

NEXT OF HEALTH & TELEMEDICINE



Kongresne informacije:

Hotel Novotel, Zagreb

Slavonska avenija 100, 10 000, Zagreb

Potvrda sudjelovanja:

Događaj je bodovan od strane Hrvatske liječničke komore.

Akreditacije:

Svi sudionici dobit će akreditacije s imenom na registracijskom stolu.

Akreditacija je službeni dokument i potrebno ju je nositi sa sobom u svakom trenutku.

Kotizacije:

KATEGORIJA	CIJENA
SPECIJALIST	200,00 €
SPECIJALIZANT	120,00 €

Kotizacija uključuje:

- pristup svim predviđenim predavanjima
- kongresni materijal
- stanke za kavu i ručak prema programu

Kotizacija ne uključuje:

- osobni troškovi
- smještaj
- obroci koji nisu navedeni u rubrici „kotizacija uključuje“

Organizator:

Hrvatsko društvo za telemedicinu HLZ-a

Hrvatsko društvo za medicinsku robotiku i umjetnu inteligenciju u medicini



Partner kongresa:

Sveučilište Sjever



Tehnički organizator:

FILIDA PUTNIČKA AGENCIJA d.o.o.

Dore Pfanove 7, Zagreb


petra@filidatravel.hr

tel: 385 1 4616 522

fax: 385 1 4616 521

www.filidatravel.hr

dr.sc. Marko Lukić, dr.med.
prim.dr.sc. Martina Tomić, dr.med.
Toma Babić, dr.med.
prof.dr.sc. Nenad Vukojević, dr.med.
izv.prof.dr.sc. Tea Čaljkusić Mance, dr.med.
doc.dr.sc. Maja Baretić, dr.med.
prof.dr.sc. Sanja Seljan, dr.med.
Marko Gulan
prim.dr.sc. Velimir Altabas, dr.med.
doc.dr.sc. Sanja Perić, dr.med.
prof.dr.sc. Mirjana Bjeloš, dr.med.
izv.prof.dr.sc. Dragan Trivanović, dr.med.
dr.sc. Vedrana Aljinović-Vučić
doc.dr.sc. Katarina Fehir Šola, mr.pharm
dr.sc. Lovro Vidmar
izv.prof.dr.sc. Mislav Balković
akademik Davor Miličić
dr.sc. Franko Hržić
doc.dr.sc. Andrija Štajduhar
Goran Ivkić, dr.med.
doc.dr.sc. Sonja Jandroković, prim.dr.med.
prof.dr.sc. Biljana Kuzmanović Elabjer, dr.med.
izv.prof.dr.sc. Kristina Bojanić, dr.med.
prof.dr.sc. Gordana Ivanac, dr.med.
izv.prof.dr.sc. Oliver Vasilj, dr.med.
Igor Čvrljević, dr.med.
dr.sc. Anđela Jukić, dr.med.
prof.dr.sc. Milan Milošević, dr.med.
prof.dr.sc. Davor Mucić, dr.med.
prof.dr.sc. Stjepan Orešković
doc.dr.sc. Ivo Dumić-Čule, dr.med.
prof.dr.sc. Nina Pereza, dr.med.
akademik Miroslav Samaržija
doc.dr.sc. Kristina Krpina
Antun Aboud
doc.dr.sc. Mislav Čavka, dr.med.
Aleksandra Roglić, dr.med.
Aron Grubešić, dr.med.
Ivo Pedišić, dr.med.
Nikola Ivan Leder, dr.med.
Nika Bošković, dipl.iur.
doc.dr.sc. Vlatka Rešković
doc.dr.sc. Filip Lončarić
doc.dr.sc. Nina Jakuš



NOH

NEXT OF HEALTH

PROGRAM

Uloga AI u ranom otkrivanju bolesti

Pozitivni primjeri ranog probira pacijenata u Republici Hrvatskoj

- 10:00 - 10:15 **Marko Lukić /Online/** Pozitivni primjeri probira dijabetičke retinopatije
 10:15 - 10:30 **Martina Tomić:** Izazovi povezani s dijabetičkom retinopatijom u Republici Hrvatskoj
 10:30 - 10:45 **Toma Babić:** AI i telemedicina u nacionalnom probiru dijabetičke retinopatije
 10:45 - 11:00 **Nenad Vukojević i Tea Čaljkusić Mance:** Probir dijabetičke retinopatije u Republici Hrvatskoj
 11:00 - 11:30 Uvodna riječ organizatora - pauza uz kavu

Digitalna tehnologija koja ulazi u domove bolesnika: novi Andrija Štampar ili opasnost? Maja Baretić (tim)

- 11:30 - 11:45 **Maja Baretić:** Uvod
 11:45 - 12:00 **Sanja Seljan:** Umjetna inteligencija u zdravstvu: prednosti i ograničenja
 12:00 - 12:15 **Marko Gulan:** Sigurnost kao zajednička odgovornost pacijenta i liječnika
 12:15 - 12:30 **Velimir Altabas:** Izazov digitalnog doba - informatička (ne)pismenost pacijenata

Uloga AI u ranom otkrivanju bolesti:

Digitalna rješenja za globalnu epidemiju miopije: Potencijal umjetne inteligencije u oftalmološkoj skrbi

- 12:30 - 12:45 **Sanja Perić:** Pandemijski porast kratkovidnosti: znanstveni uvidi i javnozdravstvene perspektive
 12:45 - 13:00 **Barbara Dawidowsky:** Mogućnosti UI za rano otkrivanje i terapiju miopije
 13:00 - 13:15 **Mirjana Bjeloš:** Nova era kontrole kratkovidnosti (The Next Frontier in Myopia Control)
 13:15 - 13:30 **Rasprava**
 13:30 - 14:30 **Ručak**

AI u liječenju:

Umjetna inteligencija u službi telefarmakologije: Unapređenje dostupnosti i preciznosti farmakoterapije

- 14:30 - 14:45 **Dragan Trivanović:** Iskorak korištenjem umjetne inteligencije u onkologiji – može li AI postati dio multidisciplinarnog tima istraživača u kliničkim ispitivanjima
 14:45 - 15:00 **Vedrana Aljinović-Vučić:** Precizna medicina u istraživanju lijekova
 15:00 - 15:15 **Katarina Fehir Šola:** EU smjernice za telemedicinu u farmaciji
 15:15 - 15:30 **Lovro Vidmar:** News in pharmacogenetics
 15:30 - 15:45 **Rasprava**

Pozitivni primjeri korištenja AI u kliničkoj praksi

Povezivanje tehnologije i medicine

- 16:00 - 16:30 **SVEČANO OTVARANJE KONGRESA**
Mislav Balković Pozvano predavanje (rektor Algebra, Bernays) Predsjednik HUP
 16:30-16:45 **Stjepan Orešković:** Curriculum 2040: Preparing Physicians for an Intelligent Health System
 16:45 - 17:30 **Akademik Davor Miličić (tim):** Uvod
Vlatka Rešković: Primjena umjetne inteligencije u ehokardiografiji (10 min.)
Filip Lončarić: Umjetna inteligencija u integriranom oslikavanju miokarda (10 min.)
Nina Jakuš: Primjena umjetne inteligencije u dijagnostici i liječenju zatajivanja srca (10 min.)
Davor Miličić: rasprava i zaključak
 17:30 - 17:45 **Pauza za kavu**

Tehnički pristup medicinskim temama

- 17:45 - 18:00 **Franko Hrčić:** Izazovi razvoja modela dubokog učenja u kliničkoj praksi
 18:00 - 18:15 **Andrija Štajduhar:** Veliki jezični modeli u medicini: od edukacije do sigurne primjene (u kliničkim sustavima)
 18:15 - 18:45 **Goran Ivkić:** Medicina temeljena na dokazima- A gdje je nestao čovjek? 30 minuta

AI u dijagnostici:**Umjetna inteligencija u suvremenoj dijagnostici: Integracija, preciznost i nova dimenzija vizualizacije**

- 09:30 - 09:40 **Sonja Jandroković:** Povezivanje različitih dijagnostičkih metoda: Harmonizacija kao priprema za AI
- 09:40 - 09:55 **Biljana Kuzmanović Elabjer:** AI projekt za prepoznavanje tumora žilnice na ultrazvučnom B-prikazu
- 09:55 - 10:05 **Kristina Bojanić:** Više od mamografske slike: IA sustav u CEM analizi molekularnih podtipova raka dojke
- 10:05 - 10:20 **Gordana Ivanac:** AI u ultrazvučnoj dijagnostici tumora
- 10:20 - 10:30 **Oliver Vasilj:** Hoće li AI asistirani ultrazvučni pregled zamijeniti ginekologa?
- 10:30 - 10:45 **Pauza za kavu**

AI u liječenju bolesti i praćenju rezultata liječenja

- 10:45 - 11:00 **Igor Čvrljević:** Primjena umjetne inteligencije i 3D planiranja u maksilofacijalnoj kirurgiji
- 11:00 - 11:15 **Anđela Jukić:** Umjetna inteligencija u dijagnostici i liječenju katarakte
- 11:15 - 11:30 **Milan Milošević:** AI kao edukacijski alat u prevenciji bolesti i ozljeda
- 11:30 - 11:45 **Davor Mucić:** Digitalna psihijatrija i umjetna inteligencija: Novi horizonti mentalnog zdravlja
- 11:45 - 12:00 **Rasprava**

Edukacija i AI**Transformacija medicinskog obrazovanja: Uloga umjetne inteligencije i digitalnih alata u kurikulumu i kliničkoj praksi**


- 12:00 - 12:15 **Ivo Dumić-Čule:** AI u kurikulumu biomedicinskih fakulteta
- 12:15 - 12:30 **Nina Pereza:** Umjetna inteligencija u medicinskoj edukaciji: primjena, izazovi i prilike
- 12:30 - 12:45 Pravna regulativa **Nika Bošković:** Novosti u EU regulativi o umjetnoj inteligenciji i aplikacije na medicinu
- 12:45 - 13:00 **Rasprava**
- 13:00 - 14:00 **Ručak**

Uloga AI u ranom otkrivanju bolesti**Pozitivni primjeri ranog probira pacijenata u Republici Hrvatskoj**

- 14:00 - 14:45 **Akademik Miroslav Samaržija, Kristina Krpina, Antun Aboud:** Pozitivni primjeri ranog probira pacijenata u Republici Hrvatskoj; Nacionalni program za probir i rano otkrivanje raka pluća

AI u dijagnostici**Od klasične slike do digitalne preciznosti: AI i transformacija dijagnostike**

- 14:45 - 15:00 **Mislav Čavka:** Od rahitisa do robota: evolucija radiologa
- 15:00 - 15:15 **Aleksandra Roglić:** AI u ranom otkrivanju Alzheimerove bolesti
- 15:15 - 15:30 **Aron Grubešić:** Uloga umjetne inteligencije u menadžmentu zdravstvenog sustava
- 15:30 - 15:45 **Ivo Pedišić:** Benefiti implementacije umjetne inteligencije u CT i MR dijagnostici onkoloških pacijenata
- 15:45 - 16:00 **Nikola Ivan Leder:** Razvoj telemedicine i zakonski okvir u Hrvatskoj



NOH

NEXT OF HEALTH

SAŽECI

Pozitivni primjeri probira dijabetičke retinopatije**dr.sc. Marko Lukić, dr.med.****Moorfields Eye Hospital NHS Foundation Trust**

Sustavni probir dijabetičke retinopatije (DR) ima ključnu ulogu u prevenciji sljepoće i ranom otkrivanju bolesti, u skladu s preporukama Svjetske zdravstvene organizacije (WHO). Ujedinjeno Kraljevstvo provodi National Diabetic Eye Screening Programme (DESP) od 2003. godine, u koji je uključeno oko 4 milijuna osoba registriranih u NHS programu u Engleskoj i Walesu. Više od 80 % njih prolazi rutinski probir svake 1–2 godine koristeći standardizirane retinalne kamere i protokole za probir i upućivanje.

Finska je razvila komplementaran, visokotehnološki sustav temeljen na teleoftalmologiji, mobilnim jedinicama (Eye-Mo), digitalnim fundus kamerama (iCare DRSplus) i umjetnoj inteligenciji (RETCAD AI). Ovaj pristup povećao je pokrivenost probira s 78 % na gotovo 100 %, smanjio vrijeme između snimanja i dijagnoze na prosječno 6 dana te doveo do 86 % smanjenja DR-povezanog gubitka vida.

Oba modela dokazuju da kombinacija tehnologije, standardizacije i dostupnosti donosi mjerljive koristi u javnozdravstvenom nadzoru i očuvanju vida osoba s dijabetesom.

Ključne riječi: Dijabetička retinopatija, Probir, Fundus kamera

Izazovi povezani s dijabetičkom retinopatijom u Republici Hrvatskoj**Prim.dr.sc. Martina Tomić, dr.med.****Odjel za oftalmološke komplikacije dijabetesa, Sveučilišna klinika za dijabetes, endokrinologiju i bolesti metabolizma Vuk Vrhovac, KB Merkur, Zagreb**

Šećerna bolest (ŠB) i njene komplikacije danas su najbrže rastući globalni javnozdravstveni problem s visokom smrtnošću, invaliditetom, smanjenom kvalitetom života i velikim financijskim troškovima. Prema IDF-u, ukupni globalni troškovi ŠB-a su u posljednjih 17 godina porasli za 338%, s 232 milijarde USD u 2007. na više od jednog bilijuna USD (1.015 milijardi) u 2024. Dijabetička retinopatija (DR), komplikacija ŠB-a na očima, vodeći je uzrok sljepoće radno aktivnih osoba (20-65 godina) u razvijenim državama svijeta. Glavni izazovi povezani s DR-om u RH uključuju nezadovoljavajuću kontrolu rizičnih čimbenika, neredovite očne preglede, prekasno postavljanje dijagnoze i predugi period do početka liječenja. Sve navedeno rezultira lošim terapijskim odgovorom, velikom stopom invalidnosti i posljedično visokim troškovima. Stručne smjernice ističu važnost godišnjih pregleda fundusa radi ranog otkrivanja DR-a i pravovremenog liječenja. Međutim, za razliku od automatiziranih sustava (telemedicine i/ili AI-a) u razvijenim zemljama, u RH preglede provode subspecijalisti, što dodatno usporava proces i povećava opterećenje zdravstva.

Ključne riječi: visoki troškovi i izazovi dijabetičke retinopatije, gdje je sada Republika Hrvatska

AI i telemedicina u nacionalnom probiru dijabetičke retinopatije**Toma Babić dr.med.****Odjel za oftalmološke komplikacije dijabetesa, Sveučilišna Klinika Vuk Vrhovac, KB Merkur**

Nacionalni program probira i ranog otkrivanja dijabetičke retinopatije predstavlja integrirani javnozdravstveni model koji povezuje telemedicinu i umjetnu inteligenciju u oftalmološku praksu. Program omogućuje digitalno snimanje fundusa u domovima zdravlja i mobilnim jedinicama, udaljeno očitavanje nalaza te pomoć AI u analizi snimaka od strane grader-oftalmologa u svrhu rane detekcije patoloških promjena dijabetičke retinopatije.

Središnji informatički sustav povezan s CEZIH-om i CroDiabom omogućuje automatski prijenos podataka i praćenje ishoda. Standardizirana edukacija tehničara i oftalmologa osigurava visoku razinu kvalitete, dok pilot faza u odabranim županijama potvrđuje izvedivost i isplativost modela. Program predstavlja digitalni temelj za prevenciju sljepoće kod osoba s dijabetesom te primjer uspješne primjene umjetne inteligencije u javnozdravstvenom sustavu.

Digitalna tehnologija koja ulazi u domove bolesnika: novi Andrija Štampar ili opasnost?**Doc. dr. sc. Maja Baretić, prim.dr.med****Klinički bolnički centar Zagreb, Medicinski fakultet Sveučilišta u Zagrebu**

Digitalna tehnologija sve snažnije ulazi u domove bolesnika, mijenjajući način na koji razumijemo i provodimo brigu o zdravlju. Prisjećajući se riječi Dr. Andrije Štampara: „Glavno mjesto liječničkog djelovanja je tamo gdje ljudi žive, a ne ordinacija,“ možemo se zapitati što bi rekao danas, kada u naše živote svakodnevno ulaze digitalni “liječnici”. S jedne strane, digitalna rješenja donose mogućnost ranog prepoznavanja bolesti, praćenja kroničnih stanja i dostupnosti zdravstvenih informacija. S druge strane, nose rizik širenja dezinformacija, narušavanja povjerljivosti i udaljavanja liječnika od pacijenta. Hoće li digitalna tehnologija postati novi Štampar našeg vremena ili njezina suprotnost – ovisi o tome koliko ćemo u njoj zadržati duh javnog zdravstva i ljudskost u skrbi.

Ključne riječi:

digitalno zdravlje, Andrija Štampar, javno zdravstvo

Umjetna inteligencija u zdravstvu: prednosti i ograničenja**prof. dr. sc. Sanja Seljan****Filozofski fakultet Sveučilišta u Zagrebu, Odsjek za informacijske i komunikacijske znanosti & Sorbone
Abu Dhabi (visiting professor)**

Umjetna inteligencija (AI) brzo postaje sastavni dio suvremenog zdravstvenog sustava, od administrativne podrške i analize medicinskih zapisa do komunikacije s pacijentima.

Posebno mjesto zauzimaju veliki jezični modeli (LLM) i chatbotovi, koji omogućuju automatiziranu, dostupnu i prilagođenu komunikaciju između pacijenata i zdravstvenih djelatnika, ili u savjetovanju. Takvi sustavi mogu pomoći u edukaciji, kao podsjetnik na terapiju ili u pružanju osnovnih medicinskih informacija, i to u višejezičnoj komunikaciji.

Ovi alati donose brojne potencijalne mogućnosti kao što su povećanja učinkovitosti i dostupnosti zdravstvenih usluga, brža obradu podataka, podrška u dijagnostici ili smanjenje administrativnog opterećenja. No, istodobno prisutna su i ograničenja – netočnost ili pristranost modela, nedostatak objašnjivosti te rizici za privatnost i etiku. Ključno je razumjeti kako umjetna inteligencija može nadopuniti, ali ne i zamijeniti, ljudsku stručnost u medicini.

U izlaganju će se prikazati glavne vrste primjene AI u zdravstvu, s naglaskom na mogućnosti i izazove LLM-ova i chatbotova te otvoriti rasprava o odgovornoj i transparentnoj integraciji umjetne inteligencije u medicinsku praksu.

Telemedicina u eri umjetne inteligencije: sigurnost kao zajednička odgovornost pacijenta i liječnika
Marko Gulan, Cybersecurity Consultant
Astera Advisory

Kako umjetna inteligencija redefinira granice dijagnostike, terapije i brige o pacijentu, telemedicina postaje novo središte digitalnog zdravstva, ali i nova točka ranjivosti. Automatizirani sustavi, IoT medicinski uređaji i algoritamsko odlučivanje donose golem potencijal za precizniju i dostupniju medicinu, no istodobno otvaraju prostor za sofisticirane kibernetičke prijetnje i eroziju povjerenja između liječnika i pacijenata.

Predavanje donosi pogled stručnjaka za kibernetičku sigurnost na etičke, tehničke i regulatorne izazove nove ere medicine, u kojoj se granice između tehnologije i čovjeka sve više brišu.

U fokusu je koncept "digitalne odgovornosti"; razumijevanje da sigurnost zdravstvenih podataka nije samo pitanje sustava, već kolektivna obveza liječnika, pacijenata i tehnoloških platformi. Samo kroz suradnju, edukaciju i proaktivno upravljanje rizicima možemo osigurati da umjetna inteligencija u medicini služi čovjeku, a ne obrnuto.

Izazov informatičkog doba - informatička (ne)pismenost pacijenata**Prof. dr. sc. Velimir Altabas, dr.med.****Medicinski fakultet Sveučilišta u Zagrebu, KBC "Sestre milosrdnice", Zagreb**

Uznapredovala informatizacija zdravstvene skrbi kojoj svjedočimo u moderno doba očituje se kroz elektroničke zdravstvene kartone, telemedicinu, mobilne zdravstvene aplikacije i nosive tehnologije. Moderne tehnologije su pri tome temeljito promijenile način pružanja zdravstvenih usluga i komunikacije između pacijenata i različitih profila zdravstvenih djelatnika. Pri tome se adekvatna informatička pismenost svih uključenih dionika nameće kao imperativ u pružanju učinkovite zdravstvene zaštite. Informatička nepismenost pacijenata (p)ostaje ozbiljna prepreka ravnopravnom pristupu zdravstvenim uslugama, razumijevanju zdravstvenih informacija i aktivnom sudjelovanju u vlastitoj zdravstvenoj skrbi. Naime, ograničena informatička kompetencija može rezultirati smanjenim korištenjem telezdravstvenih usluga, lošijom kontrolom kroničnih bolesti i povećanim osjećajem isključenosti iz zdravstvenog sustava, te povećavanju društvene nejednakosti. Ovaj jaz posebno pogađa starije osobe, pacijente nižeg socioekonomskog statusa i osobe s ograničenim obrazovanjem, i može se povećavati u budućnost. Sustavno ulaganje u cjeloživotnu informatičku edukaciju, razvoj pristupačnih tehnologija i uključive zdravstvene politike ključni su preduvjeti za daljnji razvoj sveobuhvatne i učinkovite zdravstvene zaštite.

Mogućnosti AI za rano otkrivanje i terapiju miopije

**Prim.dr.sc. Barbara Dawidowsky, spec. oftalmologije, supspec. pedijatrijske oftalmologije i strabologije
Klinika za dječje bolesti, Odjel za ORL, neurokirurgiju i oftalmologiju Klinike za dječju kirurgiju**

Miopija (tj. kratkovidnost) postaje najčešći poremećaj oka koji uzrokuje sljepoću kod mladih osoba u mnogim dijelovima svijeta. Oštećenje vida zbog miopije povezano je sa strukturnim promjenama mrežnice i očne jabučice zbog izduživanja osovine oka, i posljedično, oštećenjima svih struktura oka. Do sada su u oftalmologiji korišteni podaci obrađivani AI koji su pomogli u analizi slikovnih prikaza mrežnice, prognozi progresije raznih bolesti oka i personaliziranoj terapiji no budućnost AI u oftalmologiji bi trebala pomoći u:

- ranoj detekciji miopije
- predikciji individualnog rizika pacijenta
- automatiziranom praćenju terapija

Glavna stremljenja su prema razvoju prijenosnih AI sustava koji će omogućiti jednostavniji screening populacije u primarnoj zdravstvenoj zaštiti. Kod detekcije i praćenja razvoja miopije AI sustavi morali bi pomoći u sljedećem:

1. Dijagnostika - AI analizira očne slike (OCT, fundus kamere) kako bi otkrila rane znakove miopije
2. Predikcija progresije – algoritmi koriste biometrijske podatke kako bi predviđeli napredovanje miopije, posebno kod djece
3. Personalizirana medicina - na temelju genetskih i čimbenika okoliša AI pomaže izrađivati prilagođene planove i prevencije liječenja
4. Istraživanje - velike baze podataka omogućuju AI da analizira globalne trendove rasta prevalencije miopije

Na temelju podataka o aksijalnoj duljini oka, debljini mrežnice i žilnice, AI može identificirati pacijente koji su u većem riziku od visoke miopije i povezanih komplikacija poput glaukoma, makularne degeneracije i ablacije mrežnice, i na taj način omogućuje ranu detekciju miopije i njenih komplikacija kao i pravovremenu intervenciju.

Nova era kontrole kratkovidnosti**Prof.dr.sc. Mirjana Bjeloš, dr.med.****Klinika za oftalmologiju, KB Sveti Duh**

Kratkovidnost je postala jednim od najvažnijih globalnih javnozdravstvenih izazova 21. stoljeća. Prema sadašnjim procjenama, kratkovidno je više od 2,6 milijardi ljudi diljem svijeta, a projekcije upućuju da će do 2050. godine gotovo 5 milijardi osoba – više od polovice svjetske populacije – imati kratkovidnost.

Referentni centar Ministarstva zdravstva Republike Hrvatske za dječju oftalmologiju i strabizam, Klinička bolnica „Sveti Duh“ u Zagrebu, u suradnji s Fakultetom za dentalnu medicinu i zdravstvo Osijek Sveučilišta Josipa Jurja Strossmayera u Osijeku, te pod pokroviteljstvom Ministarstva zdravstva, Ministarstva znanosti i obrazovanja i Grada Zagreba, provodi longitudinalno istraživanje „Miopija u školske djece Grada Zagreba“. Prema dostupnim podacima iz literature, ovaj je projekt jedinstven po integraciji umjetne inteligencije (AI) i klasične biostatistike u svrhu analize složenog longitudinalnog skupa podataka velikog opsega.

Očekivani ishodi uključuju definiranje indeksa rizika, fenotipove temeljene na razvojnim krivuljama te prediktivne modele namijenjene prepoznavanju djece s povećanim rizikom za razvoj kratkovidnosti ili njezinu ubranu progresiju.

Iskorak korištenjem umjetne inteligencije u onkologiji – može li AI postati dio multidisciplinarnog tima istraživača u kliničkim ispitivanjima**Izv.prof.dr.sc. Dragan Trivanović, dr.med.****Katedra za onkologiju i radioterapiju, Medicinski fakultet, Sveučilišta u Rijeci****Medicinski fakultet, Sveučilište u Puli**

Uključivanje umjetne inteligencije (AI) u kliničkoj onkologiji brzo se razvija i nameće nove standarde kliničkog rada. Najveći nositelji razvoja novih lijekova i metoda u dijagnostici i liječenju od malignih bolesti su klinička ispitivanja. Može li nam umjetna inteligencija unaprijediti ove značajne iskorake u svakodnevnom radu kod oboljelih od malignih bolesti? U procesu od razvoja novih lijekova i design-a kliničkih studija do prepoznavanja pacijenta koji će imati najveću korist u liječenju nameće se uloga umjetne inteligencije čime se planira postići brža provedba kliničkih studija dobivanja i jasnih informacija od kojih lijekova možemo očekivati najbolje pozitivne odgovore u učinkovitosti i sigurnosti. Tehnološki dio je svakako najzahtjevniji u procesu stvaranju i provođenju kliničkih studija uzimajući u obzir zahtjevne nove dijagnostičke alate koji uključuju radiomiku, digitalnu patologiju, procese koji uključuju procese poput spatial-omics, metabolomics i transcriptomics koje mogu u kratkom vremenu donijeti jasnu odluku o mogućnostima personaliziranog liječenja u kliničkim studijama uz istovremno točnu i predvidivu daljnu provedbu studije u smislu praćenja kliničkih odgovora na liječenje. Osim toga, uključivanjem umjetne inteligencije u ove postupke stvoriti će se alati koji će nam biti od esencijalne pomoći u svakodnevnom kliničkom radu u real-world ambijentu.

Ključne riječi: klinička istraživanja; multidisciplinarnost; umjetna inteligencija

PRECISION MEDICINE IN DRUG RESEARCH AND DEVELOPMENT**dr.sc. Vedrana Aljinović-Vučić****Jadran Galenski Laboratorij d.d., Medical Affairs Department, Rijeka, Croatia****School of Medicine, Department of Basic and Clinical Pharmacology and Toxicology, University of Rijeka, Rijeka, Croatia**

The main goal in drug research is to develop effective and safe drugs. Precision medicine is trying to design drugs based on patient's individual condition which represents a significant improvement in this process. Among the new fields of study, genetics of disease and pharmacogenomics have a central position in precision medicine. Processes involved in it greatly rely on adequate computer and IT support in general which result in faster drug research and development process.

In that context, pharmaceutical industry is exploring the ways to use AI for acceleration of drug discovery process, reducing failure rates in clinical trials and delivering improved drugs. Genetically validated drugs that are developed relying on these processes exert less side effects and have improved risk-benefit ratio which leads to better patients' outcomes but also to cost reductions for healthcare systems.

Key points for discussion:

- Drug efficacy or safety can be limited due to a lack of "precision mechanism".
- The odds of finding a right medication by using genomic data and computer support increase when compared with previously used methods.

Telefarmacija - digitalna budućnost farmaceutske prakse u Europi**Doc.dr.sc.Katarina Fehir Šola****ZU Ljekarna Bjelovar, Petra Preradovića 4, Bjelovar****Medicinski fakultet Osijek, Sveučilište Josip Juraj Strossmayer Osijek**

Telefarmacija predstavlja važnu sastavnicu suvremenog zdravstvenog sustava, osobito nakon pandemije COVID-19, koja je ubrzala njezinu implementaciju na globalnoj razini. Ona omogućuje pružanje farmaceutske skrbi putem telekomunikacijskih tehnologija, uključujući savjetovanje, upravljanje terapijom i udaljeno praćenje bolesnika, čime se poboljšava dostupnost i kontinuitet skrbi. Brojna istraživanja potvrđuju njezinu učinkovitost u poboljšanju ishoda liječenja kroničnih bolesti. Ipak, razvoj telefarmacije ograničen je regulatornim neujednačenostima, nedostatnom tehničkom operabilnosti te potrebom za dodatnom edukacijom zdravstvenih djelatnika i pacijenata. Stoga je nužno osigurati standarde sigurnosti, kvalitete i profesionalne odgovornosti koji će omogućiti njezinu održivu integraciju u zdravstvenu praksu.

Ključne riječi: telefarmacija, farmaceutska skrb, farmaceut

News in pharmacogenetics**Lovro Vidmar, PhD**

Personalized medicine is transforming healthcare by integrating genetic information into prevention, diagnosis, and treatment decisions. Genetic testing now enables the detection of both rare and common variants, each providing distinct yet complementary clinical insights. Rare, high-impact variants—such as those identified in BRCA1/2 or included in the ACMG list of actionable findings—can guide targeted screening, early diagnosis, and even life-saving interventions when detected at birth. In parallel, the growing use of polygenic risk scores and pharmacogenomic profiling extends precision medicine to the population level, refining risk assessment and individualizing drug therapy. This presentation will highlight how these approaches converge into a unified framework for personalized care, from monogenic disorders to complex traits. Examples from oncology, pharmacogenomics, and preventive genetics will illustrate how genetic information can be responsibly implemented in clinical workflows.

Key points:

- Rare vs. common variants in clinical genetics
- Actionable insights from cancer, pharmacogenomic, and population screening

Kurikulum 2040: Kako pripremiti liječnike za inteligentni zdravstveni sustav**Prof. dr. sc. Stjepan Orešković****Medicinski fakultet Sveučilišta u Zagrebu**

Kurikulum 2040 odgovara na pitanje kako obrazovati liječnike u doba umjetne inteligencije, robotike i digitalne medicine. Autor se oslanja na osobna iskustva u Hrvatskoj i SAD, stečena u reformi Medicinskog fakulteta Sveučilišta u Zagrebu, provedene u suradnji s Harvard Medical Internationalom, koja je uvela integriranu nastavu i ranu kliničku praksu – i postavlja novo pitanje: kako obrazovati liječnika koji će upravljati inteligentnim zdravstvenim sustavom? Danas se procjenjuje da je više od 40 % sadržaja medicinskih kurikuluma zastarjelo, a znanje u medicini udvostručuje se svakih 70 do 80 dana. Postojeći zdravstveni sustavi su sve samo ne inteligentni: prekomjerno koriste (overuse) nepotrebne postupake, nedovoljno korištenje (underuse) preventivnih i digitalnih alata te pogrešno uporabljaju (misuse) podatke i resurse. Umjesto stvarne integracije, dominiraju fragmentacija, birokracija i zastarjeli načini odlučivanja.

Ključni izazovi Kurikuluma 2040 uključuju:

- Od akumulacije znanja prema kognitivnoj prilagodljivosti i kritičkom mišljenju – razumjeti i preispitati algoritme, ne samo ih slijediti.
 - Partnerstvo čovjeka i umjetne inteligencije – tehnologija kao suradnik, a ne zamjena liječnika.
 - Redefiniranje kurikuluma – uvođenje podatkovne pismenosti, digitalne dijagnostike i sustavnog razmišljanja.
 - Etika, povjerenje i odgovornost – zaštita pacijenta u svijetu autonomnih odluka.
 - Interdisciplinarno učenje – primjeri najboljih praksi s Harvarda, Oxforda i Singapore Duke-NUS-a.
- Kurikulum 2040 govori o tome kako AI predstavlja veliku priliku za redizajn profesije: liječnik budućnosti mora biti intelektualno neovisan, tehnološki pismen i uvijek – usmjeren na čovjeka.

Izazovi razvoja modela dubokog učenja u kliničkoj praksi**Dr.sc. Franko Hržić****Tehnički fakultet, Sveučilište u Rijeci**

Modeli dubokog učenja svakodnevno postižu nove zapažene rezultate na brojnim medicinskim zadacima. Većina znanstvenih radova tvrdi da je upravo njihov model postigao novi najbolji rezultat i iskorak u odnosu na postojeća rješenja. Međutim, implementacija tih istih modela i njihovim testiranjem na kliničkim podacima rezultira značajnim odstupanjima u performansama – često u negativnom smjeru. Jedan od glavnih razloga odstupanja u rezultatima krije se u skupu podataka nad kojim je model obučen. Nerijetko modeli bivaju obučeni nad podacima koji se nalaze u “zlatnom standardu”, odnosno bivaju pročišćeni i balansirani kako bi se model mogao lakše obučiti. Dovođenjem podataka u “zlatni standard” uvodi se izvjesna razina pristranosti zbog koje model nad realnim podacima u kliničkoj praksi ne postiže jednake performanse. S druge strane, obučavanjem modela na kliničkim podacima smanjuje se mogućnost postizanja vrhunskih rezultata te signifikantno povećava vrijeme razvoja i istraživanja. Pronalaženje balansa između navedenih oprečnih zahtjeva predstavlja jedan od brojnih izazova razvoja modela dubokog učenja u kliničkoj praksi.

Ključne točke:

- Razvoj modela strojnoga učenja u svrhu znanstvenog rada značajno se razlikuje od razvoja istih za kliničku uporabu.
- Evaluacija performansi modela strojnoga učenja zahtijeva poznavanje kliničke domene i usku suradnju medicinskih i računalnih eksperata.

Veliki jezični modeli u medicini: od edukacije do sigurne primjene (u kliničkim sustavima)**doc. dr. sc. Andrija Štajduhar****Medicinski fakultet Sveučilišta u Zagrebu**

U ovom predavanju istražiti ćemo kako generativna umjetna inteligencija, osobito veliki jezični modeli (LLM), nalaze svoju primjenu u medicini i biomedicinskim istraživanjima. Predstaviti ćemo iskustva stečena kroz edukaciju studenata o umjetnoj inteligenciji na Medicinskom fakultetu te konkretne primjere primjene u praksi, od sažimanja i strukturiranja medicinske dokumentacije, preko izrade obrazaca i nalaza, do pretraživanja i RAG sustava temeljenih na odabranom znanju te njihove integracije u postojeće radne tokove. Dotaknut ćemo se i ključnih aspekata istraživanja i razvoja LLM-ova: validacije, metrika, pristranosti, otpornosti na distribucijske promjene, kao i važnosti pristupa „human-in-the-loop“ i stalnog nadzora. Posebnu ćemo pažnju posvetiti sigurnosti i odgovornoj implementaciji u kliničkim okruženjima, upravljanju rizicima, zaštiti privatnosti i usklađenosti s regulatornim okvirima. Cilj predavanja je pružiti jasan i praktičan okvir za svjesnu, mjerljivu i sigurnu primjenu LLM-ova u medicinskoj praksi i istraživanju.

Povezivanje različitih dijagnostičkih metoda: Harmonizacija kao priprema za AI
doc.dr.sc.Sonja Jandroković, prim.dr.med.
Klinički bolnički centar Zagreb
Medicinski fakultet Sveučilišta u Zagrebu

Sve veći broj pacijenata i smanjeno vrijeme dostupno za preglede i liječenje predstavljaju izazov za kliničku praksu. Umjetna inteligencija (AI) omogućuje integraciju različitih dijagnostičkih testova u jedinstven okvir, optimizira radne procese, automatizira rutinske zadatke, poboljšava obradu slika i označavanje abnormalnosti te doprinosi optimizaciji terapije i učestalosti tretmana, smanjujući nepotrebne bolničke posjete.

Proveli smo istraživanje među 125 zdravstvenih djelatnika kako bismo procijenili njihovo znanje, motivaciju i preferencije glede telemedicinskih posjeta u oftalmološkoj praksi. Rezultati su analizirani prema temama: dosadašnje iskustvo, prednosti i izazovi, poboljšanja i preporuke. Također smo prikazali korake implementacije programske podrške za integraciju podataka različitih dijagnostičkih uređaja u KBC Zagreb, s ciljem postavljanja platforme za virtualnu kliniku i buduću primjenu AI-a. Telemedicina i virtualne klinike sve više postaju ključni dio modernog zdravstvenog sustava, povećavaju dostupnost pretraga, poboljšavaju ishode liječenja i zahtijevaju pripremu svih sudionika te podizanje svijesti o njihovoj važnosti.

AI projekt za prepoznavanje tumora žilnice na ultrazvučnom B-prikazu**prof.dr.sc. Biljana Kuzmanović Elabjer, prim.dr.med.****Klinika za očne bolesti, Klinička bolnica "Sveti Duh"**

U ultrazvučnoj dijagnostici oka i orbite primjenjuju se B-prikaz, standardizirana ehografija (SE, A-prikaz) i ultrazvučna biomikroskopija (UBM). Za razliku od B-prikaza, SE omogućuje točna mjerenja u realnom vremenu bez artefakata te kvantitativnu analizu tkiva prema ehogenosti, apsorpciji ultrazvuka, vaskularnosti i konzistenciji. Većina okularnih i orbitalnih lezija ima svoj specifičan SE akustički obrazac, iako je metoda zahtjevnija za učenje.

Kao inovativni pristup, tvrtka Quantel Medical Lumibird (Francuska) — jedini svjetski proizvođač uređaja sa standardiziranom sondom — pokrenula je AI projekt za prepoznavanje tumora žilnice na ultrazvučnom B-prikazu. U projektu sudjeluje šest međunarodnih stručnjaka, uključujući autora, kao članove Medical Advisory Boarda. Sustav koristi ultrazvučne zapise (B-prikaz i SE) tumora pacijenata članova Boarda, pri čemu su najvrijedniji podaci oni dobiveni iz histopatološki potvrđenih slučajeva enukleiranih očiju. Za pouzdanu diferencijaciju nužan je pravilan unos podataka, stoga su i pozvani stručnjaci na čije dijagnoze se može osloniti. Trenutno se u bazu unose zapisi malignog melanoma žilnice, hemangioma, metastaza, nevusa i vlažne makularne degeneracije.

Ključne točke za raspravu:

Ultrazvučne metode u oftalmologiji; Inovacija i AI u dijagnostici; Važnost kvalitete podataka i ekspertize

Više od mamografske snimke: AI sustav u CEM analizi molekularnih podtipova raka dojke
izv. prof. prim. dr.sc. Kristina Bojanić, dr.med., specijalist radiolog, uže specijalizacije ultrazvuka
Dom zdravlja Osječko-baranjske županije
Fakultet za dentalnu medicinu i zdravstvo Osijek

Kontrastna mamografija (CEM) pruža uz morfološke i funkcionalne informacije o raku dojke (RD), omogućujući „virtualnu biopsiju“ bioloških obilježja RD. U jednocentričnoj retrospektivnoj kohorti 399 žena s BI-RADS 0, analizirali smo 76 zloćudnih lezija te ispitali odnos CEM-značajki i molekularnih podtipova, uz procjenu iCAD ProFound AI® skora (0–100%). Luminalni tumori (69%) češće su bili nepravilni sa spikulacijama i heterogenom imbibicijom, dok su HER2-pozitivni/tri-negativni češće imali okrugliji oblik i rubnu ili homogenu imbibiciju. Srednji AI skor bio je značajno viši kod malignih nego benignih lezija (70,5% vs. 38,0%; $p < 0,001$). ROC analiza potvrdila je dobru dijagnostičku točnost algoritma (AUC=0,75; senzitivnost 71%, specifičnost 70%). Uočen je i trend viših AI skorova kod biološki agresivnijih podtipova, što upućuje na potencijal algoritma da odražava tumorski fenotip. Značajke CEM-a odražavale su fenotipske obrasce pojedinih molekularnih podtipova, ranije opisane na MRI-ju, potvrđujući njegovu vrijednost kao praktičnog alata u biološkoj karakterizaciji tumora. U kombinaciji s umjetnom inteligencijom, CEM predstavlja korak prema biološki informiranoj i personaliziranoj dijagnostici raka dojke.

Ključne točke

1. CEM morfologija i uzorak PK imbibicije razlikuju luminalne od HER2/TN podtipova RD (fenotipski potpis).
2. ProFound AI® razlučuje maligne od benignih lezija (AUC 0,75) i raste s agresivnošću molekularnih podtipova RD.
3. Kombinacija CEM i AI omogućuje bržu trijažu BI-RADS 0 lezija uz personalizirani pristup u dijagnostičkom algoritmu RD.

AI u ultrazvučnoj dijagnostici tumora**izv.prof.dr.sc. Gordana Ivanac****Katedra za radiologiju, Medicinski fakultet Sveučilišta u Zagrebu****Klinički zavod za dijagnostičku i intervencijsku radiologiju, KB Dubrava**

Primjena umjetne inteligencije (UI) u ultrazvučnoj dijagnostici dojke i štitnjače otvara mogućnosti za znatno precizniju, bržu i standardiziraniju procjenu lezija u odnosu na klasične metode. U dijagnostici bolesti dojke, sustavi temeljeni na dubokom učenju pokazali su visoku točnost u detekciji i klasifikaciji promjena, usporedivu s iskusnim radiolozima, te mogu smanjiti broj nepotrebnih biopsija.

U području ultrazvuka štitnjače, AI algoritmi dokazano poboljšavaju diferencijaciju benignih i malignih čvorova, povećavaju dijagnostičku točnost i omogućuju dosljedniju primjenu TI-RADS kriterija.

Posebno se ističe važnost kliničke validacije i interpretabilnosti modela, kao i njihova integracija u svakodnevni radiološki rad, pri čemu UI pomaže u ranijem otkrivanju patoloških promjena, smanjenju varijabilnosti među dijagnostičarima te optimizaciji vremena pregleda, uz očuvanje ključne uloge radiologa u donošenju konačne dijagnoze.

Hoće li AI asistirani ultrazvučni pregledi zamijeniti ginekologa?**izv.prof.dr.sc. Oliver Vasilj, dr.med.****Poliklinika Medifem****Sveučilište Sjever**

Umjetna inteligencija (AI) u ultrazvučnoj dijagnostici ginekologije i porodništva donosi značajne promjene i napredak u kliničkoj praksi na globalnoj i lokalnoj razini. Njena primjena unapređuje preciznost, brzinu i učinkovitost ultrazvučnih pregleda, što ima izravan utjecaj na poboljšanje dijagnostičkih i terapijskih postupaka te zadovoljstvo pacijenata.

Umjetna inteligencija se koristi za:

- Automatsko prepoznavanje i analizu anatomske strukture (maternica, jajnici, fetus, placenta) na ultrazvučnim snimkama, smanjujući mogućnost ljudske pogreške.
- Ranu detekciju fetalnih anomalija, kromosomskih sindroma, srčanih greški
- Automatsko mjerenje, praćenje rasta i razvoja ploda te procjenu uterinskih i ovarijskih promjena kod steriliteta ili potpomognute oplodnje.
- Procjenu rizika za razvoj određenih bolesti, poput raka jajnika i stvaranja prediktivnih modela za ranu detekciju malignih promjena.

Upotreba naprednih AI sustava ubrzala je:

- Dobivanje visokokvalitetnih slika u realnom vremenu i automatizirano tumačenje nalaza, što omogućuje efikasnije i kraće preglede.
- Smanjenje subjektivnosti i ovisnosti o iskustvu liječnika, jer AI pomaže standardizirati dijagnostiku i detekciju patologija.
- Uvođenje telemedicine, jer se AI detekcija može primijeniti i za udaljene konzultacije i edukaciju manje iskusnih kolega uz podršku stručnih protokola.

Međunarodna udruženja (ESGO, ISUOG, ESHRE) preporučuju postupno uvođenje AI tehnologija uz obaveznu edukaciju, reviziju rezultata i strogu regulaciju sigurnosti podataka. Stručni nadzori naglašavaju da je ultrazvučnu dijagnostiku s AI asistencijom nužno provoditi pod nadzorom licenciranih specijalista radi pravilne interpretacije nalaza i odluke o daljnjem liječenju.

U budućnosti se očekuje:

- Daljnja automatizacija i integracija AI sustava za personaliziranu medicinu, praćenje trudnoće u realnom vremenu i prilagodbu terapije individualno za svaku pacijenticu.
- Razvoj algoritama učenja na velikim bazama podataka, što će dovesti do još efektivnije rane detekcije rijetkih i kompleksnih bolesti.
- Povećanje dostupnosti ultrazvučne dijagnostike i unapređenje edukacije liječnika putem AI podržanih simulacija i telemedicinskih konzultacija.

Umjetna inteligencija ne zamjenjuje liječnika, ali značajno olakšava i poboljšava dijagnostički proces, čini preglede bržima, preciznijima i dostupnijima većem broju žena. Pred kliničarima je zadatak da primjenu AI odgovorno nadziru i kontinuirano usvajaju najnovije preporuke stručnih udruženja.

Primjena umjetne inteligencije i 3D planiranja u maksilofacijalnoj kirurgiji**Igor Čvrljević, dr.med.****Klinika za maksilofacijalnu kirurgiju, KB Dubrava**

Primjena umjetne inteligencije (AI) i novih tehnologija značajno unapređuje maksilofacijalnu kirurgiju, omogućujući veću preciznost, optimalno planiranje, individualizirani pristup te predvidljive kirurške ishode. Digitalno planiranje i 3D printanje omogućuju izradu personaliziranih titanskih mrežica i pločica, čime se skraćuje operativno vrijeme i povećava sigurnost, osobito kod mikrovaskularne rekonstrukcije slobodnim režnjevima. AI doprinosi preciznijem planiranju resekcija tumora čeljusti i intraoralnih tumora te izradi kirurških vodilica kod kompleksnih koštanih rekonstrukcija (fibularni, podlaktični, DCIA i skapularni režnjevi). Kod operacija parotide primjena nervnog intraoperativnog monitoringa (NIM) omogućuje bržu i sigurniju identifikaciju grana facijalnog živca. Kod prijeloma kostiju lica digitalna analiza frakturirane strane omogućuje izradu personaliziranih titanskih mrežica i pločica. U ortognatskoj kirurgiji AI omogućuje precizno planiranje bimaxilarnih osteotomija te izradu personaliziranih šinja i vodilica. Završni stupanj funkcionalne i estetske rehabilitacije predstavlja digitalno potpomognuto planiranje i postavljanje dentalnih implantata.

Umjetna inteligencija u dijagnostici i liječenju katarakte**dr. sc. Anđela Jukić, dr. med., FEBO****Zavod za očne bolesti, Klinička bolnica Dubrava, Zagreb, Hrvatska**

Katarakta i dalje predstavlja vodeći uzrok sljepoće u svijetu, a broj operacija svake godine raste. U tom kontekstu, umjetna inteligencija (AI) otvara nove mogućnosti za unapređenje cjelokupne skrbi – od ranog otkrivanja bolesti do personaliziranog kirurškog planiranja i postoperativnog praćenja. Sustavi dubokog učenja već postižu više od 90% točnosti u detekciji značajne katarakte na biomikroskopskim, fundusnim i čak mobilnim snimkama, čime se otvara prostor za dostupniji probir u zajednici. AI modeli za izračun intraokularne leće (IOL) sve češće pogađaju ciljnu refrakciju unutar $\pm 0,50$ D, osobito u očima s atipičnim biometrijskim parametrima. Uz to, prediktivni algoritmi mogu procijeniti rizik od rupture kapsule ili slabosti zonula, dok računalni vid omogućuje praćenje kirurških faza u stvarnom vremenu. AI alati za postoperativni nadzor dodatno doprinose sigurnosti i učinkovitosti. Ključ uspješne primjene leži u bliskoj suradnji kliničara, inženjera i regulatornih tijela, uz naglasak na sigurnost, transparentnost i pravednu dostupnost tehnologije.

Ključne točke za raspravu:

1. Klinička spremnost AI alata
2. Suradnja čovjeka i umjetne inteligencije u kirurgiji
3. Etički i regulatorni izazovi

AI kao edukacijski alat u prevenciji bolesti i ozljeda**Izv.prof.dr.sc. Milan Milošević****Sveučilište u Zagrebu, Medicinski fakultet**

Umjetna inteligencija (AI) postaje ključni i sve dostupniji alat u biomedicini koji kroz analizu elektroničkih medicinskih kartona, genetskih zapisa, podataka s nosivih senzora i slika s dijagnostičkih uređaja, predviđa vjerojatnost razvoja i tijeka bolesti te omogućuje bolju identifikaciju pojedinaca s visokim rizikom. U prevenciji ozljeda AI omogućuje automatsko prepoznavanje rizičnih situacija na radnim mjestima, sportskoj aktivnosti i svakodnevnim navikama putem analize videonadzora i fizioloških parametara. U medicinskoj praksi primjena AI se osobito ističe u ranom otkrivanju bolesti koji omogućuju intervenciju prije pojave kliničkih simptoma. Također, AI poboljšava preciznost analize medicinskih slika te olakšava dugotrajno praćenje kroničnih bolesti s ciljem sprečavanja pogoršanja zdravlja. Napredne primjene AI uključuju integraciju s genetskim analizama, optimizaciju bolničkih resursa kroz predviđanje epidemioloških trendova te razvoj virtualnih asistenata za podršku pacijentima. U bliskoj budućnosti očekuje se šira klinička primjena ovih sustava, uz daljnji razvoj modela koji omogućuju personaliziranu medicinsku skrb na populacijskoj i individualnoj razini.

Ključne riječi: umjetna inteligencija, prevencija bolesti i ozljeda

Digitalna psihijatrija i umjetna inteligencija: Novi horizonti mentalnog zdravlja**Prof. dr. sc. Davor Mucić****Predsjednik Sekcije za digitalno mentalno zdravlje pri WPA (Svjetska Psihijatrijska Udruga)****Terapijski Centar Mali Princ, Havneholmen 82, 1561 Kopenhagen, Danska www.denlilleprins.org;****www.davormucic.com**

Digitalna psihijatrija ubrzano se razvija, osobito nakon pandemije COVID-19, uključujući telepsihijatriju, mobilne aplikacije, nosive uređaje i umjetnu inteligenciju (AI). Iako ti alati omogućuju personaliziranu, znanstveno utemeljenu skrb, izazivaju duboke etičke dileme. AI donosi potencijal za dijagnostiku, predviđanje relapsa i prilagođeno liječenje, ali izaziva zabrinutost zbog netransparentnosti, pristranosti algoritama i moguće marginalizacije ljudske prosudbe. Psihijatri strahuju da bi psihijatrija mogla postati isključivo statistička, zanemarujući njezinu narativnu i interpersonalnu dimenziju. Ove zabrinutosti podsjećaju na početne strahove vezane uz telepsihijatriju — gubitak kontrole, dehumanizaciju i etičku neizvjesnost — no danas se dodatno pogoršavaju zbog složenosti i nepredvidivosti AI sustava. Više od 30.000 aplikacija za mentalno zdravlje dodatno otežava stručnu evaluaciju i regulaciju.

Stoga je ključno razviti jasne smjernice, etičke standarde i edukacijske programe koji će zaštititi pacijente i terapeute, osigurati sigurnu primjenu digitalnih alata te podržati kliničku izvrsnost u digitalnoj psihijatriji.

Ključne točke: smjernice, etički standardi, edukacijski programi, interoperabilna i interkompatibilna telepsihijatrijska aplikacija nadograđena suvremenim AI alatima.

AI u kurikulumu biomedicinskih fakulteta**doc.dr.sc. Ivo Dumić-Čule, dr.med.****Sveučilište Sjever****Poliklinika Da Vinci**

Cilj našeg istraživanja bio je procijeniti stav liječnika čiji je svakodnevni rad značajno pod utjecajem umjetne inteligencije (artificial intelligence - AI) o važnosti uvođenja edukacije o AI u kurikulume medicinskih fakulteta. Anonimni upitnik distribuiran je u Hrvatskoj i Sloveniji među radiolozima i specijalizantima radiologije zaposlenima u primarnoj, sekundarnoj i tercijarnoj zdravstvenoj zaštiti, u javnom i privatnom sektoru. Ukupna stopa odaziva iznosila je 45%.

Velika većina sudionika – 89,6% (95% Agresti-Coull interval pouzdanosti 0,83–0,94) – složila se s potrebom uključivanja edukacije o AI u kurikulume medicinskih fakulteta. Odgovori su pokazali vrlo visoku razinu podrške u svim dobnim skupinama i neovisno o subspecijalizaciji. Nešto veća podrška zabilježena je među liječnicima zaposlenima u kliničkim bolnicama u usporedbi s onima u primarnoj zdravstvenoj zaštiti te među specijalizantima u odnosu na specijaliste radiologe, no te su razlike bile nesigifikantne, a razina podrške izrazito visoka u svim analiziranim skupinama.

Budući da su i studenti medicine u ranije objavljenim radovima izrazili podršku uvođenju edukacije o AI, a literatura i praktičari u području radiologije prepoznaju važnost takvog pristupa, zaključujemo da bi medicinski fakulteti trebali poduzeti konkretne korake kako bi pratili tehnološki napredak u medicini uključivanjem edukacije o AI u svoje kurikulume, bilo kroz postojeće ili nove kolegije.

Umjetna inteligencija u medicinskoj edukaciji: primjena, izazovi i prilike
izv. prof. dr. sc. Nina Pereza, dr. med.

Sveučilište u Rijeci, Medicinski fakultet, Centar za unaprjeđenje nastavničkih kompetencija i komunikacijskih vještina (voditeljica) i Zavod za medicinsku biologiju i genetiku (zamjenica predstojnika)

Umjetna inteligencija (engl. artificial intelligence, AI) sve snažnije transformira pristupe učenju i poučavanju u medicinskoj edukaciji, omogućujući personalizirano, interaktivno i učenje temeljeno na analizi podataka, koje je prilagođeno individualnim potrebama studenata, nastavnika te specifičnostima kurikula. U izlaganju će biti prikazan pregled suvremenih oblika primjene AI alata u medicinskoj edukaciji, uključujući adaptivne platforme za usmjereno samostalno učenje u virtualnom okruženju, chatbot-ove kao alate podrške učenju i poučavanju, sustave za vrednovanje ishoda učenja, generativni AI za izradu obrazovnih sadržaja, te tehnologije proširene i virtualne stvarnosti. Nadalje, bit će predstavljeni i primjeri primjene AI alata u medicinskoj edukaciji na Medicinskom fakultetu u Rijeci te naglašeni ključni etički i pedagoški izazovi, uključujući transparentnost algoritama, zaštitu privatnosti, nužnost razvijanja kritičkog promišljanja u studenata u visokom obrazovanju, kao i očuvanje humanističke dimenzije zdravstvene profesije.

Ključne točke:

- pregled suvremenih oblika primjene AI alata u medicinskoj edukaciji
- primjeri primjene AI alata u medicinskoj edukaciji na Medicinskom fakultetu u Rijeci
- ključni etički i pedagoški izazovi.

Kako odgovorno primijeniti umjetnu inteligenciju u zdravstvu: praktični pristupi i regulatorne obveze prema Aktu o umjetnoj inteligenciji (2024)

Nika Bošković, odvjetnica

PRODUCTA IP

Predavanje je osmišljeno tako da se u uvodnom dijelu pruži pregled strukture sustava umjetne inteligencije kako je definiran Aktom o umjetnoj inteligenciji, s posebnim naglaskom na sustave visokog rizika u području zdravstva te obveze koje korisnici takvih sustava preuzimaju.

Drugi dio predavanja bit će praktično usmjeren i obuhvatit će konkretan primjer primjene sustava umjetne inteligencije u zdravstvu. Kroz taj će se primjer istaknuti ključni elementi na koje korisnik mora obratiti pozornost kako bi ispunio zakonske obveze propisane regulatornim okvirom, smanjio rizike te uspješno uspostavio strategiju dobre prakse u korištenju takvih sustava.

U završnom dijelu predavanja, predavač će se osvrnuti na moguće posljedice nepoštivanja dobrih praksi i zakonskih obveza povezanih s primjenom sustava umjetne inteligencije u zdravstvenom kontekstu, osobito onih koji se izravno primjenjuju na pacijentima.

Pozitivni primjeri ranog probira pacijenata u Republici Hrvatskoj; Nacionalni program za probir i rano otkrivanje raka pluća

Akademik Miroslav Samaržija, doc.dr.sc. Kristina Krpina, Antun Aboud

Klinika za plućne bolesti, KBC Zagreb

Nacionalni program za probir i rano otkrivanje raka pluća započeo je provedbu u 10. mjesecu 2020. godine kao prvi nacionalni program u EU. Program je u potpunosti digitaliziran te se sastoji od sljedećih komponenti:

1. i-ELCAP guidelines
 2. Volumetrijska analiza
 3. Program umjetne inteligencije instaliran u Klinici za plućne bolesti Jordanovac KBC-a Zagreb, a putem telemedicinske mreže Republike Hrvatske analizira sve Low-Dose CT snimke
 4. Probir i narudžbu rade liječnici obiteljske medicine kroz posebno dizajniranu digitalnu platformu
- Rezultati probira: listopad 2020. - listopad 2025. : više od 74.000 Low Dose CT-a (52.000 sudionika). U sklopu Programa proveden je proces validacije AI modela dubokog učenja pod nazivom SYBIL, razvijenog na Massachusetts Institute of Technology (MIT) u Bostonu, koji predviđa rizik od razvoja raka pluća u narednih 6 godina. Uspostavljena je i formalna suradnja između MIT tima i Klinike za plućne bolesti Jordanovac, KBC Zagreb kroz potpisani sporazum o suradnji.

Sljedeće faze uključuju implementaciju modula za lokalizaciju gdje bi se karcinom pluća mogao razviti unutar SYBIL programa te razvoj algoritama umjetne inteligencije za predviđanje terapijskog odgovora kod bolesnika s karcinomom pluća.

Fokus će biti na rezultatima, digitalizaciji te SYBIL AI modelu.

Od rahitisa do robota: evolucija radiologa – primjer KBC-a Zagreb**doc. dr. sc. Mislav Čavka, prim.dr.med****Klinički bolnički centar Zagreb, Medicinski fakultet Sveučilišta u Zagrebu**

Razvoj radiologije u posljednjih stotinu i trideset godina predstavlja jednu od najbržih i najdubljih transformacija u medicini. Od prvih rendgenskih prikaza rahitisa i metaboličkih bolesti kostiju do suvremenih sustava umjetne inteligencije i robotske asistencije, radiolog je postao središnja figura digitalne medicine. Predavanje prikazuje taj put kroz primjer KBC-a Zagreb, i Kliničkog zavoda za dijagnostičku i intervencijsku radiologiju, najvećeg radiološkog zavoda u Hrvatskoj, gdje se povijesno iskustvo i tradicija spajaju s novim tehnologijama.

Naglasak je na prijelazu s analogne na digitalnu dijagnostiku, razvoju teleradiologije, automatiziranoj obradi slika i implementaciji AI algoritama u svakodnevni rad. Prikazuju se i konkretni projekti KBC-a Zagreb koji povezuju kliničku praksu, edukaciju i istraživanje – od studija bolesti kostiju i mineralnog metabolizma do digitalne forenzičke radiologije i telemedicinskih mreža.

Kroz koncept “od rahitisa do robota” ilustrira se kako se uloga radiologa razvila od pasivnog tumača slike do aktivnog dizajnera medicinskih procesa, čuvara kvalitete i ključnog sudionika u transformaciji zdravstvenog sustava budućnosti.

Umjetna inteligencija u dijagnostici Alzheimerove bolesti.**Aleksandra Roglič, dr.med.****Affidea**

Dosadašnje dijagnostičke metode prepoznaju morfološke karakteristike u kasnoj fazi Alzheimerove. Postoji velika potreba za mogućnošću izdvajanja pacijenata koji imaju blago kognitivno oštećenje (MCA) a razviti će Alzheimerovu bolest od onih koji nisu u toj rizičnoj skupini.

Nova saznanja etiologiji bolesti omogućili su razvoj bio markera koji doprinose ranom otkrivanju bolesti.

Razvoj tehnologije posebice u nuklearnoj medicini gdje se koriste specifični markeri kako bi se otkrili poremećaji metabolizam mozga.

Visoko rezolutne morfološke dijagnostičke metode omogućavaju primjerenu raznih modela umjetne inteligencije koja usporedbom veliki baza podataka također mogu ranije detektirati bolest. Razvoj funkcijskog MR omogućava rano detektiranje poremećaja određenih neuroloških funkcija prije nego što je to evidentno o kliničkoj slici.

S obzirom na multidisciplinarni pristup bolesti potrebno je uključiti složene modele umjetne inteligencije koji spajaju više različitih metoda, analiziraju i prepoznaju specifične segmente mozga koje povezuju u ukupnom volumenu i uspoređuju se velikim bazama podataka.

Cilj je prepoznati bolest te omogućiti liječenje pacijenata o ranoj fazi odnosno prije razvoja same bolesti.

Naravno s obzirom na to da je većina tih modela u fazi istraživanja upotreba tih modela u kliničkoj praksi se koristi kao pomoć pri postavljenju dijagnoze i na razini je "second opinion".

Uloga umjetne inteligencije u menadžmentu zdravstvenog sustava**Aron Grubešić, dr.med.**

Acibadem Healthcare Group pozicionirao se kao regionalni lider u implementaciji umjetne inteligencije i digitalne transformacije u zdravstvu, čime postavlja nove standarde u učinkovitosti i sigurnosti skrbi. Ključni primjer te strategije je implementacija GE Healthcare Command Centera, prvog takvog real-time zapovjednog centra u Turskoj i jednog od prvih u Europi. Ovaj centralni sustav integrira podatke iz svih bolničkih segmenata te uz pomoć AI, strojnog učenja i prediktivne analitike omogućuje dinamično praćenje i upravljanje bolničkim resursima, pacijentima i osobljem. Command Center pruža 360° pregled operacija, predviđa potrebe za krevetima i kadrom, te proaktivno upozorava na moguće zastoje u radu. Rezultati iz sličnih svjetskih primjera pokazuju do 34% kraće čekanje pacijenata, 38% bržu dijagnostiku i značajno bolje iskorištenje postojećih kapaciteta, što potvrđuje njegovu učinkovitost. Acibadem već bilježi skraćanje vremena obrade pacijenata i bolju alokaciju osoblja. U hrvatskom kontekstu, središnji Command Center predstavlja izniman potencijal za optimizaciju resursa, smanjenje listi čekanja i unapređenje kvalitete skrbi, uz izazove integracije podataka i prilagodbe postojećih sustava. Sustav utjelovljuje spoj umjetne inteligencije i vrhunske tehnologije te predstavlja temelj buduće digitalne bolnice.

Benefiti implementacije umjetne inteligencije u CT i MR dijagnostici onkoloških pacijenata**Ivo Pedišić, dr. med., specijalist radiologije****Radiochirurgia**

Implementacija umjetne inteligencije („AI“) u CT i MR dijagnostici onkoloških pacijenata donosi brojne prednosti. Algoritmi dubokog učenja omogućuju bržu i precizniju analizu slika, a u isto vrijeme, smanjuju mogućnost ljudske pogreške i povećavaju dijagnostičku točnost.

Sustavi umjetne inteligencije mogu automatski prepoznati patološke promjene, segmentirati anatomske strukture, izvoditi mjerenja i komparacije, ostavljajući radiologu više vremena za analize koje nisu dostupne umjetnoj inteligenciji i za elaboraciju nalaza u sklopu kliničkog konteksta.

Umjetna inteligencija doprinosi standardizaciji nalaza i ranijem otkrivanju patoloških promjena, što može biti ključno u liječenju, posebno kod onkoloških pacijenata.

Umjetna inteligencija ne zamjenjuje radiologa, već postaje njegov „drugi par očiju“, pomažući u prepoznavanju suptilnih promjena i optimizaciji radnih procesa.

Kombinacija stručnog iskustva i naprednih algoritama umjetne inteligencije dovodi do bržeg, točnijeg i sigurnijeg dijagnostičkog procesa, čime se poboljšava ishod liječenja i povećava povjerenje kolega drugih specijalnosti i pacijenata u suvremenu radiološku praksu.

Razvoj telemedicine i zakonski okvir u Hrvatskoj**Nikola Ivan Leder, dr.med.****Medicinski centar Gorica**

Telemedicina u Hrvatskoj posljednjih je godina doživjela snažan razvoj, posebno u području teleradiologije. Broj ustanova koje koriste telemedicinske usluge stalno raste, a iskustva pokazuju povećanje suradnje na rezanjima listi čeka i bolju dostupnost stručnjaka. Ipak, zakonodavni okvir još uvijek ne prati u potpunosti tehnološki napredak te ograničava fleksibilniju suradnju između javnog i privatnog sektora. U predavanju se prikazuje sadašnje stanje telemedicine u 2025. godini, glavni izazovi s kojima se sustav suočava te prijedlozi kako pojednostaviti regulativu i potaknuti daljnji razvoj ovog važnog segmenta moderne medicine.

Pandemijski porast kratkovidnosti: znanstveni uvidi i javnozdravstvene perspektive**Doc.dr.sc. Sanja Perić, dr.med.****KBC Zagreb**

Pandemija COVID-19 uzrokovala je značajne promjene u načinu života djece i mladih, s produljenim boravkom pred ekranima i smanjenom izloženošću prirodnom svjetlu. Brojna istraživanja bilježe porast učestalosti i progresije kratkovidnosti (miopije) tijekom i nakon pandemije, osobito među školskom djecom. Glavni mehanizmi uključuju vizualni stres pri radu na blizinu, manjak boravka na otvorenom te promjene u ritmovima spavanja i tjelesne aktivnosti. Dugoročno, povećava se rizik od visoke miopije i povezanih komplikacija. U prevenciji i praćenju kratkovidnosti sve veću ulogu ima umjetna inteligencija (AI), koja omogućuje rano otkrivanje promjena, personalizirane preporuke i analizu rizika u populacijskim studijama. Takvi alati već se primjenjuju u teleoftalmologiji i školskim programima probira vida.

S javnozdravstvenog aspekta, nužno je poticati uravnotežen digitalni stil života, redovite oftalmološke preglede i boravak na dnevnom svjetlu. Integracija AI tehnologije u preventivne programe može znatno unaprijediti kontrolu, razumijevanje i suzbijanje pandemijskog porasta kratkovidnosti.

Primjena umjetne inteligencije u ehokardiografiji**Doc.dr.sc. Vlatka Rešković Lukšić****KBC Zagreb**

Ehokardiografija predstavlja temeljnu dijagnostičku metodu u kardiologiji koja omogućuje procjenu morfologije i funkcije srca pomoću ultrazvučne tehnologije. Analiza ehokardiografskih podataka uključuje 2D i 3D oslikavanje te složene hemodinamske procjene. Iako je metoda neinvazivna i široko dostupna, kvaliteta zapisa, a time i točnost kvantifikacijskih mjerenja, uvelike ovise o iskustvu i vještini ispitivača, dok kompleksne analize često produljuju ukupno trajanje pretrage.

Primjena AI-a u ehokardiografiji obuhvaća tri ključna područja: akviziciju slike, kvantitativna mjerenja i interpretaciju nalaza. Dosadašnja istraživanja pokazala su da primjena AI-a može značajno skratiti vrijeme analize podataka uz očuvanu dijagnostičku točnost, a dodatno ima potencijal u predikciji kliničkih ishoda te identifikaciji bolesnika visokog rizika. Unatoč tome, implementacija AI-a u rutinsku kliničku praksu povezana je s brojnim izazovima, uključujući pitanja odgovornosti, pravne regulative, transparentnosti i interpretabilnosti algoritama.

U ovom će se predavanju prikazati aktualne mogućnosti umjetne inteligencije koje su već integrirane u kliničku ehokardiografiju te raspraviti potencijalni smjerovi razvoja i izazovi u daljnjoj implementaciji AI tehnologija u svakodnevni kardiološki rad.

Primjena umjetne inteligencije u ehokardiografiji**Doc. dr. sc. Nina Jakuš, dr. med.****KBC Zagreb**

Procjenjuje se kako srčano zatajivanje pogađa više od 10 milijuna stanovnika Europske Unije, te se predviđa kako će u budućnosti opterećenje na zdravstveni sustav biti izraženije, zbog rastuće populacije bolesnika sa srčanim zatajivanjem, kao i generalnog starenja stanovništva. Umjetna inteligencija, kao računarska znanost koja se bavi matematičkim algoritmima namijenjenim automatizaciji inteligentnog ponašanja, može predstavljati prijeko potrebnu podršku zdravstvenim sustavima.

Potencijalna područja primjene umjetne inteligencije u srčanom zatajivanju uključuju prevenciju i predviđanje razvoja srčanog zatajivanja, dijagnostičke metode, pomoć pri nadziranju relevantnih vitalnih parametara na daljinu, kao i predviđanje učinkovitosti određenih terapijskih opcija u subpopulacijama bolesnika, s ciljem pružanja personalizirane skrbi. S postepenom implementacijom ovih metoda u svakodnevnom kliničkom radu, nužna je kritička evaluacija potencijalnih nedostataka primjene umjetne inteligencije u liječenju bolesnika (nedostatak validacije, učenje na bazama podataka s manjkavim podacima...), te fokusiran rad na rješavanju ovih problema u stvarnom vremenu.

Implementacija umjetne inteligencije u srčanom zatajivanju predstavlja uzbudljivu priliku za unaprjeđenje zdravlja velike populacije bolesnika, stoga stavlja naglasak na važnost bliske suradnje kliničkih kardiologa i inženjera računarskih i podatkovnih znanosti u ispunjenju ovog cilja.

Umjetna inteligencija u integriranom oslikavanju miokarda**dr.sc. Filip Lončarić, dr.med.****KBC Zagreb**

Sveobuhvatno zbrinjavanje bolesnika s kardiološkim bolestima podrazumijeva učinkovito upravljanje kardiološkim informacijama, pri čemu se prikupljeni podaci koriste za postavljanje dijagnoze, procjenu rizika, vođenje terapijskih odluka te za odlučivanje o načinu daljnjeg kliničkog praćenja. U tom kontekstu, kardijalno oslikavanje predstavlja ključnu komponentu u procesu zbrinjavanja bolesnika i jedno je od mnogih međusobno povezanih dijelova kliničkog procesa: komunikacije između liječnika i bolesnika, snimanja srca, sastavljanja nalaza, interpretacije rezultata, predviđanja ishoda, odabira medicinskih intervencija te, stvaranja novih saznanja putem analize podataka. Umjetna inteligencija posjeduje snažan potencijal za unaprijeđenje svakog dijela tog procesa, čime bi se poboljšala točnost, brzina i učinkovitost cijelog sustava zbrinjavanja.

Ovo predavanje ima za cilj pružiti uvid u mogućnosti integracije umjetne inteligencije u standardni klinički rad, s posebnim naglaskom na kardijalno oslikavanje, s ciljem unaprijeđenja upravljanja medicinskim informacijama. Cilj je raspraviti o postojećim preprekama koje je potrebno prevladati kako bi se umjetna inteligencija široko implementirala i učinkovito integrirala u kliničku praksu.





NOVO



FreeStyle

Libre 2 PLUS



FreeStyle Libre 2 Plus senzor



Trajanje senzora produženo s 14 na 15 dana



Kompatibilan s automatiziranim sustavima za isporuku inzulina*



Kompatibilan sa smart-penom (NovoPen Echo® Plus)



Bez IBOA-e i MBPA: dva najčešća kožna alergena



Odobren za upotrebu od 2. godine života

*Dostupnost se razlikuje među pojedinim tržištima. Trenutno nije dostupno u Republici Hrvatskoj.

Slike su samo ilustrativne prirode. Nisu prikaz pravog pacijenta.

Kućište senzora, FreeStyle, Libre i srodne trgovačke marke su zaštićene marke društva Abbott. ©2025 Abbott. ADC-107980 v2.0. Abbott Laboratories d.o.o., Koranska 2, Zagreb.



SREBRNI SPONZORI



SPONZORI



2026

January

S	M	T	W	T	F	S
				1	2	3
4	5	6	7	8	9	10
11	12	13	14	15	16	17
18	19	20	21	22	23	24
25	26	27	28	29	30	31

February

S	M	T	W	T	F	S
1	2	3	4	5	6	7
8	9	10	11	12	13	14
15	16	17	18	19	20	21
22	23	24	25	26	27	28

March

S	M	T	W	T	F	S
1	2	3	4	5	6	7
8	9	10	11	12	13	14
15	16	17	18	19	20	21
22	23	24	25	26	27	28
29	30	31				

April

S	M	T	W	T	F	S
			1	2	3	4
5	6	7	8	9	10	11
12	13	14	15	16	17	18
19	20	21	22	23	24	25
26	27	28	29	30		

May

S	M	T	W	T	F	S
					1	2
3	4	5	6	7	8	9
10	11	12	13	14	15	16
17	18	19	20	21	22	23
24	25	26	27	28	29	30
31						

June

S	M	T	W	T	F	S
	1	2	3	4	5	6
7	8	9	10	11	12	13
14	15	16	17	18	19	20
21	22	23	24	25	26	27
28	29	30				

July

S	M	T	W	T	F	S
		1	2	3	4	
5	6	7	8	9	10	11
12	13	14	15	16	17	18
19	20	21	22	23	24	25
26	27	28	29	30	31	

August

S	M	T	W	T	F	S
						1
2	3	4	5	6	7	8
9	10	11	12	13	14	15
16	17	18	19	20	21	22
23	24	25	26	27	28	29
30	31					

September

S	M	T	W	T	F	S
		1	2	3	4	5
6	7	8	9	10	11	12
13	14	15	16	17	18	19
20	21	22	23	24	25	26
27	28	29	30			

October

S	M	T	W	T	F	S
				1	2	3
4	5	6	7	8	9	10
11	12	13	14	15	16	17
18	19	20	21	22	23	24
25	26	27	28	29	30	31

November

S	M	T	W	T	F	S
1	2	3	4	5	6	7
8	9	10	11	12	13	14
15	16	17	18	19	20	21
22	23	24	25	26	27	28
29	30					

December

S	M	T	W	T	F	S
		1	2	3	4	5
6	7	8	9	10	11	12
13	14	15	16	17	18	19
20	21	22	23	24	25	26
27	28	29	30	31		

