

Uloga umjetne inteligencije u optimizaciji doze zračenja kod kompjuterizirane tomografije (CT)

Marasović, Mate

Master's thesis / Diplomski rad

2022

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Split / Sveučilište u Splitu**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:176:536712>

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

Download date / Datum preuzimanja: **2024-11-25**

Repository / Repozitorij:



Sveučilišni odjel zdravstvenih studija
SVEUČILIŠTE U SPLITU

[Repository of the University Department for Health Studies, University of Split](#)



UNIVERSITY OF SPLIT



SVEUČILIŠTE U SPLITU

Podružnica

SVEUČILIŠNI ODJEL ZDRAVSTVENIH STUDIJA

DIPLOMSKI SVEUČILIŠNI STUDIJ

RADIOLOŠKA TEHNOLOGIJA

MATE MARASOVIĆ

**ULOGA UMJETNE INTELIGENCIJE U
OPTIMIZACIJI DOZE ZRAČENJA KOD
KOMPJUTERIZIRANE TOMOGRAFIJE (CT)**

DIPLOMSKI RAD

Split, 2022.

SVEUČILIŠTE U SPLITU

Podružnica

SVEUČILIŠNI ODJEL ZDRAVSTVENIH STUDIJA

DIPLOMSKI SVEUČILIŠNI STUDIJ

RADIOLOŠKA TEHNOLOGIJA

MATE MARASOVIĆ

**ULOGA UMJETNE INTELIGENCIJE U OPTIMIZACIJI
DOZE ZRAČENJA KOD KOMPJUTERIZIRANE
TOMOGRAFIJE (CT)**

**THE ROLE OF ARTIFICIAL INTELLIGENCE IN
RADIATION DOSE OPTIMIZATION IN
COMPUTERIZED TOMOGRAPHY (CT)**

Diplomski rad/Master's Thesis

Mentor:

Prof. dr .sc. Tade Tadić, dr. med.

Split, 2022.

SADRŽAJ

1. UVOD	1
2. CILJ RADA.....	2
3. IZVORI PODATAKA I METODE	3
4. RASPRAVA	4
4.1. VRSTE UMJETNE INTELIGENCIJE	4
4.1.1. Strojno učenje (machine learning)	4
4.1.1.1 Nadzirano učenje	5
4.1.1.2 Učenje bez nadzora	6
4.1.2. Duboko učenje (Deep learning) i umjetne neuronske mreže (ANN)	6
4.1.3. Primjena umjetne inteligencije u radiologiji.....	8
4.1.3.1 Primjena CAD-a u radiologiji.....	12
4.2. CT I DOZA ZRAČENJA	13
4.2.1 Strategija optimizacije CT doze zračenja.....	16
4.3. PRIMJENA UMJETNE INTELIGENCIJE U OPTIMIZACIJI CT DOZE ZRAČENJA	18
4.3.1. Pozicioniranje pacijenta.....	19
4.3.1.1 Usporedba između ručnog i automatskog pozicioniranja temeljenog na umjetnoj inteligenciji na CT-u kod COVID-19 pozitivnih pacijenata	21
4.3.2. Raspon skeniranja	26
4.3.3. Odabir parametara akvizicije.....	27
4.3.4. Smanjenje doze zračenja na ct-u pomoću rekonstrukcija temeljenih na dubokom učenju (deep learning based reconstruction-DLR)	28
4.3.4.1 Smanjenje doze zračenja na CT-u pomoću rekonstrukcije temeljene na dubokom učenju (DLR): studija na fantomu	32
4.4. KORIŠTENJE UMJETNE INTELIGENCIJE U OPTIMIZACIJI DOZE NA „LOW DOSE“ CT-u	34
4.4.1. Pristupi metode „deep learning“ u kompjuteriziranoj tomografiji niskim dozama (LDCT).....	36
5. ZAKLJUČAK	41
6. LITERATURA	43
7. POPIS KRATICA	46
8. ŽIVOTOPIS	47

TEMELJNA DOKUMENTACIJSKA KARTICA

DIPLOMSKI RAD

Sveučilište u Splitu
Sveučilišni odjel zdravstvenih studija
Radiološka tehnologija

Znanstveno područje: Biomedicina i zdravstvo
Znanstveno polje: Kliničke medicinske znanosti

Mentor: prof. dr. sc. Tade Tadić

ULOGA UMJETNE INTELIGENCIJE U OPTIMIZACIJI DOZE ZRAČENJA KOD KOMPJUTERIZIRANE TOMOGRAFIJE (CT)

Mate Marasović, 66177

SAŽETAK

Područje umjetne inteligencije (UI) transformira gotovo svaki aspekt modernog društva, uključujući i medicinsku radiologiju. U kompjuteriziranoj tomografiji (CT), primjena umjetne inteligencije omogućuje daljnje smanjenje doze zračenja pacijenata kroz automatizaciju i optimizaciju procesa prikupljanja podataka, uključujući pozicioniranje pacijenta i postavke parametara akvizicije. Nakon prikupljanja podataka, optimizacija parametara rekonstrukcije slike, napredni algoritmi rekonstrukcije i metode uklanjanja šuma slike poboljšavaju nekoliko aspekata kvalitete slike, posebno u smanjenju šuma slike te omogućavanju korištenja nižih doza zračenja tijekom akvizicije. Ukratko, od uvođenja CT-a, veliki broj tehničkih poboljšanja omogućio je unapređenje dijagnostičke informacije i smanjenje rizika za pacijente, ne samo smanjenjem doze zračenja, već i smanjenjem vjerojatnosti pogrešaka u izvedbi i medicinskoj interpretaciji CT pretraga.

U ovom radu prikazana je važnost primjene novih algoritama umjetne inteligencije koji imaju važnu ulogu u poboljšanju kvalitete dijagnostičke informacije uz najnižu moguću dozu za pacijente.

Ključne riječi: Umjetna inteligencija, duboko učenje, kompjuterizirana tomografija, optimizacija doze, doza zračenja

Rad sadrži: 47 stranica, 12 slika, 27 literaturnih referenca
Jezik izvornika: hrvatski

BASIC DOCUMENTATION CARD

MASTER THESIS

University of Split
University Department for Health Studies
Radiological technology

Scientific area: Biomedicine and health care

Scientific field: Clinical medical sciences

Supervisor: prof. dr. sc. Tade Tadić

THE ROLE OF ARTIFICIAL INTELLIGENCE IN RADIATION DOSE OPTIMIZATION IN COMPUTERIZED TOMOGRAPHY (CT)

Mate Marasović, 66177

SUMMARY

The field of artificial intelligence (AI) is transforming almost every aspect of modern society, including medical radiology. In computed tomography (CT), the application of artificial intelligence allows further reduction of patient radiation dose through automation and optimization of data collection processes, including patient positioning and acquisition parameter settings. After data collection, image reconstruction parameter optimization, advanced reconstruction algorithms, and image noise removal methods improve several aspects of image quality, especially in reducing image noise, and allow the use of lower radiation doses during acquisition. In short, since the introduction of CT, a number of technical improvements have made it possible to improve diagnostic information and reduce risks for patients, not only reducing radiation doses but also reducing the likelihood of errors in the performance and medical interpretation of CT scans.

This paper presents the importance of applying new artificial intelligence algorithms that play an important role in improving the quality of diagnostic information at the lowest possible dose for patients.

Keywords: Artificial intelligence, Deep learning, X-ray computed tomography, dose optimization, patient dose

Thesis contains: 47 pages, 12 figures, 27 references

Original in: Croatian

1. UVOD

Umjetna inteligencija (UI) je opći pojam koji podrazumijeva korištenje računala za modeliranje inteligentnog ponašanja uz minimalnu ljudsku intervenciju. Općenito je prihvaćeno da je umjetna inteligencija započela s izumom robota. Zahvaljujući brzom napretku u računalnoj znanosti i informatici, umjetna inteligencija brzo je postala sastavni dio moderne zdravstvene skrbi. Algoritmi umjetne inteligencije i druge aplikacije koje pokreće UI koriste se za podršku medicinskim stručnjacima u kliničkoj praksi i istraživanjima.

Kompjuterizirana tomografija (CT) podrazumijeva kompjuterizirani postupak rendgenskog snimanja u kojem se uski snop rendgenskih zraka usmjerava na pacijenta i brzo se rotira oko tijela, proizvodeći signale koje računalo obrađuje kako bi se generirale slike poprečnog presjeka. Ti se dobiveni slojevi nazivaju tomografske slike i sadrže detaljnije informacije od konvencionalnih rendgenskih slika. Nakon što računalo prikupi određeni broj uzastopnih slojeva, oni se mogu digitalno "složiti" zajedno kako bi se formirala trodimenzionalna slika pacijenta koja omogućuje lakšu identifikaciju i lociranje osnovnih struktura, kao i mogućih tumora ili abnormalnosti.

Kompjuterizirana tomografija ima široku dijagnostičku primjenu i zlatni je standard snimanja za mnoge kliničke indikacije. Međutim, CT snimanja izlažu pacijente većim dozama zračenja nego druge radiološke metode. Samim time, nosi povećan rizik od indiciranja raka za sve pacijente, posebno za one u rizičnijim kategorijama kao što su pedijatrijski ili onkološki pacijenti koji se redovito izlažu ionizirajućem zračenju.

Primjena kompjuterizirane tomografije brzo se povećala posljednjih desetljeća iz razloga što omogućava vizualizaciju anatomskih struktura visoke prostorne rezolucije. Međutim, sa povećanjem CT skeniranja na godišnjoj razini, izlaganje pacijenata ionizirajućem zračenju postaje sve veći javni problem. Sukladno toj činjenici, raste i interes za smanjenje doze zračenja na CT pregledima.

U ovom radu opisani su algoritmi koji su omogućili poboljšanu kvalitetu slike i veći potencijal za niže doze zračenja.

2. CILJ RADA

Cilj ovoga diplomskog rada bio je pregled dostupne literature vezane uz primjenu umjetne inteligencije u optimizaciji doze zračenja kod pregleda kompjuterizirane tomografije. Zatim, opisati sve veću primjenu umjetne inteligencije u radiologiji naročito u kompjuteriziranoj tomografiji. Nadalje, objasniti važnost algoritama umjetne inteligencije na CT-u koji doprinose redukciji doze zračenja. S obzirom na važnu zadaću radiološkog tehnologa u provođenju mjera zaštite od zračenja, cilj je upoznati radiološke tehnologe s novitetima i načinom primjene algoritama umjetne inteligencije u cilju optimizacije doze zračenja.

3. IZVORI PODATAKA I METODE

Rad je napisan kao sustavni pregled analizom dostupne literature na temu umjetne inteligencije i doze zračenja na CT-u. Sustavno pretraživanje podataka u PubMedu, Medline koristeći ključne riječi *umjetna inteligencija, kompjuterizirana tomografija i optimizacija CT doze* u raznim publikacijama te pregled bibliografije relevantne za ovu temu. Pregled literature uključuje citatne baze PubMed-a, Web of Science-a, i drugih baza podataka. Vremensko razdoblje objave korištenih istraživanja i studija iz medicinskih baza podataka je od 2018 do 2022. god. i obuhvaća osam studija vezanih za temu.

4. RASPRAVA

4.1 VRSTE UMJETNE INTELIGENCIJE

Umjetna inteligencija (UI) je prepoznata kao akademska disciplina sredinom 20. stoljeća, nakon čega su uslijedili ciklusi optimiziranja koji su rezultirali visokim razvojem umjetne inteligencije čiji različiti elementi utječu na gotovo svaki aspekt moderne tehnologije. Velik dio uspjeha ovog područja u posljednjih nekoliko desetljeća može se pripisati napretku u računalnoj tehnologiji, ogromnim digitalnim bazama podataka i usponu računalne infrastrukture, u kombinaciji s poboljšanim razumijevanjem teorijskih aspekata UI i primjenjivih algoritama. UI je široka disciplina koja sadrži niz potpolja, od kojih svako pristupa cjelokupnim zadacima koristeći različite strategije, pri čemu je cjelokupni zadatak razviti hardverske i softverske pristupe pomoću kojih stroj može obavljati kognitivno složene zadatke, uključujući donošenje odluka (1).

Umjetna inteligencija u različitim oblicima i obujmu korištena je za razvoj i unapređenje širokog spektra područja, kao što su bankarstvo i financijska tržišta, obrazovanje, proizvodnja, maloprodaja, e-trgovina te zdravstvo. UI je široka grana računalne znanosti koja se bavi izgradnjom „pametnih strojeva“ sposobnih za obavljanje zadataka koji obično zahtijevaju ljudsku inteligenciju. Smatra se da je pojam UI prvi put skovan 1956. godine kada je američki informatičar John McCarthy organizirao Dartmouthsku konferenciju. Prije toga, rad na području umjetne inteligencije uključivao je Turingov test koji je predložio Alan Turing kao mjeru strojne inteligencije te program za igranje šaha koji je razvio Dietrich Prinz (2).

4.1.1. Strojno učenje (machine learning)

Strojno učenje je vrsta umjetne inteligencije i računalne znanosti koja se fokusira na korištenje podataka i algoritama za oponašanje načina na koji ljudi uče, postupno poboljšavajući točnost ishoda. Algoritmi strojnog učenja grade model na temelju podataka uzorka, kako bi mogli predviđati ili donositi odluke bez izričitog

programiranja za to. Algoritmi strojnog učenja koriste se u raznim aplikacijama na različitim poljima, kao što su medicina, filtriranje e-pošte, prepoznavanje govora i računalni vid, gdje je teško ili neizvedivo razviti konvencionalne algoritme za obavljanje potrebnih zadataka.

Budući da se duboko učenje i strojno učenje obično koriste naizmjenično, važno je napomenuti razlike između njih. Strojno učenje, duboko učenje i neuronske mreže podvrste su umjetne inteligencije. Međutim, duboko učenje je zapravo podvrsta strojnog učenja, a neuronske mreže podvrsta dubokog učenja (3).

Pristupi strojnog učenja tradicionalno su podijeljeni u tri široke kategorije, ovisno o prirodi "signala" ili "povratne informacije" dostupne sustavu učenja.

Kod nadziranog učenja računalo se prikazuje s primjerima ulaza i njihovih željenih izlaza koje daje "učitelj", a cilj je naučiti opće pravilo koje preslikava ulaze na izlaze.

Kod učenja bez nadzora algoritmu učenja se ne daju oznake, ostavljajući mu samom da pronade strukturu u svom ulazu. Učenje bez nadzora može biti samo po sebi cilj (otkrivanje skrivenih obrazaca u podacima) ili sredstvo za postizanje cilja (učenje značajki).

U opciji učenja s pojačanjem računalni program stupa u interakciju s dinamičnim okruženjem u kojem mora izvesti određeni cilj (kao što je vožnja vozila ili igranje igre protiv protivnika). Dok se kreće kroz svoj problemski prostor, program dobiva povratne informacije koje su analogne nagradama, koje pokušava maksimizirati.

4.1.1.1 Nadzirano učenje

Algoritmi nadziranog učenja grade matematički model skupa podataka koji sadrži ulaze i željene izlaze. Podaci su poznati kao podaci obuke i sastoje se od skupa primjera obuke. Svaki primjer obuke ima jedan ili više ulaza i željeni izlaz, također poznat kao nadzorni signal. U matematičkom modelu, svaki primjer obuke predstavljen je nizom ili vektorom, koji se ponekad naziva vektorom značajki, a podaci obuke predstavljeni su matricom. Kroz iterativnu optimizaciju ciljne funkcije, algoritmi nadziranog učenja uče funkciju koja se može koristiti za predviđanje izlaza povezanih s novim ulazima.

Optimalna funkcija omogućit će algoritmu da ispravno odredi izlaz za ulaze koji nisu bili dio podataka obuke. Za algoritam koji poboljšava točnost svojih izlaza ili predviđanja tijekom vremena kaže se da je naučio izvršiti taj zadatak. Vrste algoritama nadziranog učenja uključuju aktivno učenje, klasifikaciju i regresiju. Klasifikacijski algoritmi se koriste kada su izlazi ograničeni na ograničeni skup vrijednosti, a regresijski algoritmi se koriste kada rezultati mogu imati bilo koju numeričku vrijednost unutar raspona. Na primjer, za klasifikacijski algoritam koji filtrira e-poštu, ulaz bi bio dolazna e-pošta, a izlaz bi bio naziv mape u koju bi se spremila datoteka e-pošte.

4.1.1.2 Učenje bez nadzora

Algoritmi za učenje bez nadzora uzimaju skup podataka koji sadrži samo ulazne podatke i pronalaze strukturu u podacima, poput grupiranja ili grupiranja točaka podataka. Algoritmi uče iz testnih podataka koji nisu označeni, klasificirani ili kategorizirani. Umjesto da odgovaraju na povratne informacije, algoritmi nenadziranog učenja identificiraju zajedničke karakteristike u podacima i reagiraju na temelju prisutnosti ili odsutnosti takvih karakteristika u svakom novom dijelu podataka.

Klaster analiza je dodjela skupa opažanja u podskupove (zване klastere) tako da su promatranja unutar istog klastera slična prema jednom ili više unaprijed određenih kriterija, dok su opažanja izvučena iz različitih skupina različita. Različite tehnike grupiranja daju različite pretpostavke o strukturi podataka, često definirane nekom metrikom sličnosti i evaluirane, na primjer, unutarnjom kompaktnošću, ili sličnošću između članova istog klastera, i razdvajanjem, razlikom između klastera. Ostale metode temelje se na procijenjenoj gustoći i povezanosti grafa.

4.1.2. Duboko učenje (Deep learning) i umjetne neuronske mreže (Artificial neural network)

Duboko učenje (također poznato kao duboko strukturirano učenje) dio je šire obitelji metoda strojnog učenja temeljenih na umjetnim neuronskim mrežama s reprezentacijskim učenjem. Učenje može biti nadzirano, polunadzirano ili nenadzirano.


Dubinsko učenje eliminira dio predobrade podataka koja je obično uključena u strojno učenje. Ovi algoritmi mogu unositi i obraditi nestrukturirane podatke, poput teksta i slika, uklanjajući dio ovisan o ljudskim ekspertima. Na primjer, recimo da smo imali

skup fotografija različitih kućnih ljubimaca i htjeli smo ih kategorizirati po "mačka", "pas", "hrčak" itd. Algoritmi dubokog učenja mogu odrediti koje su značajke (npr. uši) najvažnije za razlikovanje svake životinje od druge. U strojnom učenju ovu hijerarhiju značajki ručno uspostavlja ljudski stručnjak.

Umjetne neuronske mreže (ANN), obično jednostavno nazvane neuronske mreže (NN), računalni su sustavi inspirirani biološkim neuronskim mrežama koje čine ljudski mozak.

ANN se temelji na skupu povezanih jedinica ili čvorova zvanih umjetni neuroni, koji oponašaju neurone u biološkom mozgu. Svaka veza, poput sinapsi u biološkom mozgu, može prenijeti signal drugim neuronima. Umjetni neuron prima signal, zatim ga obrađuje i može signalizirati neurone koji su s njim povezani. "Signal" na vezi je realan broj, a izlaz svakog neurona izračunava se nekom nelinearnom funkcijom zbroja njegovih ulaza. Veze između neurona se nazivaju rubovi. Neuroni i rubovi obično imaju težinu koja se prilagođava kako učenje napreduje. Težina povećava ili smanjuje snagu signala na spoju. Neuroni mogu imati prag takav da se signal šalje samo ako ukupni signal prijeđe taj prag. Obično su neuroni agregirani u slojeve. Različiti slojevi mogu izvesti različite transformacije na svojim ulazima. Signali putuju od prvog sloja (ulaznog sloja), do posljednjeg sloja (izlaznog sloja), moguće nakon višestrukog prelaska slojeva.

Neuronske mreže uče obradom primjera, od kojih svaki sadrži poznati "ulaz" i "rezultat", tvoreći asocijacije ponderirane vjerojatnosti između njih dvoje, koje su pohranjene unutar strukture podataka same mreže. Ovakvi sustavi "uče" izvršavati zadatke razmatrajući primjere, općenito bez programiranja s pravilima specifičnim za zadatak. Na slici 1. prikazana je primjena algoritma neuronske mreže u detekciji slika dobivenih kompjuteriziranom tomografijom. Nakon prethodnih primjera s velikim količinama podataka gdje su i ulazne slike i izlazne oznake poznate sa sigurnošću, nova ulazna slika (u ovom slučaju, sken jetre kompjuteriziranom tomografijom) može se unijeti kroz mrežu, gdje se izdvajaju važne značajke prelazeći na slojeve klasifikacije. Konačno, odluka ili oznaka se prikazuje kako bi se korisnik informirao postoji li lezija jetre na kojem mjestu.




Slika 1. Neuralna mreža i duboko učenje

Izvor: <https://journals.sagepub.com/doi/full/10.1177/0146645320940827>

4.1.3. Primjena umjetne inteligencije u radiologiji

Umjetno inteligentni računalni sustavi se uvelike koriste u medicinskim znanostima. Uobičajene primjene uključuju dijagnostiku pacijenata, otkrivanje i razvoj lijekova, poboljšanje komunikacije između liječnika i pacijenta, prepisivanje medicinskih dokumenata, kao što su recepti, i liječenje pacijenata na daljinu (2).

Umjetno inteligentni sustavi u medicini imaju sljedeći tipičan obrazac. Sustav počinje s velikom količinom podataka, na tim podacima se koriste algoritmi strojnog učenja za dobivanje informacija, te se informacije zatim koriste za generiranje korisnog izlaza za rješavanje dobro definiranog problema u medicinskom sustavu. Slika 1 prikazuje tipičan tijek rada rješenja algoritma UI. Primjena umjetne inteligencije u području medicinskih znanosti uključuje usklađivanje simptoma pacijenta s odgovarajućim liječnikom, dijagnozu pacijenta, prognozu pacijenata, otkrivanje lijekova, transkribiranje bilješki i organiziranje slika i datoteka.



Slika 2. Razvoj modela umjetne inteligencije

Izvor: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7640807/>

Algoritmi umjetne inteligencije, posebno duboko učenje, pokazali su izuzetan napredak u zadacima prepoznavanja slika. Metode u rasponu od konvolucijskih neuronskih mreža do varijacijskih autoenkodera našle su bezbroj primjena u analizama medicinskih slika. Povijesno gledano, u radiološkoj praksi, obučeni liječnici vizualno su procjenjivali medicinske slike za otkrivanje, karakterizaciju i praćenje bolesti. Metode umjetne inteligencije izvrsne su u automatskom prepoznavanju složenih obrazaca u slikovnim podacima i pružanju kvantitativnih više od kvalitativnih procjena radiografskih karakteristika. Umjetna inteligencija doživjela je značajan napredak u percepciji (tumačenju senzornih informacija), omogućujući strojevima da bolje predstavljaju i interpretiraju složene podatke. Duboko učenje je podskup strojnog učenja koji se temelji na strukturi neuronske mreže koja je inspirirana ljudskim mozgom. Takve strukture automatski uče diskriminativne značajke iz podataka, dajući im mogućnost aproksimacije vrlo složenih nelinearnih odnosa. Dok je većina ranijih metoda umjetne inteligencije dovela do aplikacija s podljudskim performansama, nedavni algoritmi dubokog učenja sposobni su uskladiti, pa čak i nadmašiti ljude u aplikacijama sa specifičnim zadacima (5).

Nedavni napredak u istraživanju umjetne inteligencije doveo je do novih, nedeterminističkih algoritama dubokog učenja koji ne zahtijevaju eksplicitnu definiciju, što predstavlja bitno drugačiju paradigmu u strojnom učenju. Temeljne metode dubokog učenja postoje desetljećima, međutim, tek posljednjih godina dostupno je dovoljno podataka iz baza te dovoljno računalne snage. Dok su različite metode dubinskog učenja osmišljene za rješavanje raznih zadataka, konvolucijske neuronske mreže danas su najraširenije tipologije dubokog učenja u medicinskom oslikavanju. CNN-i se često obučavaju s označenim podacima za učenje pod nadzorom (6).

Medicinska područja koja se oslanjaju na slikovne podatke, uključujući radiologiju, patologiju, dermatologiju i oftalmologiju, imaju značajne koristi od primjene UI metoda. Unutar radiologije, obučeni liječnici vizualno procjenjuju medicinske slike i izvješćuju o nalazima kako bi otkrili, karakterizirali i nadzirali bolesti. Takva se procjena često temelji na obrazovanju i iskustvu i ponekad može biti subjektivna. Za razliku od takvog kvalitativnog zaključivanja, UI izvrsno prepoznaje složene obrasce u slikovnim podacima i može dati kvantitativnu procjenu na

automatiziran način. Točnije i preciznije radiološke procjene mogu se napraviti kada se UI integrira u klinički rad kao alat za pomoć liječnicima (5).


Budući da se slikovni podaci prikupljaju tijekom rutinske kliničke prakse, veliki skupovi podataka lako su dostupni, nudeći tako nevjerojatno bogat resurs za znanstvena i medicinska istraživanja. Radiografske slike, zajedno s podacima o kliničkim ishodima, dovele su do pojave i brzog širenja metoda koje izdvaja veliki broj značajki iz medicinskih slika pomoću algoritama za karakterizaciju podataka. Primarni pokretač pojave umjetne inteligencije u medicinskoj radiologiji bila je želja za većom djelotvornošću i učinkovitošću kliničke skrbi. Količina radioloških pregleda nastavlja rasti nerazmjernom brzinom u usporedbi s brojem dostupnih radiologa, što se nadoknađuje povećanjem produktivnosti. Ti su čimbenici pridonijeli dramatičnom povećanju radnog opterećenja radiologa. Studije izvještavaju da, u nekim slučajevima, prosječni radiolog mora analizirati jednu sliku svake 3-4 sekunde u 8-satnom radnom danu kako bi ispunio zahtjeve radnog opterećenja. Kako radiologija uključuje vizualnu percepciju, pogreške su neizbježne - osobito u takvim ograničenim uvjetima (7).

Primjena integrirane komponente umjetne inteligencije unutar radiologije značajno povećava učinkovitost te smanjuje potencijalne pogreške tijekom radnog procesa. Stoga se ulažu značajni naponi u integriranju umjetne inteligencije u medicinskom snimanju. Gotovo svi radiološki zadaci ovise o kvantificiranju i procjeni radiografskih karakteristika slika. Ove karakteristike mogu biti važne za otkrivanje, karakterizaciju ili praćenje bolesti. Primjena logike i statističkog prepoznavanja obrazaca predložena je još ranih 1960-ih godina. Kako su računala postala rasprostranjenija 1980-ih, automatizacija mnogih kliničkih zadataka umjetnom inteligencijom pomaknula je radiologiju s perceptivne subjektivne zanata na kvantitativno mjerljivu domenu.

Postoje dvije vrste metoda umjetne inteligencije koje su danas u širokoj upotrebi. Prva koristi ručno izrađene značajke koje su definirane u terminima matematičkih jednadžbi (kao što je tekstura tumora) i stoga se mogu kvantificirati pomoću računalnih programa. Te se značajke koriste kao ulazni podaci za najsvremenije modele strojnog učenja koji su osposobljeni za razvrstavanje pacijenata na načine koji mogu podržati kliničko donošenje odluka. Iako se takve značajke

percipiraju kao diskriminativne, one se oslanjaju na stručnu definiciju i stoga ne predstavljaju nužno najoptimalniji pristup kvantifikaciji obilježja za zadatak diskriminacije. Štoviše, unaprijed definirane značajke često se ne mogu prilagoditi varijacijama u modalitetima snimanja, kao što su računalna tomografija (CT), pozitronska emisijska tomografija (PET) i oslikavanje magnetskom rezonancijom (MRI).

Druga metoda, duboko učenje, posljednjih je godina privukla značajnu pozornost. Algoritmi dubokog učenja mogu automatski naučiti prikaze značajki iz podataka bez potrebe za prethodnom definicijom od strane ljudskih stručnjaka. Ovaj pristup vođen podacima omogućuje apstraktnije definicije značajki, čineći ga informativnijim i generaliziranijim. S obzirom na svoju sposobnost učenja složenih prikaza podataka, duboko učenje je također često otporno na neželjene varijacije, kao što je varijabilnost među čitačima, te se stoga može primijeniti na veliki broj kliničkih stanja i parametara. Na mnogo načina duboko učenje može odražavati ono što rade obučeni radiolozi, odnosno identificirati parametre slike, ali i odmjeriti važnost tih parametara na temelju drugih čimbenika za donošenje kliničke odluke.



Slika 3. Metode umjetne inteligencije u medicinskom snimanju

Izvor: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6268174/>

Na slici 3 shematski su prikazane dvije metode umjetne inteligencije za reprezentativni zadatak klasifikacije, kao što je dijagnoza sumnjive lezije kao benigne ili maligne. Prva metoda se oslanja na značajke izvučene iz područja od interesa na temelju stručnog znanja. Primjeri ovih značajki u karakterizaciji raka uključuju volumen, oblik, teksturu, intenzitet i mjesto tumora. Odabiru se najrobusnije značajke i unose u klasifikatore strojnog učenja.

Druga metoda koristi duboko učenje i ne zahtijeva označavanje regije – umjesto toga, sama lokalizacija je obično dovoljna. Sastoji se od nekoliko slojeva gdje se ekstrakcija značajki, odabir i konačna klasifikacija izvode istovremeno tijekom obučavanja. Kako slojevi uče sve više značajke više razine, raniji slojevi mogu naučiti apstraktne oblike kao što su linije i sjene, dok drugi dublji slojevi mogu naučiti cijele organe ili objekte.

Postoje tri glavna klinička radiološka zadatka koji se posebno odnose na onkologiju: otkrivanje abnormalnosti, nakon čega slijedi karakterizacija i naknadno praćenje promjena. Ti zadaci zahtijevaju raznolik skup vještina: medicinskih, u smislu dijagnoze bolesti i skrbi, kao i tehničkih, za snimanje i obradu radiografskih slika. Obje ove vještine upućuju na brojne mogućnosti u kojima tehnologije umjetne inteligencije mogu pozitivno utjecati na kliničke ishode identificiranjem fenotipskih karakteristika na medicinskim slikama.

4.1.3.1 Primjena CAD-a u radiologiji

Računalno potpomognuta detekcija (CADe), također nazvana računalno potpomognuta dijagnostika (CADx), sustavi su koji pomažu liječnicima u interpretaciji medicinskih slika. Tehnike snimanja u RTG, MRI i ultrazvučnoj dijagnostici daju mnogo informacija koje radiolog ili drugi medicinski stručnjak mora sveobuhvatno analizirati i procijeniti u kratkom vremenu. CAD sustavi obrađuju digitalne slike za tipične izgleda i naglašavaju uočljive dijelove, kao što su moguće bolesti, kako bi ponudili ulazne podatke koji podržavaju odluku koju je donio radiolog.

CAD je interdisciplinarna tehnologija koja kombinira elemente umjetne inteligencije s radiološkom i patološkom obradom slika. Tipična primjena je otkrivanje tumora. Na primjer, neke bolnice koriste CAD za podršku preventivnim liječničkim

pregledima u mamografiji (dijagnoza raka dojke), otkrivanju polipa u debelom crijevu i raka pluća.

Računalno potpomognuti sustavi detekcije (CADe) obično su ograničeni na označavanje uočljivih struktura i dijelova. Računalni sustavi potpomognute dijagnostike (CADx) procjenjuju uočljive strukture. Na primjer, u mamografiji CAD ističe nakupine mikrokalifikata i hiperdenzne strukture u mekom tkivu. To omogućuje radiologu da donese zaključke o stanju patologije. Druga primjena je CADq, koji kvantificira, npr. veličinu tumora ili ponašanje tumora nakon unosa kontrastnog sredstva. Računalno potpomognuta jednostavna trijaža (CAST) je još jedna vrsta CAD-a, koja obavlja potpuno automatsku početnu interpretaciju i trijažu studija u neke značajne kategorije (npr. negativne i pozitivne). CAST je osobito primjenjiv u hitnoj dijagnostičkoj slikovnoj dijagnostici, gdje je potrebna brza dijagnoza kritičnog stanja opasnog po život.

CAD se koristi u dijagnozi raka dojke, raka pluća, raka debelog crijeva, raka prostate, metastaza u kostima, koronarne arterijske bolesti, kongenitalne srčane mane, otkrivanja prijeloma, Alzheimerove bolesti, dijabetičke retinopatije, itd. CAD ima primjenu u probirnoj mamografiji (rendgenski pregled ženske dojke). Probirna mamografija koristi se za rano otkrivanje raka dojke. CAD sustavi se često koriste kako bi se tumor klasificirao kao maligni ili benigni. Nedavni napredak u tehnologiji strojnog učenja, dubokog učenja i tehnologije umjetne inteligencije omogućio je razvoj CAD sustava za koje je klinički dokazano da pomažu radiolozima u rješavanju izazova očitavanja mamografskih slika poboljšanjem stope otkrivanja raka i smanjenjem lažno pozitivnih nalaza i nepotrebnih ponovnih poziva pacijenata, značajno smanjujući vrijeme očitavanja.

4.2. CT I DOZA ZRAČENJA

Od svog uvođenja 1972. računalna tomografija se razvila u vrlo uspješnu i nezamjenjivu dijagnostičku pretragu. Važnost CT-a ogleda se u broju godišnjih CT pregleda, koji se povećavao godišnje za 6,5% tijekom posljednjeg desetljeća, što je rezultiralo s ukupno 80 milijuna CT skeniranja u 2015. u SAD-u (8). Nakon što je uveden prvi modalitet tomografskog snimanja, njegov je tehnološki razvoj brzo

napredovao. Prvo kliničko snimanje CT-om trajalo je oko 5 minuta, a rekonstrukcija slike trajala je otprilike isto toliko. Unatoč dugom vremenu rekonstrukcije, rezolucija slike bila je loša sa samo 80×80 piksela. Danas se brzine rotacije ubrzavaju na otprilike četvrtinu sekunde po rotaciji, a pokrivenost detektora, duž osi pacijenta, povećana je do 16 cm u vrhunskim sustavima, što omogućuje snimanje cijelog srca u vremenu jednog otkucaja srca. Rezolucija slika poprečnog presjeka povećana je na 512×512 piksela za većinu kliničkih primjena i na 1024×1024 piksela ili više za najsuvremenije CT skenerne.

Međutim, sve veći broj CT pregleda donosi rizik izloženosti društva zračenju, što je posebno problematično za mlađe pacijente. U skladu sa sve većom upotrebom CT pregleda, povećava se i zabrinutost zbog opasnosti od zračenja. U tom smislu radiolozi, radiološki tehnolozi i fizičari posvećuju veliku pozornost optimizaciji doze zračenja na CT-u. Strategije optimizacije doze kontinuirano se razvijaju u smislu tehnika snimanja, kao i manipuliranja dozom.

Za smanjenje i optimizaciju doze zračenja na CT-u, imperativ je osigurati da očekivane koristi informacija dobivenih od CT-a nadmašuju projicirane rizike doze zračenja za pojedinog pacijenta. Kada je prikladno, rizik od izloženosti zračenju može se ublažiti korištenjem alternativnih slikovnih modaliteta kao što su ultrazvuk i magnetna rezonanca, osobito kod žena u reproduktivnoj dobi i djece. Optimizacijom ili smanjenjem doze potrebno je pažljivo upravljati, jer napori na smanjenju doze zračenja mogu povećati šum slike i time smanjiti kvalitetu slike. CT skenovi s malo ili bez šuma često uključuju veću dozu zračenja bez dodatnih dijagnostičkih informacija. S druge strane, CT skenovi dobiveni s previše šuma ili artefakata mogu smanjiti dijagnostički sadržaj. Unutar svake regije tijela, količina podnošljivog šuma slike ovisi o kliničkoj indikaciji i vrsti abnormalnosti. Na primjer, CT abdomena indiciran za bubrežne kolike može se izvesti pri nižoj dozi zračenja budući da visoki šum slike ne narušava vidljivost bubrežnih kamenaca. CT abdomena za otkrivanje i karakterizaciju niskokontrastnih, žarišnih lezija jetre ili gušterače zahtijeva slike s nižim šumom i većom dozom zračenja u usporedbi s CT-om za detekciju bubrežnih kamenaca. Takve varijacije u kliničkim indikacijama i potrebama trebale bi se iskoristiti za optimizaciju doze zračenja u CT-u za sve regije tijela (9).

CT pretrage trebaju se izvoditi po principu ALARA (as low as reasonably achievable), što bi trebalo uključivati postavljanje ispravnih protokola skeniranja na temelju regije tijela, tjelesne težine i što je najvažnije, kliničke indikacije za provođenje slikovne pretrage (10). Višedimenzionalni pristup bitan je za optimizaciju doze zračenja kako bi se održala prihvatljiva kvaliteta slike za kliničku interpretaciju. Općenito, pristup optimizacije možemo podijeliti na čimbenike ovisne o pacijentu i čimbenik ovisne o uređaju. Važna je uspostava CT protokola specifičnih za određeno područje tijela i kliničke indikacije. Unutar svakog protokola, odgovarajuća uporaba prilagodljivih parametara skeniranja može pomoći optimizirati razine zračenja za pacijenta.

Za čimbenike ovisne o skeneru, različiti CT dobavljači su razvili tehnologije za optimizaciju doze zračenja uz održavanje ili poboljšanje kvalitete slike modificiranjem parametara skeniranja i rekonstrukcije kao što su struja cijevi (mA) i napon (kV), konfiguracija detektora, vrijeme rotacije portala, broj rotacije portala, veličina vokselu slike, debljina presjeka, filtri zraka, rekonstrukcijske jezgre i tehnike rekonstrukcije slike.

Zabrinutost oko potrebe za optimizacijom i smanjenjem doze CT zračenja dovela je do poboljšane učinkovitosti CT skeniranja i uvođenja nekoliko tehnika rekonstrukcije i softvera koji se temelje na obradi slike.

Inovacije u CT-u bile su impresivne u slikovnim i medicinskim tehnologijama u domeni hardvera i softvera. Opseg i brzina CT skeniranja poboljšani su uvođenjem CT skenera s više detektorskih redova s detektorima širokog spektra i većim brzinama rotacije gentrija. Kako bi se uhvatilo u koštac sa zabrinutošću zbog rastućih doza zračenja zbog sve veće upotrebe CT-a i kako bi se poboljšala kvaliteta slike, razvile su se rekonstrukcijske tehnike od filtrirane povratne projekcije (filtered back projection) do tehnika iterativne rekonstrukcije (iterative reconstruction techniques), a nedavno i tehnike rekonstrukcije slike temeljene na dubokom učenju (deep learning based image reconstruction). Ove novije tehnike bazirane na umjetnoj inteligenciji dubokog učenja omogućuju poboljšanu ili zadržanu kvalitetu slike u odnosu na tehniku filtrirane povratne projekcije uz redukciju doze zračenja (9).

4.2.1 Strategija optimizacije CT doze zračenja

Za optimizaciju doze, preduvjet je razumijevanje parametara CT-a uključujući napon cijevi, jakost struje cijevi, nagib, indeks ponderirane CT doze (CTDI_w), indeks volumne CT doze (CTDI_{vol}), proizvod duljine doze (DLP) i efektivnu dozu. Krajnji cilj optimizacije doze je minimiziranje doze zračenja za dobivanje kvalitetne dijagnostičke CT snimke. Stoga moramo odrediti kako dobiti dijagnostičku kvalitetu CT slika uz optimizaciju doze. Četiri temeljna parametra koji određuju kvalitetu CT slike jesu šum slike, kontrast slike, prostorna rezolucije i artefakti. U principu, doza zračenja obrnuto je proporcionalna kvadratu šuma slike.

Checkup Items	Recommendations
Body size-adapted CT protocol	<ul style="list-style-type: none">√ Traditionally based on body weight or body mass index√ Based on cross-sectional dimensions and/or body attenuation for better dose adaptation to individually varied body habitus√ Use best-fit equation rather than dose table or chart
Tube current modulation	<ul style="list-style-type: none">√ Always turn on if applicable√ Set up appropriate reference image quality index√ Check how much modulated tube current reaches to maximal limits ("tube current saturation") and adjust parameters such as tube voltage and scan speed to obtain maximal dose reduction by tube current modulation
Optimal tube voltage at equivalent radiation dose	<ul style="list-style-type: none">√ Select most dose-efficient tube voltage√ Consider lower tube voltages for contrast-enhanced examination, higher tube voltages for examinations requiring lower noise (e.g., unenhanced brain CT) and for examinations detecting low-contrast lesions (e.g., microabscesses in liver or ground-glass opacity in lung)
Longitudinal scan range	<ul style="list-style-type: none">√ Adjust to minimal range as required for clinical indications, desirably by using clear anatomic landmarks
Repeated scanning	<ul style="list-style-type: none">√ Reduce number of repeated scanning√ Omit precontrast examination if possible
Scan modes	<ul style="list-style-type: none">√ Use low-dose scan mode to maximize benefit-risk ratio of CT examination (e.g., prospectively ECG-triggered sequential or high-pitch dual-source spiral scanning in cardiac CT)
Noise-reducing image reconstruction algorithms	<ul style="list-style-type: none">√ Use noise-reducing, spatial resolution-preserving algorithms (e.g., iterative reconstruction algorithms) at lower radiation dose

Slika 4. Parametri i preporuke za optimizaciju CT doze zračenja

izvor: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3253393/>

Kako bismo bili u skladu s ALARA principom, u situaciji kada se očekuju jednaki ili veći dijagnostički rezultati, CT treba zamijeniti alternativnim dijagnostičkim metodama bez ili s manje ionizirajućeg zračenja, kao što su ultrazvuk, magnetska rezonancija. S druge strane, potrebno je uložiti sve napore da se smanji doza zračenja uz zadržavanje kvalitete CT snimaka. Na primjer, minimiziranje raspona skeniranja CT pregleda prema potrebi je jednostavan način za postizanje ovog cilja. Za višefazne CT

protokole, broj ponovljenih skeniranja treba svesti na najmanju moguću mjeru, a skeniranje prije kontrasta treba koristiti samo kada se dijagnostičke informacije o nativnim CT slikama ne mogu dobiti iz postkontrastnog skeniranja. Zbog značajne doze zračenja perfuzijskog CT-a, potrebno je pažljivo odrediti njegovu kliničku indikaciju i slikovni protokol.

CT protokol prilagođen veličini i težini pacijenta temeljni je dio optimizacije CT doze. Potrebno je odrediti optimalni napon i struju cijevi za prilagođenu dozu zračenja. Jedna od uobičajenih zabluda je da je snižavanje napona cijevi pri istoj struji cijevi dobra strategija za snižavanje doze CT-a. Zapravo, višu struju cijevi treba koristiti pri nižem potencijalu cijevi kako bi se kompenzirao povećani šum slike (11). Još jedna zabluda je da modulacija struje cijevi može automatski prilagoditi dozu CT zračenja različitim veličinama tijela i anatomskim regijama. Međutim, ovo je pogrešno i za svaku anatomsku regiju i svaki napon cijevi treba odrediti definiranu ciljnu kvalitetu slike s obzirom na veličinu pacijenta i dijagnostički zadatak.


Modulacija struje cijevi uvelike doprinosi optimizaciji CT doze smanjenjem doze prema veličini tijela, obliku i atenuaciji bez degradacije kvalitete slike. Struja cijevi može se podesiti u ravnini x-y (kutni način), z-osi ili u kombinaciji. Pacijent treba biti smješten u CT izocentru kako bi se izbjegla pogrešna modulacija struje cijevi. Ostali čimbenici koji utječu na modulaciju struje cijevi uključuju napon cijevi, maksimalnu struju cijevi, brzinu skeniranja i smjer skeniranja. Optimalni napon cijevi treba odrediti za veličinu pacijenta i svaku vrstu CT pregleda kako bi se postigao optimalni kompromis između kontrasta, šuma, artefakata i brzine skeniranja. Važnost optimalnog napona cijevi važan je za optimizaciju doze CT-a kako bi se maksimizirale kliničke prednosti CT pregleda pri niskoj dozi zračenja i kako bi se odredio napon cijevi s najučinkovitijom dozom.

Stvarni rizici izlaganja zračenju zbog dijagnostičkog snimanja niskim dozama su prilično nepoznati. Međutim, mnogi znanstvenici vjeruju da niske razine ionizirajućeg zračenja u rasponu od 5-125 mSv imaju vrlo mali, ali statistički značajan porast rizika od indukcije raka. Nekoliko čimbenika koji pretežno utječu na rizik od raka zbog izloženosti zračenju treba pažljivo razmotriti pri uspostavljanju CT protokola. To uključuje genetsku osjetljivost, dob pacijenta i spol. Procjena CT doze pomaže dati neki

smjer u smislu optimizacije CT doze. Sama procjena također može povećati svijest o nužnosti optimizacije doze CT-a.

4.3. PRIMJENA UMJETNE INTELIGENCIJE U OPTIMIZACIJI CT DOZE ZRAČENJA

U kompjuteriziranoj tomografiji umjetna inteligencija osigurava smanjenje doze zračenja pacijenata kroz automatizaciju i optimizaciju procesa prikupljanja podataka, uključujući pozicioniranje pacijenta i postavke parametara akvizicije. Na slici 5 shematski su prikazani procesi uključeni u CT pregled, od postavljanja pacijenta na dijagnostički stol do rekonstrukcije konačnih slika.



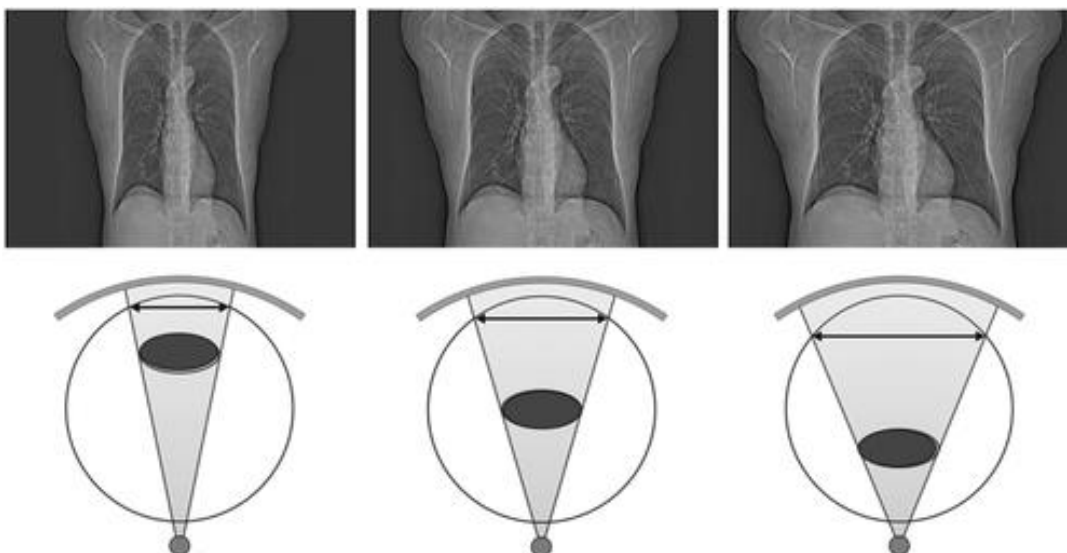
Slika 5. Ilustracija izvođenja pregleda kompjutorizirane tomografije (CT)

Izvor: <https://journals.sagepub.com/doi/full/10.1177/0146645320940827>

Pretraga se izvodi tako da se pacijent postavlja na stol, a anatomska regija interesa smještena je u središta CT gentryja. Prvo se dobiva CT lokalizatora, te radiološki tehnolog označava početnu i krajnju lokaciju na kojoj se skeniranje treba obaviti. Odabire se ispravan protokol skeniranja, na temelju kliničkih indikacija za pregled, a zatim se odabiru specifični parametri skeniranja kako bi se dobile optimalne CT slike. Konačno, slike se rekonstruiraju pomoću niza parametara koji određuju karakteristike slike, kao što su oštrina slike i polje pregleda (FOV). Tehnike umjetne inteligencije mogu biti uključene u svaki od ovih koraka.

4.3.1. Pozicioniranje pacijenta

Geometrija CT sustava je takva da se rendgenska cijev i detektor rotiraju oko fiksnog centra, koji se naziva "izocentar". Posebni filter (bow-tie filter) koristi se za smanjenje broja rendgenskih fotona koji pogađaju periferiju pacijenta, jer je pacijentova debljina tamo manja i potrebno je manje fotona. Kako su pacijenti najdeblji u izocentru, u tom području filter ima najmanju količinu slabljenja. Bow-tie filter važan je alat za optimizaciju doze za pacijente. Međutim, ako pacijent nije centriran u izocentar, postoji neusklađenost između pretpostavke korištene u razvoju filtera i stvarnog postavljanja pacijenta. To uzrokuje pogrešnu primjenu doze na nekim mjestima na tijelu, a šum slike se povećava u odnosu na položaj pacijenta u izocentru. Još od 2000. godine, CT sustavi uključuju značajku, nazvanu 'automatska kontrola ekspozicije' (AEC), koja povećava struju cijevi (tj. povećava broj rendgenskih fotona) za deblje dijelove tijela i smanjuje struju cijevi (tj. smanjuje broj rendgenskih fotona) za tanje dijelove tijela. Kako bi sustav procijenio atenuaciju neke regije tijela, oslanja se na informacije koje dobiva iz CT lokalizatora. Kao što je prikazano na slici 6 s rendgenskom cijevi ispod pacijentovog stola, ako je pacijent postavljen previsoko ili prenisko u odnosu na izocentar, sustav doživljava da je pacijent pretanak, odnosno predebeo. To je zato što se prostorna kalibracija CT sustava izvodi u izocentru.



Slika 6. Izvedbe automatske kontrole ekspozicije na CT-u.

Izvor: <https://journals.sagepub.com/doi/full/10.1177/0146645320940827>

Sustav automatske kontrole ekspozicije automatski određuje potreban broj fotona pri svakoj projekciji kroz pacijenta. Za vrlo velike pacijente to znači da sustav treba dodatno povećati broj fotona kako bi se postigla određena kvaliteta pregleda. Kako pacijenti nisu homogeni, krajnji rezultat je tipično da struja cijevi oscilira gore-dolje unutar jedne rotacije gentryja, te se u prosjeku povećava kroz debele dijelove tijela (npr. ramena i kukovi), a smanjuje se na prosječno, kroz tanje dijelove tijela (npr. prsa). Kako bi ovi algoritmi ispravno funkcionirali, bitno je da je pacijent pozicioniran u izocentar sustava. Međutim, kako je anatomija pacijenta prilično varijabilna, to može biti teško postići u praksi (1).

Nedavno je u CT sustav integrirana trodimenzionalna infracrvena kamera čiji primjer je prikazan na slici 6.



Slika 7. Trodimenzionalna kamera i njezin položaj iznad pacijentovog stola (lijevo). Optička slika i trodimenzionalna mapa dubine pacijenta dobivena pomoću kamere iznad glave (desno).

Izvor: <https://journals.sagepub.com/doi/full/10.1177/0146645320940827>

Kamera je smještena iznad pacijentovog stola i proizvodi trodimenzionalnu sliku pacijentove površine s informacijama o dubini. Koristeći algoritme umjetne inteligencije, koji su isprobani na više od 1000 pacijenata iz tri različite bolnice, detektira specifične orijentire na površini pacijenta; na temelju dijela tijela koji će se skenirati i trenutne visine stola, sustav automatski pomiče stol okomito kako bi

pozicionirao pacijenta tako da se većina skeniranog dijela tijela nalazi u izocentru (12). Slika 8 sažima rezultate studije Saltybaeva i sur. (12), pokazujući da su prosječne i maksimalne pogreške značajno smanjene korištenjem ovog algoritma umjetne inteligencije za automatsko centriranje pacijenta. Smatrajući da je pogreška >20 mm klinički neprihvatljiva, pristup umjetne inteligencije smanjuje ozbiljne pogreške s 40-50% na 0.

Anatomic region and centring method	Average absolute error \pm standard deviation (mm)	Maximum absolute error (mm)	Percentage of patients with error >20 mm
Chest			
Manual	19 \pm 9	39	50%
Automatic	7 \pm 4	15	0%
Abdomen			
Manual	18 \pm 11	43	40%
Automatic	4 \pm 2	9	0%

Source: Saltybaeva et al. (2018).

Slika 8. Prikaz pogrešaka ručnog i automatiziranog pozicioniranja

Izvor: <https://journals.sagepub.com/doi/full/10.1177/0146645320940827>

4.3.1.1 Usporedba između ručnog i automatskog pozicioniranja temeljenog na umjetnoj inteligenciji na CT-u kod COVID-19 pozitivnih pacijenata

Točno pozicioniranje i centriranje bolesnika u kompjutoriziranoj tomografiji ostaje važno pitanje za smanjenje doze i šuma slike. Podaci iz studije pokazali su da pogrešno centriranje pacijenata za 6 cm, rezultira povećanjem do 41% površinske doze i 22% povećanja šuma slike (13). Kako bi postigli visoku kvalitetu dijagnostičke slike uz smanjenu dozu zračenja, tehnolozi ulažu dodatni napor kako bi točno odabrali raspon skeniranja i pažljivo centrirali pacijente tijekom CT pregleda. Međutim, ručno pozicioniranje i precizno centriranje je dugotrajan proces i ovisan o tehnologu, a često je nedosljedan i neoptimalan. Za pacijente s zaraznim bolestima interakcija između tehnologa i pacijenata također nosi potencijalni rizik od prijenosa infekcije. Nedavni napredak u tehnologijama umjetne inteligencije pokazao je izuzetan napredak u

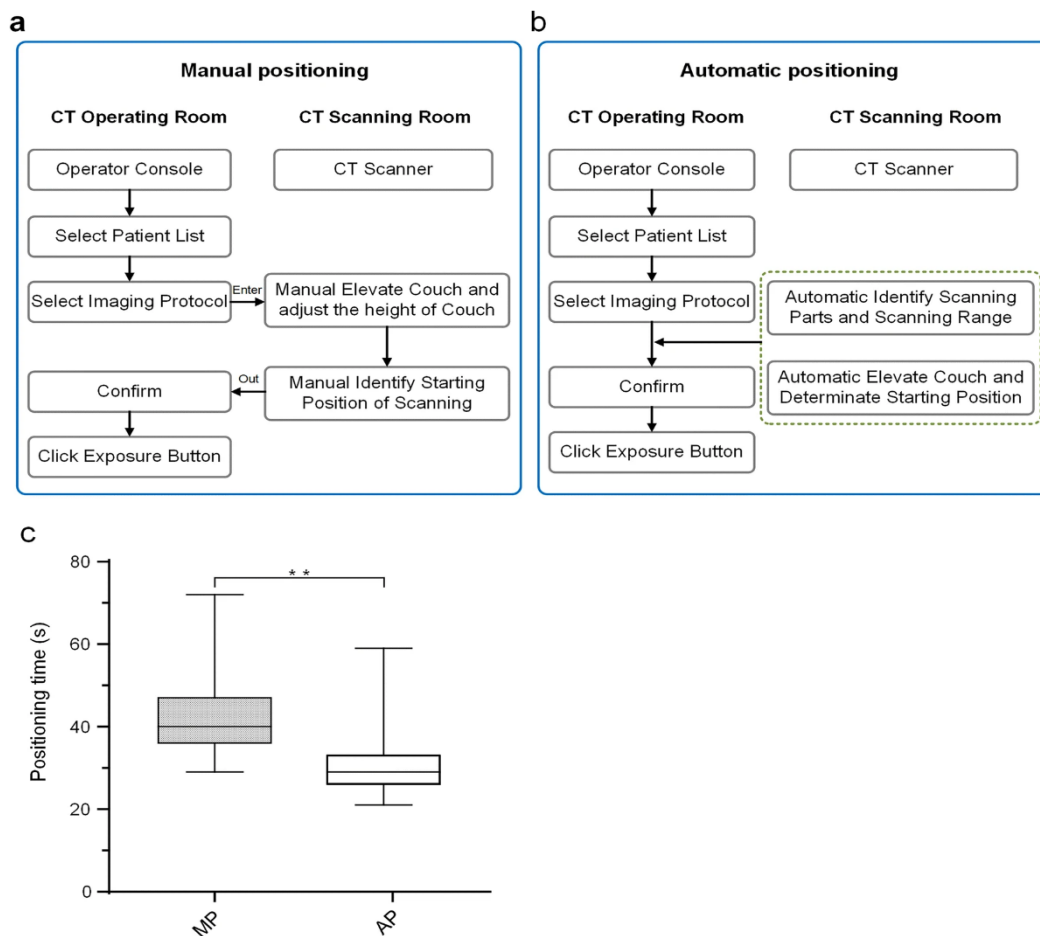
prepoznavanju i tumačenju složenih obrazaca u slikovnim podacima. Kombinacija umjetne inteligencije i CT snimanja može pružiti bržu, točniju i učinkovitiju dijagnozu temeljenu na slikovnoj dijagnostici (14).

Zahvaljujući 3D vizualnim sensorima, UI može identificirati pozu i oblik pacijenata i realizirati automatizirani radni tijek beskontaktnog prikupljanja slike. Yang Wang i suradnici (2020) izvijestili su da U-HAPPY (United imaging Human Automatic Planbox for PulmonarY) CT ima funkciju s automatskim pozicioniranjem i skeniranjem, što pomaže u smanjenju doze zračenja. Booi i sur. i Saltybaeva i sur. također su izvijestili o preciznosti centriranja pacijenata na CT-u pomoću 3D kamera koje se oslanjaju na duboku neuronsku mrežu za konturiranje slike. Nedavno je GE Healthcare predstavio Revolution Maxima CT, koji se oslanja na algoritme dubokog učenja i tehnologiju senzora dubine u stvarnom vremenu za centriranje pacijenata, lociranje željene anatomije i automatsko skeniranje. Ovaj CT skener uspješno je korišten za dijagnosticiranje pacijenata oboljelih od COVID-19, međutim ovakva primjena UI na tehniku CT skeniranja još je u fazi istraživanja.

Studija iz 2021. god. (15) imala je za svrhu analizirati i usporediti tijekom rada snimanja, pozicioniranje i centriranje pacijenta, dozu zračenja i kvalitetu slike pacijenata oboljelih od COVID-19 koji su podvrgnuti CT skeniranju koristeći isti CT protokol na istom CT uređaju, uspoređujući konvencionalni način ručnog pozicioniranja (MP) s načinom automatskog pozicioniranja (AP) temeljenim na umjetnoj inteligenciji. U studiji je sto dvadeset i sedam odraslih pacijenata s COVID-19 virusom podvrgnuto CT-u toraksa koristeći isti protokol skeniranja uz razliku načina pozicioniranja. Dio pacijenata svrstan je u grupu s ručnim pozicioniranjem (MP grupa), a drugi dio u grupu pozicioniranja metodom automatskog pozicioniranja temeljenom na AI-u (AP grupa). Zabilježeni su i uspoređeni doza zračenja, vrijeme pozicioniranja pacijenta i udaljenost od centra dviju skupina. Šum slike i omjer signal-šum (SNR) procijenila su tri iskusna radiologa i uspoređivala ih između dvije skupine.

Tijek procesa snimanja za obje grupe prikazan je na slici 9. CT skeniranje prsnog koša izvedeno je na Revolution Maxima CT-u opremljenom softverom za automatsko centriranje i anatomske pozicioniranje pacijenata koji se temelji na umjetnoj inteligenciji (GE Healthcare) od apex pulmonisa do dijafragme. Obje grupe koristile su

isti protokol skeniranja sa sljedećim parametrima: napon cijevi, 120 kVp; vrijeme rotacije gentrija 0,4 s; visina, 1,375:1; vidno polje skeniranja (SFOV), 50 cm; debljina sloja, 5 mm; struja cijevi (mA), automatizirana modulacija struje cijevi (ATCM) za dobivanje indeksa šuma od 11,57; sve aksijalne slike rekonstruirane su standardnim algoritmom rekonstrukcije sa standardnim kernelom; vidno polje za rekonstrukciju (DFOV), 35–50 cm; debljina rekonstrukcije, 1,25 mm (15).




Slika 9. Shematski dijagram za korake rada ručnog i automatskog pozicioniranja

Izvor: <https://link.springer.com/article/10.1007/s00330-020-07629-4#Fig1>

Automatsko pozicioniranje bazirano na umjetnoj inteligenciji koristi fiksnu, stropnu 2D/3D video kameru koja može odrediti udaljenosti do točaka u svom vidnom polju. Prikazuje standardne RGB video slike na postojećim zaslonima osjetljivim na dodir montiranim na gentriju CT sustava. Informacije iz standardnog izlaza kamere koriste se, zajedno s preciznim prostornim informacijama o geometriji gentrija i stola

CT sustava, za određivanje anatomske lokacije orijentira te početne i završne lokacije za lokalizacijsko skeniranje. Softver za automatsko pozicioniranje koristi dva algoritma dubokog učenja (RGBLandmarkNet mrežu i DepthLandmarkNet mrežu) s različitim ulazima koji proizvode usporedive izlaze za identifikaciju svih anatomskih orijentira na tijelu pacijenta. Svi identificirani orijentiri koriste se za određivanje orijentacije pacijenta (prvo glava ili stopala). Mreža RGBLandmarkNet koristi 2D video slike kao ulaze i izlaze svih unaprijed definiranih lokacija orijentira u X i Z osi. Paralelno, DepthLandmarkNet mreža koristi 3D podatke o dubini iz kamere kako bi također proizvela sve unaprijed definirane lokacije orijentira. 3D slike dubine koriste se za generiranje "oblaka točaka" na konturi površine pacijenta. Oblak točaka se zatim segmentira kako bi se dobila kontura tijela. Kontura tijela koristi se za determinističko izračunavanje vertikalnog geometrijskog središta pacijenta. Mjesto središnje točke zatim se koristi za izračunavanje potrebne visine stola za centriranje pacijenta. S pacijentom na stolu za CT skeniranje, položaj i centriranje pacijenta mogu se izvesti automatski pomoću gumba na jedan dodir na konzoli u kontrolnoj sobi (15).



Slika 10. Princip automatskog pozicioniranja temeljenog na umjetnoj inteligenciji

Izvor: <https://link.springer.com/article/10.1007/s00330-020-07629-4#Fig1>

Što se tiče točnosti pozicioniranja, ispravno pozicioniranje podrazumijeva potpunu pokrivenost ako uključuje apex pulmonis i dijafragmu. Dakle, ako su slike apex pulmonisa i dijafragme bile potpuno prekrivene, pozicioniranje pacijenta se smatralo uspješnim; inače je definirano nepotpunim ili netočnim. Na slici 11 prikazan je primjer neispravnog topograma prsnog koša (slika a), te na slici b ispravan CT topogram prsnog koša. Na slici c prikazana je usporedba točnosti pozicioniranja za

topogram prsnog koša dobivenog ručnim pozicioniranjem u usporedbi s automatskim pozicioniranjem (podaci su prikazani kao n (%), gdje je n broj pacijenata s kompletnim CT topogramom; n = 127) (15).



Slika 11: Usporedba točnosti pozicioniranja na CT topogramu prsnog koša

Izvor: <https://link.springer.com/article/10.1007/s00330-020-07629-4>

Rezultati studije po pitanju redukcije doze zračenja pokazuju da je grupa za pozicioniranje temeljena na umjetnoj inteligenciji imala značajno nižu vrijednost CTDI_{vol} ($13,3 \text{ mGy} \pm 2,4$ naspram $14,9 \text{ mGy} \pm 2,3$, $p < 0,001$), vrijednost DLP ($437,4 \text{ mGy.cm} \pm 95,6$ naspram $523,4 \text{ mGy} \pm 0,7 \pm 0,7 \text{ cm}$), i ED vrijednost ($6,1 \text{ mSv} \pm 1,3$ vs. $7,3 \text{ mSv} \pm 1,2$, $p < 0,001$) od grupe za ručno pozicioniranje (15).

Studija je analizirala i uspoređivala tijekom rada snimanja, dozu zračenja i kvalitetu slike za pacijente s COVID-19 koji su pregledani bilo konvencionalnom metodom ručnog pozicioniranja bilo metodom automatskog pozicioniranja i centriranja temeljenim na umjetnoj inteligenciji. Rezultati su pokazali da metoda temeljena na umjetnoj inteligenciji ne samo da je automatski pozicionirala pacijente s 99% točnošću i smanjila vrijeme pozicioniranja pacijenta, već je također smanjila dozu zračenja pacijenata i ukupni šum slike. Skraćivanje vremena pregleda pacijenata i brzo dijagnosticiranje bolesti postaje još potrebnije tijekom pandemije COVID-19, jer bi brzi probir i liječenje pacijenata trebali biti važne mjere za suzbijanje pandemije. Funkcija automatskog pozicioniranja automatski otkriva anatomske orijentir pomoću algoritama dubokog učenja i omogućuje minimiziranje radnji pozicioniranja. U tehnici automatskog pozicioniranja i centriranja pacijenata temeljenoj na umjetnoj inteligenciji,

3D kamera detektira informacije o dubini pacijenata i izračuna potrebnu elevaciju stola za postavljanje centriranja u odabranom protokolu. Funkcija automatskog centriranja optimizira dozu zračenja i kvalitetu slike bez obzira na vještinu operatera.

Vrijeme pozicioniranja u skupini s automatskim pozicioniranjem bilo je značajno kraće nego u drugoj skupini: $29,0 \text{ s} \pm 7,0$ naspram $40,0 \text{ s} \pm 11,0$, $p < 0,001$. Točnost pozicioniranja i udaljenost izvan središta određene su pomoću CT slika prsnog koša pacijenta. Značajno veća točnost pozicioniranja zabilježena je u skupini s automatskim pozicioniranjem (126 od 127, 99,0%) naspram skupine s ručnim pozicioniranjem (117 od 127, 92,0%). Sve udaljenosti izvan centra pacijenata dobivene metodom temeljenom na UI bile su značajno manje od onih dobivenih ručnom metodom (srednja udaljenost izvan centra $1,56 \text{ cm} \pm 0,83$ u UI skupini naspram $4,05 \text{ cm} \pm 2,40$ u skupini s ručnim pozicioniranjem, $p < 0,001$).


Šum slike predstavljen je SDev mjerenjem m. erector spinae u gornjim i srednjim područjima prsnog koša. U oba područja, razine šuma na CT slikama dobivenim automatskim pozicioniranjem bile su statistički niže od onih na CT slikama dobivenim ručnom metodom: srednji šum u gornjem dijelu prsnog koša kod grupe s automatskim pozicioniranjem iznosio je $49,7\text{HU} \pm 7,3$ naspram $54,1\text{HU} \pm 9,3$ kod grupe s ručnim pozicioniranjem. Srednji šum u srednjem prsnom košu kod prve grupe iznosio je $48,9\text{HU} \pm 8,5$ naspram $53,9\text{HU} \pm 9,1$ kod druge grupe (oba $p < 0,001$). Međutim, nije bilo značajne razlike za vrijednosti šuma u području aorte i traheje u obje skupine.

Ukratko, studija pokazuje da uporaba automatskog pozicioniranja i centriranja pacijenata temeljenog na umjetnoj inteligenciji rezultira manjom dozom zračenja, većom učinkovitosti pregleda, većom preciznošću pozicioniranja i višom kvalitetom slike na CT snimanju prsnog koša. Ova tehnika ima važnu dodatnu kliničku vrijednost za dijagnosticiranje zaraženih pacijenata kao što su pacijenti s COVID-19 kako bi se smanjio rizik od prijenosa infekcija između pacijenata i medicinskih radnika (15).

4.3.2. Raspon skeniranja

Nakon što je pacijent na odgovarajući način pozicioniran na stolu, operater mora odrediti specifičnu regiju tijela o kojoj će se podaci prikupljati. Ovaj proces također koristi lokalizatorski radiogram. Operater obično mora ručno odrediti liniju na početnu i

završnu poziciju željenog skeniranja. Varijacije od operatera do operatera rezultiraju ili previše ili premalo pokriveno regije. Operateri imaju tendenciju da budu donekle oprezni; stoga često proširuju raspon skeniranja dalje nego što je potrebno kako bi se izbjegla mogućnost isključivanja anatomije iz skeniranja. Algoritmi umjetne inteligencije obučeni su da točno identificiraju specifičnu ljudsku anatomiju iz medicinskih slika. Na temelju indikacije pregleda (a time i uputa koje je operater odabrao za pregled), sustav može automatski odabrati raspon skeniranja koji je optimalno usredotočen na potrebnu anatomske pokrivenost. Na slici 9 vidi se primjena algoritma umjetne inteligencije u automatskom postavljanju raspona skeniranja kako bi pokrio cijelu anatomiju pluća (prozirno sivo polje) ili samo anatomiju srca (tamno sivo polje).



Slika 9. CT lokalizator snimljen u anteriorno-posteriornoj projekciji (lijevo) i u lateralnoj projekciji (desno)

Izvor: <https://link.springer.com/article/10.1007/s00330-020-07629-4>

4.3.3. Odabir parametara akvizicije

Za danu vrstu protokola skeniranja i kliničke indikacije, mnogi parametri moraju biti pravilno odabrani kako bi se optimizirala doza zračenja CT pregleda. Za prikupljanje podataka, ovi su parametri povezani s načinom na koji se zračenje primjenjuje na pacijenta, kako se pomiče stol pacijenta i rendgenska cijev i koriste li se druge posebne tehnike. Trenutno neki AEC sustavi koriste jednostavne tehnike strojnog učenja za odabir optimalnog potencijala cijevi i struje cijevi. Jedna od kompliciranijih

odluka uključuje apliciranje kontrasta i vremena skeniranja, tako da je koncentracija kontrastnog sredstva najveća u području od interesa tijekom prikupljanja podataka. Da bi se to postiglo, prikupljeni su podaci u više vremenskih točaka na velikom broju pacijenata dok je kontrast ubrizgavan i putovao kroz pacijentov kardiovaskularni sustav. Na temelju ovih podataka, algoritam je u stanju predvidjeti konačnu visinu i širinu rezultirajuće krivulje kontrasta u aorti. Na temelju ovih podataka, sustav može predvidjeti cijelu krivulju kontrasta koristeći samo nekoliko podatkovnih točaka na uzlaznom rubu krivulje, na temelju čega se može postaviti optimalno vrijeme skeniranja (Hinzpeter i sur., 2019.). Kliničke studije su pokazale bolju ujednačenost koncentracije kontrasta u rasponu skeniranja paralelno sa smanjenjem potrebne doze kontrastnog sredstva. Smanjenje količine kontrasta može se postići smanjenjem brzine ubrizgavanja, što smanjuje rizik od oštećenja vene u koju se kontrastno sredstvo ubrizgava (15).

4.3.4. Smanjenje doze zračenja na ct-u pomoću rekonstrukcija temeljenih na dubokom učenju (deep learning based reconstruction-DLR)

Kompjuterizirana tomografija, jedna od najrevolucionarnijih inovacija 20. stoljeća, važna je dijagnostička pretraga koja diktira strategije liječenja i omogućuje donošenje vitalnih odluka u svakodnevnoj kliničkoj praksi. Unatoč ogromnim prednostima u širokom rasponu kliničkih stanja i sve većoj upotrebi, i dalje postoji zabrinutost oko potencijalnih rizika izlaganja ionizirajućem zračenju. Ova zabrinutost bila je pokretačka snaga za razvoj nekoliko tehnologija i strategija za smanjenje doze, među kojima su nove metode rekonstrukcije dobile značajnu pozornost od strane dobavljača i istraživača u posljednje vrijeme (16).

Inovacije u CT-u bile su impresivne među slikovnim i medicinskim tehnologijama u domeni hardvera i softvera. Opseg i brzina CT skeniranja poboljšani su uvođenjem CT skenera s više detektorskih redova s detektorima širokog spektra i većim brzinama rotacije gentrija. Kako bi se uhvatila u koštac sa zabrinutošću zbog rastućih doza zračenja zbog njegove sve veće upotrebe i kako bi se poboljšala kvaliteta slike, tehnike CT rekonstrukcije razvile su se od filtrirane povratne projekcije do komercijalnog izdavanja tehnika iterativne rekonstrukcije, a nedavno i rekonstrukcije

slike temeljene na dubokom učenju (DL). Ove novije tehnike rekonstrukcije omogućuju poboljšanu ili zadržanu kvalitetu slike u odnosu na filtriranu povratnu projekciju pri nižim dozama zračenja (16).

Radiologija je svjedočila izvanrednim tehnološkim napretcima počevši s dvodimenzionalnom projekcijskom radiografijom, napredujući do trodimenzionalnih visoko rezolutnih, modernih mogućnosti snimanja presjeka tijela. Među svim slikovnim tehnologijama, računalna tomografija je pronašla sve važniju ulogu za probir, dijagnozu i praćenje različitih kliničkih stanja. CT se pojavio kao modalitet izbora u nekoliko patologija, uključujući traumu, infektivna stanja i onkološka stanja. Od svog uvođenja kao medicinske tehnologije snimanja 1972., CT softver i hardver razvijali su se izuzetno brzim tempom. U usporedbi s današnjim CT skenerima, prijašnji aparati bili su spori jer im je trebalo puno vremena za akviziciju i rekonstrukciju slike, a ipak su stvarali lošu rezoluciju slike. Povijesno gledano, prvi CT je imao vrijeme akvizicije i rekonstrukcije od nekoliko minuta, a svaki je imao razlučivost slike od samo 80×80 piksela. Najsuvremeniji moderni CT skeneri s više detektora mogu snimiti cijelo tijelo za manje od pet sekundi, a cijeli prsni koš, abdomen i zdjelicu za manje od dvije sekunde uz vrijeme rotacije gentrija do 0,25 sekunde i pokrivenost skeniranjem do 16 cm u jednoj rotaciji gentrija. Nekoliko skenera omogućuje rekonstrukciju submilimetarske debljine presjeka s matricom od 1024×1024 , a na nekim skenerima i do 2048×2048 .

Nedavni ključni fokus u CT-u bio je na rekonstrukciji slike, koja je napredovala od prve algebarske rekonstrukcijske metode (AR) 1970-ih do konvencionalnih i tehnika filtrirane povratne projekcije (FBP) od 1980-ih do 2000-ih i tehnike iterativne rekonstrukcije (I-RT) od kasnih 2000-ih. Iako iterativne tehnike rekonstrukcije omogućuju korisnicima da smanje dozu zračenja u usporedbi s FBP uz zadržavanje ili poboljšanje kvalitete slike, postoji zabrinutost zbog gubitka uočljivosti abnormalnosti niskog kontrasta i značajnih promjena u izgledu ili teksturi slike s I-RT. Posljednjih godina umjetna inteligencija otvorila je nove mogućnosti u medicini i medicinskom oslikavanju. Među primjenama umjetne inteligencije u radiologiji, tehnike rekonstrukcije slike temeljene na dubokom učenju pokazale su se obećavajuće u smanjenju doze zračenja na zavidnu razinu (17).

Tehnike filtrirane povratne projekcije (FBP) bile su i na mnogim trenutnim skenerima ostaju poželjna metoda rekonstrukcije slike od otkrića i uvođenja CT skeniranja u kliničku praksu. FBP pruža dovoljnu kvalitetu slike bez značajnih zahtjeva za računskom snagom. Međutim, uz CT niske doze zračenja, šum slike i artefakti na FBP slikama mogu se znatno povećati. Kako bi se riješilo ovo ograničenje FBP-a pri niskim dozama zračenja, napredak u računskoj snazi početkom 2000-ih doveo je do uvođenja I-RT-a u kliničku praksu. Od njihovog uvođenja, I-RT je temelj za rekonstrukciju slike za većinu CT protokola i pregleda. Kako bi omogućili daljnje smanjenje doze, dobavljači CT-a nedavno su uveli tehnike rekonstrukcije slike temeljene na dubokom učenju (DL).

Standardna metoda rekonstrukcije slike u CT-u koristila je povratnu projekciju višestrukih slikovnih podataka pod istim kutom pod kojim su i dobiveni. Međutim, ova metoda je rezultirala zamućenjem generiranih slika, pa je tako razvijena FBP tehnika za izmjenu podataka sinograma korištenjem visokopropusnih filtara prije povratne projekcije. Stvaranjem negativnih slikovnih piksela na rubu slike, rekonstrukcija slike temeljena na FBP-u zanemaruje ravna područja kako bi se odabrali oštri rubovi. To poboljšava oštrinu slike i smanjuje zamućene rubove. Unatoč korištenoj jednostavnoj matematici, FBP radi na pretpostavkama i ne uzima u obzir geometriju konusnog snopa izračunatih podataka smatrajući da je pojedinačna detektorska ćelija beskonačno mala. Čak i danas, FBP ostaje dominantna metoda rekonstrukcije slike na većini ranih CT skenera s jednim ili nekoliko detektorskih redova do većih detektorskih nizova zbog svoje brzine i prihvatljive kvalitete slike. Međutim, s pojavom skenera koji mogu generirati tanje slojeve na finijoj matrici i važnosti smanjenja povezane doze zračenja, tehnike rekonstrukcije slike temeljene na FBP-u povezane s većim šumom slike i artefaktima više se ne smatraju idealnima (17).

Kako bi se riješila ograničenja rekonstrukcije slike temeljene na FBP-u, razvijene su metode iterativne rekonstrukcije temeljene na sinogramu. Metode iterativne rekonstrukcije zahtijevaju veću računsku snagu i stoga se obično implementiraju na grafičkim procesorskim jedinicama (GPU). Iterativne tehnike rekonstrukcije mogu se klasificirati kao hibridne (HI-RT) i I-RT-ove temeljene na modelu (MI-RT). U HI-RT, iterativno filtriranje podataka o projekciji i slikovnih podataka smanjuje artefakte i šum slike. U usporedbi s HI-RT, MI-RT ima veći potencijal smanjenja šuma i artefakata, te


stoga može omogućiti veće smanjenje doze zračenja povezanog s CT skeniranjem. Nekoliko studija je izvijestilo da MI-RT može smanjiti dozu zračenja više od HI-RT i FBP, uz održavanje kvalitete slike za nekoliko rutinskih i nerutinskih kliničkih indikacija i područja tijela i u odraslih i kod pedijatrijskih pacijenata (17).

S boljim računalnim sposobnostima u hardverskoj i softverskoj domeni, dostupnošću podataka za obuku, validaciju i testiranje, tehnike rekonstrukcije temeljene na umjetnoj inteligenciji pojavile su se kao održive opcije za rekonstrukciju CT slike. Sustavi strojnog učenja rade na prepoznavanju uzoraka i zahtijevaju iskustvo i stručnost u projektiranju prve komponente sustava, nazvane ekstraktor značajki. Pikseli slike mogu se promijeniti u prikladan prikaz podataka ili vektor značajki pomoću alata za izvlačenje značajki. Nakon ekstrakcije značajke, klasifikator, još jedna ključna komponenta, može otkriti i klasificirati uzorke unosa. U dubokom učenju (DL), glavnoj komponenti strojnog učenja, duboke neuronske mreže koriste više slojeva umjetnih neurona sposobnih za izvođenje matematičkih izračuna za dodijeljeni zadatak. Različiti matematički izračuni zasebno se primjenjuju za kvantitativne slike i radiomiku, zajedno s nenadziranim i nadziranim strojnim učenjem za dodavanje dijagnostičkih informacija. DL može rukovati mnogim podacima, naučiti i koristiti različite strukture modela izvan ljudskih sposobnosti. Kada se prikaže s velikim označenim i neobilježenim podacima, DL može izdvojiti važne značajke. Za razliku od tradicionalnog strojnog učenja, mogućnost učenja prikaza podataka uklanja potrebu za korištenjem ručno izrađenih značajki za duboko učenje. Stoga se primjene dubokog učenja u radiologiji povećavaju za detekciju objekata, segmentaciju slike i klasifikaciju. Dok se većina primjena dubokog učenja fokusira na analizu slike, koja je od neprocjenjive važnosti za radiologiju, DL je pronašao novi teren u rekonstrukciji CT slike (17).

Algoritmi dubokog učenja se mogu podklasificirati u složene autoenkodere, duboke Boltzmannove strojeve, duboke neuronske mreže (DNN), konvolucijske neuronske mreže (CNN) i ostale. Unaprijed obučeni algoritmi temeljeni na DL-u koriste prikaze podataka za generiranje kodiranja slike za klasifikaciju. Tehnike rekonstrukcije slike temeljene na DL mogu generirati visoku kvalitetu slike pri niskim razinama šuma i izvesti bolju rekonstrukciju slike čak i na tanjim slojevima, što je inherentno ograničenje FBP-a i nekih iterativnih tehnika rekonstrukcije.

4.3.4.1 Smanjenje doze zračenja na CT-u pomoću rekonstrukcije temeljene na dubokom učenju (DLR): studija na fantomu

Tehnike strojnog učenja primjenjuju se u različitim područjima kao što je opće prepoznavanje objekata. Takve tehnike u medicinskom slikovnom području uglavnom se koriste za računalno potpomognutu dijagnostiku (CAD). Posljednjih godina duboka konvolucijska neuronska mreža (DCNN) koja je vrsta strojnog učenja naširoko se koristi za CAD i pokazuje visoke performace. DCNN se može koristiti ne samo za opći CAD koji otkriva lezije, već i za aplikacije kao što su filtri koji uklanjaju artefakte. Osim toga, korišten je za uklanjanje specifičnih objekata koji ometaju dijagnozu. Također, razvijena je tehnika rekonstrukcije slike kompjutorizirane tomografije pod nazivom "Rekonstrukcija temeljena na dubokom učenju (DLR)" koja uključuje filtar za smanjenje šuma i artefakata od strane DCNN-a. Navedena tehnika također ima sposobnost smanjenja doze zračenja.



Slika 10. Shema DLR tehnike. Procesi filtriranja koji uklanjaju šum slike i artefakte radi poboljšanja pouzdanosti signala dio su procesa rekonstrukcije slike.

Izvor: <https://epos.myesr.org/poster/esr/ecr2018/C1656/Methods%20and%20materials#poster>

Studija na fantomu (27) koja je proučavala utjecaj rekonstrukcija temeljenih na dubokom učenju na smanjenje doze zračenja provedena je skeniranjem 200 mm akrilnog fantomskog cilindra pomoću CT od 320 redova detektora sa 120 kV napona cijevi. Referentna struja cijevi određena je na 100 mA korištenjem automatske

modulacije struje cijevi. Kako bi se procijenila sposobnost DLR-a na smanjenje doze zračenja, fantom je skeniran strujom cijevi od 10 do 100 mA u intervalu od 10 mA. Skup podataka slika rekonstruiran je hibridnom iterativnom rekonstrukcijom (hibridna IR) (AIDR 3D, Canon Medical Systems Corporation) i rekonstrukcijom temeljenom na dubokom učenju (DLR). Procjenjivale su se karakteristike šuma skupa podataka korištenjem spektra snage šuma (NPS) i standardne devijacije (SD) CT broja (27).

Vrijednost SD na slici referentne doze (100 mA) rekonstruirane hibridnim IR-om i one pri 20 mA rekonstruirane DLR-om bile su ekvivalentne (13,7 HU nasuprot 13,2 HU). Ovaj rezultat je pokazao da bi DLR mogao smanjiti 80% izloženosti zračenju s gledišta SD vrijednosti. Međutim, čak i ako je SD ekvivalentan, dijagnostička sposobnost slike je degradirana kada je omjer niskofrekventnog šuma velik. Zaključak je da bi DLR mogao smanjiti najmanje 30% izloženosti zračenju u usporedbi s konvencionalnom rekonstrukcijom.

Iz procjene standardne devijacije CT broja, slika sa redukcijom doze zračenja od 20% rekonstruirana DLR-om bila je ekvivalentna slici referentne doze rekonstruiranoj hibridnim IR-om. Kada se uzimaju u obzir karakteristike šuma pomoću NPS-a, čak i ako je doza zračenja smanjena za 30%, slika rekonstruirana DLR-om superiornija je slici referentne doze rekonstruirane hibridnim IR-om. Uzimajući u obzir dobivene rezultate, zaključci studije su da bi DLR mogao smanjiti najmanje 30% doze zračenja u usporedbi s konvencionalnim hibridnim IR-om (27).

DLR koji uključuje konvolucijske neuronske mreže – koje se sastoje od više slojeva matematičkih jednadžbi – u proces rekonstrukcije slike smanjuje šum slike, poboljšava prostornu razlučivost i zadržava poželjnu teksturu šuma na CT slikama.

Primjena DLR tehnike omogućuje značajno smanjenje doze na CT-u koji se izvodi za različite kliničke indikacije uz očuvanje kvalitete dijagnostičke slike.

4.4. KORIŠTENJE UMJETNE INTELIGENCIJE U OPTIMIZACIJI DOZE NA „LOW DOSE“ CT-u

Kompjutorizirana tomografija ima ključnu ulogu u medicinskoj slikovnoj praksi. CT može proizvesti dvodimenzionalne ili trodimenzionalne slike dijela tijela pacijenta. S povećanjem broja CT skeniranja, godišnja efektivna doza po glavi stanovnika udvostručila se tijekom posljednjih 15 godina. Istodobno, to je povećalo zabrinutost zbog opasnosti od zračenja CT-om (17). Optimizacija doze CT-a važna je kako bi se smanjili rizici od pretjeranoga zračenja pacijenata. Cilj optimizacije doze je minimizirati dozu zračenja u dijagnostičkom oslikavanju uz održavanje kvalitete slike na prihvatljivoj razini kvalitete, osiguravajući dijagnostičku točnost. ALARA principom moguće je primijeniti određene mjere za smanjenje doze koliko je to moguće. Promjenom parametara skeniranja kao što su struja cijevi (mA), nagib, potencijal/napon cijevi (kVp) i vrijeme rotacije/ekspozicije (s), može se postići smanjenje doze CT-a. Na primjer, kod CT-a prsnog koša moguće je dozu zračenja smanjiti na 3 mGy s tehnikama iterativne rekonstrukcije, u usporedbi s 12 mGy koristeći tehnike filtrirane stražnje projekcije. Do sada su razvijene različite strategije za redukciju doze na CT-u, međutim, to može dovesti do kompromitirane kvalitete CT slike, u smislu kontrasta i razlučivosti, te nastajanja šuma i artefakata. Kvaliteta slike u CT-u može se procijeniti ispitivanjem omjera signala i šuma, razlučivosti slike, radnih karakteristika prijemnika (ROC) ili analize vizualnog gradiranja (VGA).

Low dose CT prvi je put uveden 1990-ih za probir raka pluća. Danas su CT s malim dozama (low dose CT) usporedivi s redovitim CT pretragama, u smislu dijagnostičke izvedbe i sposobnosti karakterizacije (18). Prema velikoj europskoj studiji o medicinskim dozama zračenja, prosječna učinkovita doza za redoviti CT prsnog koša je 6,6 mSv.

CT skeniranje se smatra low dose CT-om kada je doza manja od 1 mSv (19). Ultraniške doze CT-a mogu doseći razinu doze bliske običnoj rendgenskoj snimci prsnog koša. Smanjenjem struje cijevi (mAs), a time i doze zračenja, izravno se povećava količina šuma na CT slikama. Šum slike može se smanjiti povećanjem napona

cijevi (kVp) ili struje cijevi (mAs), smanjenjem brzine rotacije gentrija ili smanjenjem vrijednosti pitch faktora.

Pojava kompjuterizirane tomografije s niskim dozama (LDCT) pružila je priliku za otkrivanje karcinoma pluća u ranoj fazi i potencijal za smanjenje ukupne smrtnosti pacijenata oboljelih od raka pluća. U 2020. godini, rak pluća bio je drugi najčešći rak i vodeći uzrok smrti od raka kod muškaraca i žena u SAD-u (20). Većina pacijenata s dijagnozom raka pluća imala je udaljenu ili metastatsku bolest; manje od 20% ima dijagnosticiranu lokaliziranu bolest (tj. stadij 1). Rak pluća tradicionalno se klasificira u dvije glavne kategorije: karcinom pluća nemalih stanica (NSCLC) koji uključuje adenokarcinom, karcinom skvamoznih stanica i karcinom velikih stanica te karcinom malih stanica pluća, koji je agresivniji i ima lošije stope preživljavanja. Otprilike 85% karcinoma pluća je NSCLC (21). Rizik od razvoja raka pluća je u velikoj mjeri određen dobi i pušačkim statusom osobe, a procjenjuje se da pušenje uzrokuje gotovo 90% svih karcinoma pluća. Ostali čimbenici rizika za rak pluća uključuju izloženost okolišu, terapiju zračenjem, druge (nekancerogene) bolesti pluća, rasu/etničku pripadnost i obiteljsku anamnezu. U 2013. Radna skupina *US Preventive Services Task Force* (USPSTF) preporučila je godišnji probir karcinoma pluća kompjuteriziranom tomografijom niskom dozom (LDCT) kod odraslih u dobi od 55 do 80 godina koji imaju 30-godišnju povijest pušenja i trenutno puše ili su prestali u posljednjih 15 godina. Nacionalno ispitivanje raka pluća nedavno je pokazalo da probir visokorizičnih populacija uz korištenje niskih doza računalne tomografije (LDCT) smanjuje smrtnost od raka pluća (22). Na temelju ovog ohrabrujućeg rezultata, smjernice National Comprehensive Cancer Network-a preporučile su LDCT za odabrane pacijente s visokim rizikom od raka pluća. To sugerira da će se obavljati sve veći broj LDCT pregleda. LDCT tehnika je relativno jednostavna, ali neki CT parametri su važni i trebaju biti točno definirani kako bi se postigla dobra dijagnostička kvaliteta i minimizirala isporučena doza zračenja. Zbog visoke kontrastne rezolucije između zraka i plućnih nodula, LDCT omogućuje nisku dozu zračenja uz održavanje dobre dijagnostičke kvalitete. Ne postoji konsenzus o tome koja se razina doze smatra niskom dozom, a čimbenici koji utječu na dozu u CT-u su različiti, kao što su napon cijevi (kVp, kilovolti vrh), struja cijevi (mA, miliamper) i brzina rotacije cijevi (s, sekunda). Nedavna studija, usmjerena na određivanje distribucije efektivne doze povezane s


jednim LDCT pregledom, zaključila je da se prihvatljivi CT probir može postići uz ukupnu prosječnu efektivnu dozu od približno 2 mSv.

4.4.1. Pristupi metode „deep learning“ u kompjuteriziranoj tomografiji niskim dozama (LDCT)

Posljednjih godina uočen je značajan napredak u umjetnoj inteligenciji, koja ima primjenu u raznim djelatnostima i znanosti. AI se može definirati kao tehnologija koja koristi računalne algoritme učenja za rješavanje problema. To je širok pojam koji može sadržavati algoritme dubokog učenja ili strojnog učenja. Za CT niske doze, UI tehnologije, uključujući strojno učenje, korištene su za transformaciju slika CT niske doze u visokokvalitetne preglede. Rješenja temeljena na umjetnoj inteligenciji mogu smanjiti šum u slikama nastalim low dose CT-om. Strojno učenje može brzo obraditi veliku količinu medicinskih slikovnih podataka i identificirati složene interakcije i asocijacije iz visokodimenzionalnih podataka, kako bi se omogućila rana i točna dijagnoza bolesti (23).

Razvijena su različita rješenja za rekonstrukciju CT slike s malom dozom, kao što su adaptivna statistička iterativna rekonstrukcija (ASIR) i algoritmi iterativne rekonstrukcije temeljeni na novom modelu (MBIR). Uz pomoć umjetne inteligencije, radiološki tehnolozi sada mogu izvesti CT preglede sa smanjenim dozama. Optimizacija je posebno važna u pregledima koji koriste veće doze ionizirajućeg zračenja, uključujući CT skeniranja. Postoje brojne istraživačke studije o tome kako UI tehnologije mogu pomoći u optimizaciji doze u LDCT-u na različite načine, uključujući smanjenje šuma na slikama LDCT-a, pretvaranje slika niske doze u normalne obnavljanjem struktura i očuvanjem detalja.

Razvijeni su različiti modeli dubokog učenja kako bi se smanjili šumovi koji nastaju na slikama LDCT-a, uključujući Generative Adversarial Network (GAN), Convolutional Neural Network (CNN) i Recurrent Neural Network (RNN). Ovi modeli su kategorizirani u dvije skupine na temelju stupnja primjene modela dubokog učenja; prije rekonstrukcije i poslije rekonstrukcije (23).



Slika 11. Mreže dubokog učenja za smanjenje šuma na slikama LDCT-a: konvolucijske neuronske mreže (CNN), rekurentne neuronske mreže (RNN) i generativne adversarijske mreže (GAN). Svaki blok predstavlja skriveni sloj podataka u mrežama dubokog učenja.

Izvor: [https://www.radiographyonline.com/article/S1078-8174\(21\)00090-0/fulltext](https://www.radiographyonline.com/article/S1078-8174(21)00090-0/fulltext)

Kompjutorizirana tomografija je široko korišten medicinski modalitet slike u kliničkoj medicini budući da daje izvrsne vizualizacije finih strukturnih detalja ljudskog tijela. Protokoli za skeniranje niskim dozama (LDCT) kompromitiraju omjer signala i šuma CT slika zbog nastajanja šuma i artefakata u prostoru slike. Stoga su tijekom posljednjih desetljeća osmišljene različite metode za proizvodnju visokokvalitetnih CT slika iz slika LDCT-a. U novije vrijeme, za razliku od konvencionalnih metoda, pristupi pretvaranja LDCT slika temeljeni su na dubokom učenju (DL) upravo zbog svojih karakteristika, visokih performansi i brzog izvršenja.

Kompjutorizirana tomografija jedan je od pouzdanih i neinvazivnih modaliteta koji pomaže u otkrivanju patoloških abnormalnosti u ljudskom tijelu kao što su tumori, vaskularne bolesti, plućni noduli, unutarnje ozljede i prijelomi kostiju. Uz dijagnostičku podršku, CT je također koristan u vođenju različitih kliničkih postupaka, uključujući intervencije, terapije zračenjem i operacije. Međutim, često izlaganje CT skeniranju pacijenta izlaže riziku zračenja. Prekomjerno izlaganje zračenju može uzrokovati razvoj metaboličkih abnormalnosti, raka uzrokovanog zračenjem i drugih genetskih poremećaja koji brzo smanjuju kvalitetu života pacijenata. Stoga su predloženi protokoli CT (LDCT) skeniranja s niskim dozama kako bi se smanjila izloženost pacijenata zračenju uz održavanje odgovarajuće dijagnostičke kvalitete.

CT skeniranje je rendgenski postupak koji stvara 2D ili 3D slike presjeka uz pomoć računalne obrade. CT snimci su detaljniji od konvencionalnih rendgenskih

snimaka i mogu otkriti oblik, dimenzije, gustoću i unutarnje defekte različitih anatomija. Sukladno tome, CT skener koristi motorizirani izvor rendgenskih zraka koji ispušta uske snopove rendgenskih zraka dok se rotira oko pacijenta. Postoje posebni digitalni detektori X-zraka koji se nalaze točno nasuprot izvora zračenja. Dok X-zrake prolaze kroz pacijenta, detektori ih registriraju i prenose na računalo. Rekonstruirani slojevi mogu se prikazati pojedinačno u 2D obliku ili se složiti zajedno kako bi se generirala 3D slika. Analiza i ispravljanje kvalitete CT slike nakon rekonstrukcije obvezni su zadatak naknadne obrade. To je uglavnom uzrokovano smanjenom kvalitetom rekonstrukcije na koju utječe smanjenje struje rendgenske cijevi koja se radi kako bi se spriječilo štetno izlaganje pacijenata zračenju.

Strojno učenje (ML) je grana umjetne inteligencije koja olakšava aplikaciji da automatski uči i da se poboljšava kroz iskustvo, a ne korištenjem korisnički definiranih programa. ML postiže ovo automatsko učenje pomoću tehnike koja se naziva učenje značajki. Cilj učenja značajki je pomoći aplikaciji ML-a u automatskom pronalaženju reprezentacija potrebnih za rješavanje ciljanog problema ML-a.

Duboko učenje (DL) je poznato kao metoda učenja predstavljanja. Omogućuje računalu da automatski pronađe prikaze iz sirovih podataka potrebnih za klasifikaciju i detekciju. Dakle, DL model se sastoji od više razina prikaza značajki (više skrivenih slojeva osim ulaznih i izlaznih slojeva) počevši od sirovog ulaza do apstraktnije više razine. Dakle, ova značajka visoke razine hvatanja DL modela pokazuje svoju sposobnost da nauči nesigurne distribucije šuma preko LDCT slika tijekom učenja temeljenog na podacima. Osim toga, metoda učenja temeljena na podacima može se učinkovito prilagoditi bilo kojoj vrsti šuma. Stoga poboljšava ukupnu učinkovitost pretvorbe LDCT slika i posjeduje novu prednost u odnosu na druge metode LDCT pretvorbe (23).

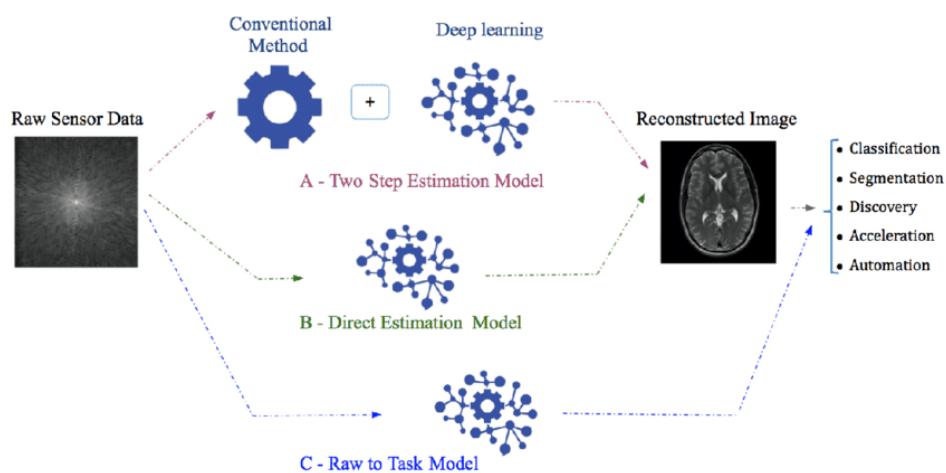
Zbog svoje učinkovitosti sve više se preporuča rekonstrukcija slike temeljena na dubokom učenju na LDCT-u. Korištenjem različitih metoda dubokog učenja, smanjenje šuma slike može se postići prije ili poslije rekonstrukcije. Kod niskodoznog CT-a koristi se manje zračenja što može biti štetno za kvalitetu slike, osobito s povećanom razinom šuma. Stoga se predlaže korištenje tehnike smanjenja šuma temeljene na umjetnoj inteligenciji. Stare tehnike rekonstrukcije CT slike na low dose CT-u još uvijek se

široko koriste u trenutnoj kliničkoj praksi, ali usvajanjem umjetne inteligencije kvaliteta slike može se značajno poboljšati (24).

Rješenja temeljena na umjetnoj inteligenciji također su raznolika u pogledu svoje arhitekture. Mogu postojati ograničenja, na primjer s mrežnim mogućnostima ili nedovoljnom kvalitetom slike. S rješenjima umjetne inteligencije, CT skeniranja s niskim dozama mogu se optimizirati i izvesti uz niže zračenje. Također je važno razmotriti etičku stranu i koristiti samo rješenja koja su sigurna i etički prihvatljiva (24).

Umjetna inteligencija je zadobila značajan interes zbog svog potencijala poboljšavanja rekonstrukcije CT slika. Više istraživačkih skupina radi na primjeni umjetne inteligencije na poboljšanju rekonstrukcije CT slika. Metode dubokog učenja omogućuju implementaciju složenijih funkcija, koje imaju potencijal omogućiti CT preglede s nižim dozama i CT s rijetkim uzorkovanjem. Ove UI tehnike imaju potencijal smanjiti doze CT zračenja uz ubrzavanje vremena rekonstrukcije. Također, duboko učenje može se koristiti za optimizaciju kvalitete slike bez smanjenja doze zračenja, npr. naprednijom DECT monokromatskom rekonstrukcijom slike i redukcijom metalnih artefakata. Ove metode još nisu spremne za kliničku primjenu; međutim, očekuje se da će UI u bliskoj budućnosti igrati glavnu ulogu u rekonstrukciji CT slike. Očekuje se da će se UI uklopiti u trenutni tijek kliničkog CT snimanja poboljšavajući postojeće metode rekonstrukcije, na primjer značajno ubrzavajući proces rekonstrukcije budući da se primjena obučene mreže može izvršiti trenutačno.

Zaključno, metode rekonstrukcije slike temeljene na dubokom učenju postaju sve popularnije zbog svojih prednosti u usporedbi sa starim i sadašnjim metodama rekonstrukcije slike temeljene na tehnikama filtrirane povratne projekcije i iterativne rekonstrukcije. Prednosti dubokog učenja uključuju veće smanjenje šuma slike, poboljšanje teksture slike i smanjenje artefakata u usporedbi s drugim tehnikama rekonstrukcije slike.



Slika 12. Vizualizacija uobičajenih paradigmi rekonstrukcije temeljene na dubokom učenju iz neobrađenih senzorskih podataka. Prikazan je model obrade u dva koraka gdje duboko učenje nadopunjuje konvencionalne metode

Izvor: https://www.researchgate.net/figure/A-Biomedical-image-processing-workflow-usually-involves-two-steps-optimized_fig2_339616185

5. ZAKLJUČAK

CT je jedna od najvažnijih dijagnostičkih pretraga u svakodnevnoj kliničkoj praksi. Unatoč golemim prednostima ove pretrage, i dalje postoji zabrinutost oko hipotetskih rizika izlaganja ionizirajućem zračenju. Ova zabrinutost bila je razlog za razvoj nekoliko tehnologija i strategija za smanjenje doze, među kojima su nove metode rekonstrukcije CT-a dobile značajnu pozornost od strane dobavljača i istraživača u posljednje vrijeme. Optimizacija doze zračenja CT-a važna je stavka kako bi se smanjili rizici od zračenja pacijenata. Cilj optimizacije doze je minimizirati dozu zračenja u dijagnostičkom oslikavanju uz održavanje kvalitete slike na prihvatljivoj razini, osiguravajući dijagnostičku točnost. Niz mjera za smanjenje doze na što nižu razumnu mjeru čini ALARA strategiju.

Zabrinutost oko potrebe za optimizacijom i smanjenjem doze CT zračenja dovela je do poboljšane učinkovitosti CT skenera i uvođenja nekoliko tehnika rekonstrukcija i koje se temelje na umjetnoj inteligenciji (UI). Tehnike umjetne inteligencije mogu se koristiti u svakoj fazi CT pregleda kako bi se poboljšala kvaliteta dobivenih slika, poboljšao radni tijek, smanjio šum slike, a sve uz smanjenje doze zračenja za pacijenta. Trenutačno korištenje trodimenzionalne infracrvene kamere omogućuje automatizirano pozicioniranje pacijenta u izocentru. Korištenje automatskog pozicioniranja i centriranja pacijenta temeljenog na umjetnoj inteligenciji rezultira manjom dozom zračenja, većom učinkovitošću pregleda, većom preciznošću pozicioniranja i višom kvalitetom slike. Ova tehnika ima važnu dodanu kliničku vrijednost za dijagnosticiranje infektivnih pacijenata kao što su pacijenti s COVID-19 infekcijom, kako bi se smanjio rizik od prijenosa infekcije između pacijenata i medicinskih radnika. Važna primjena umjetne inteligencije je kod CT-a niskih doza (low dose CT, LDCT). LDCT ima tendenciju da proizvodi nižu kvalitetu slike od uobičajene kompjuterizirane tomografije, međutim tehnologije umjetne inteligencije, posebno duboko učenje, mogu pomoći u poboljšanju kvalitete slike LDCT-a smanjenjem šuma.

Metode rekonstrukcije slike temeljene na dubokom učenju sve su popularnije zbog svojih prednosti u usporedbi sa starim i sadašnjim metodama rekonstrukcije slike temeljene na tehnikama filtrirane povratne projekcije i iterativne rekonstrukcije. Prednosti dubokog učenja uključuje veće smanjenje šuma slike, poboljšanje teksture slike i smanjenje artefakata u usporedbi s drugim tehnikama rekonstrukcije slike.

6. LITERATURA

1. McCollough CH, Leng S. Use of artificial intelligence in computed tomography dose optimisation. *Annals of the ICRP*. 2020;49(1_suppl):113-125. doi:10.1177/0146645320940827
2. Basu, Kanadpriya et al. "Artificial Intelligence: How is It Changing Medical Sciences and Its Future?." *Indian journal of dermatology* vol. 65,5 (2020): 365-370. doi:10.4103/ijd.IJD_421_20
3. J. Hu, H. Niu, J. Carrasco, B. Lennox and F. Arvin, "Voronoi-Based Multi-Robot Autonomous Exploration in Unknown Environments via Deep Reinforcement Learning," in *IEEE Transactions on Vehicular Technology*, vol. 69, no. 12, pp. 14413-14423, Dec. 2020, doi: 10.1109/TVT.2020.3034800.
4. Domingos, Pedro (22 September 2015). *The Master Algorithm: How the Quest for the Ultimate Learning Machine Will Remake Our World*. Basic Books. ISBN 978-0465065707.
5. Hosny A, Parmar C, Quackenbush J, Schwartz LH, Aerts HJWL. Artificial intelligence in radiology. *Nat Rev Cancer*. 2018;18(8):500-510. doi:10.1038/s41568-018-0016-5
6. Litjens G et al. A survey on deep learning in medical image analysis. *Med. Image Anal* 42, 60–88 (2017).
7. McDonald RJ et al. The effects of changes in utilization and technological advancements of cross-sectional imaging on radiologist workload. *Acad. Radiol* 22, 1191–1198
8. OECD (2017) *Health at a glance 2017: OECD indicators*. OECD Publishing, Paris
9. Singh R, Wu W, Wang G, Kalra MK. Artificial intelligence in image reconstruction: The change is here. *Phys Med*. 2020 Nov;79:113-125. doi: 10.1016/j.ejmp.2020.11.012. Epub 2020 Nov 24. PMID: 33246273.
10. C.G. Macias, J.J. Sahouria The appropriate use of CT: quality improvement and clinical decision-making in pediatric emergency medicine *Pediatr Radiol*, 41 (S2) (2011), pp. 498-504

11. Park EA, Lee W, Kang JH, Yin YH, Chung JW, Park JH. The image quality and radiation dose of 100-kVp versus 120-kVp ECG-gated 16-slice CT coronary angiography. *Korean J Radiol.* 2009;10:235–243.
12. Booiij, R., Budde, R.P.J., Dijkshoorn, M.L., et al. 2019. Accuracy of automated patient positioning in CT using a 3D camera for body contour detection. *Eur. Radiol.* 29, 2079–2088.
13. Marsh RM, Silosky MS (2017) The effects of patient positioning when interpreting CT dose metrics: a phantom study. *Med Phys* 44(4):1514–1524. <https://doi.org/10.1002/mp.12137>
14. Shi F, Wang J, Shi J et al (2020) Review of artificial intelligence techniques in imaging data acquisition, segmentation and diagnosis for covid-19. *IEEE Rev Biomed Eng.*
15. Gang, Y., Chen, X., Li, H. et al. A comparison between manual and artificial intelligence–based automatic positioning in CT imaging for COVID-19 patients. *Eur Radiol* 31, 6049–6058 (2021). <https://doi.org/10.1007/s00330-020-07629-4>
16. Kambadakone A. Artificial Intelligence and CT Image Reconstruction: Potential of a New Era in Radiation Dose Reduction. *J Am Coll Radiol.* 2020 May;17(5):649-651. doi: 10.1016/j.jacr.2019.12.025. Epub 2020 Jan 28. PMID: 32004484.
17. Ramandeep S., Weiwen W. Review paper Artificial intelligence in image reconstruction: The change is here; Review paper: 2020
18. Hinzpeter, R., Eberhard, M., Gutjahr, R., et al. 2019. CT angiography of the aorta: contrast timing by using a fixed versus a patient-specific trigger delay. *Radiology* 291, 531–538.
19. Padole A., Ali Khawaja R.D., Kalra M.K., Singh S. CT radiation dose and iterative reconstruction techniques. *AJR Am J Roentgenol.* 2015; 204 (PMID: 25794087): W384-W392
20. Padole A., Ali Khawaja R.D., Kalra M.K., Singh S., CT radiation dose and iterative reconstruction techniques., *AJR Am J Roentgenol.* 2015; 204 (PMID: 25794087): W384-W392
21. European Union, European Commission Radiation Protection No. 180. Medical radiation exposure of the European population., 2014

22. National Cancer Institute. Surveillance, Epidemiology, and End Results Program: Cancer Stat Facts: lung and bronchus cancer. Accessed December 28, 2020.
23. American Cancer Society. What is lung cancer? Published 2019. Accessed March 18, 2019.
24. National Lung Screening Trial Research Team, Aberle DR, Adams AM, et al. Reduced lung-cancer mortality with low-dose computed tomographic screening. *N Engl J Med.* 2011;365(5):395-409. doi:10.1056/NEJMoa1102873
25. Kulathilake, K.A.S.H., Abdullah, N.A., Sabri, A.Q.M. et al. A review on Deep Learning approaches for low-dose Computed Tomography restoration. *Complex Intell. Syst.* (2021).
26. E. Immonen, J. Wong, M. Nieminen, L. Lanca, F. Guan, E. Metsälä, The use of deep learning towards dose optimization in low-dose computed tomography: A scoping review , 2021
27. T. Higaki¹, E. Nishimaru¹, Y. Nakamura¹, F. Tatsugami¹, Z. Yu², J. Zhou², A. Prabhu Verleker³, N. Akino³, K. Awai¹; ¹Hiroshima/JP, ²Vernon Hills, IL/US, ³Otawara/JP, Radiation dose reduction in CT using Deep Learning based Reconstruction (DLR): A phantom study:2018

7. POPIS KRATICA

CT – kompjutorizirana tomografija (*eng. computed tomography*)

UI – umjetna inteligencija (*eng. artificial intelligence*)

SNR – odnos signal-šum (*eng. signal-to-noise ratio*)

ALARA- “*as low as reasonably achievable*”

CAD – kompjuterski potpomognuta dijagnostika (*eng. computer-aided diagnosis*)

LDCT- kompjuterizirana tomografija niskim dozama (*eng. low-dose computed tomography*)

AEC- automatska kontrola ekspozicije (*eng. automatic exposure control*)

CTDI- CT dozni indeks (*eng. CT dose indeks*)

ML- strojno učenje (*eng. machine learning*)

DL- duboko učenje (*eng. deep learning*)

CNN- konvolucijska neuralna mreža (*eng. convolutional neural network*)

DLR – rekonstrukcije temeljene na dubokom učenju (*eng. deep learning–based reconstruction*)

8. ŽIVOTOPIS

Ime i prezime: Mate Marasović

Datum i mjesto rođenja: 28.01.1997., Split

Državljanstvo: hrvatsko

E-mail: matemarasovic1@gmail.com

OBRAZOVANJE I OSPOSOBLJAVANJE

listopad 2019.-danas	Diplomski studij radiološka tehnologija Sveučilišni odjel zdravstvenih studija Sveučilište u Splitu
svibanj 2019.-lipanj 2019.	Razlikovni modul Sveučilišni odjel zdravstvenih studija Split
listopad 2015 - srpanj 2018.	Fakultet zdravstvenih studija, Rijeka Smjer: Radiološka tehnologija
rujan 2011. - lipanj 2015.	V. Gimnazija „Vladimir Nazor“, Split

RADNO ISKUSTVO

studeni 2021.-danas	KBC Rijeka Zavod za dijagnostičku i intervencijsku radiologiju
lipanj 2021.- listopad 2021.	Klinička bolnica Dubrava, Zagreb Odjel za nuklearnu medicinu
prosinac 2018.-prosinac 2019 -	Dom zdravlja PGŽ, KBC Rijeka

ZNANJA I VJEŠTINE:

Strani jezici: Engleski jezik, Talijanski jezik

Vozačka dozvola: B kategorija

Poznavanje rada na računalu: Windows operativni sustavi Microsoft Office (Word, Exel, Access, Power Point, Outlook)