

Mogućnosti primjene umjetne inteligencije u vaskularnoj kirurgiji

Naletilić, Fran

Master's thesis / Diplomski rad

2024

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, School of Medicine / Sveučilište u Zagrebu, Medicinski fakultet**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:105:161060>

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

Download date / Datum preuzimanja: **2024-09-01**



Repository / Repozitorij:

[Dr Med - University of Zagreb School of Medicine Digital Repository](#)



SVEUČILIŠTE U ZAGREBU
MEDICINSKI FAKULTET

Fran Naletilić

Mogućnosti primjene umjetne inteligencije u
vaskularnoj kirurgiji

DIPLOMSKI RAD



Zagreb, 2024.

Ovaj diplomski rad izrađen je u Zavodu za vaskularnu kirurgiju Kliničkog bolničkog centra Zagreb pod vodstvom doc. dr.sc. Tomislav Meštrović, dr.med i predan je na ocjenu u akademskoj godini 2023/2024.

SKRAĆENICE

UI — Umjetna inteligencija

DALY — godine života prilagođene invalidnosti (engl. *Disability-adjusted life years*)

KVB — Kardiovaskularna bolest

AAA — Aneurizma abdominalne aorte

PAOB — Periferna arterijska okluzivna bolest donjih ekstremiteta

CVB — Cerebrovaskularne bolesti

DVT — Duboko venska tromboza

PE — Plućna embolija

TIA — Tranzitorni ishemijski napad

EVAR — Endovaskularne rekonstrukcije aneurizme abdominalne aorte

CT — Kompjutorizirana tomografija

CTA — Kompjutorizirana tomografija angiografija

MRI — Magnetska rezonanca (engl. *Magnetic resonance imaging*)

SPECT — kompjuterizirana tomografija s emisijom jednog fotona

POSSUM — Fiziološki i operativni indeks za procjenu smrtnosti i morbiditeta (engl. *Physiological and Operative Severity Score for enUmeration of Mortality and Morbidity*)

SADRŽAJ

SAŽETAK

SUMMARY

1. UVOD	1
2. UMJETNA INTELIGENCIJA	2
2.1. Povijest umjetne inteligencije	2
2.2. Osnove umjetne inteligencije.....	3
2.3. Strojno učenje	3
2.4. Računalni vid	5
2.5. Duboko učenje	5
2.6. Korištenje umjetne inteligencije u medicini	6
3. EPIDEMIOLOGIJA I ETIOLOGIJA BOLESTI VASKULARNE KIRURGIJE	7
3.1. Epidemiologija aterosklerotske kardiovaskularne bolesti	7
3.2. Etiologija i epidemiologija vaskularnih bolesti	8
3.3. Metode procjene i stratifikacije rizika	10
3.4. Komplikacije operacija	11
4. PRIMJENA UMJETNE INTELIGENCIJE U DIJAGNOSTICI	12
4.1. Ehokardiografija	12
4.2. Kompjutorizirana tomografija	13
4.3. Magnetska rezonanca.....	13
4.4. Nuklearna medicina	14
5. OPERATIVNI ZAHVATI & UMJETNA INTELIGENCIJA, ROBOTIKA, PROŠIRENA STVARNOST I VIRTUALNA STVARNOST	15
6. PRAĆENJE BOLESNIKA U PERIOPERATIVNOM RAZDOBLJU	17
7. SPECIFIČNI PRIMJER KORIŠTENJA UI U VASKULARNOJ KIRURGIJI	19
7.1. Periferna arterijska okluzivna bolest.....	19

7.1.1. Stratifikacija rizika i dijagnostika	19
7.1.2. Predoperativno i postoperativno praćenje.....	20
7.1.3. Dugotrajna prognoza pacijenta	21
7.2. Aneurizma abdominalne aorte	21
7.2.1. Detekcija i dijagnostika.....	22
7.2.2. Intraoperativna upotreba umjetne inteligencije	23
7.2.3. Praćenje pacijenata.....	24
7.3. Cerebrovaskularna bolest i stenoza karotida.....	24
8. EDUKACIJA & UMJETNA INTELIGENCIJA	25
9. PITANJA ETIKE PRI KORIŠTENJU UMJETNE INTELIGENCIJE.....	27
9.1. Opravdanost uporabe	27
9.2. Privatnost i povjerljivost.....	28
9.3. Odgovornost i profesionalna odgovornost.....	29
9.4. Pravednost i pristranost.....	30
9.5. Sigurnost	31
9.6. Transparentnost i objašnjivost	32
9.7. Etički principi Svjetske zdravstvene organizacije o umjetnoj inteligenciji	32
10. ZAKLJUČAK	34
ZAHVALE	35
LITERATURA	36
ŽIVOTOPIS	47

SAŽETAK

Mogućnosti primjene umjetne inteligencije u vaskularnoj kirurgiji

Unatoč tehnološkom napretku u područjima prevencije, detekcije i terapije, kardiovaskularne bolesti i dalje predstavljaju vodeći uzrok smrtnosti diljem svijeta i veliki javnozdravstveni teret. Upravo zbog učestalosti ovih bolesti, ozbiljnosti njihovih posljedica, kao i činjenice da ih često detektiramo prekasno, u borbi protiv bolesti poput aneurizme abdominalne aorte, cerebrovaskularne bolesti ili periferne arterijske okluzivne bolesti, potrebna su nova, moderna rješenja. Jedno od takvih rješenja je upravo umjetna inteligencija, koja omogućuje računalima obavljanje zadataka koji obično zahtijevaju ljudsku inteligenciju, poput prepoznavanja govora, donošenja odluka i rješavanja problema.

Cilj ovoga rada je istražiti mogućnosti i prepreke u kliničkoj primjeni umjetne inteligencije u vaskularnoj kirurgiji iz do sad dostupne literature.

Područja primjene umjetne inteligencije u vaskularnoj kirurgiji su izrazito široka; kao alat za olakšavanje administracije i intraoperativnog odlučivanja i kao pomagalo za stratifikaciju rizika od nastanka, detekciju i dijagnostiku bolesti. Uz dijagnostiku i operativne zahvate, umjetna inteligencija ima potencijalno mjesto i u postoperativnom praćenju pacijenata. Algoritmi za predviđanje komplikacija omogućuju pravovremenu intervenciju, smanjujući rizik od postoperativnih komplikacija, ubrzavajući oporavak i smanjujući troškove liječenja. U području edukacije, umjetna inteligencija i virtualna stvarnost omogućuju kirurzima vježbanje složenih zahvata u sigurnom okruženju, poboljšavajući njihove vještine i pripremljenost za stvarne operacije.

Iako su istraživanja u ovom području i dalje daleko od kliničke integracije, umjetna inteligencija obećava puno ali, kao i svaki novitet u medicini, nisu bez svojih poteškoća. Etičke implikacije poput pitanja privatnosti, sigurnosti, odgovornosti i pravednosti bit će ključne za osiguravanje povjerenja pacijenata i medicinskog osoblja. Daljnja istraživanja, pažljiva implementacija umjetne inteligencije kao i interdisciplinarna suradnja kliničara, istraživača i regulatornih tijela bit će ključna za postizanje optimalnih rezultata i sigurnosti pacijenata.

Ključne riječi: umjetna inteligencija; strojno učenje; duboko učenje; vaskularne bolesti; vaskularni kirurški zahvati

SUMMARY

Possibilities of using artificial intelligence in vascular surgery

Cardiovascular diseases continue to be the leading cause of death globally and a major public health challenge, despite significant advancements in prevention, detection, and treatment technologies. Due to the prevalence of these diseases, the severity of their consequences, and the fact that they are often detected too late, new, modern solutions are needed in the fight against diseases such as abdominal aortic aneurysm, cerebrovascular disease, or peripheral arterial occlusive disease. One such solution is artificial intelligence, which enables machines to perform tasks that typically require human intelligence, such as decision-making, speech recognition and problem-solving.

The aim of this paper is to explore the possibilities and obstacles in the clinical application of artificial intelligence in vascular surgery, based on the currently available literature.

The applicability of artificial intelligence in vascular surgery is quite broad; it can serve as a tool for facilitating administration and intraoperative decision-making, as well as an aid for risk stratification, detection, and diagnosis of diseases. In addition to diagnostics and surgical procedures, artificial intelligence, also, has potential in the postoperative monitoring of patients. Predictive algorithms for complications enable timely intervention, reducing the risk of postoperative complications, speeding up recovery and lowering treatment costs. In the field of education, artificial intelligence and virtual reality allow surgeons to practice complex procedures in a safe environment, improving their skills and preparedness for real operations.

Although research in this area is still far from clinical integration, artificial intelligence promises a lot, but like any innovation in medicine, it is not without its challenges. Ethical implications such as issues of privacy, security, responsibility, and fairness will be crucial for ensuring the trust of patients and medical staff. Further research, careful implementation of artificial intelligence as well as interdisciplinary collaboration between clinicians, researchers and regulatory bodies will be essential to achieve optimal results and patient safety.

Key words: artificial intelligence; deep learning; machine learning; vascular diseases; vascular surgical procedures

1. UVOD

Umjetna inteligencija (UI) pojavila se sredinom 20. stoljeća i temelji se na radovima britanskog matematičara Alana Turinga. U poznatom radu „Računalna tehnologija i inteligencija“ (*engl. Computing machinery and intelligence*) Turing je predstavio svoj misaoni eksperiment „Igra oponašanja“ (*engl. imitation game*), kasnije poznat i kao Turingov test. Cilj testa bio je procijeniti sposobnost stroja da izrazi inteligentno ponašanje ekvivalentno ili neodvojivo od ljudskog (1). Iako je Turingovo pitanje „Mogu li strojevi razmišljati?“ (*engl. "can machines think?"*) (2) potaknulo mnoge znanstvene rasprave, Weizenbaumov rad iz 1972. godine, koji poziva znanstvenike da promatraju utjecaj svoje tehnologije iz perspektive javnosti, postao je možda i važniji. Weizenbaum, njemačko-američki informatičar, je sugerirao da umjesto da se pitamo jesu li strojevi inteligentni, trebali bismo razmatrati „jesu li korisni?“ i „trebamo li ih?“ (3,4).

Danas, zamisao da se digitalni pomoćnici poput Alexe ili Sirija koriste za osobno medicinsko savjetovanje, uz potporu podataka prikupljenih pametnim telefonima, više nije samo plod mašte velikih znanstvenika. Razvojem dubokog učenja (*engl. deep learning*) i neuronskih mreža, UI je doživjela eksponencijalni rast u svim područjima, uključujući i medicini, gdje se koristi, između ostalog, za dijagnostiku, liječenje i praćenje pacijenata (1,5,6).

Njega pacijenata s vaskularnim stanjima znatno se promijenila u posljednjih nekoliko godina zahvaljujući napretku u opcijama liječenja; ponajviše bolesti karotidnih arterija, abdominalnih aortalnih aneurizama i periferne arterijske bolesti. Klasični kirurški zahvati zamjenjuju se različitim tehnikama koje uključuju upotrebu katetera, balona i stentova. Budući da su vaskularne bolesti često povezane s ozbiljnim komorbiditetima, prednosti ovakvih, manje invazivnih dijagnostičkih i terapijskih metoda je neupitna (7). Unatoč tehničkim naprecima i inovacijama u dijagnostici i liječenju, bolesti kardiovaskularnog sustava i dalje predstavljaju značajan zdravstveni problem diljem svijeta (8). Stanja u pacijenata s kojima se susreću vaskularni kirurzi nerijetko su kompleksna, raznolika i zahtijevaju preciznu dijagnostiku i individualizirane terapijske pristupe (9). Prepreke s kojima se susreću vaskularni kirurzi ne staju u operacijskim salama; one se nastavljaju i u područjima prevencije, stratifikacije rizika, administracije, dijagnostike te postoperativnog praćenja bolesnika (10,11). Postoji jasna

potreba za novim alatima koji bi mogli olakšati i poboljšati rad vaskularnih kirurga na kliničkoj i administrativnoj razini (12).

Korištenje UI obećava upravo to - napredak vaskularne kirurgije, omogućavajući bolje planiranje operacija, precizniju dijagnostiku i personaliziranu medicinu, što dovodi do poboljšanih ishoda za pacijente i optimizacije resursa u zdravstvenim ustanovama (10). Cilj ovoga rada je prikazati trenutne mogućnosti i ograničenja umjetne inteligencije u vaskularnoj kirurgiji.

2. UMJETNA INTELIGENCIJA

2.1. Povijest umjetne inteligencije

Umjetna inteligencija (UI) ima svoje korijene u radovima britanskog matematičara Alana Turinga iz sredine 20. stoljeća. Turing je 1950. godine objavio rad „Računalna tehnologija i inteligencija“ u kojem je predstavio igru oponašanja, kasnije poznatu kao Turingov test, osmišljenu kako bi se procijenila sposobnost stroja da izrazi inteligentno ponašanje neodvojivo od ljudskog (2). U ranim godinama, znanstvenici poput Christophera Stracheya razvili su prve programe koji su bili sposobni učiti i skupljati podatke, kao što je računalni program za društvenu igru dame (13,14).

Tijekom 1960-ih i 1970-ih godina, istraživanje se usmjerilo prema računalima, koja posjeduju intuitivne aspekte inteligencije i razvijanju programa, koji prikazuju *intelligentno* ponašanje. U 1980-ima dolazi do promjene pristupa, s fokusom na rješavanje dobro definiranih matematičkih modela. Ta promjena pristupa, gdje se UI stavlja u fokus kao pomagalo matematičaru, značajno je ubrzala i usmjerila razvoj UI (15).

Ovi rani napori postavili su temelje za suvremenu umjetnu inteligenciju, omogućujući razvoj složenih algoritama i modela koji se danas koriste u različitim primjenama, uključujući prepoznavanje govora, autonomnu vožnju, analizu financijskih podataka, upravljanje

pametnim gradovima, kao i medicinu, gdje se UI koristi kao pomagalo u dijagnostici i zbrinjavanju pacijenata (16).

2.2. Osnove umjetne inteligencije

Umjetna inteligencija (UI) obuhvaća razvoj algoritama i modela koji omogućuju računalima obavljanje zadataka koji obično zahtijevaju ljudsku inteligenciju, poput prepoznavanja govora, donošenja odluka i rješavanja problema (17). Glavni koncepti UI uključuju strojno učenje, duboko učenje i računalni vid (18).

Strojno učenje omogućuje računalima da uče iz podataka, prepoznaju obrasce i donose odluke s minimalnom ljudskom intervencijom. Duboko učenje, podskup strojnog učenja, koristi višeslojne neuronske mreže, modele koji su inspirirani ljudskim mozgom, za analizu apstraktnih podataka (19). Računalni vid omogućuje računalima interpretaciju i razumijevanje vizualnih informacija iz svijeta, što je posebno korisno u medicinskoj dijagnostici i analizi slika (20).

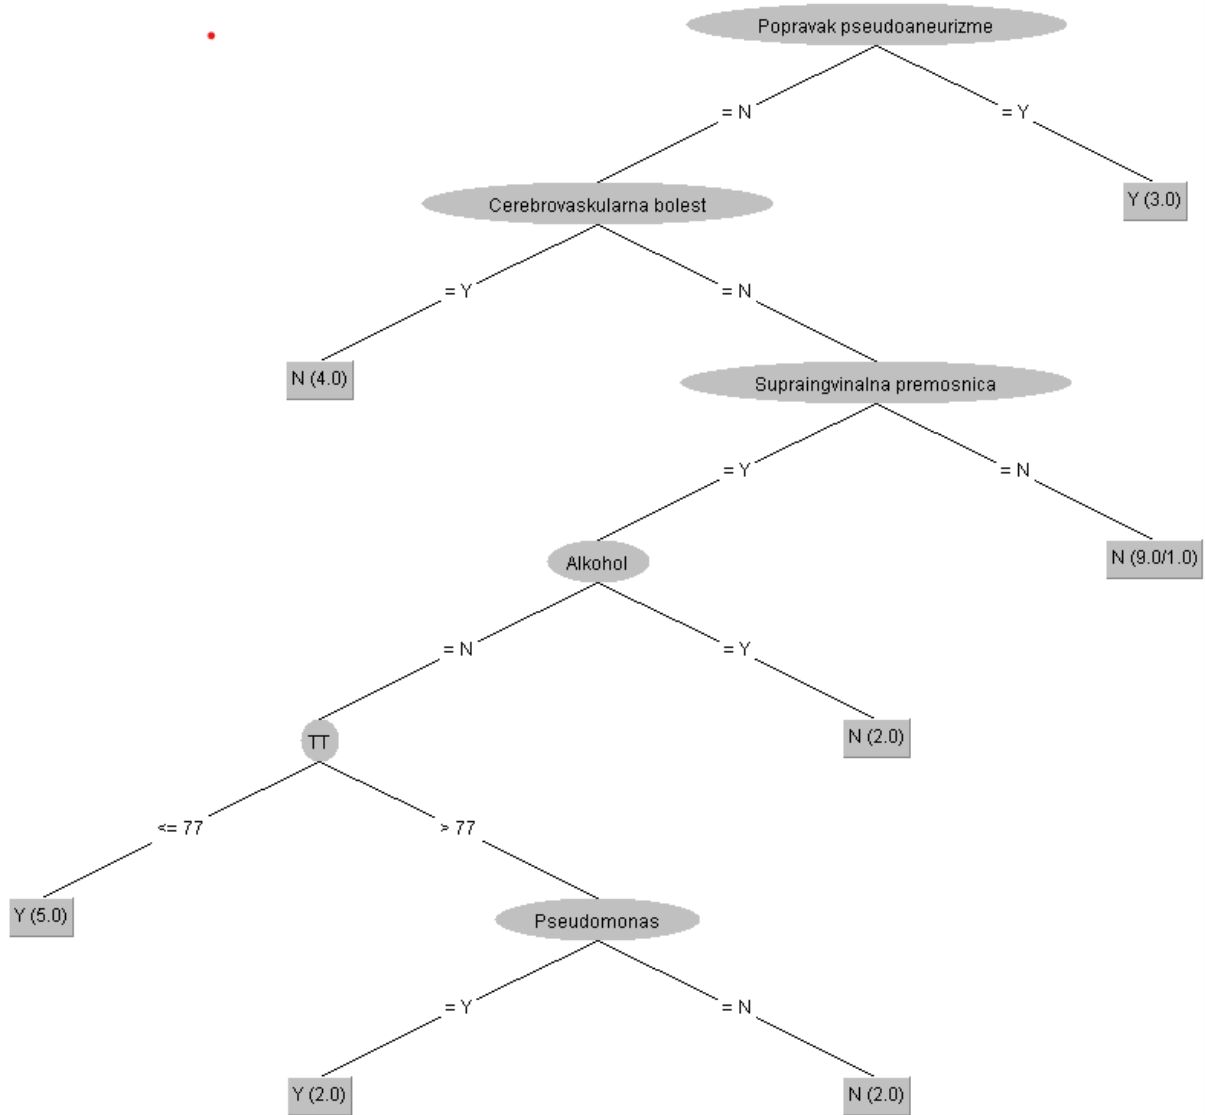
Ovi osnovni koncepti UI omogućili su razvoj aplikacija koje poboljšavaju dijagnostiku, liječenje i praćenje pacijenata, te automatizaciju administrativnih zadataka, čime se smanjuje opterećenje medicinskog osoblja i povećava produktivnost.

2.3. Strojno učenje

Strojno učenje (*engl. machine learning*) je grana umjetne inteligencije koja se bavi razvojem algoritama koji omogućuju računalima da uče iz podataka bez da su za to eksplicitno programirani. Ovi algoritmi analiziraju velike količine podataka i prepoznaju obrasce, čime im je omogućeno da donose odluke i predviđanja na temelju istih podataka (21).

Postoje dvije glavne vrste strojnog učenja: nadzirano i nenadzirano učenje (*engl. unsupervised and supervised learning*). Kod nadziranog učenja, algoritmi uče na temelju označenih podataka (Slika 1), dok u nenadziranom učenju algoritmi pokušavaju otkriti skrivenu strukturu i obrasce neoznačenim podacima, bez da su unaprijed definirane kategorije ili oznake podataka (22).

Algoritmi strojnog učenja koriste se u mnogim primjenama, uključujući prepoznavanje govora i analiza slika, poglavito u medicinskoj dijagnostici (23).



Slika 1. Primjer stabla odlučivanja (engl. decision tree), jedne od metoda nadziranog strojnog učenja, u analizi infekcija nakon angiokirurških rekonstrukcija (preliminarna analiza dijela podataka iz baze podataka Zavoda za vaskularnu kirurgiju Klinike za kirurgiju KBC Zagreb).


2.4. Računalni vid

Računalni vid je područje umjetne inteligencije koje omogućuje računalima interpretaciju i razumijevanje vizualnih informacija iz svijeta. UI pomoću računalnog vida može obraditi digitalnu sliku te brzo i precizno identificirati i klasificirati objekte, detektirati anomalije i pratiti kretanje objekata u stvarnom vremenu, što je posebno korisno u medicinskoj dijagnostici i edukaciji, te mnogim drugim, ne medicinskim granama (24).

Računalni vid kao disciplina obuhvaća različite metode i tehnike, koje omogućuju programima da interpretiraju i analiziraju vizualne podatke. Ove metode uključuju jednostavne statističke tehnike, poput razlikovanje praga boja i rubova, sve do složenih algoritama strojnog učenja, koje danas koriste najsofisticiraniji programi UI. Na primjer, računalni vid omogućuje prepoznavanje lica, gdje program, pomoću algoritama, analizira razlike u karakteristikama lica kako bi ih uspješno identificirao (25).

2.5. Duboko učenje

Duboko učenje (*engl. deep learning*), podskup strojnog učenja, temelji se na umjetnim neuronskim mrežama (Slika 2) i koristi višeslojne neuronske mreže za analizu podataka. Ove mreže omogućuju otkrivanje složenih struktura i poveznica u velikim skupovima podataka. Primjena dubokog učenja u sklopu UI je široka: prepoznavanje slika, analiza govora i prirodno jezično procesiranje, sposobnost računala da razumiju, interpretiraju i generiraju ljudski jezik (26).



Slika 2. Primjer jednostavne "feed-forward" neuronske mreže.

Duboko učenje ima sposobnost automatiziranog učenja, pomoću kojeg podaci ne trebaju biti prethodno pripremljeni i analizirani. Ova sposobnost omogućuje učinkovitije i brže odgovore od tradicionalnih metoda strojnog učenja, jer duboko učenje može automatski izvući značajke i obrasce iz sirovih podataka (27).

Duboko učenje također igra ključnu ulogu u razvoju tehnologije i tehnika u znanosti i industriji, gdje omogućuje napredne analize i predviđanja, utemeljena na velikim količinama podataka (28).

2.6. Korištenje umjetne inteligencije u medicini

Umjetna inteligencija ima široku primjenu u medicini, uključujući medicinsku dijagnostiku, robotiku, edukaciju i upravljanje podacima. UI sustavi pomažu u poboljšanju točnosti dijagnostike, učinkovitosti liječenja i kvaliteti zdravstvene skrbi (29). UI također igra ključnu ulogu u upravljanju zdravstvenim sustavima putem elektroničkih zdravstvenih zapisa, automatizaciji administrativnih zadataka i podršci liječnicima u donošenju odluka (30). Automatizacija administrativnih zadataka u medicini, pomoću UI, donosi značajne prednosti u

poboljšanju učinkovitosti i smanjenju opterećenja zdravstvenog osoblja. UI sustavi se koriste za automatizaciju rutinskih zadataka kao što su zakazivanje pacijenata, upravljanje zdravstvenim kartonima i obrada osiguranja. Na primjer, prirodno jezično procesiranje omogućava automatizirano prepoznavanje i unos podataka iz medicinskih dokumenata, čime se drastično smanjuje potreba za ručnim unosom i mogućnost ljudske pogreške (29). Nadalje, algoritmi strojnog učenja mogu analizirati velike količine administrativnih podataka kako bi identificirali obrasce i potrebe pacijenata, što rezultira bržom obradom zahtjeva i učinkovitijim korištenjem resursa (30). Istraživanja uporabe UI za administrativne zadatke pokazala su obećavajuće rezultate u smanjenju opterećenja pružatelja medicinskih usluga i povećanju produktivnosti. Korišteni alati su različitog stupnja razvoja. Neki su na samom početku, dok se drugi rutinski koriste na dnevnoj osnovi. (7) Ova tehnologija ne samo da poboljšava produktivnost, već i omogućuje medicinskom osoblju da se više fokusira na pacijente i u skladu s time pruža kvalitetniju zdravstvenu skrb.

3. EPIDEMIOLOGIJA I ETIOLOGIJA BOLESTI VASKULARNE KIRURGIJE

3.1. Epidemiologija aterosklerotske kardiovaskularne bolesti

Epidemiologija kardiovaskularne bolesti (KVB) duboko je povezana s globalnim zdravstvenim opterećenjem koje one uzrokuju (7). Kardiovaskularne bolesti predstavljaju vodeći uzrok smrtnosti u svijetu, s procjenom da je 17 milijuna ljudi umrlo od ovih bolesti 2012. godine, a očekuje se da će ta brojka porasti na 24 milijuna godišnje do 2030. godine (31). Posebno zabrinjava visoka prevalencija rizičnih čimbenika za kardiovaskularne bolesti kod djece i mladih odraslih osoba. Sjedilački način života, abdominalna pretilost i loše prehrambene navike doprinose dislipidemiji i visokom krvnom tlaku koje prethode nastanku KVB-a (32). Uz rastući broj smrtnih ishoda, postoji očita potreba za poboljšanjem preventivnih mjera i tretmana. Kako bi se suprotstavili ovoj pandemiji, zdravstvene politike sve više naglašavaju važnost bolje kontrole rizičnih faktora kao što su hipertenzija, pušenje, dijabetes i nezdrave prehrambene navike. U radu "Health effects of dietary risks in 195 countries" iz 2019. godine, pokazano je da su u 2017. godini, nezdrave prehrambene navike bile odgovorne za 10 milijuna smrtnih slučajeva od kardiovaskularnih bolesti i 255 milijuna izgubljenih godina života

prilagođenih invalidnosti (engl. *disability-adjusted life years, DALYs*). Ključni dijetalni rizici koji su doprinijeli ovim brojkama uključuju visok unos natrija te nizak unos cjelovitih žitarica i voća (33).

Socioekonomski faktori često su zanemareni pri procjeni rizika za razvoj kardiovaskularnih bolesti, iako igraju ključnu ulogu u utjecaju na zdravstvene ishode. Studije ističu da ljudi iz nižih socioekonomskih slojeva, često izloženi većem riziku od akutnog koronarnog sindroma, primaju suboptimalnu medicinsku i socijalnu skrb, te imaju lošije dugoročne zdravstvene ishode u usporedbi s onima iz viših socioekonomskih krugova. To ukazuje na potrebu za uključivanjem socioekonomskog statusa u modele stratifikacije rizika kako bi se poboljšale preventivne mjere i mjere rane detekcije (34,35).

Pušenje je glavni uzrok preventabilne smrtnosti i bolesti u Sjedinjenim Američkim Državama, uzrokujući godišnje više od 480,000 preranih smrti i gubitke veće od 300 milijardi dolara zbog izgubljene produktivnosti i direktnih troškova (36). Iako češće povezano sa ne vaskularnim kliničkim učinkom, pušenje ima značajan utjecaj na razvoj nekih vaskularnih bolesti; ponajviše periferne arterijske okluzivne bolesti i aneurizme abdominalne aorte (37).

3.2. Etiologija i epidemiologija vaskularnih bolesti

Vaskularni kirurzi liječe veliki broj kliničkih manifestacija povezanih s aterosklerozom: aneurizma abdominalne aorte (AAA), periferna arterijska okluzivna bolest donjih ekstremiteta (PAOB), cerebrovaskularna bolest (CVB), venska tromboza (36). U nastavku slijede relevantne informacije vezano za epidemiologiju i etiologiju četiri uobičajena vaskularna poremećaja: Aneurizma abdominalne aorte, periferna arterijska okluzivna bolest, cerebrovaskularne bolesti i venska tromboza.

Aneurizma abdominalne aorte (AAA) se dugo smatrala degenerativnom posljedicom ateroskleroze, ali novije studije pokazuju multifaktorijalnu etiologiju koja uključuje genetiku, proteolizu i nedostatak elemenata u tragovima. Čimbenici rizika uključuju muški spol, stariju dob, bijelu rasu, pridružene vaskularne bolesti, hipertenziju, pušenje, obiteljsku povijest i hiperlipidemiju. Prevalencija varira ovisno o spolu, dobi i metodi detekcije, s većom

učestalošću kod muškaraca starijih od 60 godina. Na rizik od rupture utječe promjer same aneurizme, brzina rasta i debljina stjenke (38–40).

Često kasno prepoznata, periferna arterijska okluzivna bolest (PAOB) predstavlja značajni zdravstveni problem u svijetu, s prevalencijom od >10% kod osoba starijih od 60 godina (31). Ateroskleroza je glavni uzrok PAOB-a, kao i cerebrovaskularnih i koronarnih bolesti. Rizik se povećava uz pušenje, dijabetes, hiperkolesterolemiju, hipertenziju i stariju dob. Godišnja incidencija klaudikacija raste s dobi. Prirodni tijek bolesti pokazuje da se stanje poboljšava ili ostaje stabilno kod 55% pacijenata, pogoršava kod 16%, a 25% zahtijeva intervenciju. Stopa smrtnosti u pet godina iznosi 29% (41,42).

Cerebrovaskularne bolesti (CVB) su heterogena skupina poremećaja, koji se razlikuju po svojim patofiziološkim mehanizmima i kliničkim manifestacijama (43). Unatoč razlikama, CVB se mogu podijeliti na ishemijske i hemoragijske te često imaju fatalne ishode ili teške posljedice za preživjele. Rizični čimbenici uključuju hipertenziju, pušenje, dijabetes, hipertrofiju lijeve klijetke, koronarnu bolest, fibrilaciju atriya i pozitivnu obiteljsku anamnezu na CVB. Glavni prediktor razvoja budućeg moždanog udara je tranzitorni ishemijski napad (TIA). Za 2016. godinu zabilježena je incidencija od jednog moždanog udara po stanovniku svakih 40 sekundi u SAD-u, što čini CVB velikim teretom na zdravstvo (31). Incidencija cerebrovaskularne bolesti raste s godinama, od 1.7-3.6 na 1000 osoba godišnje za dob 55-64 te 10.3-37.3 na 1000 osoba za starije od 85 godina.

Venska tromboza, uključujući duboku vensku trombozu i plućnu emboliju, se pojavljuje s godišnjom incidencijom od 1 na 1000 odraslih osoba. Stopa pojavnosti se naglo povećava nakon 45. godine života, te su nešto više kod muškaraca nego kod žena u starijoj životnoj dobi (44). Duboka venska tromboza (DVT) i plućna embolija (PE) imaju veliki broj stečenih i urođenih faktora rizika. Stečeni faktori uključuju prethodnu povijest DVT/PE, operacije, traume, nepokretnost, rak, trudnoću, korištenje oralnih kontraceptiva, pretilost, starost i prisutnost lupus antikoagulansa ili antikardiolipinskih antitijela, a u urođene faktore rizika spadaju: nedostatak antitrombina III, proteina C ili S, ili prekomjerna aktivnost inhibitora plazminogena (45).

3.3. Metode procjene i stratifikacije rizika

Do sada, ako bi se odabrali kandidati za liječenje, odluka o terapiji za prevenciju kardiovaskularnih bolesti (KVB) se temeljila na procjeni klasičnih čimbenika rizika; čimbenici koji se mogu modificirati poput LDL kolesterola, pušenja, dijabetesa, krvnog tlaka, te dva najveća ne promjenjiva čimbenika- dob i spol. S time u vidu, lijekovi poput statina uglavnom se propisuju prema razini LDL kolesterola, antihipertenzivi prema razini krvnog tlaka, a terapijski ciljevi se prilagođavaju dodatnim čimbenicima rizika (*npr. prisutnost dijabetesa*) (46). Za procjenu kardiovaskularnog rizika postoje razne metode procjene i stratifikacije rizika, od kojih svaka ima svoje prednosti i mane. Neke od klinički najčešće korištenih jednadžbi za procjenu i stratifikaciju rizika KVB-a su:

1. Sistematska procjena koronarnog rizika (*SCORE2, engl. Systematic Coronary Risk Evaluation*)
2. Procjena rizika Aterosklerotske kardiovaskularne bolesti (*engl. ASCVD Risk Score*)
3. Framinghamska procjena rizika (47).

Na primjer, SCORE2 model se ističe time što je razvijen na temelju velikih kohortnih studija diljem Europe te ima mnoge verzije prilagođene pojedinim zemljama, što povećava njegovu točnost. Međutim, ovaj model uključuje samo smrtno slučajevne od kardiovaskularnih bolesti, što može dovesti do podcjenjivanja ukupnog kardiovaskularnog rizika (47,48).

Uz ove metode koje su utemeljene na procjeni rizika na osnovu klasičnih čimbenika rizika, sve veću popularnost dobivaju i serološki markeri poput N-terminalni prohormon moždanog natriuretskog peptida (NT-proBNP), slikovni markeri (*engl. imaging markers*) poput kalcificiranosti koronarnih arterija (*engl. CAC Score*) i korištenje genetskih procjena rizika (49,50).

Trenutni sustavi za procjenu rizika od KVB su dostupni, jeftini i korisni, ali mogu pogrešno klasificirati pojedince s višestrukim ili zbunjujućim čimbenicima (*engl. confounding variables*). Idealna metoda stratifikacije rizika integrirala bi sveobuhvatan skup biomarkera, slikovnih tehnika i genetskih informacija kako bi pružila precizniji profil rizika čime bi se omogućila ranija ciljana intervencija i poboljšanje kliničkih ishoda (47).

3.4. Komplikacije operacija

Pacijenti u sklopu vaskularne kirurgije često se suočavaju s povećanim rizikom od postoperativnih komplikacija, što uključuje kako kardiovaskularne tako i ne kardiovaskularne komplikacije. Glavni čimbenici rizika za nastanak kardiovaskularnih komplikacija uključuju starost, pretilost, preboljeni moždani udar, lošu funkcionalnu sposobnost srca, operacija aorte, kao i nagle promjene u razinama troponina (57). Neke od tipičnih kardiovaskularnih komplikacija su miokardijalni infarkt, dekompenzacija srčanog zatajivanja, srčane aritmije i moždani udar (58). Najčešće ne kardiovaskularne komplikacije su: infekcija rane, septički i hemoragični šok, zatajenje bubrega, respiratorne komplikacije, venska tromboembolija, amputacija te potreba za ponovnom operacijom (58,59).

Do sada, pri predviđanju nastanka komplikacija, koristile su se metode poput indeksa revidiranog kardiovaskularnog rizika RCRI (engl. *Revised Cardiac Risk Index*) i indeksa kardiovaskularnog rizika VSG-CRI (engl. *Vascular Surgery Group Cardiac Risk Index*), ali pokazalo se da te metode nisu dovoljno precizne u predviđanju rizika unutar 30 dana nakon operacije (58,60).

Umjetna inteligencija nudi nove mogućnosti kroz razvoj modela predviđanja ishoda na bazi strojnog učenja. Primjerice, ovi sustavi pokazuju obećavajuće rezultate u procjeni uspješnosti liječenja aneurizme abdominalne aorte. *Endoleak* je komplikacija koja se javlja u 10-20% slučajeva nakon endovaskularne rekonstrukcije aneurizme abdominalne aorte (EVAR) (61). Kod te komplikacije dolazi do perzistirajućeg protoka u aneurizmu što dovodi pacijenta u rizik od ruptur aneurizme (62). Korištenjem karakteristika pacijenata, CT angiografije i strojnog učenja razvijeno je nekoliko uspješnih modela koji predviđaju povećanje aneurizme s preko 90% preciznošću (63,64).

4. PRIMJENA UMJETNE INTELIGENCIJE U DIJAGNOSTICI

4.1. Ehokardiografija

Ehokardiografija je nezamjenjiv dijagnostički alat i služi kao temelj dijagnostike kardiovaskularnih bolesti u stvarnom vremenu za kliničku skrb (65). Unatoč svojim mnogim prednostima poput široke dostupnosti i pristupačnosti, temeljna mana ehokardiografije je u varijabilnoj interpretaciji slika, u usporedbi s drugim radiološkim metodama dostupnim danas. Integracija UI ima potencijal transformirati ovu dijagnostičku metodu, automatizacijom mjerenja i očitavanja rezultata, čime se povećava dijagnostička točnost i smanjuje varijabilnost promatrača (66).

Sposobnost UI za automatsko ili potpomognuto generiranje slika može biti posebno korisna u okruženjima s ograničenom stručnošću. UI omogućava operatorima koji nisu stručnjaci da izvode ehokardiogramе dijagnostičke kvalitete. Primjer toga je tijekom COVID-19 pandemije, kada je omogućena dijagnostika na daljinu, čime se smanjila izloženost dijagnostičara virusu (67). Koristeći UI temeljenu na dubokom učenju kao vodilju, medicinske sestre, bez prethodnog znanja ehokardiografije, su generirale dijagnostički kvalitetne snimke svojih pacijenata (68).

Osim automatske akvizicije slika, primjena UI u ehokardiografiji obuhvaća i sofisticirane zadatke kao što su automatizirana interpretacija slika. UI se pokazao učinkovitim u kvantificiranju volumena i ejekeijske frakcije lijeve i desne klijetke iz 2D i 3D slika, pružajući standardizaciju inače subjektivne procjene, čime bi se mogla smanjiti šansa za ljudske pogreške i varijabilnost u interpretaciji (69,70). Algoritam za prirodno jezično procesiranje je primijenjen na već postojećim, tekstualnim, ehokardiografskim izvješćima. Iako učinkovitost samog algoritma kada se primjeni na vanjski skup podataka ukazuje na slabu primjenjivost, ovo također ukazuje na potencijalni smjer daljnjeg istraživanja (69,71).

Uz dijagnostičke primjene, UI se primjenjuje i na prognostiku. Koristeći nalaze ehokardiografije i medicinskih informacija pacijenata, programiran je algoritam za predviđanje mortaliteta koji je imao veću točnost od standardnih, kliničkih skala za procjenu rizika (72).

Unatoč manjku randomiziranih kontrolnih studija, potreba za integraciju UI u ehokardiografiju postoji. UI može preobraziti ehokardiografiju u alat koji točno i precizno može otkriti stanja, prethodno predvidiva korištenjem konvencionalnih metoda (73).

4.2. Kompjutorizirana tomografija

Jedna od najčešćih visoko rezolucijskih modaliteta anatomske slikovne dijagnostike je kompjutorizirana tomografija (CT), pomoću koje se dobiva uvid u detalje lezije, njezinu veličinu, morfologiju i strukturne promjene susjednih tkiva (74). Napretkom znanosti, razvijena je i metoda CT angiografije (CTA) koja, pomoću kontrasta, brže, jeftinije i manje invazivno daje uvid u stanje vaskularnog sustava pacijenta (75).

Primjena strojnog učenja u CT dijagnostici srca značajno je porasla u posljednjem desetljeću. Razvijen je algoritam na bazi dubokog učenja koji poboljšava kvalitetu uređaja, time omogućavajući dobivanje CT slika s reduciranim dozama zračenja (76). Sličan pristup korišten je i za izračunavanje kalcijuskog skora iz koronarne CTA, smanjujući izloženost pacijenata zračenju (76). Osim poboljšanja kvalitete slika, razvijen je i algoritam za detekciju stenoza koronarnih arterija većih od 25% koji pokazuje obećavajuće rezultate, sa preko 90% specifičnosti, osjetljivosti i točnosti (77).

Međutim, usprkos ovim napretcima, postoje značajni izazovi u implementaciji UI modela zbog nedostatka standardizacije podataka i dijagnostičkih kriterija među različitim medicinskim ustanovama. To uključuje varijacije u dijagnostičkim standardima, ograničene resurse i probleme vezane uz dijeljenje podataka te zaštitu privatnosti pacijenata. Rješenje ovih problema zahtijeva blisku suradnju medicinskih istraživačkih centara i regulatornih tijela kako bi se uspostavile standardizirane smjernice za prikupljanje i dijeljenje podataka (78).

4.3. Magnetska rezonanca

Zbog trenda ka manje invazivnim zahvatima radi boljeg oporavka i rjeđih nuspojava, postoji stvarna potreba za naprednim metodama slikovnog prikaza poput magnetske rezonance (MRI) (79).

Korištenje MRI-a u sklopu vaskularne kirurgije je višestruko; u sklopu magnetske rezonantne angiografije, gdje se bez potrebe za kontrastnim sredstvima vrše procjene stenoze, aneurizme i druge vaskularne patologije, procesiranje i stvaranje 3D slika za predoperativno planiranje, te u procjeni vitalnih funkcionalnih područja kako bi se izbjegla oštećenja (79).

Uključivanjem UI u MRI pružaju se dodatne mogućnosti:

1. Automatska segmentacija i analiza slika - Algoritmi dubokog učenja koriste se za automatsku segmentaciju krvnih žila ili srca na MRI slikama, što pomaže u preciznom identificiranju vaskularnih abnormalnosti ili procjeni srčane mase i funkcije. To smanjuje vrijeme potrebno za ručnu analizu i povećava točnost dijagnoza (80,81).
2. Pобољшanje kvalitete slike - UI algoritmi poboljšavaju kvalitetu MRI slika smanjujući šum i poboljšavajući kontrast, što olakšava točniju dijagnostiku vaskularnih struktura i patologija (82).
3. Procjena rizika i prognoza - jedna od glavnih prednosti korištenja UI je upravo u stratifikacija i procjena prognoze pacijenata. Algoritmi strojnog učenja analiziraju velike količine podataka kako bi identificirali pacijente s visokim rizikom, koji zahtijevaju intervenciju ili praćenje. Primjenom UI modela temeljenim na trodimenzionalnom kretanju srca, uspješno je predviđen ishod kod pacijenata s plućnom hipertenzijom neovisno o konvencionalnim čimbenicima rizika (83).

4.4. Nuklearna medicina

Nuklearna medicina ima jedinstvenu ulogu u dijagnostici i detekciji infekcija i upala. Metode poput kompjuterizirane tomografija s emisijom jednog fotona (SPECT) ili skeniranje bijelih krvnih stanica prethodno obilježenih Indijem-111, posebno su korisne u predoperativnoj obradi ili u praćenju postoperativnih promjena kao što su infekcije vaskularnih presađaka (84). Ujedno, primjenom UI, dolazi do smanjene izloženosti zračenju, zbog manje potrebe korištenja radiofarmaka i optimizaciji same doze. Korištenjem UI postiže se napredak u:

1. Automatskoj detekciji bolesti- razvijen je algoritam koji detektira srčanu amiloidozu tijekom scintigrafije s usporedivom točnosti stručnjaka, čime se pojednostavila i ubrzala dijagnostika ove bolesti (85).

2. Procjena rizika i prognoza- korištenjem modela na bazi strojnog učenja za analizu pacijenata koji su prošli SPECT miokardijalne perfuzije i koristeći njihove parametre snimaka za modeliranje, pokazano je da algoritam može preciznije izračunati kardiovaskularnu smrtnost u pacijenata (86).
3. Karakterizacija vaskularnih plakova - UI se koristi za kvantifikaciju i karakterizaciju aterosklerotskog plaka, što pomaže u procjeni rizika od akutnog koronarnog sindroma. Korištenje UI tijekom koronarnog CTA omogućuje bržu procjenu stenozе, volumena i drugih nepovoljnih karakteristika plaka (87).

5. OPERATIVNI ZAHVATI & UMJETNA INTELIGENCIJA, ROBOTIKA, PROŠIRENA STVARNOST I VIRTUALNA STVARNOST

Operativni zahvati u vaskularnoj kirurgiji imaju ključnu ulogu u liječenju raznih vaskularnih stanja koja mogu ozbiljno ugroziti zdravlje i život pacijenata. S razvojem medicinske tehnologije, kirurški postupci su postali manje invazivni, što smanjuje vrijeme oporavka, rizik od razvoja infekcija i drugih postoperativnih komplikacija. Inovacije poput robotom asistirane kirurgije, sustava uvećane stvarnosti (engl. *augmented reality*), naprednih slikovnih tehnika i upotrebe umjetne inteligencije dodatno poboljšavaju preciznost i uspješnost kirurških zahvata s jednostavnim krajnjim ciljem; kvalitetnija skrb pacijenata.

Uvećana stvarnost je interaktivno iskustvo koje podrazumijeva integraciju računalno generiranog sadržaja i stvarnog svijeta sa svrhom poboljšanja efikasnosti i kvalitete provedbe zadataka (88). Do nedavno, generirani računalni sadržaj je bio prikazan na monitoru, te je operater gledao isključivo u njega tijekom operacije. Razvoj tehnologije je omogućio superpoziciju sadržaja na samo radno polje operatera, što se može poistovjetiti s globalnim položajnim sustavom za navigaciju, jer kirurg, u svakom trenutku, zna gdje se nalazi u odnosu na ostalu anatomiju i patologiju pacijenta. Superpozicija poboljšava i olakšava zahvate vaskularnih kirurga, jer tijekom endovaskularnih operacija fokus operatera ostaje na operacijskom polju, a ne na ekranu koji prikazuje slike CTA ili fluoroskopije (89).

Komercijalizacija tehnologije je dodatno pogurala razvoj i inovaciju. Neki od primjera su AccuVein-a (AccuVein Inc., NY USA), za postavljanje perifernog venskog puta i Google Glass (Google Inc., CA USA), za superpoziciju računalnog sadržaja, u stvarnom vremenu, tijekom

operacije (88). Sustavi uvećane stvarnosti danas omogućuju da se pomoću CTA nalaza rekonstruiraju slike, potom isprintaju 3D modeli i na za to prilagođenom ekranu uprizori operacijsko polje, koje onda možemo koristiti za predoperativnu pripremu i uvježbavanje samog zahvata. Kroz ovakve, napredne, metode vizualizacije, operater ima priliku individualizirati pristup samom pacijentu u sigurnom okruženju, gdje potencijalne greške nisu na štetu pacijenta (88). Primjenom proširene stvarnosti u vaskularnoj kirurgiji pojednostavljuje se navigacija i poboljšava vizualizacija tijekom kompleksnih zahvata, te se koristi kao medij za edukaciju kirurga o kompleksnim zahvatima (89).

Za razliku od proširene stvarnosti, virtualna stvarnost (engl. *virtual reality*) podrazumijeva potpuno računalno stvoreni sadržaj s ciljem što realističnijeg iskustva za kirurga. Ujedno se na virtualnu stvarnost, pomoću za to predviđenih pomagala, može djelovati, što dodatno pomaže rekreirati stvarne zahvate i slučajeve u svrhu edukacije.

UI ima značajan potencijal u poboljšanju različitih aspekata vaskularne kirurgije, uključujući dijagnozu, planiranje i izvođenje kirurških zahvata. Pomoću algoritama za automatsku segmentaciju slika različitih radioloških modaliteta, UI omogućava detaljnu procjenu geometrije i morfologije aneurizma u sklopu predoperativnog planiranja (90). Tijekom samih zahvata, korištenjem naprednih algoritama, softver UI se koristi za automatizirani 3D prikaz vaskularnog sustava, fuzijom CTA slika i fluoroskopskog nalaza u stvarnom vremenu (91). Detaljnije o specifičnim primjerima korištenja UI u vaskularnim bolestima u 7. poglavlju.

Na UI, virtualnu i proširenu stvarnost se blisko nadovezuje i robotika. Korištenje kirurških sustava poput da Vinci (Intuitive Surgical Inc., CA USA) je postalo uvrježeno u laparaskopskom zbrinjavanju mnogih vaskularnih stanja: AAA, trombendartektomija aorte ili zdjeličnih arterija, ugradnja raznih premosnica poput aortofemoralnog premoštenja, aneurizma slezenske arterije i mnoga druga (92). Prednosti robotom-asistirane laparaskopske operacije nad otvorenom operacijom uključuju: smanjeno intraoperativno krvarenje, brži postoperativni oporavak, brzo cijeljenje operativnih rana, manje šanse za razvoj incizijske hernije (92). Ujedno, korištenjem robotskih sustava za vršenje zahvata, postiže se bolja koordinacija, spretnost i vizualizacija, pogotovo u slučajevima mikrovaskularne kirurgije (92).

U slučaju endovaskularnog pristupa, razvijeno je nekoliko komercijalnih kirurških sustava, poput Magellan-a (Auris Health Inc., CA USA), koji omogućavaju operateru plasiranje katetera pod boljom kontrolom u anatomske teže dostupne krvne žile. Unatoč obećavajućim rezultatima

ovih uređaja, postoji ograničeni broj istraživanja u njihovu uspješnost zbog njihove kompleksnosti, visoke cijene i potrebe sa opsežnom dodatnom opremom (93).

Kombinacija umjetne inteligencije, robotike, proširene i virtualne stvarnosti omogućuje vaskularnim kirurzima da izvedu složenije zahvate s većom preciznošću i manjim rizikom. Ove tehnologije ne samo da poboljšavaju intraoperativne performanse i ishode pacijenata, već također olakšavaju kontinuiranu edukaciju i usavršavanje kirurških vještina, čime se postavljaju novi standardi u vaskularnoj kirurgiji.

6. PRAĆENJE BOLESNIKA U PERIOPERATIVNOM RAZDOBLJU

Perioperativno razdoblje zahtjeva posebno pažljivo praćenje pacijenata zbog: kompleksnosti samih zahvata, koji mogu voditi neželjenim komplikacijama, povećanog rizika od hemodinamskih promjena i uspostave personalizirane skrbi radi optimiziranja oporavka pacijenta. Iako je klinička primjena UI tek na početku, sposobnost naprednih algoritama UI za analizu velikih skupova podataka pojednostavljuje individualizaciju i optimizaciju skrbi pacijenata u ovom rizičnom periodu.

Koristeći kliničke i kirurške elektronske zdravstvene podatke od preko 37 milijuna slučajeva, izrađen je algoritam strojnog učenja za predviđanje postoperativnih komplikacija s osjetljivošću i specifičnošću od 76% (94). Na osnovi rezultata, studija je zaključila da se ovakvi modeli za predviđanje mogu koristiti u kliničkom okruženju, kao pomagalo pri donošenju odluka i identifikaciji visoko rizičnih pacijenata (94). Nadalje, kroz algoritme se mogu evaluirati operativni planovi, te prikazati potencijalne praznine koje treba poboljšati.

Nagla srčano-respiratorna nestabilnost pacijenata je česta i nepoželjna postoperativna komplikacija koja, bez brze dijagnostike i trenutne terapije, može ostaviti trajne posljedice. Kontinuirano praćenje vitalnih parametara, poput krvnog tlaka, pulsa, periferne zasićenosti krvi kisikom i drugih, sustavno se koriste u operacijskim salama, prostorijama za buđenje i jedinicama za intenzivnu njegu, kako bi se pravovremeno otkrilo pogoršanje vitalnih funkcija (95). Uz samo praćenje vitalnih parametara, razvoj prediktivnih modela UI pružaju kliničaru mogućnost sprječavanja razvoja dekompenzacije u ovih rizičnih skupina. Iako tek na početku, razvijaju se algoritmi, temeljeni na strojnom učenju, koji predviđaju rizik od postoperativne

tahikardije, odnosno srčane dekompenzaciju, na temelju praćenja vitalnih parametara u trosatnom razdoblju nakon operacije (95). Kroz dodatno istraživanje i vanjsku validaciju, ovakvi algoritmi bi mogli drastično pomoći u prevenciji dekompenzacije pacijenata zaprimljenih zbog akutnih vaskularnih stanja.

Uz srčano-respiratornu dekompenzaciju, važno je spomenuti i hemodinamsku nestabilnost, kao čestu, po život opasnu, komplikaciju i uzrok hipotenzije u intraoperativnom i perioperativnom razdoblju. Jedan od prvih validiranih primjera korištenja UI u klinici je algoritam za predviđanje razvoja hipotenzije (engl. *The Hypotension Prediction Indeks*) (96). Ovaj algoritam se dosad primjenjivao u intraoperativnom okruženju, s dokazanim učinkom u prevenciji intraoperativne hipotenzije, kroz predviđanje razvoja iste, 5-15 minuta prije nastanka (96). Zbog toga, liječnički tim ima više vremena poduzeti primjerene korake u zbrinjavanju urušaja pacijenta.

Detaljnije o primjeni specifičnih algoritama UI u vaskularnim bolestima u svrhu stratifikacije rizika i predviđanja ishoda u 7. poglavlju.

Ključno za nastavak razvoja kvalitetnih modela UI leži u što većim kliničkim bazama pacijenata iz kojih ti algoritmi mogu učiti te, posljedično, davati što točnije rezultate. Jedan od pojmova korištenih u sklopu sveobuhvatnog praćenja pacijenata u ovom razdoblju pomoću UI je perioperativna inteligencija (97). Perioperativna inteligencija je model pomoću kojeg se može identificirati rizične pacijente, promptno uspostaviti terapiju i rano prepoznati komplikacije. Takav jedan, izmišljeni, model bi koristio sve elektronske zdravstvene podatke, uz epidemiološke podatke, laboratorijske nalaze, nalaze s pacijentovog monitoringa i ostale dostupne podatke, da liječnik i UI mogu napraviti informiranu odluku o liječenju pacijenta (97). Je li ovakva tehnologija moguća i realistična? To jedino vrijeme može pokazati.

7. SPECIFIČNI PRIMJER KORIŠTENJA UI U VASKULARNOJ KIRURGIJI

7.1. Periferna arterijska okluzivna bolest

Periferna arterijska okluzivna bolest (PAOB) pogađa više od 230 milijuna ljudi diljem svijeta. Bolest je povezana s visokim stopama morbiditeta i mortaliteta (98). Dijagnoza i klasifikacija PAOB oslanja se na kombinaciju kliničkog pregleda, mjerenja gležanj-brahijalnog indeksa, funkcionalne procjene (test na traci za trčanje) i identifikacije arterijskih lezija putem slikovnih metoda. Unatoč visokim rizicima od kardiovaskularne smrtnosti i amputacije, PAOB ostaje nedovoljno dijagnosticirana i podcijenjena (99). Često se dijagnosticira u naprednom stadiju bolesti zbog niske svijesti pacijenata i visoke prevalencije asimptomatske bolesti ili atipičnih simptoma. Rano otkrivanje i liječenje PAOB ključno je za sprečavanje napredovanja bolesti i poboljšanje ishoda za pacijente.

7.1.1. Stratifikacija rizika i dijagnostika

S pristupom strojnom učenju, UI može analizirati stotine čimbenika rizika te prepoznati one odnose između čimbenika, koje klasični modeli stratifikacije rizika ne mogu, jer uključuju svega nekoliko čimbenika rizika.

Tehnike procesiranja prirodnog jezika dobivaju sve veću pažnju u poboljšanju analize medicinske dokumentacije, a nekoliko studija ih je koristilo za bolju identifikaciju pacijenata s PAOB na temelju medicinske dokumentacije. Afzal i suradnici razvili su NLP sustav za automatsko bilježenje slučajeva PAOB iz kliničkih bilješki, koristeći skup podataka od 1569 pacijenata (uključujući 806 pacijenata s PAOB i 763 kontrole) (100). Algoritam koristi obradu cjelokupnog teksta i klasifikaciju pacijenata, te je pokazao veću točnost i preciznost u usporedbi s prethodnim modelima koji su samo bilježili ICD-9 dijagnostičke kodove (engl. *International Statistical Classification of Diseases and Related Health Problems*). Algoritam je dalje unaprijeđen da može iz medicinske dokumentacije identificirati prijeteću kritičnu ishemiju ekstremiteta, što omogućuje širu upotrebu tog algoritma kao pomagala u kliničkoj praksi (101).

Napravljen je i veliki pomak u istraživanju i razvijanju algoritama temeljenih na strojnom učenju za identifikaciju i dijagnostiku pacijenata s PAOB. U jednom istraživanju, baziranom na kohorti od 703 pacijenta, načinjen je algoritam strojnog učenja za usporedbu težine PAOB i funkcionalnih ograničenja zbog bolesti. Analizom hodne pruge u 6 minuta i upitnika o kvaliteti života, potvrđen je ne linearni odnos između ovih varijabli, što je važno s obzirom na asimptomatski tok bolesti i implementaciju UI kao alata u dijagnostici iste (102). U sklopu druge studije na kohorti od 1755 pacijenata, načinjen je algoritam nadziranog strojnog učenja, temeljenog na različitim podacima, uključujući kliničke, demografske, slikovne i genomske podatke pacijenata (103). Osnovni cilj ovog modela bila je dijagnostika i detekcija PAOB u pacijenata, te je naknadno prilagođen da predvidi 8-godišnju smrtnost od svih uzroka kod pacijenata.

Osim same potvrde dijagnoze važna je i klasifikacija bolesti radi daljnjeg planiranja terapije. U tome veliku korist ima CTA, kao metoda izbora u lokalizaciji i potvrdi opsežnosti stenozе arterija (104). Korištenjem neuronskih mreža koja automatiziraju CTA, studija temeljena na 265 pacijenata s PAOB, je uspješno klasificirala stenozе arterija iznad i ispod koljena s preko 90% točnosti (105). Planiranje i određivanje tipa optimalnog endovaskularnog liječenja poboljšano je pomoću UI, koja nudi mogućnost kreiranja individualizirane terapijske strategije.

7.1.2. Predoperativno i postoperativno praćenje

Slikovna dijagnostika igra ključnu ulogu u nadziranju pacijenata s perifernom arterijskom bolešću (PAD). Doppler ultrazvuk, pruža detaljne informacije o arterijskoj anatomiji i hemodinamici, jeftin je, neinvazivan i lako dostupan, što ga čini idealnim za probir, predoperativno planiranje i postoperativno praćenje PAD-a. Međutim, dvodimenzionalni ultrazvuk nije idealan za vizualizaciju vaskularnog stabla donjih ekstremiteta i može biti podložan razlikama između dijagnostičara (89). Kako bi se to poboljšalo, razvijeni su trodimenzionalni ultrazvučni sustavi s idejom standardizacije samog postupka pregleda ultrazvukom (106). Kako bi se izbjegla invalidnost pacijenata zbog gubitka ekstremiteta u postoperativnom razdoblju, u velikom naletu je korištenje algoritama za predviđanje preživljenja uda i potrebe amputacije (107). Uz takav pristup, može se drastično smanjiti broj DALY-a u svijetu od ove bolesti.

Jedna od otegotnih okolnosti prilikom zbrinjavanja pacijenata koji boluju od PAOB je raznolikost same bolesti; razlike u anatomskoj lokaciji, težini lezija, simptomima, funkcionalnim testovima, komorbiditetima i ostalo. Zbog toga, odluka o tipu terapije često nije jednostavna te zahtjeva multidisciplinarni pristup (99). Razvijeni su modeli na osnovi neuronske mreže kao potporni alat u donošenju odluka o terapiji kod femoralne PAOB. Rezultati su pokazali da takav jedan model može biti koristan u donošenju *evidence-based* odluka (108).

7.1.3. Dugotrajna prognoza pacijenta

Prognoza pacijenata ne ovisi samo o ranoj detekciji i uspješnoj terapijskoj intervenciji, već i promjeni životnog stila koji je prethodio razvoju PAOB. Primjerice, Chi i suradnici su razvili sustav UI kako bi identificirao promjene životnog stila koje će u najvećoj mjeri smanjiti 10-godišnji rizik od KVB. Iako se ovaj model koristi samo strojno učenje, pretvoren je u sustav podrške pri odlučivanju promjena stila života koji pak uzima u obzir i ograničenja pacijenata (109).

7.2. Aneurizma abdominalne aorte

Trenutne smjernice za zbrinjavanje Aneurizme abdominalne aorte (AAA) navode da na osnovu postojanja simptoma, ista treba biti promptno zbrinuta (110). U slučaju asimptomatske AAA, indikacije za popravak postaju složenije. Oslanjaju se na procjenu rizika od rasta i rupture na osnovi izmjerenog maksimalnog promjera aneurizme slikovnim pretragama u intervalima od 12 mjeseci kod suspektnih aneurizmi (110). Unatoč ovim smjernicama, AAA je životno ugrožavajuće stanje zbog toga što često ne bude dijagnosticirano do nakon rupture. Ako dođe do rupture, situacija je još lošija - mortalitet u takvim slučajevima prelazi 80% (111), čime se ističe potreba za novim, inovativnim tehnikama kako bi se bolje procijenio rizik od nastanka kobnih posljedica. Do sada je razvijeno nekoliko modela, odnosno bodovnih sustava za procjenu operacijskog mortaliteta kod operacije aneurizama abdominalne aorte. POSSUM (engl. *Physiological and Operative Severity Score for enUmeration of Mortality and Morbidity*) je prvi široko prihvaćeni model kod rupturirane aneurizme abdominalne aorte

(rAAA), uveden 1991. godine. Ovaj model koristi 12 fizioloških i 6 operacijskih varijabli za izračunavanje ukupnog broja bodova za procjenu operacijskog mortaliteta. Iako je POSSUM koristan za praćenje kvalitete liječenja, izrazito je složen jer zahtjeva prikupljanje velikog broja varijabli, što ga čini manje pogodnim u hitnim situacijama (51,52).

Kako bi se nadvladali nedostaci POSSUM-a, razvijeni su mnogi modeli, jedan od kojih je GAS (engl. *Glasgow Aneurysm Score*). Uveden je 1994. godine, te se oslanja samo na pet preoperativnih varijabli, što čini veliku prednost ovog modela jer uvelike pojednostavljuje korištenje u kliničkoj praksi. Varijable odabrane za skor su: dob, prisutnost hemoragijskog šoka, srčane bolesti, cerebrovaskularne bolesti i bolesti bubrega (53).

Sa sličnim razmišljanjem prikladnosti za rutinsku kliničku upotrebu je i osmišljen Hardman indeks 1996. godine. On također koristi svega pet faktora za predviđanje operacijskog mortaliteta: dob preko 76 godina, gubitak svijesti pri dolasku u bolnicu, znakove ishemije na EKG-u, kreatinin iznad 190 $\mu\text{mol/L}$ i hemoglobin ispod 90 g/L. Vrijednosti indeksa se kreću od 0 do 5, a rezultat od 3 ili više ukazuje na 100% mortaliteta (54,55).

Među novijim modelima procjene rizika je model iz 2007. godine ERAS (engl. *Edinburgh Ruptured Aneurysm Score*), koji koristi samo tri preoperativne varijable što ga čini vrlo praktičnim u stresnim i hitnim slučajevima: hemoglobin ispod 90 g/L, najbolji Glasgow Coma Score ispod 15, i sistolički krvni tlak ispod 90 mmHg (56).

7.2.1. Detekcija i dijagnostika

Napredak tehnologije je uvelike smanjio ograničenja u zdravstvu. Jedna od prednosti tehnologije je u stratifikaciji rizika. Integracijom različitih izvora podataka u algoritme UI za otkrivanje specifičnih obrazaca bolesti poput AAA, moglo bi se pozitivno utjecati na kliničko odlučivanje i optimizirati medicinsku skrb uz niže troškove (112).

Do rupture može doći i u manjim aneurizmama ili aneurizma može biti neprecizno izmjerena. Jedna studija je pokazala da u 87% slučajeva kod manualnog mjerenja maksimalnog promjera, krajnje prihvaćeni promjer se razlikovao u rasponu od ± 5 mm. Preciznost mjerenja je bolja

kod poluautomatskih metoda, ali i dalje nije savršena (113). Prostora za napredak ima, a obećavajuće rezultate u stratifikaciji rizika, detekciji i dijagnostici pokazuje UI.

Korištenjem dubokog učenja, izrađen je model za automatizirano mjerenje maksimalnog promjera AAA, koji osim svoje izrazite brzine u mjerenju od samo 30 sekundi po CTA snimci nosi i prednost u preciznosti, postižući zavidnu apsolutnu grešku od $\pm 0,8$ mm (114). Osim za mjerenje promjera, izrađen je i algoritam za rani probir malih AAA koji pokazuje obećavajuće rezultate uz potrebu za evaluacijom na većim skupinama pacijenata (115). Primjena ovog modela u svakodnevnoj kliničkoj praksi bi, potencijalno, drastično umanjila rizik od ne dijagnosticiranih AAA, te smanjila broj smrtnih slučajeva.

Za dodatnu korist pacijenta i olakšanje rada vaskularnih kirurga, istražena je mogućnost razvoja sustava za automatsku segmentaciju aorte, detekciju aortalnog lumena i infrarenalnih AAA. Korištenjem skupa od 100 pacijenata te njihovih CTA, uspoređena je brzina i točnost UI sa specijalistom vaskularnim kirurgom. Osim visoke točnosti i preciznosti u mjerenjima i dijagnostici, algoritam je pokazao i zavidnu brzinu segmentacije slika, raspona od 27 sekundi do 4 minute po pacijentu (90). Potencijalna ušteda vremena uz održavanje točnosti i preciznosti analize i segmentacije CTA može imati značajne kliničke posljedice.

7.2.2. Intraoperativna upotreba umjetne inteligencije

Primjena UI u operacijama AAA je višestruko moguća i korisna. Može se koristiti za fuziju slika CTA pri EVAR zahvatu. U tom obliku, UI pomaže u integriranju CTA slika (engl. *image guidance*) u fluoroskopske nalaze u stvarnom vremenu. S tim algoritmom se postiže automatizirani 3D prikaz anatomije krvnih žila i pridruženih malformacija, čime se smanjuje doza i izloženost radiofarmacima uz, za kirurga, jednako dobru vizualizaciju struktura (91). Sam algoritam se stalno prilagođava promjenama položaja pacijenta i intervencijama kirurga, što ga čini izrazito korisnim i potencijalno opravdava potrebu za dodatnim troškovima u vidu uređaja i programa za provođenje ovog sustava (91). Uz to, veliku pažnju i financiranje dobiva sustav za navigaciju na osnovi UI i elektromagnetske tehnologije. Primamljivost ovog modela je u tome što ne koristi radiofarmake tijekom endovaskularnih zahvata. Ujedno omogućava 3D vizualizaciju operateru u zahtjevnim dijelovima operacije (116,117).

S druge strane, ishod same operacije ovisi i o kvaliteti planiranja iste. Korištenjem algoritma UI na predoperativnim CTA, postignuta je personalizirana simulacija krajnjeg odredišta stenta i uspješnosti operacije. Zbog naprednog uvida koji nam donose, ovakvi sustavi mogu biti nezamjenjivi u prevenciji postoperativnih komplikacija (118).

Osim za vizualizaciju, algoritam UI na bazi dubokog učenja je iskorišten kao pomagalo u odlučivanju tijekom EVAR zahvata. UI je korištena za procjenu suboptimalnih zona sidrenja stenta (engl. *landing zone*), te je, unatoč potrebi za detaljnijim istraživanjem na vanjskim skupovima pacijenata, pokazao obećavajuće rezultate točnosti, specifičnosti i osjetljivosti (119).

7.2.3. Praćenje pacijenata

Zaključno, uz poboljšanu dijagnostiku i operativno zbrinjavanje, UI mijenja i mogućnosti dugoročne brige i praćenja pacijenata. Predviđanje razvoja komplikacija poput *endoleakova*, endotenzije i promjene položaja presatka ključno je za dugoročno preživljene pacijenata. Korištenjem neuronskih mreža, UI je uspješno stratificirala pacijente u nisko-rizične i visoko-rizične za razvoj postoperativnih komplikacija unutar 5 godina od EVAR zahvata (120). Takvi algoritmi čine okosnicu za oporavak pacijenata od invazivnih zahvata u svrhu zbrinjavanje AAA.

7.3. Cerebrovaskularna bolest i stenoza karotida

CVB spadaju u domenu vaskularnih, životno ugrožavajućih stanja čije je rano prepoznavanje i promptno zbrinjavanje ključno za dobar ishod. Uz interdisciplinarni pristup, endovaskularno liječenje nudi bolji ishod po pacijenata s CVB. Unatoč ovom napretku u operativnom zbrinjavanju i dalje postoji jasna potreba za poboljšanu detekciju i prevenciju nastanka ove bolesti. Rana detekcija okluzija velikih krvnih žila mozga je imperativ u prevenciji razvitka kliničkih simptoma i posljedica. Jedna od mogućnosti za to je računalom-posredovana trijaža pacijenata. Na osnovu UI, sustava za komunikaciju i čitača CTA nalaza pacijenata, razvijen je

model za automatsku detekciju stenoza velikih krvnih žila i brži početak liječenja (engl. *time to treat*) (121).

Od ostalih metoda rane detekcije, vrijedno je spomena istraživanje o strojnom učenju i neuronskim mrežama i kako nam UI može pomoći identificirati moždani udar na osnovu analize krvnih nalaza. Rezultati sugeriraju da bi primjena ovakvih algoritama ponajviše mogla doprinijeti hitnim odjelima, za postavljanje sumnje u dijagnozu moždanog udara, čime bi se ubrzao početak liječenja ovih pacijenata (122).

Među potencijalnim uzrocima CVB nalazi se i stenoza karotida. U svrhu prevencije nastanka TIA i/ili moždanog udara, razvijeno je više algoritama UI za detekciju, klasifikaciju segmentaciju slika stenozе i stratifikaciju rizika od daljnje progresije bolesti. Pomoću nadziranog tipa strojnog učenja, UI može analizirati radiološke slike ultrazvuka karotida, te pratiti rizik za razvoj CVB. Iako rezultati potvrđuju mogućnost korištenja ovih algoritama u kliničkoj praksi i potencijal za primjenu istih kroz više radioloških modaliteta (CT, MRI i ultrazvuk), potrebna su daljnja istraživanja na vanjskim skupinama pacijenata prije implementacije (123,124). Isto tako, pomoću neuronskih mreža, UI može biti i usmjerena na predviđanje postoperativnih rezultata nakon operacija karotida poput stentiranja karotidnih arterija. Precizno predviđanje nastanka velikih, neželjenih kardiovaskularnih komplikacija donosi sa sobom veliku korist na račun pacijenta. Sustavi UI testirani u ovoj studiji su pokazali 85,8% osjetljivost, 80,8% preciznost i 60,8% specifičnost u predviđanju neželjenih komplikacija nakon operacije karotida (125).

8. EDUKACIJA & UMJETNA INTELIGENCIJA

Transformirajući potencijal UI u zdravstvenoj skrbi leži na svim razinama, uključujući kirurško obrazovanje. Nakon prikaza mnogih prednosti korištenja UI u vaskularnoj kirurgiji, smisljeno je pitati se što misle i kakva je prihvaćenost ove tehnologije među vaskularnim kirurzima. Prema jednom istraživanju podnesenom u Kanadi, vaskularni kirurzi prepoznaju značajan potencijal UI i strojnog učenja u poboljšanju različitih dijelova njihove prakse, uključujući, edukaciju dijagnostiku, prognozu pacijenata, odabir pacijenata za zahvat, analizu slika i intraoperativno vođenje. Međutim, izražavaju zabrinutost zbog mogućih pogrešaka koje bi

mogle naštetiti pacijentima, pristranosti na temelju demografskih podataka te nedostatka znanja i vještina u korištenju tih tehnologija. Unatoč ovim zabrinutostima, kirurzi pokazuju velik interes za dodatnu edukaciju i obuku u području UI, prepoznajući važnost ovih tehnologija u budućem razvoju vaskularne kirurgije (126).

UI ima potencijal značajno poboljšati sve komponente kirurške kompetencije, uključujući tehničke vještine, donošenje odluka i upravljanje kriznim situacijama. Slijedom spomenutog u 5. poglavlju, primjena UI, zajedno sa sustavima uvećane i virtualne stvarnosti, omogućuje nikad zorniji prikaz vaskularnog sustava i njegovih boljki sa svrhom usavršavanja kirurških vještina u sigurnom okruženju. Ujedno, preko pružanja personaliziranih materijala za obuku, prilagođenih individualnim potrebama i stilovima učenja, mnoge tvrtke upravo u UI pronalaze način za unapređenje edukacije (127). Tvrtke poput YourAnastomosis (Pečuh, Mađarska) nude individualizirane modele za vježbanje, koji uključuju: replike stvarnih kirurških situacija i operacijskih polja pomoću proširene stvarnosti i 3D modela, instrumentarij i silikonske replike krvnih žila (128).

Također, UI može pružiti povratne informacije u stvarnom vremenu i analizu izvedbe pojedinog zahvata, što omogućava učinkovitije razvoj vještina, individualiziran potrebama pojedinca. Korištenjem virtualne stvarnosti i simulacijskih tehnologija, UI omogućava kirurzima da vježbaju u sigurnom okruženju bez rizika za pacijente (127). Ovakav tip treninga postao je neophodan za kirurško obrazovanje, povećavajući samopouzdanje i kompetenciju mladih kirurga. Uz mlade kirurge, iskusniji kirurzi mogu koristiti od UI. UI omogućava standardiziranu evaluaciju kompetencije zdravstvenih profesionalaca i odgovara na rastuće zahtjeve za poboljšanjem kvalitete, certifikacijom i akreditacijom (129).

Jedno od područja UI koje može kirurzima drastično pojednostaviti praćenje novih istraživanja je prirodno jezično procesiranje. Ovi sustavi su sposobni prikupljati, analizirati i sistematizirati velike količine istraživanja koje se na dnevnoj bazi publiciraju diljem svijeta. S napretkom tehnologije, liječnici imaju pristup velikim količinama podataka, što može dovesti do preopterećenja informacijama. Iako su istraživanja na samome početku, ovakvo jedno pomagalo bi moglo rezimirati i objašnjavati kompleksnu literaturu, te omogućiti da je svaka potrebna informacija kirurgu na dohvat ruke (127).

Iako UI pokazuje veliki potencijal kao alat za poboljšanje tehničkih i ne tehničkih vještina, klinička primjena još uvijek zaostaje, uključujući integrirane UI u formalne medicinske kurikulume; kao medij za učenje, ali i kao tematika o kojoj se moramo educirati.

9. PITANJA ETIKE PRI KORIŠTENJU UMJETNE INTELIGENCIJE

Korištenje umjetne inteligencije, dakako, povlači sa sobom niz etičkih pitanja vezanih za istinitost, točnost, pravednost, odgovornost, privatnost, povjerljivost, transparentnost i sigurnost iste u medicinskim postupcima. Brojni su razlozi iz kojeg liječnik ili drugi medicinski profesionalac može preispitivati etičnost uporabe umjetne inteligencije. Među najčešće razmatranu problematiku uporabe umjetne inteligencije svrstavaju se sljedeće stavke (130):

- Opravdanost uporabe
- Privatnost i povjerljivost
- Odgovornost i profesionalna odgovornost
- Pravednost i pristranost
- Sigurnost
- Transparentnost i objašnjivost

9.1. Opravdanost uporabe

Iako se nerijetko može činiti kako alati iz domene umjetne inteligencije uvelike ubrzavaju zamorne administrativne i tehničke procese te oslobađaju više vremena za stručnu djelatnost profesionalaca, dovodi se u pitanje potreba i opravdanost uporabe umjetne inteligencije u medicinskim procesima i postupcima. Nikad ne treba smetnuti s uma da UI koristi alate i metode koji najčešće ostaju nedostupni ljudskoj procjeni i nadzoru, kako algoritamski slijed donošenja zaključka tako i dedukcija i objašnjenje samog zaključka (krajnjeg rezultata). Također, ne postoji garancija da u slijedu obrade podataka koristi znanstveno dokazane

činjenice koje podupire struka. Poznato je kako metodologija sustava nije savršena već se temelji na uočavanju obrazaca odnosno statističkoj vjerojatnosti promatrane točke (ideje, zaključka). S druge strane, stalni porast troškova u zdravstvu, manjak radne snage i duge liste čekanja idealno su plodno tlo za razvoj alata koji bi pojedini proces donošenja odluke skratio, ubrzao i pojednostavio. Nikad jedan pojedinac (profesionalac, liječnik) ne može uzeti u obzir tu količinu podataka koju može razmotriti UI. Isto tako, u isto vrijeme može biti obrađen veći broj pacijenata nego što bi to mogao pojedini profesionalac. U jednu ruku postoji bojazan nekolicine da će UI u budućnosti zauvijek ugasiti dio radnih mjesta odrađujući zadatke znatno brže i efikasnije nego čovjek. Opravdanost takvog ishoda također treba razmotriti sa socioekonomske strane i pružiti adekvatnu reorganizaciju posla i radne snage kako radna mjesta ne bi bila nepotrebno izgubljena. Dakle, hoćemo li razmotriti pomoć u vidu korištenja UI? Kada, u kojem omjeru? Ako ćemo se voditi preporukama i smjernicama, citirajući Kodeks medicinske etike Američkog medicinskog društva (131), zaključujemo kako svaka inovacija u medicinskoj praksi koja direktno utječe na pacijenta mora biti temeljena na znanstvenim dokazima i činjenicama i razvijena u koordinaciji s pojedincima s primjerenim kliničkim iskustvom, čime rizik štetnosti od navedene inovacije za pacijente postaje minimalan, a vjerojatnost da će primjerena inovacija imati određene benefite za pacijenta maksimalan. Potreban je nadzor i stalna evaluacija ne samo razvoja inovacije već i njene integracije u zdravstveni sustav. Isti dokument navodi kako znanstvena zajednica treba kontinuirano nadgledati sve alate korištene u procesima vezanim za skrb pacijenata kako ne bi, unatoč dobroj namjeri, došlo do negativnih ishoda poput npr. diskriminacije ili stigmatizacije oboljelih.

9.2. Privatnost i povjerljivost

Prikupljanje, bilježenje i dokumentiranje medicinskih podataka svakodnevnica je rada zdravstvenog sustava. Relevantni medicinski podaci nalaze se arhivirani u medicinske kartone, medicinsku dokumentaciju, registre, baze podataka i druge zapise a sve sa svrhom sistematičnog i cjelovitog prikupljanja informacija o pacijentu u sklopu pacijentu usmjerene skrbi. Cjelovita informacija temelj je dijagnostičko terapijskog procesa i nenadoknadiva okosnica odlučivanja o skrbi pacijenta. Pacijent treba biti upoznat o svakom zapisu i upotrebi njegovih podataka, te za sekundarno korištenje istih dati privolu (poput sudjelovanja u

istraživanjima i slično). Među osnovna prava pacijenta pripada i pravo na privatnost te pravo na povjerljivost. Ona osiguravaju povjerljiv odnos liječnika i pacijenta te ograničavaju mogućnost zlouporabe podataka. Ipak, prikupljeni podaci postaju dio interesa javnih službi radi npr. epidemioloških praćenja, a sve češće i kao baza podataka za moderne sustave pretraživanja uz korištenje UI. Kako bi se problem kršenja prava pacijenata zaobišao, koristi se tzv. „anonimizacija“ podataka koja osigurava da istraživački relevantna činjenica ostane isključivo to, bez da na bilo koji način ugrozi pacijentovu privatnost. U svrhu zaštite podataka i nemogućnosti re-identifikacije pacijenata razvijene su brojne tehnike poput diferencijalne privatnosti, generiranja sintetičnih podataka i k- anonimnost (engl. *differential privacy*, *synthetic data generation* i *k-anonymity*) koje svakako doprinose boljoj zaštiti podataka, no i dalje ostaje otvoreno pitanje autonomije pacijenta i upravljanja vlastitim podacima (38).

9.3. Odgovornost i profesionalna odgovornost

U ovome kontekstu razgraničujemo dvije vrste odgovornosti. Jedno značenje odgovornosti (engl. *responsibility*) tiče se dužnosti ispravnog (iz)vršenja nekog djelovanja, a ne uključuje nužno stvarnu (pravnu ili bilo kakvu drugu) odgovornost. Drugo značenje odgovornosti (engl. *accountability*), tiče se dužnosti opravdanja (svrhe, namjere i razloga) vlastitih postupanja drugima (ili trećima) te odgovaranja za posljedice istih (132).

Logično je postaviti pitanje- hoće li za odluke koje donese UI biti odgovoran liječnik, UI ili netko treći? U dosadašnjoj medicinskoj praksi, liječnik s odobrenjem za samostalni rad pred zakonom odgovara za svaku donesenu odluku vezanu uz skrb pacijenta, što svakako ima i smisla u sustavu u kojem proces donošenja odluka ovisi o nalazima i dokumentaciji koju evaluira sam liječnik (ili medicinski tim) , čime se u konačnici i potkrepljuje donesena odluka. Ukoliko UI evaluira nalaze pacijenta na temelju usporedbe s bazom podataka i sličnosti s varijablama istih (simptomi, znakovi, nalazi...), hoće li UI ili možda njegov koordinator preuzeti odgovornost i za ishode liječenja?

Držati liječnika odgovornim možemo smatrati neetičnim iz više razloga. Prvi, a koji je i ranije spomenut, je da tehnika rada UI sustava često ostaje nepoznata krajnjem korisniku usluge (engl. *black-box* izazov UI), čime i sama kontrola nad navedenim sustavom postaje zahtjevna i teško

je uočiti pogrešku ili pristranost u donošenju odluke. Primjerice vaskularni kirurg koji dobije statistički izraženu stratifikaciju rizika pojedinog pacijenta i, ukoliko je rizik za razvoj neke bolesti manji od rizika od operacije, on odluči pacijentu ne dati pojedinu terapiju. Kada se ipak ispostavi da je prijeko potrebno liječenje, na kome leži krivica? Ovom problemu nastoji se doskočiti stvaranjem alata koji predočavaju proces donošenja odluke. Ovdje se javlja i dodatan problem dovoljne razumljivosti procesa u kojem svakodnevno informaciju pokušava dobiti sve veći broj dionika, a informiranost i predznanje nužno za potpuno razumijevanje nisu postojeći. Međutim, ovdje treba reći kako je taj problem općenito prisutan u medicini i kako svakom dodatnom nadogradnjom kojom sustav postaje sve sofisticiraniji manji broj dionika zaista razumije podlogu njegova rada, slično kao i kod npr. složenih dijagnostičkih pretraga (133).

9.4. Pravednost i pristranost

Pristranost se može odrediti kao sustavno odstupanje od stvarne vrijednosti. Ono može nastati u bilo kojem dijelu (ili trenutku) razvoja, primjene i/ili uporabe umjetne inteligencije. Ipak, pristranosti se može razlučiti na onu koje nastaje na razini podataka (engl. *data bias*), na razini samog sustava umjetne inteligencije (engl. *algorithmic bias*), te na razini primjene i raspodjele istih u stvarnom okruženju (134).

Znamo kako na profesionalne odluke liječnika ne bi smjeli utjecati čimbenici poput spola, rase, dobi, etničkog porijekla, političke pripadnosti, seksualne orijentacije i slično. Međutim, UI je sustav koji je odraz djelovanja ljudi a koji su i sami često i nesvjesno pod utjecajem predrasuda vezanih uz ove čimbenike. U zemljama koje koriste algoritme osmišljene za pomoć pri donošenju odluka o skrbi pacijenata (npr. SAD) primijećena je rasna i kontekstualna pristranost.

U studiji objavljenoj u Science-u u listopadu 2019., istraživači su otkrili značajnu rasnu pristranost u algoritmu koji se naširoko koristi u američkom zdravstvenom sustavu za usmjeravanje zdravstvenih odluka. Algoritam se temelji na trošku (a ne na bolesti) kao zamjenu za potrebe; međutim, američki sustav zdravstvene skrbi trošio je manje novca za crne nego za bijele pacijente s istom razinom potreba. Dakle, algoritam je pogrešno pretpostavio da su bijeli pacijenti bolesniji od jednako bolesnih crnih pacijenata. Istraživači su procijenili da je rasna

predrasuda smanjila broj crnih pacijenata koji primaju dodatnu skrb za više od polovice (135). Ovo je samo jedan u nizu mnogobrojnih primjera za pristranost sustava UI u donošenju odluka. Ne smijemo zaboraviti kako se sami podaci na kojima se zasniva „treening“ UI odnose na većinu populacije (engl. *majorities*) i zanemaruju manjine i određene populacijske skupine. Time dolazimo do problematike pristranosti podataka na temelju kojeg slijedi pristranost algoritma (8).

9.5. Sigurnost

Sljedeće pitanje na koje ćemo se osvrnuti je pitanje sigurnosti i online sigurnosti pacijenata pri korištenju UI. Pacijenti mogu biti u opasnosti od netočnih preporuka ili objašnjenja preporuka koje previdi regulatorni sustav aplikacije. Postoji opasnost od davanja preporuka na temelju širokog spektra lažno pozitivnih ili lažno negativnih rezultata pretraživanja literature koja, ukoliko bude široko dostupna, može odjednom ugroziti velik broj ljudi (za razliku od ljudske pogreške koja se, naravno, također događa ali u tom slučaju neposredno ugrožava jednog pacijenta). Aplikacija koja pruža informacije može biti krivo kodirana i davati krivu preporuku, za što je poznat primjer aplikacije stvorene u UK-u (NHS COVID-19) koja je prema pogrešnom algoritmu davala netočne preporuke o samoizolaciji nakon kontakta s oboljelim. Aplikaciju je preuzelo 19 milijuna ljudi i utjecaj takve pogreške odigrao je značajnu ulogu na širenje bolesti (136).

Naravno, tu je pitanje etičnosti već pri samoj tvorbi algoritma, koja u startu može biti pristrana kako bi pogodovala određenoj interesnoj skupini i pridonijela profitu.

Što se tiče računalne sigurnosti (engl. *cyber security*), postoji bojazan od proboja u informacijski sustav koji sadrži osjetljive informacije o brojnim pojedincima i krađa kojih bi dovela do kršenja prava na privatnost informacija pacijenata. Ti bi se podaci također lako mogli koristiti u protuzakonite svrhe, mijenjati način na koji algoritam barata podacima i ponovno nas dovesti do pitanja zlorabe znanja.

9.6. Transparentnost i objašnjivost

Kao što smo raspravili u točki *Odgovornost i profesionalna odgovornost*, u medicini postoji jasan uzročno-posljedični slijed donošenja odluka temeljen na znanstvenim činjenicama, a koje donosi stručnjak (liječnik) na temelju dostupnih informacija o pacijentovu stanju te stručne literature. Ovakav se jasno definiran slijed potencijalno gubi u sustavu koji nije pod ljudskom kontrolom, ne može razložiti slijed donošenja odluka niti transparentno izvijestiti krajnjeg korisnika o porijeklu korištenog izvora. Ovime se cijeli misaoni proces dijagnostičkog dijela medicine zapravo briše i preskače, a rezultat ovisi o informacijama na koje liječnik nema utjecaja. Isto vrijedi i ako je korisnik aplikacije, koja daje preporuke o zdravlju, pacijent. Izostaje informacija o izvoru na temelju kojeg se donosi preporuka i tko u krajnjoj liniji iza tog izvora stoji. Općenito se ovim izazovima nastoji doskočiti ili razvojem algoritama koji su objašnjivi, razvojem sposobnosti predočavanja postupaka donošenja odluka ili razvojem mogućnosti pružanja cjelovitih objašnjenja. Cilj je omogućiti svima onima kojih se umjetna inteligencija tiče i dotiče osnove kojima ti sustavi donose odluke i predviđanja, a s krajnjim ciljem poticanja povjerenja (132).

9.7. Etički principi Svjetske zdravstvene organizacije o umjetnoj inteligenciji

Kako bi razvoj i korištenje UI bilo što sigurnije, transparentnije, odgovornije i po prihvaćenim etičkim standardima, WHO (engl. *World Health Organization*) je sastavila etičke principe za korištene UI u medicini prema kojima je potrebno (137):

- Izbjegavati nanositi štetu drugima (engl. *do not harm* ili „neškodljivost“).
- Promicati dobrobit drugih kada je to moguće („dobročinstvo“). Rizike od štete treba svesti na minimum, a maksimizirati koristi. Očekivani rizici trebaju biti u ravnoteži s očekivanim koristima.
- Osigurati da se prema svim osobama postupa pošteno, što uključuje zahtjev da niti jedna osoba ili skupina ne bude izložena diskriminaciji, zanemarivanju, manipulaciji, dominaciji ili zlostavljanju ("pravda" ili "poštenost").

- Postupati s osobama na načine koji poštuju njihove interese u donošenju odluka njihovim životima i njihovoj osobi, uključujući odluke o zdravstvenoj skrbi, informirano razumijevanje prirode izbora koji treba napraviti, njegovog značaja, interese osobe i vjerojatne posljedice. (“autonomija”).

10. ZAKLJUČAK

Vjerojatno ne bi bilo posve pogrešno zaključiti da je dosadašnja upotreba računala u medicini išla ponešto u krivome smjeru. Jedan od takvih primjera su liječnici koji opslužuju strojeve i gledaju više ekran nego pacijenta. Upravo je umjetne inteligencija jedno od potencijalnih rješenja za to, jer bi njena uporaba mogla osloboditi liječnika od rutinskih, služinskih poslova, time mu omogućujući više vremena za skrb orijentiranu na pacijenta.

Konkretni primjeri navedeni u ovom radu, o korištenju naprednih algoritama, su pokazali da UI omogućuje detaljniju analizu medicinskih slika, precizniju procjenu rizika i optimizaciju kirurških zahvata. Također, UI može pratiti postoperativni oporavak i pravovremeno identificirati potencijalne komplikacije, čime se osigurava kontinuirana skrb za pacijente.

U konačnici, UI i sva tehnologija u koju je ona uključena aktivno mijenja područje vaskularne kirurgije kroz brojne inovacije koje poboljšavaju detekciju, dijagnostiku, terapiju i edukaciju. Preciznost i učinkovitost UI sustava mogu značajno smanjiti komplikacije i unaprijediti rezultate liječenja, pružajući kirurzima moćan alat za donošenje informiranih odluka.

Uza sve prednosti, upozorenja o korištenju UI su mnogobrojna; primjerice, „UI je vjerojatno najveća prijetnja s kojom se suočava čovječanstvo“ (138). Tvorac ove izjave je Elon Musk, i unatoč okolnostima ove izjave i kontroverznosti osobe koja ju je izjavila, ova izjava podsjeća nas na potrebu za oprezom i odgovornošću pri implementaciji UI u medicinskoj praksi. Etička pitanja, uključujući privatnost podataka, pravednost i transparentnost algoritama, te potreba za kontinuiranom edukacijom liječnika, moraju biti pažljivo razmotreni kako bi se osigurala sigurna i učinkovita implementacija UI u kliničkoj praksi.

Zaključno, umjetna inteligencija ima potencijal transformirati vaskularnu kirurgiju, ali njezin uspjeh ovisit će o suradnji između kliničara, istraživača i regulatornih tijela. Samo kroz zajednički napor moći će se iskoristiti puni potencijal UI i unaprijediti skrb za pacijente s vaskularnim bolestima.

ZAHVALE

Na prvom mjestu želim izraziti svoju duboku zahvalnost svom mentoru, Doc. dr. sc. Tomislavu Meštroviću, dr. med., na neizmjernej pomoći i stručnom vodstvu pri pisanju ovog diplomskog rada. Vaša podrška i savjeti bili su od presudne važnosti za moj napredak i završetak ovog rada.

Neizmjerne zahvale dugujem svojoj obitelji - mami, tati, sestrama Niji i Kim, teti Ljilji, te šogorima Martinu i Marku. Vaša bezuvjetna ljubav, potpora i razumijevanje tijekom svih šest godina studiranja bile su ključne. Bez vaše pomoći ne bih daleko dogurao. Posebno hvala mojim dragim bakama, Nadi i Vinki, čija mudrost, bezrezervna podrška i izvrsna kuhinja nisu samo ispunjavali moje srce, već su me motivirali i poticali da nastavim dalje kroz sve godine studija. Hvala i mom psu Sorry, mojoj životnoj najboljoj prijateljici, što je bila nepresušan izvor sreće i motivacije za mene.

Od srca zahvaljujem i Tei, koja me uvijek poticala da budem bolja verzija sebe u svakoj prilici. Tvoja motivacija, podrška i naše zajedničko danonoćno učenje u NSB-u bili su nezamjenjivi tijekom ovog puta. Posebne zahvale idu mojim najbližim prijateljima, Bićinarima. Vaše prijateljstvo, podrška i ljubav pružali su mi bijeg od zahtjevnog fakulteta i pomagali mi održati ravnotežu tijekom studiranja. Vaša prisutnost u mom životu činila je sve izazove lakšima i podnošljivijima.

Na kraju, želim posebno istaknuti svoju zahvalnost udruzi StEPP (Studentska Ekipa Prve Pomoći), koja mi je bila poput druge obitelji na fakultetu. Kroz udругu sam stekao prijateljstva za cijeli život, koja su mi bila neizmjerne podrška tijekom studiranja. Znanje i vještine koje sam usvojio kroz rad u udruzi približile su me ostvarenju mog sna da postanem liječnik kakav sam oduvijek želio biti.

Hvala svima od srca!

LITERATURA

1. Liu P ran, Lu L, Zhang J yao, Huo T tong, Liu S xiang, Ye Z wei. Application of Artificial Intelligence in Medicine: An Overview. *Curr Med Sci*. 2021;41(6):1105–15.
2. Turing AM. Computing machinery and intelligence. *Mind*. 1950;59:433–60.
3. Stilgoe J. We need a Weizenbaum test for AI. *Science*. 2023 Aug 11;381(6658):eadk0176.
4. Weizenbaum J. On the Impact of the Computer on Society. *Science*. 1972 May 12;176(4035):609–14.
5. Powezka K, Slater L, Wall M, Gkoutos G, Juszcak M. Source of data for artificial intelligence applications in vascular surgery - a scoping review [Internet]. 2023 [cited 2024 May 12]. Available from: <http://medrxiv.org/lookup/doi/10.1101/2023.10.03.23296506>
6. The Lancet. Artificial intelligence in health care: within touching distance. *The Lancet*. 2017 Dec;390(10114):2739.
7. Lee ES, Dawson DL, Pevec WC. Vascular surgery: an update. *Am Fam Physician*. 2007 Jan 1;75(1):85–90.
8. Lareyre F, Chaudhuri A, Behrendt CA, Pouhin A, Teraa M, Boyle JR, et al. Artificial intelligence-based predictive models in vascular diseases. *Semin Vasc Surg*. 2023 Sep;36(3):440–7.
9. Taher F, Hofmann A, Assadian A. Precision Medicine in Vascular and Endovascular Surgery. *J Clin Med*. 2023 Jan 29;12(3):1031.
10. Paraskevas KI, Saba L, Suri JS. Applications of Artificial Intelligence in Vascular Diseases. *Angiology*. 2022 Aug 1;73(7):597–8.
11. Raffort J, Adam C, Carrier M, Lareyre F. Fundamentals in Artificial Intelligence for Vascular Surgeons. *Ann Vasc Surg*. 2020 May;65:254–60.
12. Spanos K, Giannoukas AD, Kouvelos G, Tsougos I, Mavroforou A. Artificial intelligence application in vascular diseases. *J Vasc Surg*. 2022 Sep;76(3):615–9.
13. Bleakley C. Artificial Intelligence Emerges. 2020;75–92.
14. Bleakley C. *Poems That Solve Puzzles: The History and Science of Algorithms* [Internet]. Oxford University Press; 2020 [cited 2024 May 27]. Available from: <https://academic.oup.com/book/31959>
15. Geffner H. Artificial Intelligence: From programs to solvers. *AI Commun*. 2014 Jan 1;27(1):45–51.
16. Xiang Y, Zhao L, Liu Z, Wu X, Chen J, Long E, et al. Implementation of artificial intelligence in medicine: Status analysis and development suggestions. *Artif Intell Med*. 2020 Jan;102:101780.

17. Chowdhary KR. Fundamentals of Artificial Intelligence [Internet]. New Delhi: Springer India; 2020 [cited 2024 May 27]. Available from: <http://link.springer.com/10.1007/978-81-322-3972-7>
18. Warwick K. Artificial Intelligence: The Basics. Routledge; 2012. 183 p.
19. Nilsson NJ. Principles of artificial intelligence. Repr. Los Altos, Calif: Morgan Kaufmann Publ; 1986. 476 p.
20. Welsh R. Defining Artificial Intelligence. SMPTE Motion Imaging J. 2019 Jan 1;128:26–32.
21. Dietterich T. Machine learning. ACM Comput Surv. 1996 Dec 1;28(4es):3-es.
22. Kubat M. An Introduction to Machine Learning [Internet]. Cham: Springer International Publishing; 2017 [cited 2024 May 27]. Available from: <http://link.springer.com/10.1007/978-3-319-63913-0>
23. Carleo G, Cirac I, Cranmer K, Daudet L, Schuld M, Tishby N, et al. Machine learning and the physical sciences. Rev Mod Phys. 2019 Dec 6;91(4):045002.
24. Kutlugün E, Eyüpoğlu C. Artificial Intelligence Methods Used in Computer Vision. In: 2020 5th International Conference on Computer Science and Engineering (UBMK) [Internet]. 2020 [cited 2024 May 27]. p. 214–8. Available from: <https://ieeexplore.ieee.org/document/9219385>
25. Karn A. ARTIFICIAL INTELLIGENCE IN COMPUTER VISION. Int J Eng Appl Sci Technol [Internet]. 2021 May 1 [cited 2024 May 27];6(1). Available from: <https://ijeast.com/papers/249-254,Tesma601,IJEAST.pdf>
26. Janiesch C, Zschech P, Heinrich K. Machine learning and deep learning. Electron Mark. 2021 Sep 1;31(3):685–95.
27. Geirhos R, Jacobsen JH, Michaelis C, Zemel R, Brendel W, Bethge M, et al. Shortcut learning in deep neural networks. Nat Mach Intell. 2020 Nov;2(11):665–73.
28. Zhu X, Wang Z, Li C, Sun X. Research on Artificial Intelligence Network Based on Deep Learning. In: 2021 2nd International Conference on Information Science and Education (ICISE-IE) [Internet]. 2021 [cited 2024 May 27]. p. 613–7. Available from: <https://ieeexplore.ieee.org/document/9742327>
29. Ten Teije A, Popow C, Holmes JH, Sacchi L, editors. Artificial Intelligence in Medicine: 16th Conference on Artificial Intelligence in Medicine, AIME 2017, Vienna, Austria, June 21–24, 2017, Proceedings [Internet]. Cham: Springer International Publishing; 2017 [cited 2024 May 27]. (Lecture Notes in Computer Science; vol. 10259). Available from: <https://link.springer.com/10.1007/978-3-319-59758-4>
30. Becker A. Artificial intelligence in medicine: What is it doing for us today? Health Policy Technol. 2019 Jun 1;8(2):198–205.

31. Blais C, Rochette L, Ouellet S, Huynh T. Complex Evolution of Epidemiology of Vascular Diseases, Including Increased Disease Burden: From 2000 to 2015. *Can J Cardiol*. 2020 May 1;36(5):740–6.
32. McGill HC, McMahan CA, Gidding SS. Preventing heart disease in the 21st century: implications of the Pathobiological Determinants of Atherosclerosis in Youth (PDAY) study. *Circulation*. 2008 Mar 4;117(9):1216–27.
33. GBD 2017 Diet Collaborators. Health effects of dietary risks in 195 countries, 1990–2017: a systematic analysis for the Global Burden of Disease Study 2017. *Lancet Lond Engl*. 2019 May 11;393(10184):1958–72.
34. Fogacci F, Borghi C, Tocci G, Cicero AFG. Socioeconomic status as determinant of individual cardiovascular risk. *Atherosclerosis*. 2022 Apr;346:82–3.
35. Ignatiuk B. Socioeconomic status as a cardiovascular risk modulator: An emerging target for interventions. *Int J Cardiol*. 2022 Aug 15;361:101–2.
36. Sidawy AN. *Rutherford’s Vascular Surgery and Endovascular Therapy*. 2018;9th Edition.
37. Gordon T, Kannel WB. Predisposition to atherosclerosis in the head, heart, and legs. The Framingham study. *JAMA*. 1972 Aug 14;221(7):661–6.
38. Dossabhoy SS, Ho VT, Ross EG, Rodriguez F, Arya S. Artificial Intelligence in Clinical Workflow Processes in Vascular Surgery and Beyond. *Semin Vasc Surg*. 2023 Sep;36(3):401–12.
39. Pleumeekers HJ, Hoes AW, van der Does E, van Urk H, Grobbee DE. Epidemiology of abdominal aortic aneurysms. *Eur J Vasc Surg*. 1994 Mar;8(2):119–28.
40. Singh K, Bønaa KH, Jacobsen BK, Bjørk L, Solberg S. Prevalence of and Risk Factors for Abdominal Aortic Aneurysms in a Population-based Study : The Tromsø Study. *Am J Epidemiol*. 2001 Aug 1;154(3):236–44.
41. McDaniel MD, Cronenwett JL. Basic data related to the natural history of intermittent claudication. *Ann Vasc Surg*. 1989 Jul;3(3):273–7.
42. Barnes RW. Vascular Holism: The Epidemiology of Vascular Disease. *Ann Vasc Surg*. 1995 Nov 1;9(6):576–82.
43. Gorelick PB. Cerebrovascular disease. Pathophysiology and diagnosis. *Nurs Clin North Am*. 1986 Jun;21(2):275–88.
44. Cushman M. Epidemiology and Risk Factors for Venous Thrombosis. *Semin Hematol*. 2007 Apr;44(2):62–9.
45. Goldhaber SZ, Morpurgo M. Diagnosis, treatment, and prevention of pulmonary embolism. Report of the WHO/International Society and Federation of Cardiology Task Force. *JAMA*. 1992 Oct 7;268(13):1727–33.

46. Mancia G, De Backer G, Dominiczak A, Cifkova R, Fagard R, Germano G, et al. 2007 Guidelines for the Management of Arterial Hypertension: The Task Force for the Management of Arterial Hypertension of the European Society of Hypertension (ESH) and of the European Society of Cardiology (ESC). *J Hypertens*. 2007 Jun;25(6):1105–87.
47. Sofogianni A, Stalikas N, Antza C, Tziomalos K. Cardiovascular Risk Prediction Models and Scores in the Era of Personalized Medicine. *J Pers Med*. 2022 Jul 20;12(7):1180.
48. SCORE2 working group and ESC Cardiovascular risk collaboration. SCORE2 risk prediction algorithms: new models to estimate 10-year risk of cardiovascular disease in Europe. *Eur Heart J*. 2021 Jul 1;42(25):2439–54.
49. Neumann JT, Riaz M, Bakshi A, Polekhina G, Thao LTP, Nelson MR, et al. Prognostic Value of a Polygenic Risk Score for Coronary Heart Disease in Individuals Aged 70 Years and Older. *Circ Genomic Precis Med*. 2022 Feb;15(1):e003429.
50. Natriuretic Peptides Studies Collaboration null, Willeit P, Kaptoge S, Welsh P, Butterworth A, Chowdhury R, et al. Natriuretic peptides and integrated risk assessment for cardiovascular disease: an individual-participant-data meta-analysis. *Lancet Diabetes Endocrinol*. 2016 Oct;4(10):840–9.
51. Fassoulaki A, Chondrogiannis K, Staikou C. Physiological and operative severity score for the enumeration of mortality and morbidity scoring systems for assessment of patient outcome and impact of surgeons' and anesthesiologists' performance in hepatopancreaticobiliary surgery. *Saudi J Anaesth*. 2017;11(2):190–5.
52. Copeland GP, Jones D, Walters M. POSSUM: a scoring system for surgical audit. *Br J Surg*. 1991 Mar;78(3):355–60.
53. Samy AK, Murray G, MacBain G. Glasgow aneurysm score. *Cardiovasc Surg Lond Engl*. 1994 Feb;2(1):41–4.
54. Hardman DT, Fisher CM, Patel MI, Neale M, Chambers J, Lane R, et al. Ruptured abdominal aortic aneurysms: who should be offered surgery? *J Vasc Surg*. 1996 Jan;23(1):123–9.
55. Meštrović T. Razvoj modela za predviđanje operacijskoga mortaliteta bolesnika s rupturom aneurizama trbušne aorte [Internet] [info:eu-repo/semantics/doctoralThesis]. University of Zagreb. School of Medicine; 2014 [cited 2024 May 31]. Available from: <https://urn.nsk.hr/urn:nbn:hr:105:440251>
56. Tambyraja A, Murie J, Chalmers R. Predictors of outcome after abdominal aortic aneurysm rupture: Edinburgh Ruptured Aneurysm Score. *World J Surg*. 2007 Nov;31(11):2243–7.
57. Fleisher LA, Eagle KA, Shaffer T, Anderson GF. Perioperative- and long-term mortality rates after major vascular surgery: the relationship to preoperative testing in the medicare population. *Anesth Analg*. 1999 Oct;89(4):849–55.
58. Smeili LAA, Lotufo PA. Incidence and Predictors of Cardiovascular Complications and Death after Vascular Surgery. *Arq Bras Cardiol*. 2015 Nov;105(5):510–8.

59. Khuri SF, Henderson WG, DePalma RG, Mosca C, Healey NA, Kumbhani DJ, et al. Determinants of long-term survival after major surgery and the adverse effect of postoperative complications. *Ann Surg*. 2005 Sep;242(3):326–41; discussion 341-343.
60. Bertges DJ, Goodney PP, Zhao Y, Schanzer A, Nolan BW, Likosky DS, et al. The Vascular Study Group of New England Cardiac Risk Index (VSG-CRI) predicts cardiac complications more accurately than the Revised Cardiac Risk Index in vascular surgery patients. *J Vasc Surg*. 2010 Sep;52(3):674–83, 683.e1-683.e3.
61. Baum RA, Carpenter JP, Tuite CM, Velazquez OC, Soulen MC, Barker CF, et al. Diagnosis and treatment of inferior mesenteric arterial endoleaks after endovascular repair of abdominal aortic aneurysms. *Radiology*. 2000 May;215(2):409–13.
62. Chuter TA, Reilly LM, Faruqi RM, Kerlan RB, Sawhney R, Canto CJ, et al. Endovascular aneurysm repair in high-risk patients. *J Vasc Surg*. 2000 Jan;31(1 Pt 1):122–33.
63. Raffort J, Adam C, Carrier M, Ballaith A, Coscas R, Jean-Baptiste E, et al. Artificial intelligence in abdominal aortic aneurysm. *J Vasc Surg*. 2020 Jul;72(1):321-333.e1.
64. Masuda T, Baba Y, Nakaura T, Funama Y, Sato T, Masuda S, et al. Applying patient characteristics, stent-graft selection, and pre-operative computed tomographic angiography data to a machine learning algorithm: Is endoleak prediction possible? *Radiogr Lond Engl* 1995. 2022 Nov;28(4):906–11.
65. Siontis KC, Noseworthy PA, Attia ZI, Friedman PA. Artificial intelligence-enhanced electrocardiography in cardiovascular disease management. *Nat Rev Cardiol*. 2021 Jul;18(7):465–78.
66. Kusunose K, Haga A, Abe T, Sata M. Utilization of Artificial Intelligence in Echocardiography. *Circ J*. 2019;83(8):1623–9.
67. Cheema BS, Walter J, Narang A, Thomas JD. Artificial Intelligence–Enabled POCUS in the COVID-19 ICU: A New Spin on Cardiac Ultrasound. *JACC Case Rep*. 2021 Feb 1;3(2):258–63.
68. Narang A, Bae R, Hong H, Thomas Y, Surette S, Cadieu C, et al. Utility of a Deep-Learning Algorithm to Guide Novices to Acquire Echocardiograms for Limited Diagnostic Use. *JAMA Cardiol*. 2021 Jun 1;6(6):624–32.
69. Vidal-Perez R, Grapsa J, Bouzas-Mosquera A, Fontes-Carvalho R, Vazquez-Rodriguez JM. Current role and future perspectives of artificial intelligence in echocardiography. *World J Cardiol*. 2023 Jun 26;15(6):284–92.
70. Zhang J, Gajjala S, Agrawal P, Tison GH, Hallock LA, Beussink-Nelson L, et al. Fully Automated Echocardiogram Interpretation in Clinical Practice. *Circulation*. 2018 Oct 16;138(16):1623–35.
71. Turchioe MR, Volodarskiy A, Pathak J, Wright DN, Tcheng JE, Slotwiner D. Systematic review of current natural language processing methods and applications in cardiology. *Heart*. 2022 Jun 1;108(12):909–16.

72. Samad MD, Ulloa A, Wehner GJ, Jing L, Hartzel D, Good CW, et al. Predicting Survival From Large Echocardiography and Electronic Health Record Datasets: Optimization With Machine Learning. *JACC Cardiovasc Imaging*. 2019 Apr 1;12(4):681–9.
73. Yao X, Rushlow DR, Inselman JW, McCoy RG, Thacher TD, Behnken EM, et al. Artificial intelligence–enabled electrocardiograms for identification of patients with low ejection fraction: a pragmatic, randomized clinical trial. *Nat Med*. 2021 May;27(5):815–9.
74. Patel PR, De Jesus O. CT Scan. In: StatPearls [Internet]. Treasure Island (FL): StatPearls Publishing; 2024 [cited 2024 May 30]. Available from: <http://www.ncbi.nlm.nih.gov/books/NBK567796/>
75. Rankin SC. CT angiography. *Eur Radiol*. 1999;9(2):297–310.
76. Wolterink JM, Leiner T, Viergever MA, Išgum I. Generative Adversarial Networks for Noise Reduction in Low-Dose CT. *IEEE Trans Med Imaging*. 2017 Dec;36(12):2536–45.
77. Kang D, Dey D, Slomka PJ, Arsanjani R, Nakazato R, Ko H, et al. Structured learning algorithm for detection of nonobstructive and obstructive coronary plaque lesions from computed tomography angiography. *J Med Imaging Bellingham Wash*. 2015 Jan;2(1):014003.
78. Liao J, Huang L, Qu M, Chen B, Wang G. Artificial Intelligence in Coronary CT Angiography: Current Status and Future Prospects. *Front Cardiovasc Med*. 2022 Jun 17;9:896366.
79. Sinha K, Berczeli M, Lumsden AB, Roy TL. Imaging: New Frontiers in Vascular Training. *Methodist DeBakey Cardiovasc J*. 18(3):39–48.
80. Winther HB, Hundt C, Schmidt B, Czerner C, Bauersachs J, Wacker F, et al. v-net: Deep Learning for Generalized Biventricular Mass and Function Parameters Using Multicenter Cardiac MRI Data. *JACC Cardiovasc Imaging*. 2018 Jul;11(7):1036–8.
81. Qian J, Li H, Wang J, He L. Recent Advances in Explainable Artificial Intelligence for Magnetic Resonance Imaging. *Diagnostics*. 2023 Jan;13(9):1571.
82. Hartung MP, Grist TM, François CJ. Magnetic resonance angiography: current status and future directions. *J Cardiovasc Magn Reson Off J Soc Cardiovasc Magn Reson*. 2011 Mar 9;13(1):19.
83. Lanzafame LRM, Bucolo GM, Muscogiuri G, Sironi S, Gaeta M, Ascenti G, et al. Artificial Intelligence in Cardiovascular CT and MR Imaging. *Life*. 2023 Feb 11;13(2):507.
84. Sureshkumar A, Hansen B, Ersahin D. Role of Nuclear Medicine in Imaging. *Semin Ultrasound CT MR*. 2020 Feb;41(1):10–9.
85. Kamel MA, Abbas MT, Kanaan CN, Awad KA, Baba Ali N, Scalia IG, et al. How Artificial Intelligence Can Enhance the Diagnosis of Cardiac Amyloidosis: A Review of Recent Advances and Challenges. *J Cardiovasc Dev Dis*. 2024 Apr 13;11(4):118.

86. Haro Alonso D, Wernick MN, Yang Y, Germano G, Berman DS, Slomka P. Prediction of cardiac death after adenosine myocardial perfusion SPECT based on machine learning. *J Nucl Cardiol Off Publ Am Soc Nucl Cardiol*. 2019 Oct;26(5):1746–54.
87. Covas P, De Guzman E, Barrows I, Bradley AJ, Choi BG, Krepp JM, et al. Artificial Intelligence Advancements in the Cardiovascular Imaging of Coronary Atherosclerosis. *Front Cardiovasc Med* [Internet]. 2022 Mar 21 [cited 2024 May 30];9. Available from: <https://www.frontiersin.org/articles/10.3389/fcvm.2022.839400>
88. Khor WS, Baker B, Amin K, Chan A, Patel K, Wong J. Augmented and virtual reality in surgery—the digital surgical environment: applications, limitations and legal pitfalls. *Ann Transl Med*. 2016 Dec;4(23):454.
89. Condino S, Piazza R, Carbone M, Bath J, Troisi N, Ferrari M, et al. Bioengineering, augmented reality, and robotic surgery in vascular surgery: A literature review. *Front Surg*. 2022 Aug 19;9:966118.
90. Caradu C, Spampinato B, Vrancianu AM, Bérard X, Ducasse E. Fully automatic volume segmentation of infrarenal abdominal aortic aneurysm computed tomography images with deep learning approaches versus physician controlled manual segmentation. *J Vasc Surg*. 2021 Jul;74(1):246-256.e6.
91. Maurel B, Martin-Gonzalez T, Chong D, Irwin A, Guimbretière G, Davis M, et al. A prospective observational trial of fusion imaging in infrarenal aneurysms. *J Vasc Surg*. 2018 Dec;68(6):1706-1713.e1.
92. Štádler P, Dorosh J, Dvořáček L, Vitásek P, Matouš P, Lin JC. Review and current update of robotic-assisted laparoscopic vascular surgery. *Semin Vasc Surg*. 2021 Dec;34(4):225–32.
93. Cruddas L, Martin G, Riga C. Robotic endovascular surgery: current and future practice. *Semin Vasc Surg*. 2021 Dec 1;34(4):233–40.
94. Corey KM, Kashyap S, Lorenzi E, Lagoo-Deenadayalan SA, Heller K, Whalen K, et al. Development and validation of machine learning models to identify high-risk surgical patients using automatically curated electronic health record data (Pythia): A retrospective, single-site study. *PLOS Med*. 2018 Nov 27;15(11):e1002701.
95. Vistisen ST, Johnson AEW, Scheeren TWL. Predicting vital sign deterioration with artificial intelligence or machine learning. *J Clin Monit Comput*. 2019 Dec 1;33(6):949–51.
96. van der Ven WH, Veelo DP, Wijnberge M, van der Ster BJP, Vlaar APJ, Geerts BF. One of the first validations of an artificial intelligence algorithm for clinical use: The impact on intraoperative hypotension prediction and clinical decision-making. *Surgery*. 2021 Jun 1;169(6):1300–3.
97. Maheshwari K, Ruetzler K, Saugel B. Perioperative intelligence: applications of artificial intelligence in perioperative medicine. *J Clin Monit Comput*. 2020 Aug;34(4):625–8.
98. Song P, Rudan D, Zhu Y, Fowkes FJI, Rahimi K, Fowkes FGR, et al. Global, regional, and national prevalence and risk factors for peripheral artery disease in 2015: an updated systematic review and analysis. *Lancet Glob Health*. 2019 Aug;7(8):e1020–30.

99. Aboyans V, Ricco JB, Bartelink MLEL, Björck M, Brodmann M, Cohnert T, et al. Editor's Choice – 2017 ESC Guidelines on the Diagnosis and Treatment of Peripheral Arterial Diseases, in collaboration with the European Society for Vascular Surgery (ESVS). *Eur J Vasc Endovasc Surg.* 2018 Mar 1;55(3):305–68.
100. Afzal N, Sohn S, Abram S, Scott CG, Chaudhry R, Liu H, et al. Mining peripheral arterial disease cases from narrative clinical notes using natural language processing. *J Vasc Surg.* 2017 Jun 1;65(6):1753–61.
101. Afzal N, Mallipeddi VP, Sohn S, Liu H, Chaudhry R, Scott CG, et al. Natural language processing of clinical notes for identification of critical limb ischemia. *Int J Med Inf.* 2018 Mar 1;111:83–9.
102. Qutrio Baloch Z, Raza SA, Pathak R, Marone L, Ali A. Machine Learning Confirms Nonlinear Relationship between Severity of Peripheral Arterial Disease, Functional Limitation and Symptom Severity. *Diagnostics.* 2020 Aug;10(8):515.
103. Ross EG, Shah NH, Dalman RL, Nead KT, Cooke JP, Leeper NJ. The use of machine learning for the identification of peripheral artery disease and future mortality risk. *J Vasc Surg.* 2016 Nov;64(5):1515-1522.e3.
104. Rotzinger DC, Lu TL, Kawkabani A, Marques-Vidal PM, Fetz G, Qanadli SD. Computed Tomography Angiography in Peripheral Arterial Disease: Comparison of Three Image Acquisition Techniques to Optimize Vascular Enhancement—Randomized Controlled Trial. *Front Cardiovasc Med.* 2020 Apr 28;7:68.
105. Luo X, Ara L, Ding H, Rollins D, Motaganahalli R, Sawchuk AP. Computational methods to automate the initial interpretation of lower extremity arterial Doppler and duplex carotid ultrasound studies. *J Vasc Surg.* 2021 Sep;74(3):988-996.e1.
106. Janvier MA, Destrempe F, Soulez G, Cloutier G. Validation of a New 3D-US Imaging Robotic System to Detect and Quantify Lower Limb Arterial Stenoses. In: 2007 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society [Internet]. Lyon, France: IEEE; 2007 [cited 2024 May 31]. p. 339–42. Available from: <http://ieeexplore.ieee.org/document/4352293/>
107. Lareyre F, Behrendt CA, Chaudhuri A, Lee R, Carrier M, Adam C, et al. Applications of artificial intelligence for patients with peripheral artery disease. *J Vasc Surg.* 2023 Feb 1;77(2):650-658.e1.
108. Yurtkuran A, Tok M, Emel E. A clinical decision support system for femoral peripheral arterial disease treatment. *Comput Math Methods Med.* 2013;2013:898041.
109. Chi CL, Nick Street W, Robinson JG, Crawford MA. Individualized patient-centered lifestyle recommendations: an expert system for communicating patient specific cardiovascular risk information and prioritizing lifestyle options. *J Biomed Inform.* 2012 Dec;45(6):1164–74.
110. Chaikof EL, Dalman RL, Eskandari MK, Jackson BM, Lee WA, Mansour MA, et al. The Society for Vascular Surgery practice guidelines on the care of patients with an abdominal aortic aneurysm. *J Vasc Surg.* 2018 Jan 1;67(1):2-77.e2.

111. Reimerink JJ, van der Laan MJ, Koelemay MJ, Balm R, Legemate DA. Systematic review and meta-analysis of population-based mortality from ruptured abdominal aortic aneurysm. *Br J Surg*. 2013 Oct;100(11):1405–13.
112. Ahmed Z, Mohamed K, Zeeshan S, Dong X. Artificial intelligence with multi-functional machine learning platform development for better healthcare and precision medicine. *Database J Biol Databases Curation*. 2020 Jan 1;2020:baaa010.
113. Mora CE, Marcus CD, Barbe CM, Ecarnot FB, Long AL. Maximum Diameter of Native Abdominal Aortic Aneurysm Measured by Angio-Computed Tomography: Reproducibility and Lack of Consensus Impacts on Clinical Decisions. *Aorta Stamford Conn*. 2015 Apr;3(2):47–55.
114. Lareyre F, Chaudhuri A, Flory V, Augène E, Adam C, Carrier M, et al. Automatic Measurement of Maximal Diameter of Abdominal Aortic Aneurysm on Computed Tomography Angiography Using Artificial Intelligence. *Ann Vasc Surg*. 2022 Jul;83:202–11.
115. Golla AK, Tönnies C, Russ T, Bauer DF, Froelich MF, Diehl SJ, et al. Automated Screening for Abdominal Aortic Aneurysm in CT Scans under Clinical Conditions Using Deep Learning. *Diagn Basel Switz*. 2021 Nov 17;11(11):2131.
116. Muluk SC, Elrakhawy M, Chess B, Rosales C, Goel V. Successful endovascular treatment of severe chronic mesenteric ischemia facilitated by intraoperative positioning system image guidance. *J Vasc Surg Cases Innov Tech*. 2022 Mar;8(1):60–5.
117. Park A. GE Healthcare joins \$33M funding for Cleveland Clinic spinout Centerline Biomedical | Fierce Biotech [Internet]. 2022 [cited 2024 Jun 1]. Available from: <https://www.fiercebiotech.com/medtech/ge-healthcare-joins-33m-funding-cleveland-clinic-spinout-centerline-biomedical>
118. Perrin D, Badel P, Orgéas L, Geindreau C, Dumenil A, Albertini JN, et al. Patient-specific numerical simulation of stent-graft deployment: Validation on three clinical cases. *J Biomech*. 2015 Jul 16;48(10):1868–75.
119. Li A, Javidan AP, Namazi B, Madani A, Forbes TL. Development of an Artificial Intelligence Tool for Intraoperative Guidance During Endovascular Abdominal Aortic Aneurysm Repair. *Ann Vasc Surg*. 2024 Feb 1;99:96–104.
120. Karthikesalingam A, Attallah O, Ma X, Bahia SS, Thompson L, Vidal-Diez A, et al. An Artificial Neural Network Stratifies the Risks of Reintervention and Mortality after Endovascular Aneurysm Repair; a Retrospective Observational study. *PLoS One*. 2015;10(7):e0129024.
121. Morey JR, Zhang X, Yaeger KA, Fiano E, Marayati NF, Kellner CP, et al. Real-World Experience with Artificial Intelligence-Based Triage in Transferred Large Vessel Occlusion Stroke Patients. *Cerebrovasc Dis Basel Switz*. 2021;50(4):450–5.
122. O’Connell GC, Walsh KB, Smothers CG, Ruksakulpiwat S, Armentrout BL, Winkelman C, et al. Use of deep artificial neural networks to identify stroke during triage via subtle changes in circulating cell counts. *BMC Neurol*. 2022 Jun 3;22(1):206.

123. Saba L, Sanagala SS, Gupta SK, Koppula VK, Johri AM, Khanna NN, et al. Multimodality carotid plaque tissue characterization and classification in the artificial intelligence paradigm: a narrative review for stroke application. *Ann Transl Med.* 2021 Jul;9(14):1206–1206.
124. Kordzadeh A, Askari A, Abbassi OA, Sanoudos N, Mohaghegh V, Shirvani H. Artificial intelligence and duplex ultrasound for detection of carotid artery disease. *Vascular.* 2023 Dec;31(6):1187–93.
125. Cheng CA, Chiu HW. An artificial neural network model for the evaluation of carotid artery stenting prognosis using a national-wide database. In: 2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) [Internet]. Seogwipo: IEEE; 2017 [cited 2024 Jun 4]. p. 2566–9. Available from: <https://ieeexplore.ieee.org/document/8037381/>
126. Li B, de Mestral C, Mamdani M, Al-Omran M. Perceptions of Canadian vascular surgeons toward artificial intelligence and machine learning. *J Vasc Surg Cases Innov Tech.* 2022 Sep 1;8(3):466–72.
127. Pakkasjärvi N, Luthra T, Anand S. Artificial Intelligence in Surgical Learning. *Surgeries.* 2023 Mar;4(1):86–97.
128. Youranastomosis [Internet]. [cited 2024 Jun 6]. Available from: <https://youranastomosis.com/>
129. Lareyre F, Adam C, Carrier M, Chakfé N, Raffort J. Artificial Intelligence for Education of Vascular Surgeons. *Eur J Vasc Endovasc Surg.* 2020 Jun 1;59(6):870–1.
130. Fjeld J, Achten N, Hilligoss H, Nagy A, Srikumar M. Principled Artificial Intelligence: Mapping Consensus in Ethical and Rights-Based Approaches to Principles for AI. *SSRN Electron J.* 2020 Jan 1;
131. American Medical Association. Ethically Sound Innovation in Medical Practice | AMA-Code [Internet]. [cited 2024 Jun 5]. Available from: <https://code-medical-ethics.ama-assn.org/ethics-opinions/ethically-sound-innovation-medical-practice>
132. Hagendorff T. The Ethics of AI Ethics: An Evaluation of Guidelines. *Minds Mach.* 2020 Mar 1;30(1):99–120.
133. Fischer UM, Shireman PK, Lin JC. Current applications of artificial intelligence in vascular surgery. *Semin Vasc Surg.* 2021 Dec 1;34(4):268–71.
134. Mittermaier M, Raza MM, Kvedar JC. Bias in AI-based models for medical applications: challenges and mitigation strategies. *NPJ Digit Med.* 2023 Jun 1;6(1):113.
135. Obermeyer Z, Powers B, Vogeli C, Mullainathan S. Dissecting racial bias in an algorithm used to manage the health of populations. *Science.* 2019 Oct 25;366(6464):447–53.
136. Hern A. Fault in NHS Covid app meant thousands at risk did not quarantine. *The Guardian* [Internet]. 2020 Nov 2 [cited 2024 Jun 5]; Available from:

<https://www.theguardian.com/world/2020/nov/02/fault-in-nhs-covid-app-meant-thousands-at-risk-did-not-quarantine>

137. World Health Organization. Ethics and governance of artificial intelligence for health [Internet]. [cited 2024 Jun 5]. Available from: <https://www.who.int/publications-detail-redirect/9789240029200>
138. Isaacson W. TIME. 2023 [cited 2024 Jun 6]. Inside Elon Musk's Struggle for the Future of AI. Available from: <https://time.com/6310076/elon-musk-ai-walter-isacson-biography/>

ŽIVOTOPIS

Zovem se Fran Naletilić, rođen sam 16.10.1999. godine. Završio sam XV. gimnaziju u Zagrebu, gdje sam stekao srednjoškolsku diplomu kroz International Baccalaureate (IB) program. Trenutno sam student šeste godine Medicinskog fakulteta Sveučilišta u Zagrebu. Radno iskustvo tokom školovanja uključuje poziciju pripravnika u Takeda Pharmaceuticals Croatia d.o.o., pružatelja prve pomoći u CroMedic d.o.o., te medicinske ispomoći na sportskim natjecanjima Sveučilišta u Zagrebu. Aktivno sam sudjelovao u brojnim medicinskim kongresima te sam član upravnog odbora udruge StEPP kroz koju sam educirao brojne studente i laike o važnostima prve pomoći i hitne medicine. Također sam bio demonstrator na Zavodu za fiziku i biofiziku na Medicinskom fakultetu. Govorim tečno engleski i imam osnovno znanje njemačkog jezika.