignitetom na radiografiji prsnog koša.


Izvor: de Hoop B, De Boo DW, Gietema HA, van Hoorn F, Mearadji B, Schijf L, i ostali. Computer-aided Detection of Lung Cancer on Chest Radiographs: Effect on Observer Performance. Radiology. 01. studeni 2010.;257(2):532–40.

Zbog sve veće količine podataka te bolje računalne opreme sve se više ulaže u duboke neuronske mreže jer daju odlične rezultate. Dok standardni CAD sustavi mogu detektirati većinom jednu abnormalnost ili bolest, oni sustavi koji su konstruirani prema dubokim mrežama mogu više i kvalitetnije detektirati određene značajke.(24,27)

6.3. Primjena CAD-a kod višeparametarskog MR snimanja

CAD sustavi se razvijaju za precizno i automatizirano otkrivanje i dijagnosticiranje karcinoma prostate, no ipak je dijagnostička točnost različitih CAD sustava temeljenih na magnetskoj rezonanciji sporna. U posljednjem desetljeću višeparametarsko MR snimanje postaje dominantni dijagnostički alat za dijagnosticiranje i ocjenjivanje karcinoma prostate. Jedno od glavnih ograničenja višeparametarskog MR snimanja je da interpretacija zahtjeva iskusne radiologe sposobne da analiziraju podatke iz različitih MR sekvenci. To dovodi do varijabilnosti dijagnoze između interpretatora slike. Automatizacija i precizno otkrivanje karcinoma prostate iz multiparametarskih MR sekvenci je potrebno za minimaliziranjem vremena očitavanja, smanjenje rizika za nedovoljno ili prekomjerno liječenje te omogućavanja velikog probira za karcinom. Mnogo je napora uloženo u kvantitativnu analizu višeparametarskih MR podataka te na vezu između mjerljivih karakteristika i detekciju bolesti. Prvi CAD sustavi su bili koncentrirani na specifična područja prostate i to uglavnom na perifernu zonu, dok se noviji sustavi orijentiraju na procjenu cijele prostate. Za automatiziranu procjenu zloćudnosti softver izračunava vrijednost predviđanja zloćudnosti u pikselu, definiranu kao indeks prikaza malignosti (MAI) iz podataka sadržanih na slikama T2W, DWI i DCE. Za izračun je nekoliko osnovnih slikovnih značajki povezanih sa karcinomom prostate kvantificirano i uspoređeno sa unaprijed definiranim razinama predviđanja. Algoritam predviđanja zloćudnosti zatim obrađuje kvantificirane parametre koji daju pojedinačnu prediktivnu vrijednost za svaki slikovni piksel koji smanjuje ukupnu razinu nesigurnosti vrijednosti. MAI ima raspon od 0 do 1, gdje 0 ukazuje na najnižu razinu predviđene malignosti, a 1 na najvišu razinu. Budući da je MAI izračunat za svaki slikovni piksel mogao bi se preslikavat na MR slike kako bi se pokazali odnosi sa anatomijom prostate.(28)

Automatizirana analiza se provodi u tri koraka. Prvi korak je zajednička registracija DWI i DCE sa slikama T2W. Zajednička registracija je nužna kako bi se omogućila točna prostorna korelacija značajki iz različitih skupova slika. Drugi korak je računanje osnovnih funkcionalnih parametara. Osnovni funkcijski parametri izračunatih iz podataka slike za DWI je vrijednost prividnog koeficijenta difuzije (ADC) na temelju piksela. Za DCE je skup farmakokinetičkih parametara te normalizirani T2W podatci koji se generiraju koristeći pravokutni računski volumen od interesa koji što bliže obuhvaća prostatu. Zadnji korak uključuje predviđanje malignosti koje koristi izlaze iz prvog i drugog koraka kao ulaz za računalnu analizu značajke slike i osnovnih funkcionalnih parametara. Kao rezultat se dobije pikselna MAI mapa (Slika 15.). Postoji usporediva dijagnostička točnost za otkrivanje karcinoma prostate pomoću neovisnog automatiziranog alata za analizu MAI te analize višeparametarskih MR snimci ljudskog čitatelja. Alat za analizu bi se mogao koristiti kao sustav potpore za otkrivanje malignoma kod manje iskusnih radiologa. Također postoji budući potencijal računalne analize za napredne procjene lezija, kao što je opseg karcinoma te predviđanje stadija karcinoma.(28,29)



MAI value	Colour
0,1	Dark Blue
0,2	Blue
0,3	Light Blue
0,4	Lighter Blue
0,5	Cyan
0,6	Light Cyan
0,7	Light Green
0,8	Yellow
0,9	Orange
1	Red

Slika 15. Primjer MAI mape na T2W slici.

Izvor: Roethke MC, Kuru TH, Mueller-Wolf MB, Agterhuis E, Edler C, Hohenfellner M, i ostali. Evaluation of an Automated Analysis Tool for Prostate Cancer Prediction Using Multiparametric Magnetic Resonance Imaging. PLOS ONE. 25. srpanj 2016.;11(7):e0159803.

6.4. Procjena CAD sustava

Procjena CAD sustava se može provesti na nekoliko načina. Najčešće se provode procjene osjetljivosti i specifičnosti što uključuje analizu podataka generiranih u laboratoriju ili testnom okruženju te utjecajem CAD-a na rad radiologa u stvarnim uvjetima kliničke prakse. Metoda samostalne osjetljivosti i specifičnosti dobiva informacije na temelju promatranjem CAD sustava na slučajevima koji su dokazani točni. Osjetljivost se određuje postotkom pozitivnih slučajeva u kojima CAD sistem označava mjesto bolesti. Specifičnost se karakterizira brojem lažnih CAD oznaka po normalnoj slici ili slučaju. Rezultati ove metode ovise o prikupljenim slučajevima, odnosno njihovim brojem i težinom interpretacije nalaza. Slučajevi moraju biti nepoznati CAD sistemu, odnosno ne smiju biti korišteni za obuku CAD sistema. Metoda analize podataka generiranih u laboratoriju koriste radiologe da procjenjuju potvrđene slučajeve kako bi se utvrdila osjetljivost i stopa povratne informacije kod interpretiranja nalaza čitača bez pomoć CAD-a sa čitačem koji koristi CAD. Metoda je korisna za procjenu potencijalne koristi CAD sistema i pruža procjenu u otkrivanju bolesti i stopi obrade. Metoda utjecaja CAD-a u stvarnim uvjetima kliničke prakse se na mnogo načina smatra najboljom procjenom sistema jer ocjenjuje doprinos ili njegov nedostatak u kliničkoj praksi. Ti podatci se samo odnose na određenu kliničku praksu, no cjelokupna izvješća iz različitih praksi bi trebala pokazati vrijednosti ili nedostatke CAD-a. Postoje dva načina procjene CAD-a u kliničkom ispitivanju. Prvi oblik je sekvencionalno čitanje u kojem se nalaz prvo interpretira, a zatim slijedi unos CAD-a. Važno je da se poveća postotak otkrivanja bolesti te smanji lošu interpretaciju. Drugi pristup ispitivanju je putem povijesne kontrole u kojem se postotak promjene u stopi otkrivanja utvrđuje usporedbom podataka prije i nakon uvođenja CAD-a u kliničku praksu.(23)

CAD je klinički dokazana tehnologija koja služi radiolozima za povećanje detekcije abnormalnosti i bolesti. Također može smanjiti napor kod interpretacija radiologa te pomaže kod neiskusnih stručnjaka da se što prije i što sigurnije nauče interpretirati nalaze. Izgradnja velikih baza te napredak neuronskih mreža i dubokog učenja čine da algoritam sve više nadilazi medicinske stručnjake u interpretaciji raznih slikovnih zadataka. To uključuje dijagnozu pneumonije, dijabetičke retinopatije, klasifikaciju karcinoma kože, otkrivanje popipa i masa kolonoskopijom, aritmije, identifikacija krvarenja... CAD će se definitivno poboljšavati tijekom godina te postati pouzdani softver za otkrivanje, a kasnije najvjerojatnije i dijagnostiku bolesti.(24)

ZAKLJUČAK

Umjetna inteligencija se pokazala da ima visoku korisnost u radiologiji te još veći potencijal u budućnosti. Ekspertni sustavi se nisu pokazali da imaju veliku aktivnu ulogu kod radiologije jer se pokazalo da se ne isplati ugrađivati takve sustave zbog ne efikasnosti i. Višeslojne umjetne neuronske mreže imaju svoju korist u radiologiji. Pošto se mogu koristiti u svrhu klasifikacije, imaju mnogo mjesta primjene. Kao primjer korištenja tradicionalnih metoda umjetne inteligencije imaju visoku primjenu kod potpomognute računalne detekcije u mamografiji. Iako za otkrivanje tumorskih masa nije najprikladnija metoda, za otkrivanje mikrokalcfikata je odlučna metoda jer ima višu stopu točnosti kod detekcije od radiologa. Iako tradicionalne metode umjetnih neuronskih mreža imaju veliku primjenu u radiologiji, sve ih više zamjenjuju metode dubokog učenja poput konvolucijskih neuronskih mreža. Te vrste neuronskih mreža bolje su od tradicionalnih jer ne zahtijevaju unaprijed definirane značajke već oni sami uče iz dobivenih podataka. Na temelju ispitivanja razlika između tradicionalnih mreža i konvolucijskih neuronskih mreža, konvolucijske neuronske mreže su dale superiornije rezultate u mnogo slučajeva. Taj pristup već ima neke primjene unutar radiologije, no i dalje su takve neuronske mreže još u ispitivanju i istraživanju te je njihova izgradnja teža i skuplja u odnosu na tradicionalne. Metode umjetne inteligencije se isprobavaju i eksperimentiraju u raznim granama medicine gdje je radiologija kao dijagnostika od neizbježne važnosti. U onkologiji se koriste za planiranje radioterapija, smanjenju doza i radiometrije s velikim uspjehom. Kod nuklearne medicine također ima visoku uporabu. Pomaže u otkrivanju rubova na snimkama te kod segmentacije organa. Osim dijagnostičke koristi, služi i za praćenje i smanjenje primijenjene doze zračenja, a pokušava se izgraditi algoritam koji bi poboljšavao kvalitetu slike u nuklearnoj medicini. Svoju primjenu i istraživanje također nalazi u hepatologiji. Uspjeh nalazi u povećanju postotka kod dijagnoze kronične bolesti jetre na ultrazvuku uvođenjem konvolucijske neuronske mreže. Osim toga ima i veliku uspješnost kod klasifikacije stadija fibroze jetre, kod segmentacije jetre i njenih lezija te kod segmentacije jetrenih krvnih žila.

Iako metode umjetne inteligencije daju vrlo dobre rezultate za njihovu primjenu u radiologiji, i dalje nisu dovoljno istražene i provjerene kako bi se moglo reći da su sigurne za primjenu u radiologiji.

LITERATURA

1. Park WJ, Park J-B. History and application of artificial neural networks in dentistry. *Eur J Dent.* listopad 2018.;12(4):594–601.
2. Mišljenčević D, Maršić I. Umjetna inteligencija. Zagreb: Školska knjiga; 1991.
3. Saba T, Al-zahrani S, Rehman A, Abdul S, Ksa A. Expert System for Offline Clinical Guidelines and Treatment.
4. Liebowitz J. *The Handbook of Applied Expert Systems.* CRC Press; 2019. 725 str.
5. Russell SJ, Norvig P. *Artificial intelligence: a modern approach.* Englewood Cliffs, N.J: Prentice Hall; 1995. 932 str. (Prentice Hall series in artificial intelligence).
6. Graupe D. *Principles Of Artificial Neural Networks (3rd Edition).* World Scientific; 2013. 382 str.
7. Yamashita R, Nishio M, Do RKG, Togashi K. Convolutional neural networks: an overview and application in radiology. *Insights Imaging.* 01. kolovoz 2018.;9(4):611–29.
8. Shen D, Wu G, Suk H-I. Deep Learning in Medical Image Analysis. *Annu Rev Biomed Eng.* 21. lipanj 2017.;19:221–48.
9. Lu F, Wu F, Hu P, Peng Z, Kong D. Automatic 3D liver location and segmentation via convolutional neural network and graph cut. *Int J Comput Assist Radiol Surg.* 01. veljača 2017.;12(2):171–82.
10. Hosny A, Parmar C, Quackenbush J, Schwartz LH, Aerts HJWL. Artificial intelligence in radiology. *Nat Rev Cancer.* kolovoz 2018.;18(8):500–10.
11. Weikert T, Francone M, Abbara S, Baessler B, Choi BW, Gutberlet M, i ostali. Machine learning in cardiovascular radiology: ESCR position statement on design requirements, quality assessment, current applications, opportunities, and challenges. *Eur Radiol.* 2021.;31(6):3909–22.
12. Yasaka K, Abe O. Deep learning and artificial intelligence in radiology: Current applications and future directions. *PLOS Med.* 30. studeni 2018.;15(11):e1002707.
13. Kocher M. Artificial intelligence and radiomics for radiation oncology. *Strahlenther Onkol.* 2020.;196(10):847.
14. Nensa F, Demircioglu A, Rischpler C. Artificial Intelligence in Nuclear Medicine. *J Nucl Med.* 01. rujan 2019.;60(Supplement 2):29S-37S.
15. Hall M. Artificial intelligence and nuclear medicine. *Nucl Med Commun.* siječanj 2019.;40(1):1–2.
16. Cao J-S, Lu Z-Y, Chen M-Y, Zhang B, Juengpanich S, Hu J-H, i ostali. Artificial intelligence in gastroenterology and hepatology: Status and challenges. *World J Gastroenterol.* 28. travanj 2021.;27(16):1664–90.

17. Alirri OI. Deep learning and level set approach for liver and tumor segmentation from CT scans. *J Appl Clin Med Phys*. 10. kolovoz 2020.;21(10):200–9.
18. Ciecholewski M, Kassjański M. Computational Methods for Liver Vessel Segmentation in Medical Imaging: A Review. *Sensors*. 12. ožujak 2021.;21(6):2027.
19. Liu K-L, Wu T, Chen P-T, Tsai YM, Roth H, Wu M-S, i ostali. Deep learning to distinguish pancreatic cancer tissue from non-cancerous pancreatic tissue: a retrospective study with cross-racial external validation. *Lancet Digit Health*. 01. lipanj 2020.;2(6):e303–13.
20. Zheng H, Chen Y, Yue X, Ma C, Liu X, Yang P, i ostali. Deep pancreas segmentation with uncertain regions of shadowed sets. *Magn Reson Imaging*. svibanj 2020.;68:45–52.
21. Tatsugami F, Higaki T, Nakamura Y, Yu Z, Zhou J, Lu Y, i ostali. Deep learning-based image restoration algorithm for coronary CT angiography. *Eur Radiol*. listopad 2019.;29(10):5322–9.
22. Lessmann N, van Ginneken B, Zreik M, de Jong PA, de Vos BD, Viergever MA, i ostali. Automatic Calcium Scoring in Low-Dose Chest CT Using Deep Neural Networks With Dilated Convolutions. *IEEE Trans Med Imaging*. veljača 2018.;37(2):615–25.
23. Castellino RA. Computer aided detection (CAD): an overview. *Cancer Imaging*. 23. kolovoz 2005.;5(1):17–9.
24. Qin C, Yao D, Shi Y, Song Z. Computer-aided detection in chest radiography based on artificial intelligence: a survey. *Biomed Eng OnLine*. 22. kolovoz 2018.;17(1):113.
25. Henriksen EL, Carlsen JF, Vejborg IM, Nielsen MB, Lauridsen CA. The efficacy of using computer-aided detection (CAD) for detection of breast cancer in mammography screening: a systematic review. *Acta Radiol*. 01. siječanj 2019.;60(1):13–8.
26. Lee RS, Gimenez F, Hoogi A, Miyake KK, Gorovoy M, Rubin DL. A curated mammography data set for use in computer-aided detection and diagnosis research. *Sci Data*. 19. prosinac 2017.;4(1):170177.
27. Soleymanpour E, Pourreza HR, ansaripour E, Yazdi MS. Fully Automatic Lung Segmentation and Rib Suppression Methods to Improve Nodule Detection in Chest Radiographs. *J Med Signals Sens*. 2011.;1(3):191–9.
28. Roethke MC, Kuru TH, Mueller-Wolf MB, Agterhuis E, Edler C, Hohenfellner M, i ostali. Evaluation of an Automated Analysis Tool for Prostate Cancer Prediction Using Multiparametric Magnetic Resonance Imaging. *PLOS ONE*. 25. srpanj 2016.;11(7):e0159803.
29. Liang F, Li M, Yao L, Wang X, Liu J, Li H, i ostali. Computer-aided detection for prostate cancer diagnosis based on magnetic resonance imaging. *Medicine (Baltimore)* [Internet]. 19. srpanj 2019. [citirano 16. lipanj 2021.];98(29). Dostupno na: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6708830/>

PRIVITCI

Privitak A: Popis ilustracija

Slike

Slika 1. Osnovna struktura građe ekspertnog sustava	8
Slika 2. Jednostavan primjer ekspertnog sustava koji koristi ulančavanje unaprijed	11
Slika 3. Višeslojna unaprijedna umjetna neuronska mreža konfiguracije 2x3x3x2	12
Slika 4. Izgled i građa TLU perceptrona	15
Slika 5. Primjer mogućeg izgleda decizijske granice	16
Slika 6. Računanje vrijednosti kernela i tenzora te postavljanje dobivene vrijednosti u mapu značajki	18
Slika 7. Maksimalno sažimanje koji primjenjuje filter veličine 2x2 i umanjuje dimenziju mape	19
Slika 8. Učenje i klasifikacija konvolucijske neuronske mreže kod benignih ili malignih lezija na CT slikama	20
Slika 9. Segmentacija jetre od ostalih struktura	28
Slika 10. Segmentacija mogućih lezija unutar jetre	28
Slika 11. Segmentacija gušterače i predviđanje lokacije tumora modelom konvolucijske mreže	29
Slika 12. Otkrivanje i kvantificiranje kalcifikata na CT-u bez kontrasta	30
Slika 13. Korištenje CAD sustava kod probirne mamografije	33
Slika 14. CAD sustav označuje regije od interesa sa mogućim malignitetom na radiografiji prsnog koša	34
Slika 15. Primjer MAI mape na T2W slici	36

KRATAK ŽIVOTOPIS

Zovem se Dejan Ivanišević, rođen u Slavonskom Brodu 12.7.1998. godine. Išao sam u Osnovnu školu Dragutin Tadijanović Slavonski Brod te Srednju medicinsku školu Slavonski Brod smjer medicinski tehničar opće njege. Preddiplomski stručni studij radiološke tehnologije na Fakultetu zdravstvenih studija u Rijeci sam upisao 2018./2019. akademske godine. U studentskom zboru Fakulteta zdravstvenih studija sam bio zamjenik predstavnika preddiplomskog stručnog studija radiološke tehnologije. Također sam odradio 9 sati volonterskog rada u KBC-u Rijeka tijekom pandemije COVID-19.

