

ULOGA UMJETNE INTELIGENCIJE U LIJEČENJU PSIHIJATRIJSKIH POREMEĆAJA

Anamarija PETEK ERIC

Klinički bolnički centar Osijek, Klinika za psihijatriju, J. Huttlera 4, Osijek, Hrvatska
Medicinski fakultet Osijek, J. Huttlera 4, Osijek, Hrvatska
Fakultet za dentalnu medicinu i zdravstvo Osijek, Crkvena 21, Osijek, Hrvatska
ana5ek@gmail.com

Ivan ERIC

Klinički bolnički centar Osijek, Klinika za kirurgiju, J. Huttlera 4, Osijek, Hrvatska
Medicinski fakultet Osijek, J. Huttlera 4, Osijek, Hrvatska
ivaneric982@gmail.com

Sanda ANTON

Klinički bolnički centar, Klinika za psihijatriju, J. Huttlera 4, Osijek, Hrvatska
Medicinski fakultet Osijek, J. Huttlera 4, Osijek, Hrvatska
sanda.anton1@gmail.com

Marina PERKOVIĆ KOVAČEVIĆ

Klinički bolnički centar Osijek, Klinika za psihijatriju, J. Huttlera 4, Osijek, Hrvatska
Medicinski fakultet Osijek, J. Huttlera 4, Osijek, Hrvatska
marina.perkovic@gmail.com

Sažetak

Primjena umjetne inteligencije (UI) donijela je izvjesnu revoluciju u različite javne sektore, uključujući zdravstvo. U području psihijatrije UI nudi obećavajući pristup za poboljšanje strategija liječenja i upravljanja psihijatrijskim poremećajima. Sažetak istražuje višeslojnu ulogu UI-ja u psihijatrijskoj skrbi i njegovu primjenu u kliničkim uvjetima. Algoritmi umjetne inteligencije odlični su u obradi ogromnih količina podataka i identifikiranju složenih uzoraka, čineći ih neprocjenjivim alatima za psihijatrijska istraživanja. Tehnike strojnog učenja analiziraju različite izvore podataka, od genetskih markera i neuroslikovnih podataka do elektroničkih zdravstvenih zapisa i ishoda koje prijavljuju pacijenti. Integrirajući te podatke, UI olakšava identifikaciju biomarkera, predviđanje reakcija na liječenje i personalizirane intervencije prilagođene individualnim pacijentima. Jedna značajna primjena umjetne inteligencije u psihijatriji jest razvoj prediktivnih modela za rano otkrivanje i intervenciju. Ti modeli koriste se podatcima iz različitih izvora kako bi identificirali osobe s rizikom razvoja psihijatrijskih poremećaja, omogućujući pravovremene intervencije radi sprječavanja ili ublažavanja napredovanja simptoma. Osim toga, instrumenti za probir temeljeni na UI-ju pomažu kliničarima u preciznoj dijagnozi psihijatrijskih stanja analizirajući obrasce govora, izraza lica i druge ponašajne znakove. Također, digitalne terapije pokretane umjetnom inteligencijom nude

skalabilne i dostupne intervencije za osobe s psihijatrijskim poremećajima. Simulacije virtualne stvarnosti, „chatbotovi“ (platforme za razgovor) i aplikacije za pametne telefone pružaju psihoterapiju, kognitivno-bihevioralnu terapiju (KBT) i intervencije bazirane na svjesnosti, nadopunjujući tradicionalne modalitete liječenja. Te digitalne platforme pružaju kontinuiranu podršku, prate napredak simptoma i prilagođavaju intervencije u stvarnom vremenu na temelju povratnih informacija korisnika, čime se poboljšava terapijska suradljivost i ishodi liječenja. U kliničkim postavkama dinamični sustavi umjetne inteligencije u pružanju podrške pri odlučivanju pomažu kliničarima u planiranju liječenja i upravljanju medikamentoznom terapijom. Algoritmi obrade prirodnog jezika (engl. *neurolinguistic patterns* – NLP) analiziraju kliničke bilješke i podatke o pacijentima kako bi generirali preporuke za liječenje usklađene s praksama temeljenima na dokazima i preferencijama pacijenata. Takvi sustavi podrške odlučivanju poboljšavaju učinkovitost liječenja, smanjuju nuspojave i smanjuju troškove zdravstvene skrbi optimizacijom uporabe resursa. Unatoč svojim potencijalnim koristima, implementacija umjetne inteligencije u psihijatrijsku skrb predstavlja nekoliko izazova. Etička razmatranja u vezi s privatnošću podataka, pristranosti algoritama i autonomijom pacijenata zahtijevaju posebnu pozornost kako bi se osigurala odgovorna upotreba tehnologija UI-ja. Osim toga, integracija UI-ja u postojeće zdravstvene infrastrukture zahtijeva prevladavanje tehničkih prepreka, osiguranje interoperabilnosti i pružanje adekvatne obuke zdravstvenim stručnjacima. Zaključno, umjetna inteligencija ima ogroman potencijal za transformaciju pejzaža psihijatrijske skrbi omogućavajući rano otkrivanje, personalizirane intervencije i pristupe liječenju temeljene na podacima. Iskorištavanjem snage UI-ja kliničari mogu poboljšati ishode liječenja, unaprijediti iskustva pacijenata i unaprijediti naše razumijevanje psihijatrijskih poremećaja. Međutim, uspješna integracija UI-ja u kliničku praksu zahtijeva rješavanje etičkih, tehničkih i regulatornih izazova kako bi se osigurala sigurna i učinkovita implementacija.

Ključne riječi: umjetna inteligencija, psihijatrijski poremećaji, strategije liječenja, personalizirane intervencije, prediktivno modeliranje

Ključna poruka rada: Integracija algoritama UI omogućuje personalizirane intervencije, ranu detekciju i prediktivno modeliranje, mijenjajući i unapređujući psihijatrijsku skrb putem pristupa vođenih podacima.

1. Uvod

Umjetna inteligencija (UI) postaje nezaobilazan alat u suvremenom društvu, sa rastućim utjecajem na raznovrsne industrije, s posebnim naglaskom na domenu zdravstva. Njezin potencijal da inovira razvoj medicine, nalazi se u sposobnosti analize velike količine podataka, prepoznavanja obrazaca i pružanja personaliziranih preporuka. Rastući utjecaj UI nalazimo i u psihijatriji, gdje dijagnostika i liječenje često ovise o složenim, djelomično

subjektivno temeljenim, procjenama kliničara. Integracija umjetne inteligencije u ovo područje nudi nove mogućnosti za poboljšanje kvalitete skrbi i optimizaciju terapijskih postupaka. Prema Svjetskoj zdravstvenoj organizaciji (SZO), oko bilijun ljudi boluje od psihijatrijskih poremećaja, a od toga oko 300 milijuna boluje od depresije (WHO, 2020; GBD, 2017). Tradicionalne metode liječenja često nisu dovoljne za ispunjavanje kompleksnih potreba pacijenata, što naglašava potrebu za inovativnim rješenjima. UI donosi personalizirane terapije, organizirane sustave kao podršku kliničkom odlučivanju te prediktivne modele koji omogućuju rano otkrivanje simptoma poremećaja i modifikaciju terapijskih mogućnosti. Na primjer, algoritmi strojnog učenja već su pokazali učinkovitost u predviđanju reakcije na antidepresive, omogućujući kliničarima da optimiziraju terapijski pristup (Bobo i sur., 2022). Unatoč ovim obećavajućim mogućnostima, integracija umjetne inteligencije u kliničku praksu nije bez izazova. Problemi poput pristranosti algoritama, nedostatka standardiziranih podataka i složenosti algoritama ograničavaju njezinu širu primjenu. Nadalje, pitanja očuvanja privatnosti i etičkih implikacija korištenja osjetljivih podataka u psihijatriji zahtijevaju pažljivo razmatranje. Murdoch (2021) i Yadav i suradnici (2023) istaknuli su da čak i najsuvremeniji sustavi zaštite podataka ne mogu u potpunosti eliminirati rizik od propusnosti informacija, što dodatno naglašava potrebu za strogim regulatornim okvirima. Ovi izazovi zahtijevaju strog regulatorni okvir kako bi se osigurala učinkovita i odgovorna primjena UI-a u zdravstvenim sustavima. Cilj ovog preglednog rada je pružiti sustavnu analizu uloge umjetne inteligencije u liječenju psihijatrijskih poremećaja. Fokus će biti na ključnim primjenama poput personaliziranih terapija, digitalnih intervencija te alata za podršku u donošenju kliničkih odluka. Također će biti razmotreni tehnički i etički izazovi s kojima se suočavaju istraživači i kliničari pri implementaciji ovih tehnologija. Na kraju, rad će istražiti perspektive daljnjeg razvoja, naglašavajući potrebu za multidisciplinarnim pristupom u razvoju odgovorne i učinkovite primjene UI-a u psihijatriji. Izradom ovog pregleda želi se pridonijeti boljem razumijevanju potencijala umjetne inteligencije u području mentalnog zdravlja te ponuditi smjernice za njezinu integraciju u kliničku praksu. Pritom je ključno osigurati da koristi za pacijente nadmašuju potencijalne rizike, postavljajući temelje za budućnost psihijatrijske skrbi koja je preciznija, personaliziranija i inkluzivnija.

2. Primjena umjetne inteligencije u medicini – dosadašnja saznanja

Primjena umjetne inteligencije (UI) u medicini značajno je unaprijedila dijagnostiku, liječenje i metodologiju istraživanja, osobito u područjima gdje složenost bolesti zahtijeva analizu velikih količina podataka i prepoznavanje obrazaca (Briganti, 2020). UI se sve češće koristi u neurologiji i psihijatriji, pružajući kliničarima alate za preciznije i personalizirane pristupe pacijentima. Dosadašnja saznanja potvrđuju učinkovitost UI-a u dijagnostici, razvoju prediktivnih modela, personalizaciji terapijskih opcija te digitalnim terapijskim intervencijama. (Krishan i sur., 2023; Alami i sur., 2020).

Dijagnostika poremećaja središnjeg živčanog sustava

Jedno od posebno značajnih područja primjene UI-a u medicini je dijagnostika neuroloških i psihijatrijskih poremećaja. Algoritmi strojnog učenja pokazuju iznimnu točnost u analizi podataka dobivenih tehnikama poput magnetne rezonancije (MR), elektroencefalografije (EEG) i pozitronske emisijske tomografije (PET) (Tveit i sur., 2023; Zaharchuk 2021). Na primjer, istraživanja sugeriraju da UI može prepoznati rane biomarkere Alzheimerove bolesti s točnošću koja nadmašuje tradicionalne metode dijagnostike (He i sur., 2023). Sličan napredak zabilježen je i u dijagnostici epileptičkih napada. Modeli dubokog učenja, poput konvolucijskih neuralnih mreža (engl. *Convolutional Neural Networks* – CNN) analiziraju EEG podatke kako bi identificirali obrasce koji prethode napadima, omogućujući pravovremene intervencije i prilagodbu terapija u stvarnom vremenu (Yamashita i sur., 2018; Truong i sur., 2018). Istraživanje Singh i suradnika (2023) naglašava razvoj nosivih uređaja i implantabilnih sustava koji omogućuju kontinuirano praćenje pacijenata i pravovremeno detektiranje napada. Iako postoje izazovi u vezi s potrošnjom energije i računalnim zahtjevima, istraživanje pokazuje da su ovi sustavi visoko osjetljivi, s primjerima visoke preciznosti (99,81% osjetljivosti), te imaju potencijal za modificiranje liječenja epilepsije u budućnosti.

Personalizirane terapije i prediktivni modeli

Integriranje genetskih analiza, kliničkih zapisa i neuroslikovnih podataka potpomaže razvoj personaliziranog terapijskog pristupa temeljenog na UI-u. Ovakvi sustavi pomažu u predviđanju odgovora na terapiju i prilagodbi liječenja specifičnim potrebama pacijenata. Kod Parkinsonove bolesti, istraživanja primjene UI naglašavaju važnost uočavanja nemotoričkih simptoma bolesti kao što su poremećaji spavanja i kognitivne promjene, koji se mogu pojaviti prije motoričkih simptoma i pomoći u ranoj dijagnozi, te naglašava potrebu za većim skupovima podataka kako bi se poboljšala učinkovitost UI modela (Bind i sur., 2015; Dixit i sur., 2023). Prediktivni modeli razvijeni uz pomoć UI-a također omogućuju rano prepoznavanje rizika za razvoj bolesti. Na primjer, algoritmi strojnog učenja pokazali su visoku razinu točnosti u klasifikaciji faza multiple skleroze i predviđanju odgovora na liječenje. Štoviše, upravo modeli UI pomažu prepoznavanju kognitivnih oštećenja, motoričkih smetnji (hod i sl.) i drugih simptoma, pružajući učinkovitije načine za napredovanje bolesti i prilagodbu terapije u stvarnom vremenu. (Naji i sur., 2023; Aslam i sur., 2022).

Digitalne terapije kao podrška u rehabilitaciji

Digitalne terapije temeljene na UI-u značajno povećavaju dostupnost i učinkovitost terapijskih intervencija (Bakker i sur., 2016). Aplikacije za kognitivno-bihevioralnu terapiju (KBT) pružaju personalizirane terapijske sadržaje i kontinuiranu podršku pacijentima. Na primjer, Woebot, automatizirani chatbot temeljen na modelu UI, koristi interaktivne tehnike za smanjenje simptoma depresije i anksioznosti, a njegove se prednosti posebno ogledaju kod mladih korisnika (18 – 20 godina života) s ograničenim pristupom

tradicionalnim terapijama (Fitzpatrick i sur., 2017). U spomenutom istraživanju, je uporaba Woebota kod jedne skupine ispitanika rezultirala značajnim smanjenjem simptoma depresije prema rezultatima upitnika PHQ-9, u usporedbi s kontrolnom skupinom koja je primila ne-terapijski sadržaj. U odnosu na anksioznost, iako je u obje skupine došlo do redukcije simptoma, grupa ispitanika koja je koristila Woebot imala je značajnije poboljšanje. U rehabilitaciji, UI sustavi pomažu pacijentima koji se oporavljaju od moždanog udara ili ozljeda kralježnice (Luvizotto i sur., 2022). Robotski sustavi implementiraju povratne informacije u stvarnom vremenu kako bi prilagodili terapijske planove i potaknuli neuroplastičnost. Istraživanje Senadheera i suradnika (2024) pokazalo je da se kod pacijenata koji su koristili terapije temeljene na UI, posebno robotske sustave i biofeedback, dogodio ubrzaniji oporavak motorike nakon moždanog udara u usporedbi s konvencionalnim metodama.

Razvoj tehnologija UI za kliničku primjenu

Od sredine 20. stoljeća, razvoj sustava poput MYCIN-a (engl. *Medical Diagnosis and Therapy System – MYCIN*) i kasnijih naprednih algoritama strojnog i dubokog učenja omogućio je značajna poboljšanja u medicini (Avanzo i sur., 2024). Algoritmi računalnog vida, primjerice, danas analiziraju snimke magnetne rezonancije s preciznošću usporedivom s iskusnim radiolozima (Hosny i sur., 2018; Mustafa, 2023). Sustavi poput IBM Watson Health koriste obradu prirodnog jezika za analizu kliničkih podataka, pružajući liječnicima preporuke temeljene na dokazima i optimizirajući proces donošenja odluka (Kohn i sur., 2014). Unatoč dosadašnjim uspjesima, primjena UI-a u medicini suočava se s izazovima kao što su pristranost podataka, nedostatak standardizacije i problemi interoperabilnosti među sustavima. Integracija različitih izvora podataka zahtijeva multidisciplinarni pristup, dok zakonska i etička pitanja, osobito u osjetljivim područjima poput psihijatrije, ostaju ključne prepreke za širu primjenu. Međutim, kontinuirani napredak tehnologija i interdisciplinarna suradnja pružaju temelje za daljnji razvoj i učinkovitiju primjenu UI-a u kliničkoj praksi (Li i sur., 2024).

3. Primjena umjetne inteligencije u liječenju poremećaja središnjeg živčanog sustava

Bolesti središnjeg živčanog sustava (SŽS) predstavljaju značajno javnozdravstveno opterećenje, podrazumijevajući i neurodegenerativne bolesti poput Alzheimerove i Parkinsonove bolesti te psihijatrijske poremećaje poput depresije i shizofrenije. Njihova složenost zahtijeva multidisciplinarni pristup u kojem umjetna inteligencija (UI) ima sve važniju ulogu (Vatansever i sur., 2021). Napredne tehnike strojnog i dubokog učenja omogućuju analizu velikih i heterogenih podataka, pružajući nove uvide u patofiziologiju, ranu dijagnostiku i personalizirane terapije (Mirjebrelli i sur., 2024; Badrulhisham i sur., 2024).

Prediktivni modeli za rano otkrivanje poremećaja

Jedan od ključnih načina na koje UI doprinosi liječenju poremećaja SŽS-a jest razvoj prediktivnih modela koji omogućuju ranu detekciju specifičnih simptoma bolesti i pravovremene intervencije. Na primjer, algoritmi strojnog učenja koriste podatke dobivene iz elektroničkih zdravstvenih zapisa, genetskih analiza i neuroslikovnih tehnologija kako bi identificirali rizične skupine (Kalani, 2024). Kod Alzheimerove bolesti, su upravo prediktivni modeli pokazali značajne rezultate u otkrivanju ranih znakova bolesti. Istraživanje Mukherji i suradnika (2022) pokazalo je da algoritmi mogu predvidjeti progresiju bolesti s točnošću većom od 85%, koristeći kombinaciju podataka iz Alzheimer Disease Neuroimaging Initiative (ADNI), koji uključuju longitudinalno istraživanje s širokim spektrom iz neuropsiholoških testova i snimki mozga. Slično tome, UI je uspješno primijenjen u ranom otkrivanju depresivnih epizoda, analizirajući obrasce govora, izraze lica i bihevioralnih promjena zabilježenih tijekom provođenja terapije ili putem mobilnih aplikacija. Ova saznanja omogućuju ciljane pravovremene intervencije koje smanjuju rizik od razvoja težih oblika poremećaja (Zafar i sur., 2024; Wang i sur., 2018).

Na podatcima utemeljeni individualizirani terapijski pristupi

Personalizacija terapijskih pristupa ključan je iskorak u liječenju poremećaja SŽS-a. Integracijom podataka o biomarkerima, farmakogenetici i povijesti bolesti, UI omogućuje prilagodbu terapijskih protokola svakom pojedinom pacijentu. Kod Parkinsonove bolesti, na primjer, UI sustavi poput različitih vrsti rekurentnih neuralnih mreža (RNM) pokazali su visoku razinu točnosti integrirajući podatke o motoričkim simptomima kod bolesnika s ciljem predlaganja optimalne doze levodope, čime se može poboljšati kvaliteta života i smanjuju nuspojave (Riasi i sur., 2024). Sustavi strojnog učenja također su pokazali sposobnost predviđanja odgovora na određene lijekove, što je osobito korisno kod izbora psihofarmaka (npr. antidepresiva). Istraživanje Kautzky i suradnika (2021) utvrdilo je da UI modeli i kombinacije više različitih algoritama mogu precizno predvidjeti odgovor pacijenata na antidepresive, omogućujući kliničarima da odaberu najprikladniji lijek i time skrate vrijeme potrebno za postizanje terapijskog učinka.

Digitalne terapije kao podrška u liječenju

Digitalne terapije koje koriste UI postaju sve popularniji alat za liječenje poremećaja SŽS-a, osobito u psihijatriji. Na primjer, razvoj aplikacija za pametne telefone omogućuju pacijentima pristup kognitivno-bihevioralnoj terapiji (KBT) putem interaktivnih chatbotova ili vođenih programa. Sustavi temeljeni na umjetnoj inteligenciji prilagođavaju terapijski sadržaj individualnim potrebama pacijenata, osiguravajući veću učinkovitost liječenja i bolji klinički odgovor. Virtualna stvarnost (VS), u kombinaciji s UI-om, koristi se u liječenju fobija i posttraumatskog stresnog poremećaja (PTSP) (Spytska, 2024). Primjerice, UI prilagođava simulacije u stvarnom vremenu, omogućujući pacijentima postupnu desenzitizaciju na traumatske podražaje u sigurnom i kontroliranom okruženju. Maples-Keller i suradnici (2017) zabilježili su značajno smanjenje simptoma kod više od 70% pacijenata nakon samo 10 terapijskih tretmana potpomognutih VS-om.

Umjetna inteligencija i kliničke odluke

Umjetna inteligencija pruža vrijednu podršku kliničarima u složenim slučajevima poput shizofrenije i bipolarnog poremećaja. Algoritmi obrade prirodnog jezika (engl. *Natural Language Processing* – NLP) omogućuju analizu medicinske dokumentacije, bilješki razgovora pacijenata i drugih pisanih podataka, pružajući preporuke utemeljene na dokazima. Na primjer, sustavi poput IBM Watson Health integriraju najnovije znanstvene dokaze s individualnim podacima pacijenta kako bi pružili personalizirane planove liječenja (Johnson i sur., 2021). Osim toga, UI sustavi mogu pomoći u procjeni težine simptoma i praćenju terapijskog odgovora odnosno procjeni učinkovitosti terapije. Gashkarimov i suradnici (2023) opisuju različite modele strojnog učenja, uključujući dijagrame u donošenju odluka, vektorsku analizu i metode dubokog učenja, koje imaju kapacitete analize podatka o pacijentima (kao što su obrasci verbalne ekspresije, bihevioralni podaci i genetske informacije) kako bi identificirali rane znakove shizofrenije i predvidjeli napredovanje bolesti. Rezultati sugeriraju da modeli strojnog učenja mogu značajno poboljšati dijagnostičku preciznost i pomoći u prilagodbi modaliteta liječenja temeljenih na individualnim karakteristikama pacijenta. Iako su rezultati primjene UI-a u liječenju bolesti i poremećaja središnjeg živčanog sustava obećavajući, i dalje postoje tehnički, etički i zakonodavni izazovi. Pristranost algoritama, oslanjanje na heterogene izvore podataka i složenost interpretacije rezultata ograničavaju njezinu širu implementaciju. Međutim, kontinuirani razvoj tehnologija, povećana dostupnost podataka i suradnja između znanstvenih i kliničkih stručnjaka pružaju mogućnosti za daljnje unaprjeđenje dijagnostike i terapije (Norori i sur., 2021).

4. Osvrt na povijesni razvoj i tehnologije umjetne inteligencije u medicini

Razvoj umjetne inteligencije (UI) u medicini započeo je sredinom 20. stoljeća, kada su pionirski računalni sustavi pokazali potencijal u medicinskoj dijagnostici. Jedan od najpoznatijih ranih sustava bio je MYCIN, razvijen 1970-ih na Sveučilištu Stanford. MYCIN je koristio pravila temeljena na znanju stručnjaka (infektologa i mikrobiologa) za dijagnostiku bakterijskih infekcija i preporuku odgovarajućih terapija, poput antibiotika. MYCIN je demonstrirao točnost usporedivu s liječnicima, no nije bio široko primijenjen zbog regulatornih i tehnoloških ograničenja (Shortliffe, 1977). Njegova važnost leži u postavljanju temelja za buduće sustave podrške odlučivanju. Tijekom 1990-ih, uvođenje elektroničkih zdravstvenih zapisa (EHR) revolucioniralo je prikupljanje i upravljanje medicinskim podacima. Integracija algoritama strojnog učenja omogućila je analizu velikih količina strukturiranih podataka, čime se unaprijedila dijagnostika i personalizirana terapija (Hirani i sur., 2024). Početkom 21. stoljeća, razvoj tehnologije dubokog učenja (engl. *deep learning*) i konvolucijskih neuronskih mreža omogućio je analizu nestrukturiranih podataka, uključujući kliničke bilješke, genetske informacije i

medicinske slike (Avanzo i sur., 2024). Primjeri primjene uključuju automatsko otkrivanje tumora na MRI snimkama i personalizaciju terapije.

Današnji razvoj UI-a u medicini temelji se na razvoju nekoliko ključnih tehnologija:

Strojno učenje (engl. *Machine learning* – ML): Algoritmi strojnog učenja omogućuju analizu medicinskih podataka, prepoznavanje obrazaca i prediktivnu analitiku. Na primjer, sustavi strojnog učenja koriste se u prepoznavanju čimbenika rizika i optimizaciji terapijskih protokola u kardiologiji i onkologiji. U istraživanju Esteve i suradnika (2017), ovakvi sustavi analizirali su dermoskopske slike sa preciznošću od 91% u otkrivanju melanoma, što je usporedivo s kliničkom razinom dijagnosticiranja iskusnih dermatologa. U domeni kardiologije, upravo su algoritmi strojnog učenja bili svojevrсни pionirski model UI korišten za prepoznavanje atrijske fibrilacije analizom podataka iz prenosivih uređaja, poput pametnih satova, pružajući mogućnost ranog otkrivanja simptoma i smanjenja rizika od moždanog udara (Halcox i sur., 2017; Turakhia i sur., 2019).

Duboko učenje (engl. *Deep Learning* – DL): Ova podvrsta strojnog učenja koristi višeslojne neuronske mreže za analizu složenih podataka. DL algoritmi pokazali su značajnu preciznost u analizi slika magnetske rezonance (MR) i kompjutorizirane tomografije (CT) u dijagnostici tumora, neuroloških poremećaja i kardiovaskularnih bolesti (Hosny i sur., 2018; Jiang i sur., 2023). Naji i suradnici (2023) izvijestili su o preciznosti od 95% u identifikaciji lezija multiple skleroze (MS), što nadilazi rezultate dobivene standardnim metodama. Modeli strojnog učenja kod karcinoma pluća pokazuju uspjeh u analizi CT snimki kako bi klasificirala tumore prema malignosti. Sustavi poput Google DeepMind-a pridonijeli su smanjenju lažno negativnih rezultata za 11% u usporedbi s kliničkom procjenom radiologa (Shafi i sur., 2022).

Računalni vid (engl. *Computer Vision* – CV): Računalni vid kao tehnologija omogućuje analizu slikovnih pretraga za otkrivanje patologija poput tumora i moždanih udara. BioMind, sustav temeljen na UI-u, koristi računalni vid za prepoznavanje lezija mozga na MR snimkama, postižući preciznost koja je često usporediva s iskusnim radiolozima (Kondova i sur., 2024). Istraživanja u oftalmologiji pokazuju kako računalni vid može analizirati snimke mrežnice i dijagnosticirati dijabetičku retinopatiju s preciznošću od 94%, čime se omogućuje ranija intervencija (Khan i sur., 2023).

Obrada prirodnog jezika (engl. *Natural Language Processing* – NLP): NLP se primjenjuje za analizu pisanih i govornih podataka, poput kliničkih bilješki, transkripta terapijskih razgovora i govora pacijenata. U psihijatriji se NLP koristi za identifikaciju ranih znakova depresije i suicidalnih ideja analizom govora i interakcija. Althoff i suradnici (2016) proveli su analizu velike skale terapijskih razgovora koristeći NLP te ukazali na potencijal za identifikaciju suicidalnih misli s visokim stupnjem preciznosti. Također, NLP se koristi u analizi kliničkih zapisa radi detekcije nepravilnosti u liječenju ili osiguravanja konzistentnosti terapijskih protokola. Na primjer, prema Sharma i suradnicima (2020), NLP pomaže u prepoznavanju emocionalnog sadržaja suicidalnih pacijenata.



Prediktivna analiza: Integracija kontinuiranih medicinskih zapisa u prediktivne modele omogućuje prognozu budućih zdravstvenih ishoda. Walsh i suradnici (2023) demonstrirali su da modeli strojnog učenja mogu identificirati pacijente s visokim rizikom od pogoršanja simptoma depresije analizom medicinske dokumentacije i bihevioralnih obrazaca. U kardiologiji su Khera i suradnici (2021) dokazali su da se prediktivna analiza može koristiti za identifikaciju pacijenata s visokim rizikom od srčanog udara analizom povijesti bolesti i laboratorijskih nalaza, omogućujući pravovremene preventivne reakcije.

5. Tranzicija umjetne inteligencije u psihijatriju

Primjena umjetne inteligencije (UI) u psihijatriji započela je kasnije nego u drugim medicinskim područjima zbog izazova povezanih s prirodom duševnih poremećaja i nestrukturiranim podacima (Galatzer-Levy, 2023). Mentalno zdravlje obuhvaća složene i subjektivne aspekte, što otežava standardizaciju podataka potrebnih za UI. Ipak, posljednje desetljeće obilježeno je napretkom u integraciji UI-a u psihijatriju s ciljem poboljšanja dijagnostike i terapije (Shatte i sur., 2019).

Algoritmi u otkrivanju depresije i anksioznosti

Jedan od prvih uspješnih prijelaza UI-a u psihijatriju bio je razvoj algoritama za prepoznavanje ranih znakova depresije i anksioznosti. Algoritmi strojnog učenja analiziraju govorne uzorke, facijalne ekspresije i fiziološke reakcije kako bi prepoznali simptome (Garcia-Ceja i sur., 2018). Sustavi dubokog učenja dodatno omogućuju pravovremene intervencije analizom bihevioralnih obrazaca prikupljenih putem nosivih uređaja i mobilnih aplikacija (Galatzer-Levy, 2023).

Inovacije u liječenju shizofrenije i bipolarnog poremećaja

Primjena UI-a u težim duševnim poremećajima, poput shizofrenije i bipolarnog poremećaja, pokazuje potencijal u personalizaciji terapija. Algoritmi obrade prirodnog jezika koriste se za analizu govora pacijenata sa shizofrenijom, omogućujući kliničarima da prepoznaju pogoršanje simptoma i prilagode terapijski izbor (Shatte i sur., 2019). Kod bipolarnog poremećaja, algoritmi omogućuju predikciju maničnih i depresivnih epizoda bolesti analizom podataka prikupljenih putem mobilnih uređaja (Garcia-Ceja i sur., 2018).

Umjetna inteligencija i individualiziran pristup u psihijatriji

Jedan od ključnih ciljeva primjene UI-a u psihijatriji je individualiziranje terapijskog pristupa. Integracijom farmakogenetskih podataka, medicinske dokumentacije i informacija o okolišnim čimbenicima, UI omogućuje stvaranje prilagođenih planova liječenja koji optimiziraju učinak terapije i minimiziraju pojavnost nuspojava. Tako algoritmi dubokog učenja koriste genetske podatke za predviđanje odgovora pacijenata na određene psihofarmake (antidepresive, antipsihotike), omogućujući kliničarima da

odabir najučinkovitije terapije (Bobo i sur., 2022; Tai i sur., 2024). Kod transkranijalne magnetske stimulacije (TMS), algoritmi UI imaju mogućnost modificirati parametre intenziteta stimulacije kako bi povećali učinkovitost liječenja depresije kao i predvidjeti terapijski. Erguzel i Tarhan (2018) su pokazali kombiniranje različitih modela strojnog učenja može sa osjetljivošću od 95,6% i točnošću od 86,4% predvidjeti terapijski odgovor pacijenata na liječenje TMS-om.

Digitalne terapije i alati za podršku

Jedan od najinovativnijih prijelaza UI-a u psihijatriju uključuje razvoj digitalnih terapija, poput aplikacija za pametne telefone i virtualnih asistenata. Chatbotovi razvijeni na umjetnoj inteligenciji, poput Woebota, pružaju korisnicima kognitivno-bihevioralne terapije (KBT) kroz interaktivne susrete. Fitzpatrick i suradnici (2017) pokazali su da Woebot može smanjiti simptome depresije kod korisnika u ranim fazama korištenja. Virtualna stvarnost (VS), integrirana s UI algoritmima, koristi se za liječenje posttraumatskog stresnog poremećaja (PTSP) i fobija. Primjena VS omogućava postupnu desenzitizaciju pacijenta na traumatske podražaje u kontroliranim okruženjima, što smanjuje simptome i poboljšava kvalitetu života. Istraživanje Rizzo i Shiling (2017) pokazalo je učinkovitost terapije primjenom VS u liječenju PTSP-a kod veterana.

Primjena nosivih uređaja i senzora u psihijatriji

Nosivi uređaji, poput pametnih satova i senzora za praćenje vitalnih znakova, postaju nezaobilazni alati u prikupljanju podataka o mentalnom zdravlju. Tako se podaci o spavanju, srčanom ritmu i tjelesnoj aktivnosti koriste se za prepoznavanje obrazaca koji upućuju na depresiju ili anksioznost. Gross i Kaushanskaya (2020) su uočili da nosivi uređaji u kombinaciji s algoritmima strojnog učenja mogu predvidjeti simptome depresije s visokim stupnjem preciznosti.

Izazovi u implementaciji umjetne inteligencije u psihijatriju

Unatoč značajnom napretku, primjena UI-a u psihijatriji suočava se s brojnim tehničkim i etičkim izazovima. Nedostatak standardiziranih podataka i pristranosti algoritama ograničavaju primjenu UI-a u različitim populacijama. Dokazano je da pristranost u podacima može dovesti do netočnih dijagnoza kod manjinskih populacija (Obermeyer i sur., 2019). Pitanja očuvanja privatnosti su također važna, posebno u analizi osjetljivih podataka o mentalnom zdravlju. Međutim, napredak u objašnjivim modelima umjetne inteligencije i razvoj zakonodavnih okvira postavljaju obećavajuće temelje za daljnju integraciju UI-a u psihijatrijsku praksu (Doshi-Velez i Kim, 2017).

6. Umjetna inteligencija i liječenje psihijatrijskih poremećaja

Umjetna inteligencija (UI) značajno doprinosi liječenju psihijatrijskih poremećaja, omogućujući individualiziranu terapiju, kontinuirano praćenje simptoma i primjenu inovativnih metoda. UI povećava učinkovitost terapija analizom velikih količina podataka, posebno za populacije s ograničenim pristupom tradicionalnoj skrbi (Gooding i sur., 2021).

Terapija avатарom (engl. *Avatar Therapy*) za liječenje halucinacija kod shizofrenije

Terapija avатарom koristi umjetnu inteligenciju za kreiranje virtualnih avatara koji predstavljaju glasove koje pacijenti čuju. Tijekom terapije, pacijenti razgovaraju s avatarima, dok terapeut upravlja njihovim odgovorima radi izazivanja promjena u percepciji halucinacija. Craig i suradnici (2018) su proveli su randomizirano kontrolirano istraživanje koje je pokazalo značajno smanjenje intenziteta halucinacija nakon primjene terapije avатарom. Sustavi poput AVATAR-a (engl. *Automated Virtual Agent for Therapeutic Avatar Responses*) koriste umjetnu inteligenciju za prilagođavanje intonacije i sadržaja avatara individualnim potrebama pacijenata. Freeman i suradnici (2022) pokazali su da ova tehnologija dodatno poboljšava kontrolu nad simptomima slušnih halucinacija. Nosivi uređaji za praćenje psihijatrijskih simptoma

Nosivi uređaji za praćenje psihijatrijskih simptoma

Nosivi uređaji, poput Apple Watch-a i Fitbita, koriste UI za kontinuirano praćenje fizioloških i biheviornalnih parametara, uključujući otkucaje srca, obrasce spavanja i tjelesnu aktivnost. Ovi uređaji mogu detektirati pogoršanje simptoma kod depresije i bipolarnog poremećaja. Istraživanje Hickey i suradnika (2021) pokazala je da nosivi uređaji mogu predvidjeti manične epizode s preciznošću od 85% analizom fizioloških podataka. Sustav Biofourmis koristi fiziološke signale kako bi upozorio kliničare na rane znakove akutnih epizoda, dok Mindstrong analizira obrasce korištenja pametnih telefona za praćenje promjena u mentalnom zdravlju korisnika (Mohr i sur., 2017).

Virtualna stvarnost u liječenju anksioznih poremećaja i PTSP-a

Virtualna stvarnost (engl. *Virtual Reality* – VR) predstavlja računalno generiranu simulaciju trodimenzionalnog okruženja u kojem korisnici mogu interaktivno sudjelovati na način koji se doima kao stvaran. Trenutni standardni VR sustavi koriste ili VR naočale s ekranom montiranim na glavi korisnika ili prostore sa višestrukim projekcijama kako bi stvorili realistične slike, zvukove i druge senzacije u virtualnom okruženju. Konkretno, VR je fenomen u kojem su korisnici “uronjeni” u računalno generirani svijet putem sučelja između čovjeka i računala, pri čemu korisnici mogu “prirodno” komunicirati s virtualnim značajkama ili objektima (Schultheis i Rizzo, 2001). Ova vrsta terapije postaje standardni alat u liječenju anksioznih poremećaja, fobija i posttraumatskog stresnog

poremećaja (PTSP). Integracijom UI-a u VR sustave moguće je prilagoditi simulacije individualnim potrebama pacijenata, omogućujući sigurno i kontrolirano izlaganje traumatskim podražajima. Primjerice, platforma Limbix koristi VR za liječenje socijalne anksioznosti simulirajući društvene situacije koje izazivaju nelagodu i stres, dok UI analizira reakcije pacijenta i postupno prilagođava intenzitet podražaja (Emmelkamp i sur., 2021). Istraživanje Rizzo i suradnika (2014) pokazalo je da terapija VR dovodi do redukcije simptome PTSP-a kod ratnih veterana za 50% nakon osam tjedana terapije. Jedinstven pristup VR-a s primjenom UI-a omogućuje ne samo desenzitizaciju, već i dublje razumijevanje emocionalnih reakcija pacijenata kroz analizu podataka o njihovom ponašanju tijekom tretmana.

Chatbotovi i digitalni asistenti za terapijsku podršku

Chatbotovi poput Woebot i Wysa postaju korisni alati u podršci mentalnom zdravlju, pružajući pristupačne terapijske intervencije. Fitzpatrick i suradnici (2017) u randomiziranom kontroliranom ispitivanju pokazali su da je Woebot smanjio simptome depresije za 22% nakon dva tjedna korištenja kod mladih odraslih s blagim do umjerenim simptomima depresije. Wysa kombinira umjetnu inteligenciju s tehnikama meditacije i emocionalne podrške, a istraživanja poput Bending i suradnika (2022) ukazuju na potencijal aplikacije u poboljšanju mentalnog zdravlja kod mlađih generacija. Ovi alati nude kontinuiranu dostupnost, smanjujući pritisak na tradicionalne sustave mentalnog zdravlja.

Neurofeedback terapija podržana UI-om

Neurofeedback terapija koristi UI za analizu električne aktivnosti mozga u stvarnom vremenu, a putem povratnih informacija pacijenti imaju mogućnost učiti i utjecati na aktivnost mozga i svoje emocionalno stanje. Ova metoda posebno je korisna kod poremećaja pažnje (ADHD), anksioznosti i poremećaja spavanja. Istraživanje Mitsea i suradnika (2024) pokazalo je da neurofeedback može smanjiti simptome anksioznosti za 30–50% nakon osam do deset terapijskih primjena. UI algoritmi, poput onih implementiranih u sustavu Neuroptimal, omogućuju precizno praćenje i prilagodbu terapijskih protokola svakoj osobi, smanjujući potrebu za dugotrajnim tretmanima (Rogala i sur., 2016). Primjena UI-a u liječenju psihijatrijskih poremećaja brzo se razvija, a budućnost obećava još homogeniju integraciju s nosivim uređajima, genetičkim analizama i telemedicinskim platformama. Razvoj objašnjivih algoritama (engl. *Explainable Artificial Intelligence* – XAI) pomoći će kliničarima bolje razumjeti odluke koje UI sustavi donose, povećavajući njihovo povjerenje u nove tehnologije. Primjeri budućih inovacija uključuju: CompanionMX aplikacija koja koristi govorne podatke za detekciju promjena u mentalnom zdravlju poblje emocionalnom stanju korisnika. Istraživanje Miner i suradnika (2016) pokazalo je da algoritmi u aplikaciji mogu detektirati promjene u emocionalnom tonu govora, predviđajući pogoršanje simptoma depresije i anksioznosti s preciznošću od 75%. Daljnji razvoj terapijskih metoda poput Avatar Therapy i VS

otvara put prema hibridnim modelima koji kombiniraju digitalne alate i tradicionalne metode, osiguravajući optimalne ishode za pacijente. Istraživanje Alaa i suradnika (2022), obuhvatilo 15 sustavnih pregleda sa 852 bibliografska podatka koji analiziraju primjenu UI u dijagnosticiranju bolesti/poremećaja poput: Alzheimerove bolesti, shizofrenije, bipolarnog poremećaja i PTSP-a. Rezultati ukazuju na širok raspon točnosti, od 21% do 100%, prepoznavanju specifičnih simptoma bolesti modelima UI što ukazuje na značajan potencijal primjene ovih tehnologija ranom otkrivanju i liječenju bolesti uz naglasak na nužnosti provedbe daljnjih istraživanja i meta-analiza koje uključuju depresiju i anksiozne poremećaje kako bi se bolje razumjela učinkovitost UI u širem kontekstu. UI značajno unapređuje liječenje psihijatrijskih poremećaja, pružajući kliničarima i pacijentima inovativne i učinkovite alate. Sustavi poput Avatar Therapy, različitih vrsta nosivih uređaja, platforme virtualne stvarnosti i chatbotovi dokazuju da UI može imati utjecaj na individualiziranje terapijskog odabira i poboljšati kvalitetu života pacijenata. Nastavak razvoja tehnologija, u kombinaciji s regulativnim prilagodbama i edukacijom kliničara, osigurat će još veću integraciju UI-a u psihijatrijsku praksu.

7. Prednosti i ograničenja umjetne inteligencije u psihijatrijskoj skrbi

Prednosti primjene UI-a u psihijatrijskoj skrbi

Jedna od najvažnijih prednosti primjene umjetne inteligencije (UI) u psihijatriji jest njezina sposobnost analize kompleksnih skupova podataka i prepoznavanja obrazaca koji ne mogu biti primijećeni od kliničara. Ove karakteristike omogućuju inovativne pristupe liječenju, povećavajući učinkovitost terapija i smanjujući vremenski okvir potreban za postizanje terapijskih rezultata.

Virtualna stvarnost kao terapija

Virtualna stvarnost se sve više prepoznaje kao koristan alat u procjeni i liječenju psihijatrijskih stanja, jer nudi uronjeno okruženje koje može simulirati realitetne scenarije. To omogućuje pacijentima da se suoče i interagiraju sa svojim strahovima ili simptomima u kontroliranom okruženju. Ovakva terapija nalazi svoje mjesto u liječenju anksioznih poremećaja, PTSP-a, fobija, psihotičnih poremećaja, pa čak i stanja poput autizma i demencije i to ponajviše putem terapije izlaganja i razvijanju strategija suočavanja bolesnika (Kim i Kim, 2020). Na primjer, u istraživanju Maples-Keller i suradnika (2017), terapije virtualne stvarnosti prilagođene pomoću UI algoritama smanjile su intenzitet flashbackova kod 70% sudionika u šest tjedana primjene terapije. U istraživanju se također ističe da je ovaj terapijski model omogućio sigurno suočavanje s traumatskim podražajima u okruženju koje je kontrolirano, čime je terapija postala učinkovitija. Platforma Bravemind, koju su razvili Institut za kreativne tehnologije Sveučilišta Južne Kalifornije u Sjedinjenim Američkim Državama (engl. *University of*

Southern California Institute for Creative Technologies – USC ICT), koristi UI za prilagodbu intenziteta podražaja temeljenih na fiziološkim odgovorima pacijenta, osiguravajući postupnu desenzitizaciju i optimizaciju terapijskog procesa čime se osigurava poboljšanje dugoročnih terapijski ishodi (Bravemind – VR).

Individualizirano prilagođavanje terapijskih protokola

Jedinstvena sposobnost UI-a da integrira podatke o biomarkerima, povijesti bolesti i genetskim predispozicijama pacijenata ključna je za personalizaciju terapijskih planova. Sustavi koji koriste podatke iz prenosivih uređaja i kliničkih zapisa mogu pomoći u prepoznavanju obrazaca povezanih s pogoršanjem simptoma mentalnih poremećaja. Na primjer, sustavi temeljeni na strojnom učenju pokazali su sposobnost predviđanja relapsa depresije analizom uzoraka spavanja, aktivnosti i promjena raspoloženja (Jacobson i sur., 2019). U farmakoterapiji, sustavi poput GeneSight analiziraju farmakogenetičke podatke kako bi predložili optimalne lijekove za specifične pacijente. Ovi sustavi koriste informacije o genima kao što su CYP2D6 i CYP2C19, koji su ključni za metabolizam lijekova, kako bi preporučili antidepresive, antipsihotike i stabilizatore raspoloženja. Analiza Rosenblatt i suradnika (2017) zaključila je da primjena farmakogenetskog probira može povećati vjerojatnost remisije za 40% kod pacijenata s velikim depresivnim poremećajem. Ovaj sustav pomaže u individualnom prilagođavanju izbora lijeka u liječenju psihijatrijskih poremećaja analizom gena povezanih s metabolizmom i učinkom lijekova poput antidepresiva (skupina selektivnih inhibitora ponovne pohrane serotonina (SSRI): fluoksetin, sertralini; skupina inhibitora ponovne pohrane serotonina i noradrenalina: venlafaksin), antipsihotika (aripiprazol, olanzapin) i stabilizatora raspoloženja (litij, lamotrigin). Osim toga, integracija genetskih podataka s kliničkim informacijama omogućuje preciznije odabire lijekova za poremećaje raspoloženja, uključujući bipolarni poremećaj i shizofreniju. Sustavi temeljeni na UI pomažu u personalizaciji liječenja, osiguravajući bolje ishode za pacijente (Zeier i sur., 2018).

Dostupnost terapijskih mogućnosti i digitalne platforme

Još jedna ključna prednost UI-a u psihijatrijskoj skrbi je povećana dostupnost terapijskih usluga kroz digitalne platforme. Chatbotovi poput Wysa i Replika koriste prirodni jezik (NLP) kako bi pružili podršku korisnicima, posebno u skupini s blagim do umjerenim simptomima depresije i anksioznosti. Istraživanje Beatty i suradnika (2022) pokazala je da je korištenje Wysa chatbot terapije rezultiralo smanjenjem simptoma anksioznosti za 25% nakon četiri tjedna korištenja. Ove platforme smanjuju stigmatu povezanu s traženjem pomoći radi poteškoća mentalnog zdravlja jer omogućuju privatnost i kontinuiranu podršku u stvarnom vremenu. Nadalje, aplikacije koje koriste personalizirane intervencije i svakodnevne podsjetnike dodatno povećavaju angažman korisnika i učinkovitost terapije (Mehta i sur., 2021). Aplikacije poput Sanvello, koje koriste UI za praćenje emocionalnih obrazaca i pružanje personaliziranih planova za mentalnu dobrobit, povećale su angažman korisnika koristeći gamifikaciju i prilagođene preporuke. Pregled Borghouts i

suradnika (2021) istaknuo je da su aplikacije za mentalno zdravlje koje potiču angažman putem personalizacije i svakodnevnih podsjetnika učinkovitije od tradicionalnih metoda samopomoći.

Ograničenja i izazovi u primjeni UI-a u psihijatriji

Iako umjetna inteligencija (UI) donosi napredak u psihijatrijsku kliničku praksu, njena primjena nije bez izazova. Jedan od ključnih problema je pristranost algoritama, koja proizlazi iz neadekvatne zastupljenosti različitih demografskih skupina u podacima za treniranje modela. Obermeyer i suradnici (2019) pokazala je da algoritmi razvijeni na zapadno orijentiranim podacima često imaju nižu točnost u primjeni na populacije iz drugih regija, što može rezultirati dijagnostičkim pogreškama i nejednakim pristupom liječenju. Privatnost i sigurnost podataka također su ključni problemi u primjeni UI-a u psihijatriji. Iako se koriste tehnike anonimizacije i enkripcije, Wahl i suradnici (2020) upozorili su da ni najnapredniji sustavi ne mogu u potpunosti eliminirati rizik od zloupotrebe ili manipulacije podacima. Štoviše, analize velikih skupova podataka ponekad zahtijevaju deanonimizaciju kako bi se osigurala točnost modela, čime se povećava rizik od povrede privatnosti. Dodatno, nedostatak zakonskih i regulatornih okvira za upotrebu UI-a u zdravstvu predstavlja značajan izazov. Morley i suradnici (2020) istaknuli su potrebu za međunarodnim standardima koji bi definirali etičke i pravne okvire za primjenu UI-a u zdravstvenim sustavima. Primjerice, Opća uredba o zaštiti osobnih podataka (engl. *General Data Protection Regulation* – GDPR) u Europskoj uniji zahtijeva objašnjenje odluka koje donose automatizirani sustavi, što je teško ostvariti s postojećim modelima dubokog učenja. Složenost algoritama također predstavlja izazov. Sustavi dubokog učenja često djeluju kao “crne kutije”, čineći njihove odluke teško razumljivima kliničarima. Rudin (2019) naglašava potrebu za razvojem “objašnjive UI” (engl. *Explainable Artificial Intelligence* – XAI) odnosno modela koji kliničarima omogućuju bolje razumijevanje rezultata i povećavaju povjerenje u ove sustave. Rješenja za ove izazove uključuju razvoj raznovrsnijih i standardiziranih skupova podataka kako bi se smanjila pristranost algoritama, ulaganje u edukaciju kliničara o prednostima i ograničenjima UI-a te razvoj objašnjivih modela. Sustavi temeljeni na umjetnoj inteligenciji, poput SFTNet, pokazuju značajan potencijal u analizi mikroekspresija i govora za ranu dijagnostiku depresije. Istraživanje Li i suradnika (2024) utvrdila je da takvi sustavi mogu prepoznati simptome depresije analizom brzine govora i pauza s točnošću od preko 85%. Ovi sustavi olakšavaju kliničarima prepoznavanje emocionalnih stanja, no daljnja istraživanja potrebna su kako bi se osigurala njihova primjenjivost u različitim demografskim i kliničkim okruženjima.

8. Tehnički i etički izazovi primjene umjetne inteligencije u medicini

Primjena umjetne inteligencije (UI) u medicini donosi brojne tehničke i etičke izazove. Glavni problemi uključuju kvalitetu i interoperabilnost podataka, pristranost algoritama, zaštitu privatnosti, transparentnost odlučivanja i zakonsku regulativu. Za odgovornu integraciju UI-a u medicinske sustave potreban je multidisciplinarni pristup.

Standardizacija podataka i interoperabilnost sustava

Kvaliteta i standardizacija medicinskih podataka ključni su tehnički izazovi za implementaciju UI-a. Medicinski podaci često dolaze iz raznovrsnih izvora, poput elektroničkih medicinskih zapisa, genetskih baza i dijagnostičkih slikovnih prikaza, pri čemu razlike u formatima otežavaju njihovu integraciju. Rad Johnson i suradnika (2021) ukazao je da nedostatak standardizacije može smanjiti preciznost UI algoritama za više od 20%. Jedan od vodećih standarda za interoperabilnost je Fast Healthcare Interoperability Resources (FHIR), razvijen od strane HL7 International, koji omogućuje razmjenu strukturiranih informacija između zdravstvenih sustava. FHIR standard ne samo da olakšava interoperabilnost već i potiče primjenu UI tehnologija u kliničkoj praksi. Uvođenje automatiziranih alata za normalizaciju podataka i edukacija zdravstvenih djelatnika o važnosti strukturiranih zapisa ključni su koraci za poboljšanje integracije podataka.

Pristranost algoritama i socijalna nejednakost

Pristranost u algoritmima često proizlazi iz neravnomjerno zastupljenih podataka korištenih za treniranje modela. Primjerice, algoritmi trenirani na podacima zapadnih populacija mogu imati smanjenu preciznost kada se primjenjuju na druge demografske skupine. Studija Obermeyer i suradnika (2019) pokazala je da algoritmi za predviđanje zdravstvenih ishoda u afričko-američkoj populaciji imaju značajno nižu preciznost zbog nedostatka reprezentativnih podataka. Za prevladavanje ovih izazova potrebno je osigurati raznolikost podataka za treniranje modela i implementirati alate za detekciju i ispravljanje moguće pristranosti. Jedan od alata za procjenu pristranosti i osiguranja kritičnosti analizi u modelima je IBM-ov UI Fairness 360 Toolkit, koji nudi širok spektar metoda za smanjenje pristranosti (Bellamy i sur., 2019). Primjena ovakvih alata doprinosi većoj inkluzivnosti i ravnopravnosti u primjeni UI-a u zdravstvu.

Privatnost i sigurnost podataka

Zaštita privatnosti pacijenata ključno je etičko pitanje u primjeni umjetne inteligencije (UI), posebno u osjetljivim područjima poput psihijatrije. Iako se široko koriste metode anonimizacije i enkripcije, rizik od deanonimizacije i povrede privatnosti ostaje prisutan, osobito kod velikih baza podataka. Veale i Binns (2017) pokazali su da modeli

strojnog učenja mogu biti podložni napadima koji iskorištavaju parcijalne informacije za rekonstrukciju osjetljivih podataka. Inovativne tehnologije, poput federativnog učenja, omogućuju treniranje algoritama na decentraliziranim podacima bez potrebe za njihovim dijeljenjem. Ova metoda smanjuje rizik za privatnost, dok i dalje osigurava visoku učinkovitost modela (Kairouz i sur., 2021). Osim toga, diferencijalna privatnost postaje sve popularnija tehnologija zaštite podataka. Ova metoda dodaje statistički šum podacima kako bi zaštitila identitet korisnika, što omogućuje sigurno dijeljenje podataka za analize i treniranje modela UI bez ugrožavanja privatnosti pacijenata (Dwork i Roth, 2014).

Transparentnost i složenost algoritama

Algoritmi dubokog učenja često se nazivaju “crnim kutijama” jer je njihovo donošenje odluka teško razumjeti i objasniti. Ova složenost može uzrokovati nepovjerenje među kliničarima i pacijentima te ograničiti širu primjenu UI-a u medicinskoj praksi. Razvoj objašnjivih modela umjetne inteligencije (XAI) predstavlja ključni korak prema povećanju transparentnosti. Jedan od poznatih alata za objašnjavanje odluka modela je LIME (engl. *Local Interpretable Model-Agnostic Explanations* – LIME), koji pruža vizualne interpretacije razumljive kliničarima Ribeiro i suradnici (2016) su pokazali jda je primjena LIME alata povećala povjerenje kliničara u sustave UI-a za 30% u usporedbi s modelima koji ne upotrebljavaju objašnjivu UI. Dodatno, analiza Tjoa i Guan (2021) naglašava da objašnjivi modeli omogućuju identifikaciju pogrešaka u algoritmima, što smanjuje rizik od donošenja netočnih odluka u kliničkoj praksi. Integracija XAI modela pomaže u izgradnji povjerenja i učinkovitijem donošenju odluka u zdravstvenom sektoru.

Zakonodavni izazovi

Razlike u zakonskim okvirima među državama predstavljaju značajan izazov u globalnoj primjeni umjetne inteligencije (UI) u medicini. Europska unija putem Opće uredbe o zaštiti osobnih podataka nameće potrebu za objašnjenjem odluka automatiziranih sustava i osiguranje prava pacijenata na transparentnost. Nasuprot tome, mnoge zemlje nemaju tako stroge zakonske odredbe, što stvara neravnotežu u razini zaštite podataka i prava pacijenata. Rad Gerke, Minssen i Cohen (2020) naglašava da mnogi medicinski algoritmi ne ispunjavaju potrebne kriterije za odgovornost i transparentnost prema europskim standardima, što ograničava njihovu primjenu na tržištu EU-a. Međunarodna suradnja i harmonizacija zakonskih standarda ključni su koraci prema osiguravanju dosljedne i učinkovite primjene UI-a u zdravstvu. Primjerice, inicijative poput AI4H (engl. *Artificial Intelligence for Health* – AI4H) i smjernice Svjetske zdravstvene organizacije usmjerene su na razvoj globalnih pravnih i etičkih okvira za UI u medicinskoj praksi (Naik i sur., 2022).

Preporuke za prevladavanje izazova

1. Standardizacija podataka i sustava: Razviti globalne protokole za interoperabilnost medicinskih sustava, uz poticanje korištenja decentraliziranih metoda poput federativnog učenja (Kairouz i sur., 2021).
2. Raznolikost i inkluzivnost u bazama podataka: Osigurati zastupljenost različitih demografskih skupina u oblikovanju algoritama kako bi se smanjila pristranost i povećala socio-demografska heterogenost čime se omogućuju adekvatnije i kritičke preporuke modela UI (Obermeyer i sur., 2019).
3. Razvoj objašnjivih modela umjetne inteligencije (XAI): Potaknuti upotrebu tehnologija poput SHAP-a i LIME-a za transparentnost modela (Ribeiro i sur., 2016).
4. Zaštita privatnosti: Primijeniti napredne tehnologije poput diferencijalne privatnosti kako bi se osigurala sigurnost podataka (Dwork i Roth, 2014).
5. Edukacija kliničara i korisnika: Organizirati programe edukacije kako bi kliničari bolje razumjeli prednosti, ograničenja i primjenu UI tehnologija, čime bi se smanjile barijere za njihovo prihvaćanje (Wiljer i sur., 2021).

9. Buduće perspektive umjetne inteligencije u psihijatriji

Umjetna inteligencija (UI) pokazuje ogroman potencijal u modificiranju psihijatrijske skrbi i terapijskog pristupa, pružajući time kliničarima napredne alate za razumijevanje, dijagnosticiranje i liječenje složenih poremećaja mentalnog zdravlja. Trenutne implementacije već unapređuju kliničku praksu kroz precizniju dijagnostiku i inovativne terapijske pristupe. Budućnost UI-a u psihijatriji obećava daljnju personalizaciju liječenja, širu integraciju s telemedicinom i korištenje novih tehnologija za poboljšanje skrbi za pacijente. Napredni algoritmi omogućit će objedinjavanje različitih izvora podataka, uključujući genetičke informacije, rezultate neuroimaginga i obrasce ponašanja, čime će se dijagnostički protokoli dodatno unaprijediti. Primjena prediktivnih modela temeljenih na dubokom učenju može preciznije procijeniti rizik od relapsa kod pacijenata sa depresijom (Olawade i sur., 2024). Generativni UI alati, poput UI utemeljenih virtualnih terapijskih pomoćnika, dokazano poboljšavaju kliničke ishode i smanjuju opterećenje tradicionalnih sustava mentalnog zdravlja. Habicht i suradnici (2024) izvijestili su da implementacija AI potpomognutih terapija unutar nacionalnog zdravstvenog sustava u Velikoj Britaniji rezultira većim angažmanom pacijenata i bržim oporavkom. Ove tehnologije nude nove mogućnosti prilagodbe terapijskih sadržaja u stvarnom vremenu, kao i predikciju terapijskih ishoda. Thieme i suradnici (2023) ističu važnost humanocentričnog pristupa u dizajnu UI sustava kako bi se povećalo povjerenje pacijenata i kliničara.

Tehnološke inovacije u službi mentalnog zdravlja

Digitalni asistenti: Sustavi temeljeni na UI-u, poput chatbot-ova, se sve češće koriste u terapijske svrhe, za pružanje emocionalne podrške i praćenje simptoma pacijenata. Inkster i suradnici (2023) su pokazali da uporaba UI aplikacija može smanjiti simptome anksioznosti i depresije za 30% kod korisnika s ograničenim pristupom tradicionalnim terapijama. Ovi asistenti olakšavaju kontinuitet skrbi, osobito kod mlađih korisnika i onih koji preferiraju anonimnost. Dodatno, digitalni asistenti mogu poslužiti kao alat za ranu detekciju simptoma i personalizirane preporuke terapijskih intervencija.

Proširena stvarnost (engl. *Augmented Reality* – AR): Tehnologija proširene stvarnosti (AR) u kombinaciji s umjetnom inteligencijom omogućuje stvaranje kontroliranih simuliranih okruženja koja se koriste u terapiji izlaganjem. Ova metoda posebno je korisna za liječenje socijalne anksioznosti i fobija. Istraživanje Bouchard i suradnika (2017) pokazala je da je terapija virtualnom stvarnošću (VR) i proširenom stvarnošću (AR) jednako učinkovita kao i in vivo izlaganje za liječenje socijalne anksioznosti, pružajući pacijentima značajno smanjenje simptoma nakon tretmana. Osim što omogućuje terapiju u sigurnom i kontroliranom okruženju, AR smanjuje potrebu za fizičkim prisustvom u kliničkim ustanovama, omogućujući pacijentima da terapiju provode u vlastitom domu pod nadzorom terapeuta.

Napredna analiza neuroslikovnih podataka

Primjena umjetne inteligencije (UI) u analizi funkcionalne magnetske rezonance (fMRI) značajno unapređuje dijagnostiku i razumijevanje mentalnih poremećaja. Bzdok i Meyer-Lindenberg (2018) naglasili su potencijal strojnog učenja za identifikaciju biomarkera koji ukazuju na specifične obrasce moždane aktivnosti povezane s depresijom, anksioznošću i shizofrenijom. Ovi algoritmi omogućuju personalizirane terapijske pristupe i precizniju dijagnostiku, pružajući kliničarima alate za bolje razumijevanje odgovora pacijenata na terapiju. Primjena ovih metoda također pomaže u predikciji dugoročnih ishoda liječenja, što je ključno za kronične mentalne poremećaje.

Integracija UI-a s telemedicinom

Telemedicina je značajno unaprijedila dostupnost zdravstvene skrbi, osobito u udaljenim i nerazvijenim područjima. Integracija umjetne inteligencije (UI) s telemedicinskim platformama omogućuje praćenje pacijenata u stvarnom vremenu analizom verbalne ekspresije, mimike lica i fizioloških znakova. Prema sustavnom pregledu Low i suradnika (2020), tehnologije temeljene na govoru i analizi izraza lica pokazuju visok potencijal za prepoznavanje i praćenje mentalnih poremećaja poput depresije i anksioznosti. Njihovo istraživanje je istaknula kako kombinacija automatskog prepoznavanja govora i analize facijalnih ekspresija povećava točnost dijagnostike i omogućuje pravovremene intervencije. Ovi sustavi omogućuju kliničarima uvid u rane promjene mentalnog stanja pacijenata, pružajući priliku za personalizirane terapijske intervencije i prevenciju pogoršanja simptoma.

Etičke prilagodbe i mogućnosti sveobuhvatne implementacije

Univerzalna primjena umjetne inteligencije (UI) u medicini i drugim sektorima suočava se s nizom izazova. Raznolikost podataka i pristranost algoritama smanjuju točnost i primjenjivost UI-a na različite populacije. Razvoj tehnika za smanjenje pristranosti, poput algoritama za fer učenje, ključan je za osiguranje univerzalne primjenjivosti (Obermeyer i sur., 2019). Primjena globalnih standarda za zaštitu podataka i transparentnost algoritama bit će od presudne važnosti za odgovornu implementaciju UI-a. Jednako tako je važan i napredak suradnja između znanstvenika, zakonodavnih tijela i industrije. Primjer se nalazi u inicijativi „Partnership on AI“ (2023), koja uključuje vodeće tehnološke kompanije i akademske institucije u razvoju smjernica za etičku primjenu umjetne inteligencije u kliničkoj praksi.

10. Može li umjetna inteligencija zamijeniti psihijatra?

Ovo pitanje (jedno je od najkontroverznijih u suvremenoj raspravi o digitalizaciji mentalnog zdravlja ili medicine općenito. Umjetna inteligencija (UI) sve se više koristi kao podrška kliničarima u psihijatriji, omogućujući naprednu analizu složenih podataka i personalizaciju terapijskih pristupa. Algoritmi dubokog učenja, poput onih koji se koriste za analizu prirodnog jezika i neuroloških simptoma, pokazali su značajan potencijal u prepoznavanju ranih znakova depresije, anksioznosti i suicidalnih sklonosti. Na primjer, pregled Le Glaza i suradnika (2021) ističe kako algoritmi za analizu govora i teksta pomažu u otkrivanju depresivnih stanja s visokim stupnjem točnosti. Sustavi za praćenje fizioloških parametara, poput nosivih uređaja i aplikacija temeljenih na UI-u, omogućuju kliničarima donošenje pravovremenih odluka, što je ključno u slučajevima visokog rizika. Unatoč velikom napretku, primjena UI-a u psihijatriji nailazi na važna ograničenja. Ključni element terapijskog procesa, empatija, ostaje nezamjenjiv i trenutno ne može biti repliciran tehnologijom. Složenost ljudskih emocija i interpersonalne dinamike također su izazovi za UI sustave, koji su najučinkovitiji u zadacima poput praćenja simptoma i prediktivne analize, dok intervencije koje zahtijevaju intuitivno razumijevanje i neposrednu ljudsku interakciju i dalje ovise o terapeutima. Pregled Rivera i suradnika (2022) naglašava potrebu za objašnjivim modelima UI koji kliničarima omogućuju bolje razumijevanje rezultata algoritama i transparentnije donošenje odluka. Etički izazovi i pristranost algoritama također su značajni problemi u integraciji UI-a u psihijatriju. Algoritmi se često temelje na podacima koji mogu sadržavati pristranosti, što može rezultirati nejednakim terapijskim preporukama, osobito za demografski slabije zastupljene skupine. Rad Liu i suradnika (2020) analizira izazove u integraciji UI-a, uključujući probleme vezane uz točnost modela za različite demografske skupine. Zaštita privatnosti pacijenata i transparentnost u donošenju odluka također su ključni aspekti etičke primjene UI-a. Na primjer, europska Opća odredba o zaštiti osobnih podataka zahtijeva objašnjenje automatiziranih odluka, čime se povećava odgovornost, ali se istovremeno postavlja

tehnički izazovi za složene sustave dubokog učenja. Unatoč izazovima, integracija UI-a u psihijatriju predstavlja značajan napredak u personaliziranoj skrbi. Primjeri poput Woebota, aplikacije za digitalnu terapiju temeljenih na UI-u, pokazuju učinkovitost u smanjenju simptoma depresije i anksioznosti za 30% kod korisnika s ograničenim pristupom tradicionalnim terapijama, prema Inkster i suradnika (2023). Kombinacijom tehnoloških mogućnosti UI-a s ljudskom empatijom i intuicijom, klinička praksa može se dodatno obogatiti, pružajući pacijentima personaliziranu i pravovremenu skrb. Ovaj pristup ukazuje na budućnost u kojoj tehnologija neće zamijeniti terapeute, već će postati nezamjenjiv partner u poboljšanju kvalitete skrbi za mentalno zdravlje.

11. Zaključak

Umjetna inteligencija (UI) postaje jedan od ključnih alata u transformaciji medicine, osobito u području psihijatrije, gdje doprinosi ranom otkrivanju simptoma, personalizaciji terapijskih pristupa i razvoju digitalnih platformi za poboljšanje dostupnosti i učinkovitosti skrbi. Analizom velikih i kompleksnih skupova podataka, UI omogućuje prepoznavanje obrazaca koji često izmiču tradicionalnim metodama, pridonoseći boljoj dijagnostici, liječenju i razumijevanju mentalnog zdravlja. Unatoč značajnim prednostima, izazovi poput pristranosti u algoritmima, zaštite privatnosti i transparentnosti ostaju ključna pitanja koja zahtijevaju sustavno rješavanje. Odgovorna implementacija UI-a zahtijeva standardizaciju podataka, razvoj objašnjivih modela i jasno definirane etičke norme kako bi se osigurala pravedna i sigurna primjena tehnologije. Multidisciplinarna suradnja između kliničara, istraživača i zakonodavaca bit će presudna za izgradnju povjerenja u tehnologiju i prevladavanje prepreka. Edukacija zdravstvenih djelatnika o mogućnostima i ograničenjima UI-a ključno je za učinkovitu integraciju ove tehnologije u svakodnevnu praksu. U konačnici, umjetna inteligencija ima potencijal revolucionarno unaprijediti skrb za mentalno zdravlje, omogućujući personalizirane, podatkovno utemeljene pristupe koji kombiniraju tehnološku preciznost s ljudskom empatijom. Pravilno vođena implementacija osigurat će da koristi ove tehnologije daleko nadmaše potencijalne rizike, postavljajući temelje za inkluzivniju, učinkovitiju i inovativniju psihijatrijsku skrb budućnosti.

Literatura

Abd-Alrazaq, A., Alhuwail, D., Schneider, J., Toro, C. T., Ahmed, A., Alzubaidi, M., Alajlani, M., Househ, M. (2022). The performance of artificial intelligence-driven technologies in diagnosing mental disorders: an umbrella review. *NPJ digital medicine*, 5(1), 87. <https://doi.org/10.1038/s41746-022-00631-8>

- Alami, H., Rivard, L., Lehoux, P., Hoffman, S. J., Cadeddu, S. B. M., Savoldelli, M. i sur., (2020). Artificial intelligence in health care: Laying the foundation for responsible, sustainable, and inclusive innovation in low- and middle-income countries. *Global Health*, 16, 52. <https://doi.org/10.1186/s12992-020-00584-1>
- Althoff, T., Clark, K., i Leskovec, J. (2016). Large-scale analysis of counseling conversations: An application of natural language processing to mental health. *Transactions of the Association for Computational Linguistics*, 4, 463–476.
- Aslam, N., Khan, I. U., Bashamakh, A. i sur. (2022). Multiple sclerosis diagnosis using machine learning and deep learning: Challenges and opportunities. *Sensors (Basel)*, 22, 7856. <https://doi.org/10.3390/s22207856>
- Avanzo, M., Stancanella, J., Pirrone, G., Drigo, A., i Retico, A. (2024). The Evolution of Artificial Intelligence in Medical Imaging: From Computer Science to Machine and Deep Learning. *Cancers*, 16(21), 3702. <https://doi.org/10.3390/cancers16213702>
- Bakker, D., Kazantzis, N., Rickwood, D., Rickard, N. (2016). Mental health smartphone apps: Review and evidence-based recommendations for future developments. *JMIR Mental Health*, 3(1), e7. <https://doi.org/10.2196/mental.4984>
- Beatty, C., Malik, T., Meheli, S., Sinha, C. (2022). Evaluating the therapeutic alliance with a free-text CBT conversational agent (Wysa): A mixed-methods study. *Frontiers in Digital Health*, 4, 847991. <https://doi.org/10.3389/fdgth.2022.847991>
- Bellamy, R. K. E., Dey, K. i Hind, M. (2019). AI Fairness 360: An extensible toolkit for detecting, understanding, and mitigating unwanted algorithmic bias. *IBM Journal of Research and Development*, 63(4/5), 4-1. <https://aif360.mybluemix.net/>
- Bendig, E., Erb, B., Schulze-Thuesing, L., Baumeister, H. (2022). The next generation: Chatbots in clinical psychology and psychotherapy to foster mental health—A scoping review. *Verhaltenstherapie*, 32(Suppl 1), 64–76. <https://doi.org/10.1159/000501812>
- Bind, S., Tiwari, A.K., i Sahani, A.K. (2015). A survey of machine learning based approaches for Parkinson disease prediction. *International Journal of Computer Science and Information Technology*, 6(3), 1648–1655.
- Bobo, W. V., Van Ommeren, B., i Athreya, A. P. (2022). Machine learning, pharmacogenomics, and clinical psychiatry: Predicting antidepressant response in patients with major depressive disorder. *Expert Review of Clinical Pharmacology*, 15(8), 927–944. <https://doi.org/10.1080/17512433.2022.2112949>
- Borghouts, J., Eikev, E., Mark, G., De Leon, C., Schueller, S. M., Schneider, M., Stadnick, N., Zheng, K., Mukamel, D., Sorkin, D. H. (2021). Barriers to and Facilitators of User Engagement With Digital Mental Health Interventions: Systematic Review. *Journal of medical Internet research*, 23(3), e24387. <https://doi.org/10.2196/24387>



- Bouchard, S., Dumoulin, S., Robillard, G. (2017). Virtual reality compared with in vivo exposure in the treatment of social anxiety disorder: A three-arm randomised controlled trial. *The British Journal of Psychiatry*, 210(4), 276–283. <https://doi.org/10.1192/bjp.bp.116.184234>
- Bravemind – VR. (05. studenog 2024). Preuzeto s <https://medvr.ict.usc.edu/projects/bravemind.html>
- Briganti, G., Le Moine, O. (2020). Artificial intelligence in medicine: Today and tomorrow. *Frontiers in Medicine*, 7, 27. <https://doi.org/10.3389/fmed.2020.00027>
- Bzdok, D., Meyer-Lindenberg, A. (2018). Machine learning for precision psychiatry: Opportunities and challenges. *Biological Psychiatry: Cognitive Neuroscience and Neuroimaging*, 3(3), 223–230. <https://doi.org/10.1016/j.bpsc.2017.11.007>
- Badrulhisham, F., Pogatzki-Zahn, E., Segelcke, D., Spisak, T., i Vollert, J. (2024). Machine learning and artificial intelligence in neuroscience: A primer for researchers. *Brain Behavior and Immunity*, 115, 470–479. <https://doi.org/10.1016/j.bbi.2023.11.005>
- Craig, T. K. J., Rus-Calafell, M., Ward, T., Leff, J. P., Huckvale, M. A., Howarth, E., Garety, P. A. (2018). AVATAR therapy for auditory verbal hallucinations in people with psychosis: A single-blind, randomised controlled trial. *The Lancet Psychiatry*, 5(1), 31–40. <https://doi.org/10.1016/j.schres.2017.05.042>
- Dixit, S., Bohre, K., Singh, Y., Himeur, Y., Mansoor, W., Atalla, S., i Srinivasan, K. (2023). A Comprehensive Review on AI-Enabled Models for Parkinson's Disease Diagnosis. *Electronics*, 12(4), 783. <https://doi.org/10.3390/electronics12040783>
- Doshi-Velez, F., Kim, B. (2017). Towards a rigorous science of interpretable machine learning. *arXiv preprint arXiv:1702.08608*. <https://arxiv.org/abs/1702.08608>
- Dwork, C., Roth, A. (2014). The algorithmic foundations of differential privacy. *Foundations and Trends® in Theoretical Computer Science*, 9(3–4), 211–407. <https://doi.org/10.1561/04000000042>
- Emmelkamp, P. M. G., Meyerbröcker, K., Morina, N. (2020). Virtual Reality Therapy in Social Anxiety Disorder. *Current psychiatry reports*, 22(7), 32. <https://doi.org/10.1007/s11920-020-01156-1>
- Erguzel, T. T., Tarhan, N. (2018). Machine learning approaches to predict repetitive transcranial magnetic stimulation treatment response in major depressive disorder. In *Proceedings of SAI Intelligent Systems Conference (IntelliSys) 2016: Volume 2* (pp. 391–401). Springer International Publishing.

Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., i Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115–118. <https://doi.org/10.1038/nature21056>

Fitzpatrick, K. K., Darcy, A., i Vierhile, M. (2017). Delivering cognitive behavior therapy to young adults with symptoms of depression and anxiety using a fully automated conversational agent (Woebot): A randomized controlled trial. *JMIR Mental Health*, 4(2), e19. <https://doi.org/10.2196/mental.7785>.

Freeman, D., Waite, F., Startup, H., Myers, E., Lister, R. (2022). The impact of virtual reality-based therapies for psychosis: Randomised controlled trials. *Journal of Affective Disorders*, 309, 246–256. <https://doi.org/10.1016/j.jad.2022.01.046>

Galatzer-Levy, I. R., i Onnela, J. P. (2023). Machine Learning and the Digital Measurement of Psychological Health. *Annual Review of Clinical Psychology*, 19, 133–154. <https://doi.org/10.1146/annurev-clinpsy-080921-073212>

Garcia-Ceja, E., Riegler, M., Nordgreen, T., Jakobsen, P., Oedegaard, K. J., i Tørresen, J. (2018). Mental health monitoring with multimodal sensing and machine learning: A survey. *Pervasive and Mobile Computing*, 51, 1–26. <https://doi.org/10.1016/j.pmcj.2018.09.003>

Gashkarimov, V. R., Sultanova, R. I., Efremov, I. S., i Asadullin, A. R. (2023). Machine learning techniques in diagnostics and prediction of the clinical features of schizophrenia: A narrative review. *Consort Psychiatr*, 4(3), 43–53. <https://doi.org/10.17816/CP11030>

GBD 2017 Disease and Injury Incidence and Prevalence Collaborators. (2018). Global, regional, and national incidence, prevalence, and years lived with disability for 354 diseases and injuries for 195 countries and territories, 1990–2017: A systematic analysis for the Global Burden of Disease Study 2017. *The Lancet*, 392(10159), 1789–1858. [https://doi.org/10.1016/S0140-6736\(18\)32279-7](https://doi.org/10.1016/S0140-6736(18)32279-7)

Gerke, S., Minssen, T., Cohen, G. (2020). Ethical and legal challenges of artificial intelligence-driven healthcare. In *Artificial Intelligence in Healthcare* (pp. 295–336). Elsevier. <https://www.sciencedirect.com/science/article/pii/B9780128184387000125>

Gross, M. C., Kaushanskaya, M. (2020). Cognitive and linguistic predictors of language control in bilingual children. *Frontiers in Psychology*, 11, 968. <https://doi.org/10.3389/fpsyg.2020.00968>

Habicht, J., Dina, L. M., Stylianou, M., Harper, R., Hauser, T. U., Rollwage, M. (2024). Generative AI-Enabled Therapy Support Tool Improves Clinical Outcomes and Patient Engagement in NHS Talking Therapies. <https://doi.org/10.31234/osf.io/mj46k>



- Halcox, J. P. J., Wareham, K., Cardew, A., Gilmore, M., Barry, J. P., Phillips, C., et al. (2017). Assessment of remote heart rhythm sampling using the AliveCor heart monitor to screen for atrial fibrillation: The REHEARSE-AF study. *Circulation*, 136(18), 1784–1794. <https://doi.org/10.1161/CIRCULATIONAHA.117.030583>
- He, K., Gan, C., Li, Z., Rekik, I., Yin, Z., Ji, W., Gao, Y., Wang, Q., Zhang, J., Shen, D. (2023). Transformers in medical image analysis. *Intelligent Medicine*, 3, 59–78.
- Hickey, B. A., Chalmers, T., Newton, P., Lin, C. T., Sibbritt, D. (2021). Smart devices and wearable technologies to detect and monitor mental health conditions and stress: A systematic review. *Sensors*, 21(10), 3461. <https://doi.org/10.3390/s21103461>
- Hirani, R., Noruzi, K., Khuram, H., Hussaini, A. S., Aifuwa, E. I., Ely, K. E., Lewis, J. M., Gabr, A. E., Smiley, A., Tiwari, R. K., i Etienne, M. (2024). Artificial Intelligence and Healthcare: A Journey through History, Present Innovations, and Future Possibilities. *Life*, 14(5), 557.
- HL7 International. (2022). Fast Healthcare Interoperability Resources (FHIR). Preuzeto s (05.studenii 2024). Preuzeto s <https://www.hl7.org/fhir/overview.html>
- Hosny, A., Parmar, C., Quackenbush, J., Schwartz, L. H., Aerts, H. J. W. L. (2018). Artificial intelligence in radiology. *Nature Reviews Cancer*, 18(8), 500–510. <https://doi.org/10.1038/s41568-018-0016-5>.
- Inkster, B., Kadaba, M., Subramanian, V. (2023). Understanding the impact of an AI-enabled conversational agent mobile app on users' mental health and wellbeing. *Frontiers in Global Women's Health*, 4(1), 15–27. <https://doi.org/10.3389/fgwh.2023.1084302>
- Jacobson, N. C., Weingarden, H., Wilhelm, S. (2019). Digital biomarkers of mood disorders and symptom change. *NPJ digital medicine*, 2, 3. <https://doi.org/10.1038/s41746-019-0078-0>
- Jiang, X., Hu, Z., Wang, S., i Zhang, Y. (2023). Deep learning for medical image-based cancer diagnosis. *Cancers (Basel)*, 15(14), 3608. <https://doi.org/10.3390/cancers15143608>
- Johnson, A. E., Pollard, T. J., Mark, R. G. (2017). Reproducibility in critical care: a mortality prediction case study. In *Machine learning for healthcare conference* (pp. 361–376). PMLR.
- Johnson, K. B., Wei, W. Q., Weeraratne, D., Frisse, M. E., Misulis, K., Rhee, K., Zhao, J., i Snowdon, J. L. (2021). Precision medicine, AI, and the future of personalized health care. *Clinical and Translational Science*, 14(1), 86–93. <https://doi.org/10.1111/cts.12884>
- Kairouz, P., McMahan, H. B., Avent, B., Bellet, A., Bennis, M., Bhagoji, A. N., ... i Zhao, S. (2021). Advances and open problems in federated learning. *Foundations and trends® in machine learning*, 14(1–2), 1–210.

- Kalani, M., Anjankar, A. (2024). Revolutionizing neurology: The role of artificial intelligence in advancing diagnosis and treatment. *Cureus*, 16(6), e61706. <https://doi.org/10.7759/cureus.61706>
- Kautzky, A., Möller, H. J., Dold, M., Bartova, L., Seemüller, F., Laux, G., Riedel, M., Gaebel, W., Kasper, S. (2021). Combining machine learning algorithms for prediction of antidepressant treatment response. *Acta Psychiatrica Scandinavica*, 143(1), 36–49. <https://doi.org/10.1111/acps.13250>
- Khan, I. U., Raiaan, M. A. K., Fatema, K., Azam, S., Rashid, R. u., Mukta, S. H., Jonkman, M., i De Boer, F. (2023). A Computer-Aided Diagnostic System to Identify Diabetic Retinopathy, Utilizing a Modified Compact Convolutional Transformer and Low-Resolution Images to Reduce Computation Time. *Biomedicines*, 11(6), 1566. <https://doi.org/10.3390/biomedicines11061566>
- Khera, R., Haimovich, J., Hurley, N. C., McNamara, R., Spertus, J. A., Desai, N., ... i Krumholz, H. M. (2021). Use of machine learning models to predict death after acute myocardial infarction. *JAMA cardiology*, 6(6), 633–641.
- Kohn, M. S., Sun, J., Knoop, S., Shabo, A., Carmeli, B., Sow, D., Syed-Mahmood, T., Rapp, W. (2014). IBM's health analytics and clinical decision support. *Yearbook of Medical Informatics*, 9(1), 154–162. <https://doi.org/10.15265/IY-2014-0002>
- Kondova, M., Korczynski, O., Müller-Eschner, M., Chan, W., Sanner, A., Othman, A., Brockmann, M. A., i Altmann, S. (2024). Deep learning-based detection and classification of intracranial tumors on magnetic resonance imaging. *Imaging* (published online ahead of print 2024). <https://doi.org/10.1556/1647.2024.00232>
- Krishnan, G., Singh, S., Pathania, M., Gosavi, S., Abhishek, S., Parchani, A., i Dhar, M. (2023). Artificial intelligence in clinical medicine: Catalyzing a sustainable global healthcare paradigm. *Frontiers in Artificial Intelligence*, 6, 1227091. <https://doi.org/10.3389/frai.2023.1227091>
- Le Glaz, A., Haralambous, Y., Kim-Dufor, D. H. i sur., (2021). Machine learning and natural language processing in mental health: Systematic review. *Journal of Medical Internet Research*, 23(5), e15708. <https://doi.org/10.2196/15708>
- Li, X., Yi, X., Ye, J., Zheng, Y., Wang, Q. (2024). SFTNet: A microexpression-based method for depression detection. *Computer methods and programs in biomedicine*, 243, 107923. <https://doi.org/10.1016/j.cmpb.2023.107923>
- Li, Y. H., Li, Y. L., Wei, M. Y., Li, G. Y. (2024). Innovation and challenges of artificial intelligence technology in personalized healthcare. *Scientific Reports*, 14(1), 18994. <https://doi.org/10.1038/s41598-024-70073-7>

- Liu, G. D., Li, Y. C., Zhang, W., Zhang, L. (2020). A brief review of artificial intelligence applications and algorithms for psychiatric disorders. *Engineering*, 6(4), 462-467.
- Low, D. M., Bentley, K. H., Ghosh, S. S. (2020). Automated assessment of psychiatric disorders using speech: A systematic review. *Laryngoscope investigative otolaryngology*, 5(1), 96-116. <https://doi.org/10.1002/lio2.354>
- Luvizutto, G. J., Silva, G. F., Nascimento, M. R., Sousa Santos, K. C., Appelt, P. A., de Moura Neto, E., de Souza, J. T., Wincker, F. C., Miranda, L. A., Hamamoto Filho, P. T. i sur. (2022). Use of artificial intelligence as an instrument of evaluation after stroke: A scoping review based on international classification of functioning, disability and health concept: AI applications for stroke evaluation. *Topical Stroke Rehabilitation*, 29, 331-346. <https://doi.org/10.1080/10749357.2021.1926149>
- Maples-Keller, J. L., Yasinski, C., Manjin, N., i Rothbaum, B. O. (2017). Virtual reality-enhanced extinction of phobias and post-traumatic stress. *Neurotherapeutics*, 14(3), 554-563. <https://doi.org/10.1007/s13311-017-0534-y>
- Mehta, A., Niles, A. N., Vargas, J. H., Marafon, T., Gross, J. J. (2021). Acceptability and effectiveness of artificial intelligence therapy for anxiety and depression (Youper): Longitudinal observational study. *Journal of Medical Internet Research*, 23(6), e26771. <https://doi.org/10.2196/26771>
- Miner, A. S., Milstein, A., Schueller, S., Hegde, R., Mangurian, C., Linos, E. (2016). Smartphone-Based Conversational Agents and Responses to Questions About Mental Health, Interpersonal Violence, and Physical Health. *JAMA internal medicine*, 176(5), 619-625. <https://doi.org/10.1001/jamainternmed.2016.0400>
- Mirjebreili, S. M., Shalbaf, R., Shalbaf, A. (2024). Prediction of treatment response in major depressive disorder using a hybrid of convolutional recurrent deep neural networks and effective connectivity based on EEG signal. *Physical and engineering sciences in medicine*, 47(2), 633-642. <https://doi.org/10.1007/s13246-024-01392-2>
- Mitsea, E., Drigas, A., Skianis, C. (2024). Artificial Intelligence, Immersive Technologies, and Neurotechnologies in Breathing Interventions for Mental and Emotional Health: A Systematic Review. *Electronics*, 13(12), 2253.
- Mohr, D. C., Zhang, M., Schueller, S. M. (2017). Personal sensing: Understanding mental health using ubiquitous sensors and machine learning. *Annual Review of Clinical Psychology*, 13, 23-47. <https://doi.org/10.1146/annurev-clinpsy-032816-044949>
- Morley, J., Floridi, L., Kinsey, L., Elhalal, A. (2020). From What to How: An Initial Review of Publicly Available AI Ethics Tools, Methods and Research to Translate Principles into Practices. *Science and engineering ethics*, 26(4), 2141-2168. <https://doi.org/10.1007/s11948-019-00165-5>

Mukherji, D., Mukherji, M., Mukherji, N., Alzheimer's Disease Neuroimaging Initiative. (2022). Early detection of Alzheimer's disease using neuropsychological tests: A predict-diagnose approach using neural networks. *Brain Informatics*, 9(1), 23. <https://doi.org/10.1186/s40708-022-00169-1>

Murdoch, B. (2021). Privacy and artificial intelligence: Challenges for protecting health information in a new era. *BMC Medical Ethics*, 22, 122. <https://doi.org/10.1186/s12910-021-00687-3>

Mustafa, Z., Nsour, H. (2023). Using Computer Vision Techniques to Automatically Detect Abnormalities in Chest X-rays. *Diagnostics*, 13(18), 2979. <https://doi.org/10.3390/diagnostics13182979>

Naik, N., Hameed, B. M. Z., Shetty, D. K., Swain, D., Shah, M., Paul, R., Sharma, A. (2022). Legal and ethical considerations in artificial intelligence in healthcare: Who takes responsibility? *Frontiers in Surgery*, 9, 862322. <https://www.frontiersin.org/articles/10.3389/fsurg.2022.862322/full>

Naji, Y., Mahdaoui, M., Klevor, R., i Kissani, N. (2023). Artificial Intelligence and Multiple Sclerosis: Up-to-Date Review. *Cureus*, 15(9), e45412. <https://doi.org/10.7759/cureus.45412>

Norori, N., Hu, Q., Aellen, F. M., Faraci, F. D., i Tzovara, A. (2021). Addressing bias in big data and AI for health care: A call for open science. *Patterns (N Y)*, 2(10), 100347. <https://doi.org/10.1016/j.patter.2021.100347>

Obermeyer, Z., Powers, B., Vogeli, C., i Mullainathan, S. (2019). Dissecting racial bias in an algorithm used to manage the health of populations. *Science*, 366(6464), 447-453. <https://doi.org/10.1126/science.aax2342>

Olawade, D. B., Wada, O. Z., Odetayo, A., David-Olawade, A. C., Asaolu, F., Eberhardt, J. (2024). Enhancing mental health with Artificial Intelligence: Current trends and future prospects. *Journal of medicine, surgery, and public health*, 100099.

Partnership on AI. (17. studenog 2024). Developing frameworks for ethical AI applications. Preuzeto s <https://www.partnershiponai.org/>

Riasi, A., Delrobaei, M., Salari, M. (2024). A decision support system based on recurrent neural networks to predict medication dosage for patients with Parkinson's disease. *Scientific Reports*, 14(1), 8424. <https://doi.org/10.1038/s41598-024-59179-0>

Ribeiro, M. T., Singh, S., Guestrin, C. (2016). "Why should i trust you?" Explaining the predictions of any classifier. In *Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining* (pp. 1135-1144).

- Rivera, M. J., Teruel, M. A., Mate, A., Trujillo, J. (2022). Diagnosis and prognosis of mental disorders by means of EEG and deep learning: A systematic mapping study. *Artificial Intelligence Review*. Preprint: https://rua.ua.es/dspace/bitstream/10045/115017/6/Rivera_etal_2022_ArtifIntellRev_preprint.pdf
- Rizzo, A. S., Shilling, R. (2017). Clinical virtual reality tools to advance the prevention, assessment, and treatment of PTSD. *European Journal of Psychotraumatology*, 8(Suppl 5), 1414560. <https://doi.org/10.1080/20008198.2017.1414560>
- Rizzo, A., Hartholt, A., Grimani, M., Leeds, A., Liewer, M. (2014). Virtual reality exposure therapy for combat-related posttraumatic stress disorder. *Computer*, 47(7), 31–37. <https://doi.org/10.1109/MC.2014.199>
- Rogala, J., Jurewicz, K., Paluch, K., Kublik, E., Cetnarski, R., Wróbel, A. (2016). The Do's and Don'ts of Neurofeedback Training: A Review of the Controlled Studies Using Healthy Adults. *Frontiers in human neuroscience*, 10, 301. <https://doi.org/10.3389/fnhum.2016.00301>
- Rosenblat, J. D., Lee, Y., McIntyre, R. S. (2017). Does Pharmacogenomic Testing Improve Clinical Outcomes for Major Depressive Disorder? A Systematic Review of Clinical Trials and Cost-Effectiveness Studies. *The Journal of clinical psychiatry*, 78(6), 720–729. <https://doi.org/10.4088/JCP.15r10583>
- Rudin, C. (2019). Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nature Machine Intelligence*, 1(5), 206–215. <https://doi.org/10.1038/s42256-019-0048-x>
- Schultheis, M. T., Rizzo, A. A. (2001). The application of virtual reality technology in rehabilitation. *Rehabilitation Psychology*, 46(3), 296–311. <https://doi.org/10.1037/0090-5550.46.3.296>
- Senadheera, I., Hettiarachchi, P., Haslam, B., Nawaratne, R., Sheehan, J., Lockwood, K. J., Alahakoon, D., Carey, L. M. (2024). AI applications in adult stroke recovery and rehabilitation: A scoping review using AI. *Sensors (Basel)*, 24(20), 6585. <https://doi.org/10.3390/s24206585>
- Shafi, I., Din, S., Khan, A., Díez, I. T., Casanova, R. D. J. P., Pifarre, K. T., i Ashraf, I. (2022). An effective method for lung cancer diagnosis from CT scan using deep learning-based support vector network. *Cancers (Basel)*, 14(21), 5457. <https://doi.org/10.3390/cancers14215457>
- Sharma, A., Miner, A. S., Atkins, D. C., i Althoff, T. (2020). A computational approach to understanding empathy expressed in text-based mental health support. *arXiv preprint arXiv:2009.08441*.

- Shatte, A. B., Hutchinson, D. M., i Teague, S. J. (2019). Machine learning in mental health: A scoping review of methods and applications. *Psychological Medicine*, 49(9), 1426–1448. <https://doi.org/10.1017/S0033291719000151>
- Shortliffe, E. H. (1977). Mycin: A knowledge-based computer program applied to infectious diseases. In *Proceedings of the Annual Symposium on Computer Application in Medical Care* (p. 66). American Medical Informatics Association.
- Singh, A., Velagala, V. R., Kumar, T., Dutta, R. R., i Sontakke, T. (2023). The application of deep learning to electroencephalograms, magnetic resonance imaging, and implants for the detection of epileptic seizures: A narrative review. *Cureus*, 15(7), e42460. <https://doi.org/10.7759/cureus.42460>.
- Spytska, L. (2024). The use of virtual reality in the treatment of mental disorders such as phobias and post-traumatic stress disorder. *SSM - Mental Health*, 6, 100351. <https://doi.org/10.1016/j.ssmmh.2024.100351>
- Tay, J. L., Htun, K. K., i Sim, K. (2024). Prediction of Clinical Outcomes in Psychotic Disorders Using Artificial Intelligence Methods: A Scoping Review. *Brain Sciences*, 14(9), 878.
- Thieme, A., Hanratty, M., Lyons, M., Palacios, J., Marques, R. F., Morrison, C., Doherty, G. (2023). Designing human-centered AI for mental health: Developing clinically relevant applications for online CBT treatment. *ACM Transactions on Computer-Human Interaction*, 30(2), 1-50.
- Tjoa, E., Guan, C. (2021). A Survey on Explainable Artificial Intelligence (XAI): Toward Medical XAI. *IEEE transactions on neural networks and learning systems*, 32(11), 4793–4813. <https://doi.org/10.1109/TNNLS.2020.3027314>
- Torous, J., Bucci, S., Bell, I. H., Kessing, L. V., Faurholt-Jepsen, M., Whelan, P., Carvalho, A. F., Keshavan, M., Linardon, J., Firth, J. (2021). The growing field of digital psychiatry: current evidence and the future of apps, social media, chatbots, and virtual reality. *World psychiatry : official journal of the World Psychiatric Association (WPA)*, 20(3), 318–335. <https://doi.org/10.1002/wps.20883>
- Truong, N. D., Nguyen, A. D., Kuhlmann, L., Bonyadi, M. R., Yang, J., Ippolito, S. i Kavehei, O. (2018). Convolutional neural networks for seizure prediction using intracranial and scalp electroencephalogram. *Neural Networks*, 105, 104–111. <https://doi.org/10.1016/j.neunet.2018.04.018>.
- Turakhia, M. P., Desai, M., Hedlin, H., Rajmane, A., Talati, N., Ferris, T. i sur. (2019). Rationale and design of a large-scale, app-based study to identify cardiac arrhythmias using a smartwatch: The Apple Heart Study. *American Heart Journal*, 207, 66–75. <https://doi.org/10.1016/j.ahj.2018.09.002>



Tveit, J., Aurlien, H., Plis, S., Calhoun, V. D., Tatum, W. O., Schomer, D. L., i Beniczky, S. (2023). Automated interpretation of clinical electroencephalograms using artificial intelligence. *JAMA neurology*, 80(8), 805-812.

Vatansever, S., Schlessinger, A., Wacker, D., Kaniskan, H. Ü., Jin, J., Zhou, M. M., Zhang, B. (2021). Artificial intelligence and machine learning-aided drug discovery in central nervous system diseases: State-of-the-arts and future directions. *Medical Research Reviews*, 41(3), 1427–1473. <https://doi.org/10.1002/med.21764>

Veale, M., Binns, R. (2017). Fairer machine learning in the real world: Mitigating discrimination without collecting sensitive data. *Big Data & Society*, 4(2). <https://doi.org/10.1177/2053951717743530>

Wahl, B., Cossy-Gantner, A., Germann, S., Schwalbe, N. R. (2018). Artificial intelligence (AI) and global health: how can AI contribute to health in resource-poor settings?. *BMJ global health*, 3(4), e000798. <https://doi.org/10.1136/bmjgh-2018-000798>

Walsh, C. G., Johnson, K. B., Ripperger, M., Sperry, S., Harris, J., Clark, N., ... i Stead, W. W. (2021). Prospective validation of an electronic health record–based, real-time suicide risk model. *JAMA network open*, 4(3), e211428-e211428.

Wang, K., Varma, D. S., i Prosperi, M. (2018). A systematic review of the effectiveness of mobile apps for monitoring and management of mental health symptoms or disorders. *Journal of Psychiatric Research*, 107, 73–8. <https://doi.org/10.1016/j.jpsychires.2018.10.006>

Wiljer, D., Salhia, M., Dolatabadi, E., Dhalla, A., Gillan, C., Al-Mouaswas, D., Jackson, E., Waldorf, J., Mattson, J., Clare, M., Lalani, N., Charow, R., Balakumar, S., Younus, S., Jeyakumar, T., Peteanu, W., Tavares, W. (2021). Accelerating the Appropriate Adoption of Artificial Intelligence in Health Care: Protocol for a Multisteped Approach. *JMIR research protocols*, 10(10), e30940. <https://doi.org/10.2196/30940>

World Health Organization. (2020). World Mental Health Day: An opportunity to kick-start a massive scale-up in investment in mental health. World Health Organization. Preuzeto 11. studenog 2024 s <https://www.who.int/news/item/27-08-2020-world-mental-health-day-an-opportunity-to-kick-start-a-massive-scale-up-in-investment-in-mental-health>

Yadav, N., Pandey, S., Gupta, A., Dudani, P., Gupta, S., i Rangarajan, K. (2023). Data privacy in healthcare: In the era of artificial intelligence. *Indian Dermatology Online Journal*, 14(6), 788–792. https://doi.org/10.4103/idoj.idoj_543_23

Yamashita, R., Nishio, M., Do, R. K., i Togashi, K. (2018). Convolutional neural networks: An overview and application in radiology. *Insights into Imaging*, 9, 611–629. <https://doi.org/10.1007/s13244-018-0639-9>.

Zafar, F., Fakhare Alam, L., Vivas, R. R., Wang, J., Whei, S. J., Mehmood, S., Sadeghzadegan,

A., Lakkimsetti, M., i Nazir, Z. (2024). The role of artificial intelligence in identifying depression and anxiety: A comprehensive literature review. *Cureus*, 16(3), e56472.

Zaharchuk, G., Davidzon, G. (2021). Artificial intelligence for optimization and interpretation of PET/CT and PET/MR images. *Seminars in Nuclear Medicine*, 51(2), 134–142. <https://doi.org/10.1053/j.semnuclmed.2020.10.001>

Zeier, Z., Carpenter, L. L., Kalin, N. H., Rodriguez, C. I., McDonald, W. M., Widge, A. S., Nemeroff, C. B. (2018). Clinical Implementation of Pharmacogenetic Decision Support Tools for Antidepressant Drug Prescribing. *The American journal of psychiatry*, 175(9), 873–886. <https://doi.org/10.1176/appi.ajp.2018.17111282>

The role of artificial intelligence in the treatment of psychiatric disorders

Anamarija PETEK ERİĆ

Clinical Hospital Centre Osijek, Psychiatric Clinic, J. Huttler 4, Osijek, Croatia

Josip Juraj Strossmayer University of Osijek, Faculty of Medicine Osijek, J. Huttler 4, Osijek, Croatia

Josip Juraj Strossmayer University of Osijek, Faculty of Dental Medicine and Health Osijek, Crkvena 21, Osijek, Croatia

ana5ek@gmail.com

Ivan ERİĆ

Clinical Hospital Centre Osijek, Clinic for Surgery, J. Huttler 4, Osijek, Croatia

Josip Juraj Strossmayer University of Osijek, Faculty of Medicine Osijek, J. Huttler 4, Osijek, Croatia

ivaneric982@gmail.com

Sanda ANTON

Clinical Hospital Centre Osijek, Psychiatric Clinic, J. Huttler 4, 31000 Osijek, Croatia

Josip Juraj Strossmayer University of Osijek, Faculty of Medicine Osijek J. Huttler 4, Osijek, Croatia

sanda.anton1@gmail.com

Marina PERKOVIĆ KOVAČEVIĆ

Clinical Hospital Centre Osijek, Psychiatric Clinic, J. Huttlera 4, 31000 Osijek, Croatia

Josip Juraj Strossmayer University of Osijek, Faculty of Medicine Osijek, J. Huttler 4, Osijek, Croatia

marina.perkovic@gmail.com

Abstract:

The advent of Artificial Intelligence (AI) has revolutionized various sectors, including healthcare. In the realm of psychiatry, AI offers promising avenues for enhancing treatment and management strategies for psychiatric disorders. This abstract explores the multifaceted role of AI in psychiatric care and its implementation in clinical settings. AI algorithms excel in processing vast amounts of data and identifying intricate patterns, making them invaluable tools for psychiatric research. Machine learning techniques analyze diverse data sources, ranging from genetic markers and neuroimaging scans to electronic health records and patient-reported outcomes. By integrating these data, AI facilitates the identification of biomarkers, prediction of treatment responses, and personalized interventions tailored to individual patients. One significant application of AI in psychiatry is the development of predictive models for early detection and intervention. These models leverage data from

various sources to identify individuals at risk of developing psychiatric disorders, enabling timely interventions to prevent or mitigate symptom progression. Additionally, AI-based screening tools assist clinicians in accurately diagnosing psychiatric conditions by analyzing speech patterns, facial expressions, and other behavioural cues. Furthermore, AI-driven digital therapeutics offer scalable and accessible interventions for individuals with psychiatric disorders. Virtual reality simulations, chatbots, and smartphone applications provide psychoeducation, cognitive-behavioural therapy (CBT), and mindfulness-based interventions, augmenting traditional treatment modalities. These digital platforms offer continuous support, monitor symptom progression, and adjust interventions in real-time based on user feedback, thereby enhancing treatment adherence and outcomes. In clinical settings, AI-powered decision support systems assist clinicians in treatment planning and medication management. Natural language processing (NLP) algorithms analyze clinical notes and patient data to generate treatment recommendations aligned with evidence-based practices and patient preferences. These decision support systems improve treatment efficacy, minimize adverse effects, and reduce healthcare costs by optimizing resource utilization. Despite its potential benefits, the implementation of AI in psychiatric care presents several challenges. Ethical considerations regarding data privacy, algorithm bias, and patient autonomy require careful attention to ensure the responsible use of AI technologies. Additionally, integrating AI into existing healthcare infrastructures necessitates overcoming technical barriers, ensuring interoperability, and providing adequate training to healthcare professionals. In conclusion, AI holds immense promise for transforming the landscape of psychiatric care by enabling early detection, personalized interventions, and data-driven treatment approaches. By harnessing the power of AI, clinicians can enhance treatment outcomes, improve patient experiences, and advance our understanding of psychiatric disorders. However, successful integration of AI into clinical practice requires addressing ethical, technical, and regulatory challenges to ensure its safe and effective implementation.

Key words: artificial intelligence, psychiatric disorders, treatment strategies, personalized interventions, predictive modeling

Key message of the paper: The integration of AI algorithms enables personalized interventions, early detection, and predictive modeling, transforming and improving psychiatric care through data-driven approaches.