Pregledni rad

PREMA ODGOVORNOJ INTEGRACIJI UMJETNE INTELIGENCIJE U SESTRINSKU PRAKSU: STRUKTURIRANI NARATIVNI PREGLED KLINIČKOG ODLUČIVANJA, SIGURNOSTI I UPRAVLJANJA IMPLEMENTACIJOM

Pietro Giurdanella[1,2], **Alessandro Stievano**[3,4]

[1] Department of Biomedicine and Prevention, PhD School in Nursing Sciences and Public Health, University of Rome "Tor Vergata," Rome, Italy
[2] Interorganizational Department of Technical, Rehabilitation and Prevention Health Professions, Ferrara Local Health Authority and Ferrara University Hospital, Ferrara, Italy
[3] Department of Clinical and Experimental Medicine, University of Messina, Messina, Italy
[4] Centre of Excellence for Nursing Scholarship, OPI Rome, Rome, Italy

Dopisni autor: Pietro Giurdanella pietro.giurdanella@gmail.com

DOI: https://doi.org/10.65241/wh.9.2.25

Za citiranje: Giurdanella P, Stievano A. Prema odgovornoj integraciji umjetne inteligencije u sestrinsku praksu: strukturirani narativni pregled kliničkog odlučivanja, sigurnosti i upravljanja implementacijom. World of Health. 2026:2(9):219-238. https://doi.org/10.65241/wh.9.2.25

Primljeno: 13. srpnja 2026. Recenzirano: 8. listopada 2026. Prihvaćeno: 15. listopada 2026.

SAŽETAK

Pozadina: Umjetna inteligencija može podržati predviđanje rizika, rano prepoznavanje pogoršanja stanja, dokumentiranje i donošenje odluka u kliničkoj skrbi. Međutim, njezino uvođenje u sestrinsku praksu otvara pitanja koja se tiču sigurnosti, kvalitete podataka, autonomije, odgovornosti i upravljanja. Cilj je bio kritički ispitati implikacije umjetne inteligencije na sestrinsku praksu, s posebnim osvrtom na kliničko odlučivanje i prosuđivanje, sigurnost pacijenata, upravljanje implementacijom i vođenje.

Metode: Proveden je strukturirani narativni pregled kroz sustavno pretraživanje recenziranih publikacija na engleskom ili talijanskom jeziku indeksiranih u bazama PubMed/MEDLINE i CINAHL Ultimate te objavljenih od 1. siječnja 2010. do 1. listopada 2026. godine. Odabir studija i procjenu cjelovitog teksta neovisno su provela dva recenzenta. Uključene su primarne studije, pregledni radovi te konceptualni, etički ili upravljački doprinosi razvijeni primjenom eksplicitne metode. Podaci su procijenjeni pomoću alata specifičnih za dizajn studija te integrirani putem narativne sinteze.

Rezultati: Od 121 identificiranog zapisa, 102 su ostala nakon uklanjanja duplikata, a uključene su 44 publikacije: 12 primarnih studija, 27 preglednih radova i pet konceptualnih, etičkih ili upravljačkih doprinosa. Umjetna inteligencija korištena je za sintezu informacija, prepoznavanje obrazaca, predviđanje rizika, generiranje upozorenja i podršku dokumentiranju. Potencijalne koristi ovisile su o kvaliteti podataka, validaciji, integraciji u tijek rada i sposobnosti reagiranja na izlazne rezultate. Razlozi za zabrinutost bili su pristranost prema automatizaciji, lažni alarmi, dekontekstualizirani rezultati, netransparentnost, gubitak vještina, dvosmislena odgovornost i nejednakosti. Dokazi su bili snažniji za profesionalnu percepciju i uvjete implementacije nego za smanjenje neželjenih događaja ili poboljšanje kliničkih ishoda. Ljudski nadzor pokazao se kao međusektorska dimenzija.

Zaključci: Umjetna inteligencija može proširiti informacijske i prediktivne sposobnosti medicinskih sestara, ali ne zamjenjuje profesionalno prosuđivanje. Odgovorna integracija zahtijeva ljudski nadzor, sestrinsko vođenje kroz cijeli životni ciklus tehnologije, praćenje nenamjernih učinaka te procjenu sigurnosti, pravičnosti i ishoda skrbi.

Ključne riječi: umjetna inteligencija, sestrinstvo, kliničko odlučivanje, sigurnost pacijenata, vođenje, kliničko upravljanje.

UVOD

Umjetna inteligencija (UI) zauzima sve važniju ulogu u zdravstvenim sustavima kroz aplikacije sposobne za obradu kliničkih podataka, prepoznavanje obrazaca, generiranje

predviđanja te podršku donošenju odluka i organizacijskim procesima. Ove aplikacije uključuju strojno učenje, duboko učenje, obradu prirodnog jezika, prediktivne modele, sustave za podršku kliničkom odlučivanju te, odnedavno, velike jezične modele i alate generativne umjetne inteligencije. Njihova rutinska uporaba ipak ostaje ovisna o kvaliteti podataka i interoperabilnosti, profesionalnim kompetencijama, regulatornom okviru i sposobnosti organizacija da upravljaju cijelim životnim ciklusom tehnologije (1,2).

SZO prepoznaje potencijal umjetne inteligencije za dijagnostiku, liječenje, istraživanje i javno zdravstvo, ali njezinu upotrebu uvjetuje poštovanjem autonomije, sigurnosti, transparentnosti, odgovornosti, inkluzivnosti i pravičnosti (1). OECD također naglašava potrebu za informacijskim infrastrukturama, interoperabilnošću, profesionalnim kompetencijama, jasnim pravilima i kontinuiranim praćenjem (2). U europskom kontekstu, Uredba (EU) 2024/1689 usvaja pristup razmjeran riziku i daje posebnu važnost ljudskom nadzoru nad visokorizičnim sustavima, uključujući sposobnost prepoznavanja njihovih ograničenja te kritičkog tumačenja, zanemarivanja ili izmjene njihovih izlaznih rezultata (3).

Sestrinska profesija izravno je uključena u ovu transformaciju. Medicinske sestre generiraju i interpretiraju podatke o kliničkoj skrbi, prate promjene u stanju pacijenata te donose odluke u složenim i neizvjesnim situacijama. Prema Međunarodnom vijeću medicinskih sestara, digitalne tehnologije mogu pridonijeti pristupačnoj, učinkovitoj i sigurnoj skrbi kada su integrirane u etičke, pravične, održive i na osobu usmjerene sustave, podržane odgovarajućim kompetencijama te sudjelovanjem medicinskih sestara u transformaciji procesa skrbi (4).

Takvo sudjelovanje ne može biti ograničeno na ulogu krajnjih korisnika. Suradnički odbor za sestrinsko i UI vodstvo identificira razumijevanje odnosa između sestrinskih podataka i UI-ja, uključivanje medicinskih sestara kroz cijeli životni ciklus tehnologije te razvoj aplikacija usklađenih s potrebama ljudi i službi kao profesionalne prioritete (5). Nedovoljna uključenost može potaknuti uvođenje sustava koji su loše usklađeni s tijekovima rada u skrbi i nesposobni adekvatno prikazati složenost sestrinske prakse (5).

Dostupni pregledni radovi opisuju primjenu UI-ja u identifikaciji rizika, procjeni zdravstvenog stanja, klasifikaciji pacijenata, planiranju skrbi i zdravstvenom dokumentiranju. Sustavni pregled 11 studija istaknuo je njegov potencijal za procjenu i pružanje skrbi, dok je istovremeno naglasio potrebu za osiguravanjem valjanosti algoritama, transparentnosti, kontrole pristranosti i jasnog pripisivanja kliničke odgovornosti (6).

Učinci UI-ja ne ovise samo o izvedbi modela nego i o kvaliteti podataka, integraciji u informacijske sustave, upotrebljivosti alata i razumljivosti izlaznih rezultata. Precjenjivanje pouzdanosti algoritama može nepropisno utjecati na odluke i potaknuti pristranost prema automatizaciji (7). Ljudski nadzor stoga zahtijeva sposobnost provjere i kontekstualizacije rezultata, njihovu usporedbu s kliničkom procjenom te odbacivanje ili izmjenu kada je to potrebno. UI može podržati obradu informacija, ali nije ekvivalent kliničkom prosuđivanju koje integrira podatke, longitudinalna opažanja, poznavanje osobe i karakteristike konteksta skrbi (5,1).

Budući da su se postojeći pregledni radovi uglavnom bavili pojedinačnim primjenama, specifičnim tehnologijama ili ograničenim aspektima kliničkog odlučivanja, još uvijek je potrebna integrirana interpretacija odnosa između profesionalnog prosuđivanja, sigurnosti i organizacijskih uvjeta za odgovornu implementaciju (6). Ovaj strukturirani narativni pregled stoga ispituje implikacije umjetne inteligencije na sestrinsku praksu kroz tri međusobno povezana područja: kliničko odlučivanje i prosuđivanje; sigurnost pacijenata; te vođenje, implementaciju i upravljanje. Kvaliteta podataka, sestrinska dokumentacija te etička, pravna i pitanja pravičnosti tretiraju se kao međusektorske dimenzije. Cilj je opisati dostupne dokaze, identificirati suglasnosti, zabrinutosti i nedostatke te razjasniti uvjete pod kojima umjetna inteligencija može podržati sestrinsko prosuđivanje bez ugrožavanja autonomije, profesionalne odgovornosti, pravičnosti i središnjeg mjesta odnosa skrbi.

METODE

DIZAJN PREGLEDA

Proveden je strukturirani narativni pregled utemeljen na sustavnom pretraživanju literature i tematskoj narativnoj sintezi. Analiza je u početku bila organizirana prema tri unaprijed definirana područja: kliničko odlučivanje i prosuđivanje; sigurnost pacijenata; te upravljanje implementacijom i vođenje. Unutar svakog područja identificirane su suglasnosti, razlike, uvjeti primjenjivosti, rizici i nedostatci. Tijekom međupodručne usporedbe nalaza, ljudski nadzor se pokazao kao opetovana dimenzija koja povezuje ova tri područja te je stoga uzet u obzir u interpretativnoj sintezi i raspravi bez da se tretirao kao četvrto unaprijed definirano područje.

S obzirom na heterogenost ovog područja, uključene su tri kategorije publikacija: primarne empirijske studije; pregledi literature; te konceptualni, etički ili upravljački doprinosi razvijeni primjenom eksplicitne metode. Ove tri kategorije držane su odvojeno tijekom ekstrakcije podataka, kritičke procjene i prve faze sinteze kako bi se izbjeglo izjednačavanje empirijskih dokaza, sekundarnih sinteza i konceptualnih prijedloga.

Metodološka kvaliteta i transparentnost izvještavanja rukopisa provjerene su prema primjenjivim stavkama Skale za procjenu narativnih preglednih članaka (SANRA) (8); izvještavanje o pretraživanju i procesu odabira literature uzimalo je u obzir smjernice PRISMA-S (9), odnosno PRISMA 2020 (10).

Dizajn strukturiranog narativnog pregleda odabran je zbog heterogenosti prihvatljivih izvora i interpretativne svrhe sinteze, kojom se nastojalo integrirati empirijske studije, pregledne

radove i konceptualne doprinose bez izrade zbirne procjene učinkovitosti. Korišteni su sustavni postupci pretraživanja, odabira i procjene kako bi se povećale transparentnost i ponovljivost, bez oblikovanja rada kao sustavnog pregleda učinaka.

IZVORI INFORMACIJA I STRATEGIJA PRETRAŽIVANJA

Pretraživanje literature provedeno je 1. listopada 2026. godine u bazama podataka PubMed/MEDLINE i CINAHL Ultimate. Strategije pretraživanja kombinirale su pet konceptualnih komponenti koje se odnose na: umjetnu inteligenciju; sestrinstvo; kliničko odlučivanje ili sestrinsko kliničko prosuđivanje; sigurnost pacijenata; te vođenje, implementaciju ili upravljanje. Sinonimi unutar svake komponente kombinirani su operatorom OR, dok je pet glavnih komponenti međusobno kombinirano operatorom AND. U obzir su uzete publikacije na engleskom ili talijanskom jeziku objavljene od 1. siječnja 2010. do datuma pretraživanja.

Koegzistencija svih pet blokova odabrana je kako bi se identificirale publikacije koje su izravno relevantne za sjecište primjene umjetne inteligencije, sestrinske prakse, odlučivanja, sigurnosti i organizacijskih uvjeta, što je u skladu s usmjerenom prirodom ovog preglednog rada.

Pretraživanjem baze PubMed/MEDLINE identificirano je 57 zapisa, a pretraživanjem baze CINAHL Ultimate 64 zapisa, što čini ukupno 121 zapis prije uklanjanja duplikata. Rezultati su izvezeni u formatima NBIB, odnosno RIS, zadržavajući dostupne sažetke i metapodatke. Izvorni izvozi arhivirani su odvojeno i ostavljeni nepromijenjenima kako bi se osigurala sljedivost procesa pregleda. Cjelovite strategije pretraživanja i pripadajući rezultati prikazani su u dopunskom materijalu.

KRITERIJI PRIHVATLJIVOSTI

Recenzirane publikacije na engleskom ili talijanskom jeziku bile su prihvatljive ako su se u znatnoj mjeri bavile sjecištem umjetne inteligencije, sestrinstva, kliničkog odlučivanja, sigurnosti pacijenata te barem jedne dimenzije iz područja vođenja, implementacije i upravljanja. Relevantnost se smatrala znatnom kada je proizlazila iz ciljeva, metoda, nalaza ili glavne sinteze, a ne samo iz uvodnih ili zaključnih referenci.

Prihvatljive tehnologije bile su one eksplicitno opisane kao UI, strojno učenje, duboko učenje, obrada prirodnog jezika, prediktivni modeli, inteligentni sustavi za podršku odlučivanju ili generativni UI, u bilo kojem kliničkom, organizacijskom ili upravljačkom okruženju. Kontinuirana edukacija i profesionalni razvoj bili su prihvatljivi kada su bili usmjereni na medicinske sestre u praksi te izravno povezani s kliničkom praksom, sigurnošću i implementacijom umjetne inteligencije.

Uključene su primarne kvantitativne, kvalitativne ili mješovite studije; studije razvoja, validacije, implementacije ili evaluacije; narativni, sustavni, pretražni, krovni i integrativni pregledi s meta-analizom ili bez nje; te konceptualne analize s eksplicitnom metodom. Pregledni radovi i konceptualne analize tretirani su kao sekundarni ili konceptualni dokazi, čime se izbjeglo dvostruko brojanje primarnih studija.

Protokoli, uvodnici, komentari, rasprave i stajališta, gledišta, perspektive te drugi doprinosi kojima nedostaju empirijski podaci, prepoznatljiv proces sinteze ili eksplicitna metoda konceptualne analize bili su isključeni. Publikacije s marginalnom relevantnošću za sestrinstvo ili one u kojima se tražene analitičke dimenzije nisu mogle razaznati također su bile isključene.

ODABIR PUBLIKACIJA I KRITIČKA PROCJENA

Rezultati pretraživanja uvezeni su u platformu Rayyan. Od 38 potencijalnih duplikata koje je platforma identificirala, 19 je potvrđeno ručnom provjerom i uklonjeno, čime su preostala 102 jedinstvena zapisa. Dva recenzenta neovisno su pregledala naslove i sažetke koristeći unaprijed definirane kriterije, postigavši stopostotnu suglasnost. Preuzet je i u cjelovitom tekstu procijenjen 54 odabrani izvještaj; 44 publikacije su uključene, a 10 ih je isključeno uz navođenje unaprijed definiranog primarnog razloga.

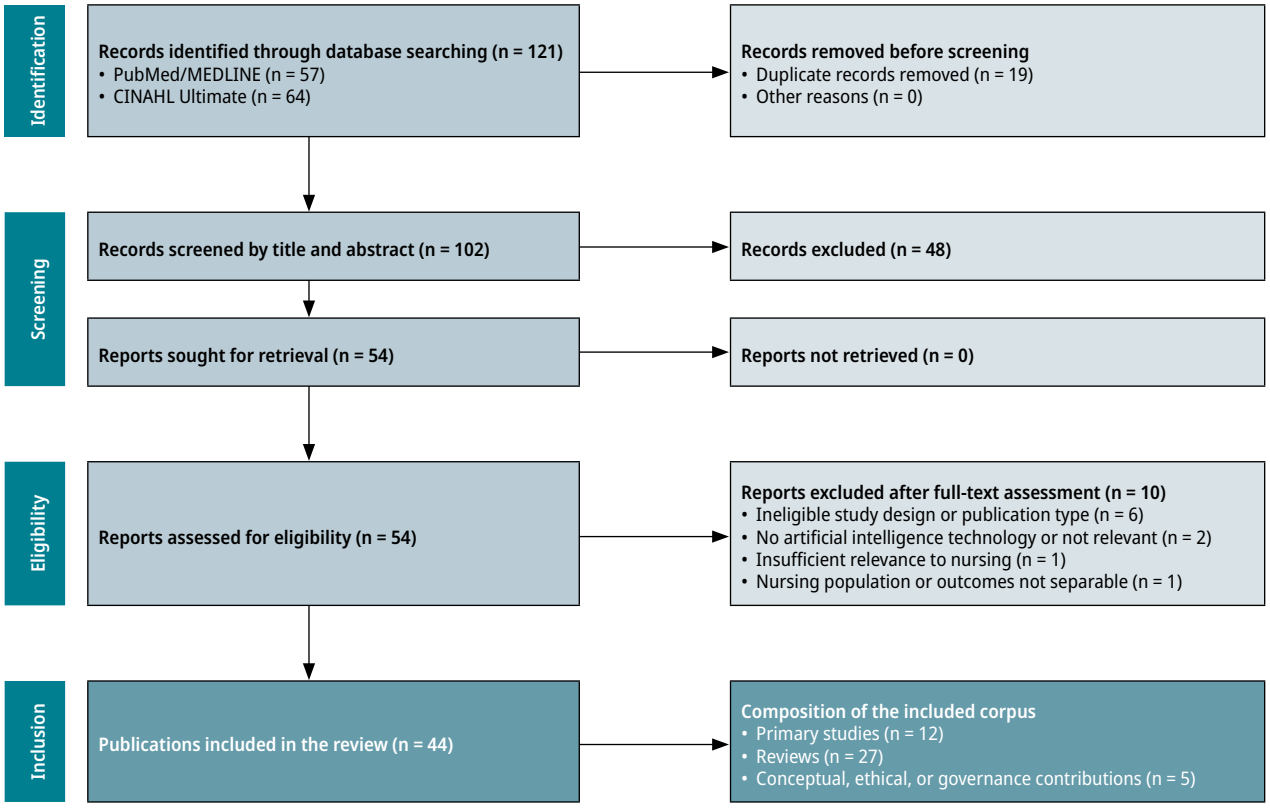
Kritičku procjenu neovisno su provela dva recenzenta, a sva neslaganja riješena su konsenzusom. JBI kontrolne liste (11) korištene su za relevantne primarne studije, SANRA (8) za narativne preglede, a specifični alati za sustavne i pretražne preglede. Konceptualni doprinosi procijenjeni su s obzirom na jasnoću cilja, metodološku transparentnost, unutarnju koherentnost, utemeljenost u izvorima i primjenjivost. Procjena kvalitete nije korištena kao kriterij isključenosti, već za ponderiranje interpretacije izvora.

IZVLAČENJE PODATAKA I NARATIVNA SINTEZA

Podaci su izvučeni pomoću strukturiranog obrasca koji je prethodno testiran na publikacijama reprezentativnima za uključene vrste radova. Prikupljene su bibliografske, metodološke i kontekstualne informacije; karakteristike i funkcije umjetne inteligencije; uloge medicinskih sestara; nalazi te implikacije za kliničko odlučivanje, sigurnost, vođenje, implementaciju i upravljanje. Za pregledne radove i konceptualne doprinose također su zabilježene karakteristike specifične za primijenjenu metodu te analizirani sadržaj.

Provedena je tematska narativna sinteza utemeljena na načelima Popaya i sur. (12). Primarne studije, sinteze literature i konceptualne analize najprije su ispitane odvojeno, a potom su integrirane analizom suglasnosti i razlika kroz različite tehnologije, okruženja i vrste publikacija. Podaci, dokumentacija, etika, pravo i pravičnost tretirani su kao međusektorske dimenzije. Preklapanje između preglednih radova i primarnih studija mapirano je kako bi se izbjeglo dvostruko brojanje dokaza. Interpretacija je uzela u obzir metodološku kvalitetu, dosljednost, relevantnost i sve nesuglasne nalaze.

REZULTATI



Slika 1. Dijagram tijeka procesa odabira publikacija, prilagođen prema modelu PRISMA 2020.

REZULTATI PRETRAŽIVANJA I ODABIRA

Pretraživanjem literature identificiran je ukupno 121 zapis. Na kraju procesa odabira, 44 publikacije ispunile su kriterije prihvatljivosti te su uključene u narativnu sintezu: 12 primarnih studija, 27 preglednih radova i pet konceptualnih, etičkih ili upravljačkih doprinosa. Proces odabira prikazan je na Slici 1.

ZNAČAJKE UKLJUČENIH PUBLIKACIJA

Uključene 44 publikacije obuhvaćale su 12 primarnih studija, 27 pregleda literature i pet konceptualnih, etičkih ili upravljačkih doprinosa razvijenih primjenom eksplicitne metode. Primarne studije uključivale su osam kvalitativnih studija, tri presječne studije i jednu retrospektivnu opservacijsku studiju o stvarnoj primjeni sustava ranog upozoravanja integriranog u elektroničku dokumentaciju. Pregledni radovi obuhvaćali su osam pretražnih pregleda, osam sustavnih ili integrativnih pregleda, osam narativnih ili strukturiranih narativnih pregleda i tri krovna pregleda. Preostalih pet doprinosa uključivalo je upravljačke okvire, modele UI pismenosti ili etičko-normativne analize razvijene primjenom eksplicitne metode.

Korpus je pokazao izraženu heterogenost u tehnologijama i funkcijama. Aplikacije su uključivale prediktivne modele, sustave ranog upozoravanja, alate za podršku kliničkom odlučivanju, automatizirano praćenje, obradu elektroničke dokumentacije, velike jezične modele i generativne sustave. Okruženja su uključivala intenzivnu skrb, onkologiju, mentalno zdravlje, perioperativnu skrb, prevenciju padova i dekubitusa, upravljanje terapijom, obiteljsku skrb i skrb u zajednici te opća klinička okruženja.

Primarne su studije pretežito bile usmjerene na profesionalnu percepciju, stavove, povjerenje, prihvatljivost i spremnost. Samo je ograničeni dio korpusa ispitivao stvarnu primjenu umjetne inteligencije u stvarnim kliničkim tijekovima rada. Pregledni radovi proširili su područje na prediktivne, organizacijske i aplikacije u skrbi, dok su konceptualni doprinosi uglavnom pružili modele za upravljanje, odgovornost, pravičnost, UI pismenost i sociotehničku sigurnost. Sažetak svake publikacije prikazan je u Dopunskoj tablici S1.

METODOLOŠKA KVALITETA

Metodološka kvaliteta bila je heterogena. Kvalitativne studije pružile su relevantne informacije o profesionalnim iskustvima i uvjetima prihvaćanja, ali su često bile ograničene malim uzorcima, jedinstvenim okruženjima, podacima koje su ispitanici sami naveli te nepotpunim izvještavanjem o refleksivnosti ili

zasićenju. Presječne studije opisale su stavove i povezanosti između varijabli, ali nisu dopuštale uzročno zaključivanje. Opservacijska studija temeljena na zapisima informacijskog sustava pružila je podatke o stvarnoj primjeni tehnologije, ali nije omogućila da se bilo kakva varijacija u kliničkim ishodima izravno pripiše korištenju sustava.

Među preglednim radovima, veća interpretativna težina pridana je sintezama s ponovljivim strategijama pretraživanja, eksplicitnim kriterijima prihvatljivosti, neovisnim odabirom i kritičkom procjenom uključenih studija. Pretražni pregledi bili su posebno informativni za mapiranje tehnologija i nedostataka, ali nisu uvijek uključivali formalnu procjenu kvalitete. Narativni pregledi pridonijeli su kliničkoj, profesionalnoj i etičkoj kontekstualizaciji, iako je njihov odabir izvora bio manje ponovljiv. Konceptualni doprinosi ponudili su korisne strukture za interpretaciju upravljanja i odgovornosti, ali su općenito oskudijevali empirijskom validacijom.

Općenito, korpus je robusnije podupirao zaključke o profesionalnim percepcijama, uvjetima implementacije, organizacijskim rizicima i zahtjevima upravljanja. Dokazi su bili manje robusni u pogledu kliničke učinkovitosti, smanjenja neželjenih događaja i poboljšanja ishoda skrbi.

KLINIČKO ODLUČIVANJE I PROSUĐIVANJE

UI je pretežito opisan kao potpora, a ne kao autonomna zamjena za sestrinsko prosuđivanje. Najčešće ponavljane funkcije uključivale su sintezu informacija, prepoznavanje obrazaca, predviđanje i stratifikaciju rizika, prepoznavanje pogoršanja stanja, određivanje prioriteta i podršku situacijskoj svjesnosti. Aplikacije su se uglavnom odnosile na početne faze kliničkog razmišljanja, dok su odabir odgovora u skrbi i naknadna refleksija o donesenoj odluci bili manje zastupljeni (13,14,15,16).

U stvarnim okruženjima, sustavi ranog upozoravanja mogli bi olakšati razmjenu informacija i učiniti promjene u riziku vidljivima, ali dostupni podaci uglavnom su dokumentirali obrasce primjene i integraciju u tijek rada, bez dokazivanja poboljšanih odluka ili kliničkih ishoda (17). Jezični modeli i generativni alati smatrani su korisnima za dohvaćanje i sintezu informacija, identificiranje propusta i izradu preliminarnog sadržaja, ali ne i kao autonomni donositelji odluka, napose u hitnim stanjima, upravljanju terapijom i visokorizičnim scenarijima (18,19).

Medicinske sestre pokazale su veću spremnost za korištenje sustava sposobnih za integraciju informacija i signaliziranje rizičnih stanja, dok se prihvatljivost smanjivala kada je algoritam zamjenjivao kontekstualnu procjenu ili bio nedovoljno transparentan. Konačna odluka ostala je profesionalna odgovornost djelatnika te je zahtijevala integraciju izlaznog rezultata s izravnim opažanjem, iskustvom, kliničkom intuicijom i karakteristikama osobe koja prima skrb (20,18,21).

Korist i pouzdanost ovisili su o kvaliteti podataka, razumljivosti izlaznih rezultata, kompatibilnosti s tijekom rada, lokalnoj validaciji i sposobnosti osporavanja preporuke. U jednoj presječnoj studiji, veće oslanjanje na sustave za podršku odlučivanju bilo je povezano s nižom razinom žaljenja zbog donesenih odluka, a taj je odnos bio dodatno osnažen povjerenjem; međutim, dizajn studije nije dopuštao utvrđivanje uzročnosti niti donošenje zaključaka o prikladnijim odlukama ili boljim kliničkim ishodima (22).

Zabrinutosti su uključivale netočne ili rezultate van konteksta, netransparentnost, pristranost prema automatizaciji, preveliko oslanjanje na sustave i mogući gubitak vještina. Općenito, dokazi su snažnije podupirali doprinos umjetne inteligencije organiziranju informacija, predviđanju rizika i jačanju kliničke budnosti, nego dokazano poboljšanje u prikladnosti donošenja odluka. Podaci o dugoročnim učincima na kliničko razmišljanje, održavanje kompetencija i upravljanje neslaganjem između profesionalnog prosuđivanja i algoritamskog rezultata ostali su ograničeni (23,24,15,25).

SIGURNOST PACIJENTA

Primjene povezane sa sigurnošću odnosile su se na rano prepoznavanje pogoršanja stanja, kontinuirano praćenje i pravovremenu intervenciju (26,14,15,27,25). Područja su uključivala predviđanje padova (28), prevenciju dekubitusa (29,19), rizik od infekcija i pogoršanje stanja u intenzivnoj skrbi (30,31), sigurnost primjene terapije (32,33) te sustave ranog upozoravanja (17,27,34).

Potencijalne koristi ovisile su o lokalnoj validaciji, kvaliteti podataka, odgovarajućim pragovima, integraciji u tijek rada i sposobnosti da se upozorenja pretoče u pravovremene intervencije (20,35,36). Praćenje nakon implementacije, revizije izvedbe i pristranosti, postupci eskalacije te mogućnost nadjačavanja izlaznih rezultata pokazali su se kao uvjeti za sigurnu uporabu (23,37,36). Rizici su uključivali lažno pozitivne i lažno negativne rezultate, zamor od alarma, pristranost prema automatizaciji, nejednakosti i lažni osjećaj sigurnosti, napose kada se izostanak upozorenja interpretirao kao izostanak rizika ili kada se izlazni rezultat nije uspoređivao sa sestrinskom procjenom (32,23,34,16).

Publikacije su jasnije opisivale mehanizme putem kojih bi UI mogao pridonijeti sigurnosti, nego što su pružile dokaze o stvarnom smanjenju neželjenih događaja. Neke intervencijske studije izvijestile su o pravovremenijoj eskalaciji skrbi, boljem pridržavanju protokola i smanjenom broju ponovnih hospitalizacija u specifičnim okruženjima, ali su kvaliteta, intervencije, ishodi i praćenje bili heterogeni (15). Pregledni radovi potvrdili su prevladavanje studija razvoja ili validacije, uz mali broj implementacija u stvarnom svijetu i ograničenu prospektivnu evaluaciju ishoda (24,28,27,31). Uzročni dokazi o smrtnosti (mortalitetu), pogreškama u primjeni terapije, komplikacijama i drugim ishodima osjetljivima na sestrinsku skrb stoga su ostali ograničeni (26,14,38,25).

UPRAVLJANJE I VOĐENJE IMPLEMENTACIJE

Usvajanje UI-ja ovisilo je o kompatibilnosti s tijekom rada, kvaliteti podataka i interoperabilnosti, organizacijskoj podršci te pravilima koja uređuju uporabu, dokumentiranje i odgovornost. Prihvaćanje je bilo veće kada je tehnologija bila korisna, razumljiva i usklađena s praksom, a manje u prisutnosti slabe transparentnosti, neadekvatne institucionalne spremnosti ili uočene prijetnje profesionalnoj autonomiji (20,22,18,21).

Publikacije su ukazale na potrebu za uključivanjem medicinskih sestara u definiranje potreba, odabir i dizajn alata, lokalnu validaciju, implementaciju i praćenje. Takva je uključenost omogućila procjenu relevantnosti za skrb, kompatibilnosti s kognitivnim i operativnim procesima te učinaka na radno opterećenje. Razlike u uporabi između različitih ustanova, odjela, smjena i profesionalnih skupina potvrdile su potrebu za prilagodbom implementacije kontekstu i njezinim praćenjem tijekom vremena (13,39,24,29,17).

Sestrinskom vođenju dodijeljena je odgovornost za sudjelovanje u donošenju tehnoloških odluka, definiranje prikladne uporabe, zaštitu autonomije i pravičnosti, promicanje kompetencija te uspostavljanje postupaka za prijavu incidenata, reviziju izlaznih rezultata i eskalaciju skrbi. Također su preporučeni zastupljenost medicinskih sestara u dizajnu i validaciji te suradnja između kliničkih stručnjaka, menadžera, informatičara i stručnjaka za etiku, pravo i sigurnost podataka (23,40,26,41).

Upravljanje je prikazano kao proces koji se proteže kroz cijeli životni ciklus tehnologije, uključujući lokalnu validaciju, postupno uvođenje, transparentnost, zaštitu podataka, dodjelu odgovornosti, postupke nadjačavanja (sustava), revizije pristranosti i praćenje pogrešaka (20,32,23,39,25). Glavne barijere bile su neadekvatna edukacija, nedovoljna infrastruktura, loša interoperabilnost, troškovi, varijabilna kvaliteta podataka, neizvjesna pravna odgovornost, implementacija odozgo prema dolje te nedostatak stabilnih mehanizama za povratne informacije. Korpus je bio suglasan oko načela odgovornog upravljanja, ali je ponudio ograničene dokaze o komparativnoj učinkovitosti, troškovima, održivosti i dugoročnim organizacijskim učincima predloženih modela (25,41,16,21).

MEĐUSEKTORSKA INTEGRACIJA NALAZA

Iako su organizirani u tri područja, nalazi su pokazali snažnu međusobnu ovisnost između kliničkog odlučivanja, sigurnosti i upravljanja. Učinci UI-ja nisu ovisili samo o tehničkoj izvedbi nego i o tome kako su izlazni rezultati interpretirani, integrirani u tijekove rada te povezani s profesionalnom i organizacijskom odgovornošću.

Ljudski nadzor pokazao se kao međusektorska dimenzija. S kliničkog stajališta, on je uključivao provjeru i kontekstualizaciju rezultata; u pogledu sigurnosti, prepoznavanje pogrešaka, pristranosti i stanja koja nisu prikazana u podacima; a na organizacijskoj razini, osiguravanje ovlasti za donošenje odluka, sljedivosti i postupaka eskalacije.

Iskustva iz stvarnog svijeta pokazala su da dostupnost sustava nije jamčila ujednačenu uporabu. Uporaba, povjerenje i nadjačavanje preporuka varirali su ovisno o kontekstu, profesionalnoj ulozi, radnom opterećenju i kompatibilnosti s tijekom rada (17,34). Međutim, ljudski nadzor se češće preporučuje u okvirima i sintezama nego što se empirijski evaluira u praksi.

Sestrinska dokumentacija također je imala dvostruku međusektorsku funkciju: kao izvor podataka za prediktivne sustave i sustave upozorenja te kao proces koji UI potencijalno podržava kroz sintezu, automatizaciju i identificiranje propusta. Publikacije su ipak naglasile potrebu za očuvanjem cjelovitosti, kontekstualizacije i profesionalne provjere dokumentacijskih izlaza. U sustavima koji se koriste u praksi, sljedivost algoritamskog rezultata, donesene odluke i bilo kojeg potkrepljivanja bila je relevantna za postizanje provjerljivosti ljudskog nadzora te kao podrška reviziji i organizacijskom učenju (15,17,18,23,34,37).

Sličnosti, razlike, uvjeti, rizici, nedostatci i implikacije koji se odnose na tri područja sažeti su u Dopunskoj tablici S2. Budući da su iste publikacije mogle pridonijeti višestrukim područjima, a pregledni radovi su se mogli preklapati u svojim primarnim studijama, učestalost pojavljivanja neke teme nije odgovarala broju neovisnih izvora dokaza.

RASPRAVA

SAŽETAK I TUMAČENJE GLAVNIH NALAZA

Ovaj pregled pokazuje da vrijednost UI-ja u sestrinskoj praksi ne ovisi samo o izvedbi algoritma, nego i o uvjetima pod kojima se izlazni rezultati interpretiraju, integriraju u tijekove rada i pretaču u akcije skrbi. Dokazi uglavnom podupiru doprinos UI-ja organiziranju informacija, predviđanju rizika i jačanju kliničke budnosti, dok ostaju manje robusni u pogledu poboljšane prikladnosti donošenja odluka i ishoda za pacijente.

Kliničko odlučivanje, sigurnost i upravljanje stoga su međusobno ovisni. Ljudski nadzor glavni je povezujući element kroz ova tri područja, ali on postaje učinkovit tek kada stručnjaci imaju kompetencije, informacije, vrijeme, ovlasti i postupke potrebne za provjeru, kontekstualizaciju i, kada je to potrebno, odbacivanje izlaznog rezultata. Sama formalna prisutnost stručnjaka u procesu ne jamči smislenu kontrolu.

Od algoritamske izvedbe do sestrinske kliničke prosudbe

Prevalencija primjena usmjerenih na sintezu informacija, prepoznavanje obrazaca i predviđanje rizika ukazuje na to da je UI trenutačno zreliji u podržavanju početnih faza kliničkog razmišljanja nego u odabiru, prilagodbi i evaluaciji odgovora u skrbi (13,15). Ova je asimetrija važna jer algoritamska klasifikacija rizika nije ekvivalentna kliničkom prosuđivanju.

Model može procijeniti vjerojatnost pogoršanja stanja pacijenta, pada, dekubitusa ili komplikacije povezane s terapijom, ali prevođenje predviđanja u odluku zahtijeva razmatranje cjelokupne kliničke slike, suprotstavljenih prioriteta, pacijentovih preferencija, dostupnih resursa i posljedica intervencije. Prediktivni kapacitet stoga je potencijalno korisna komponenta prosuđivanja, a ne njegov ekvivalent. Studije provedene u stvarnoj praksi također uglavnom opisuju obrasce uporabe i integraciju u tijek rada, bez automatskog dokazivanja poboljšanih odluka ili kliničkih ishoda (17).

Veća spremnost medicinskih sestara za korištenje sustava koji organiziraju informacije, smanjuju ponavljajuće aktivnosti ili pružaju preliminarna upozorenja, zajedno s njihovim oprezom prema netransparentnim izlaznim rezultatima ili onima koji su u sukobu s kliničkom procjenom, sugerira da povjerenje prema tehnologiji nije stabilno. Umjesto toga, ono se manifestira kao proces kalibracije na koji utječu iskustvo korištenja, transparentnost, lokalna validacija i sposobnost provjere preporuka u odnosu na stanje osobe koja prima skrb (20,18,21).

Cilj implementacije stoga ne bi trebao biti maksimiziranje pridržavanja algoritamskih preporuka, već poticanje kalibriranog povjerenja: dovoljno visokog za korištenje relevantnih informacija, ali bez smanjenja kritičke procjene ili poticanja pristranosti prema automatizaciji. Obrazloženo nadjačavanje sustava ne bi se smjeralo automatski tumačiti kao otpor prema tehnologiji. Kada je utemeljeno na kontekstualnoj procjeni, ono može predstavljati odgovorno profesionalno prosuđivanje. Međutim, kako bi se potaknulo organizacijsko učenje, neslaganje se mora moći dokumentirati i analizirati kroz postupke sposobne razlikovati ograničenja sustava od profesionalne pogreške (20,23,39).

SIGURNOST PACIJENATA: POTENCIJAL, DOKAZI I NOVI RIZICI

Razlika između izvedbe algoritma i kliničke sigurnosti od ključne je važnosti. Osjetljivost, specifičnost, točnost i sposobnost diskriminacije opisuju ponašanje modela, ali sami po sebi ne dokazuju da uvođenje tog modela dovodi do prikladnijih odluka ili manjeg broja neželjenih događaja. Učinci također ovise o tome tko prima upozorenje, njegovoj pravovremenosti, dostupnim informacijama, resursima koji se mogu aktivirati te upravljanju neslaganjem između algoritamskog rezultata i kliničke procjene.

Sustav stoga može raditi zadovoljavajuće tijekom razvoja ili validacije bez proizvodnje ekvivalentnih koristi u praksi, osobito kada njegova integracija u sestrinske tijekove rada nije prospektivno evaluirana (14,28,27,15,31,13). Prevladavanje studija razvoja i validacije nad evaluacijama ishoda čini preranim izjednačavanje sposobnosti predviđanja rizika sa sposobnošću sprječavanja njegovih posljedica.

Identificirani rizici, uključujući lažno pozitivne i lažno negativne rezultate, zamor od alarma, pristranost, lažni osjećaj sigurnosti i preveliko oslanjanje, dodatno pokazuju da tehnologija može podjednako i smanjiti i uvesti opasnosti (32,27,25,23,34). U okruženjima intenzivne skrbi i kod visokorizičnih odluka, izlazni rezultati se stoga moraju uspoređivati s izravnom procjenom medicinske sestre i njezinim kontekstualnim znanjem (27,34).

Jezični modeli i alati generativnog UI-ja uvode dodatne zabrinutosti. Formalna uvjerljivost (plauzibilnost) netočnog, nepotpunog ili dekontekstualiziranog sadržaja može učiniti pogreške teže uočljivima na prvu. Izlazne rezultate stoga treba smatrati preliminarnima i provjeriti ih prije kliničke ili dokumentacijske uporabe. Dopušteni načini korištenja, zaštita podataka i intenzitet ljudskog pregleda trebali bi biti razmjerni vjerojatnosti i ozbiljnosti potencijalne štete (42,18,19).

U konačnici, sigurnost UI-ja pokazuje se kao svojstvo sociotehničkog sustava u koji se tehnologija uvodi, a ne samog algoritma u izolaciji. Evaluacija bi trebala obuhvatiti sučelje, integraciju u tijek rada, kvalitetu podataka, kompetencije korisnika, radno opterećenje, komunikaciju, eskalaciju i praćenje nakon implementacije. Osim prediktivne izvedbe, u obzir bi trebalo uzeti neželjene događaje, propuste u skrbi, vremena reakcije, kognitivno radno opterećenje, učestalost i prikladnost nadjačavanja sustava, razlike među podskupinama te nenamjerne učinke na sestrinsku praksu.

UPRAVLJANJE IMPLEMENTACIJOM I ULOGA SESTRINSKOG VOĐENJA

Implementacija UI-ja proces je kliničke i organizacijske transformacije, a ne tek tehnička faza nakon razvoja. Čak i sustavi sa zadovoljavajućim performansama mogu donijeti ograničene koristi ako su nekompatibilni s radnim procesima, zahtjevni za provjeru ili ako se uvedu bez odgovarajuće infrastrukture, kompetencija i podrške.

Preporuke unutar cijelog korpusa mogu se grupirati u pet međusobno povezanih područja: organizacijska spremnost, sudjelovanje medicinskih sestara, vodstvo i odgovornost, pismenost u području umjetne inteligencije, nadzor kroz cijeli životni ciklus tehnologije Ova područja predstavljaju interpretativnu sintezu pregleda, a ne već potvrđeni model upravljanja.

Organizacijska spremnost uključuje interoperabilnost, kvalitetu i dostupnost podataka, tehničku podršku, dostupne resurse te integraciju u procese skrbi. Usvajanje stoga ne ovisi samo o dostupnosti tehnologije, već i o sposobnosti organizacije da je koristi bez ugrožavanja kontinuiteta, održivosti i sigurnosti skrbi (18,25,21).

Sudjelovanje medicinskih sestara i tehničara trebalo bi započeti s definiranjem potreba za skrbi te se nastaviti kroz odabir tehnologije, dizajn, lokalnu validaciju i evaluaciju. Medicinske sestre i tehničari mogu pomoći u identificiranju relevantnih podataka, procjeni kompatibilnosti s praksom te prepoznavanju nenamjernih posljedica za rad i odnos skrbi prema pacijentu. Uključenost ograničena samo na fazu nakon implementacije

smanjuje mogućnost ispravljanja dizajnerskih pretpostavki koje su nekompatibilne s procesima skrbi (39,24,26,29).

Sestrinsko vodstvo povezuje kliničku praksu, razvoj tehnologije i organizacijsku odgovornost. Ono uključuje zastupljenost u donošenju tehnoloških odluka, definiranje prikladnih načina korištenja, promicanje kompetencija te procjenu učinaka na kvalitetu, pravednost, opterećenje radom i profesionalnu autonomiju. Ono nije sinonim za puko promicanje usvajanja tehnologije, već uključuje i ovlast za traženje izmjena, ograničavanje upotrebe ili predlaganje obustave sustava koji ne osiguravaju odgovarajuće uvjete sigurnosti i svrhovitosti (23,40,41).

Upravljanje se mora protezati kroz cijeli životni ciklus tehnologije putem praćenja performansi, revizije pristranosti, analize incidenata i prikupljanja povratnih informacija od stručnjaka. Podudarnost u stavovima o temeljnim načelima snažnija je od trenutno dostupnih dokaza o komparativnoj učinkovitosti organizacijskih modela, troškovima, održivosti i dugoročnim učincima (20,32,17,41).

LJUDSKI NADZOR KAO ORGANIZACIJSKA FUNKCIJA

Ljudski nadzor postaje smislen kada su medicinske sestre i tehničari svjesni da se umjetna inteligencija koristi, kada razumiju njenu svrhu i ograničenja, kada mogu usporediti njen rezultat s kliničkom procjenom te kada imaju ovlast da taj rezultat potvrde, izmijene ili odbace (20,18,34).

Preporuke u korpusu moguće je sintetizirati u pet radnih dimenzija:

- vidljivost, što znači da je doprinos umjetne inteligencije prepoznatljiv;
- razumljivost, što se odnosi na dostupnost informacija o svrsi, ograničenjima i nesigurnosti sustava;
- kompetentnost, koja je potrebna za interpretaciju i kontekstualizaciju rezultata;
- ovlast, kao stvarna sposobnost potvrđivanja, izmjene ili odbacivanja preporuke;
- sljedivost kroz dokumentiranje rezultata, donesene odluke i bilo kakvog neslaganja.

Ove dimenzije predstavljaju interpretativnu sintezu pregleda, a ne empirijski potvrđeni model.

Nadzor bi se trebao smatrati organizacijskom funkcijom, a ne pukom individualnom odgovornošću. On zahtijeva sustave dizajnirane tako da se doprinos umjetne inteligencije može provjeriti, da ima dovoljno vremena za procjenu rezultata, eksplicitno utvrđivanje odgovornosti te nekažnjive načine prijave pogrešaka i neslaganja. Bez ovih uvjeta, pozivanje na koncept human-in-the-loop može prebaciti konačnu odgovornost na medicinsku sestru, a da im se pritom ne pruži stvarna kontrola nad algoritamskim procesom (23,43,39).

Argumentirano odbacivanje ili izmjena algoritamske preporuke također može doprinijeti organizacijskom učenju otkrivanjem ograničenja modela ili kliničkih stanja koja nisu adekvatno prikazana. Međutim, Samy i sur. (34) pokazuju da takva neslaganja mogu ostati nedokumentirana ako su alati za bilježenje zahtjevni ili loše usklađeni s kliničkim radom, što stvara jaz u sljedivosti podataka.

Dokumentiranje je stoga operativna komponenta nadzora, a ne tek naknadni zapis o donesenoj odluci. Omogućavanje sljedivosti rezultata umjetne inteligencije, sestrinske procjene, donesene odluke i bilo kakvog neslaganja dopušta rekonstrukciju procesa, pripisivanje odgovornosti te korištenje odluka o izmjeni za reviziju i organizacijsko učenje. Suprotno tome, budući da neki prediktivni sustavi izravno koriste podatke i obrasce iz sestrinske dokumentacije, nepotpunost, semantička varijabilnost i loša interoperabilnost mogu utjecati i na algoritamske inpute i na interpretaciju rezultata (15,17,28,34,37).

Razina nadzora trebala bi biti razmjerna riziku. Aktivnosti koje se mogu vratiti provjeriti mogu zahtijevati manje intenzivne kontrole od upozorenja o pogoršanju stanja pacijenta, preporuka za lijekove ili određivanja prioriteta u skrbi. Visokorizične aplikacije zahtijevaju lokalnu validaciju, jasno definiranu odgovornost, formalne postupke za upravljanje neslaganjima i kontinuirano praćenje. Ljudski nadzor ne bi trebao kompenzirati loše validirane sustave, već bi trebao biti provjerljiva komponenta upravljanja rizikom. (37,36).

IMPLIKACIJE ZA PRAKSU, VODSTVO I ISTRAŽIVANJE

U kliničkoj praksi, UI treba koristiti kao situacijsku podršku profesionalnoj procjeni. Rezultati se moraju interpretirati u svjetlu izravne procjene, kliničkog tijeka i karakteristika osobe koja prima skrb. Visokorizični procesi moraju osigurati stručnu provjeru i dokumentiranje svakog neslaganja. Korištenje generativnih alata trebalo bi ograničiti na zadatke koji su u skladu s dostupnom razinom validacije, a njihov se sadržaj mora smatrati preliminarnim sve dok se klinički ili dokumentacijski ne provjeri (18,19,42).

Za sestrinsko vodstvo prioritet je prevođenje načela upravljanja u operativne strukture. To zahtijeva sudjelovanje u tijelima za donošenje odluka, kriterije za procjenu tehnologije prije implementacije, edukaciju specifičnu za pojedine uloge te postupke za praćenje sigurnosti, pravednosti, opterećenja radom i kvalitete dokumentacije. Odluke o ažuriranju, ograničavanju ili povlačenju sustava iz upotrebe također bi se trebale temeljiti na dokazima prikupljenim tijekom njegova korištenja, a ne samo na performansama navedenima prije implementacije (40,37,41,36).

Istraživanja bi trebala smanjiti jaz između razvoja algoritama i prakse skrbi kroz prospektivne, multicentrične i pragmatične studije provedene u stvarnim radnim procesima. Buduće evaluacije trebale bi uzeti u obzir prikladnost donošenja odluka, ishode osjetljive na sestrinsku skrb, kognitivno opterećenje

radom, održavanje kompetencija, razlike među podskupinama, učinke na odnos skrbi prema pacijentu te posljedice neslaganja između profesionalne procjene i algoritamskog rezultata (13,17,15).

Usporedivost među studijama također bi se mogla poboljšati kroz zajednički skup ishoda definiran formalnim postupcima konsenzusa. Takav bi skup mogao uključivati performanse modela, štetne događaje, propuste u skrbi, prikladnost i pravovremenost donošenja odluka, opterećenje radom, upotrebljivost, kalibrirano oslanjanje (na tehnologiju), pravednost te organizacijsku održivost.

PREDNOSTI I OGRANIČENJA ISTRAŽIVANJA

Prednosti ovog preglednog rada uključuju strukturirano pretraživanje literature, neovisni odabir od strane dvaju recenzenata te odvojenu analizu primarnih studija, preglednih radova i konceptualnih doprinosa. Takav je pristup omogućio integraciju empirijskih dokaza i organizacijskih perspektiva, uz istovremeno vrednovanje i ponderiranje studija prema njihovom dizajnu i metodološkoj kvaliteti.

Unatoč tome, rad ima svoja ograničenja. Ograničavanje pretraživanja na samo dvije baze podataka te na publikacije objavljene na engleskom i talijanskom jeziku moglo je dovesti do neuključivanja studija indeksiranih isključivo u računalnim ili inženjerskim izvorima. Raznolikost dizajna, tehnologija i ishoda onemogućila je provođenje kvantitativne sinteze. Velik broj uključenih preglednih radova otvara mogućnost preklapanja među primarnim studijama. Uz to, prevladavanje studija koje se bave percepcijom, studija presjeka ili onih provedenih prije same implementacije ograničava donošenje čvrstih zaključaka o stvarnoj kliničkoj učinkovitosti. Konačno, isključivanje studija provedenih isključivo sa studentima znači da se dobiveni rezultati ne mogu proširiti na dodiplomsko obrazovanje medicinskih sestara i tehničara.

ZAKLJUČCI

Umjetna inteligencija može povećati sposobnost medicinskih sestara i tehničara u organiziranju informacija, prepoznavanju rizičnih stanja i podržavanju pravovremenih reakcija, ali dokazi još uvijek ne pokazuju dosljedno poboljšanje u donošenju odluka, sigurnosti ili kliničkim ishodima. Odgovorna integracija zahtijeva kontekstualnu validaciju, učinkovit ljudski nadzor i uključenost sestrinskog vodstva kroz cijeli životni ciklus tehnologije.

Potrebne su prospektivne studije provedene u stvarnim okruženjima skrbi kako bi se procijenili učinci na donošenje odluka, ishode osjetljive na sestrinsku skrb, pravednost, kompetencije i organizaciju rada.

DOPRINOSI AUTORA

Svi su autori doprinijeli konceptu i dizajnu ovog preglednog rada. PG je razvio strategiju pretraživanja. PG i AS neovisno su proveli odabir publikacija, ekstrakciju podataka i kritičku procjenu izvora. PG je izradio prvi nacrt rukopisa. Svi su autori doprinijeli interpretaciji rezultata, kritičkoj reviziji teksta i odobrenju konačne verzije rada.

SUKOB INTERESA

Autori izjavljuju da nema nikakvog financijskog, profesionalnog, niti osobnog sukoba interesa u vezi sadržaja ovog rada.

FINANCIRANJE

Za ovo istraživanje nije primljena nikakva posebna potpora od javnih, komercijalnih ili neprofitnih agencija za financiranje.

DOSTUPNOST PODATAKA

Podaci korišteni u ovom preglednom radu dobiveni su iz publikacija dostupnih putem odgovarajućih bibliografskih izvora. Strategije pretraživanja, tablica za ekstrakciju podataka, karakteristike uključenih publikacija i međusektorska sinteza analitičkih područja prikazani su u dopunskim materijalima. Dodatni materijali koji se odnose na proces odabira, ekstrakciju i kritičku procjenu izvora dostupni su na opravdani zahtjev kod dopisnog autora.

UPOTREBA ALATA UMJETNE INTELIGENCIJE KOD PRIPREME RUKOPISA

Tijekom pripreme rukopisa, alati generativne umjetne inteligencije korišteni su isključivo kao podrška jezičnom uređivanju, organizaciji teksta i poboljšanju jasnoće. Odluke vezane za metodologiju, prihvatljivost publikacija, ekstrakciju i interpretaciju podataka, kritičku procjenu izvora te zaključke donijeli su sami autori. Sav sadržaj generiran ili prerađen pomoću ovih alata autori su kritički provjerili te oni zadržavaju potpunu odgovornost za rukopis.

DODATNI MATERIJAL

Dopunska tablica S1. Sažetak značajki uključenih publikacija

Dopunska tablica S2. Integrativna sinteza analitičkih domena

LITERATURA

1. World Health Organization. Ethics and governance of artificial intelligence for health: WHO guidance. Geneva: World Health Organization; 2021. Available from: https://www.who.int/publications/i/item/9789240029200

2. Organisation for Economic Co-operation and Development. Scaling artificial intelligence in health. Paris: OECD Publishing; 2026. https://doi.org/10.1787/a436e12d-en
3. European Union. Regulation (EU) 2024/1689 of the European Parliament and of the Council of 13 June 2024 laying down harmonised rules on artificial intelligence (Artificial Intelligence Act). Off J Eur Union. 2024. Available from: http://data.europa.eu/eli/reg/2024/1689/oj
4. International Council of Nurses. Digital health transformation and nursing practice: position statement. Geneva: International Council of Nurses; 2023. Available from: https://www.icn.ch/sites/default/files/2023-08/ICN%20Position%20Statement%20Digital%20Health%20FINAL%2030.06_EN.pdf
5. Ronquillo CE, Peltonen LM, Pruinelli L, Chu CH, Bakken S, Beduschi A, et al. Artificial intelligence in nursing: priorities and opportunities from an international invitational think-tank of the Nursing and Artificial Intelligence Leadership Collaborative. J Adv Nurs. 2021;77(9):3707-17. doi:10.1111/jan.14855.
6. Ruksakulpiwat S, Thorngthip S, Niyomyart A, Benjasirisan C, Phianhasin L, Aldossary H, et al. A systematic review of the application of artificial intelligence in nursing care: where are we, and what's next? J Multidiscip Healthc. 2024;17:1603-1616. doi:10.2147/JMDH.S459946.
7. Kücking F, Hübner U, Przysucha M, Hannemann N, Kutza JO, Moelleken M, et al. Automation bias in AI-decision support: results from an empirical study. Stud Health Technol Inform. 2024;317:298-304. doi:10.3233/SHTI240871.
8. Baethge C, Goldbeck-Wood S, Mertens S. SANRA: a scale for the quality assessment of narrative review articles. Res Integr Peer Rev. 2019;4:5. doi:10.1186/s41073-019-0064-8.
9. Rethlefsen ML, Kirtley S, Waffenschmidt S, Ayala AP, Moher D, Page MJ, Koffel JB; PRISMA-S Group. PRISMA-S: an extension to the PRISMA Statement for reporting literature searches in systematic reviews. Syst Rev. 2021;10(1):39. doi:10.1186/s13643-020-01542-z.
10. Page MJ, McKenzie JE, Bossuyt PM, Boutron I, Hoffmann TC, Mulrow CD, et al. The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. BMJ. 2021;372:n71. doi:10.1136/bmj.n71.
11. Aromataris E, Lockwood C, Porritt K, Pilla B, Jordan Z, editors. JBI manual for evidence synthesis [Internet]. Adelaide: JBI; 2024 [cited 2026 Oct 7]. Available from: https://synthesismanual.jbi.global/ doi:10.46658/JBIMES-24-01.
12. Popay J, Roberts H, Sowden A, Petticrew M, Arai L, Rodgers M, Britten N, Roen K, Duffy S. Guidance on the conduct of narrative synthesis in systematic reviews: a product from the ESRC Methods Programme. Lancaster: Lancaster University; 2006.
13. Alves JCF, Azevedo ARR, Encarnação RMC, Pais-Vieira CFS, Alves PJP. Artificial intelligence technologies supporting clinical judgement in nursing: a scoping review. J Adv Nurs. 2026;[Epub ahead of print]. doi:10.1111/jan.70670.
14. Martinez-Ortigosa A, Martinez-Granados A, Gil-Hernández E, Rodriguez-Arrastia M, Ropero-Padilla C, Roman P. Applications of artificial intelligence in nursing care: a systematic review. J Nurs Manag. 2023;2023:3219127. doi:10.1155/2023/3219127.
15. Mikkonen K, Tuunainen S, Oikarinen A, Jansson M, Woo B, Zhou W, et al. Artificial intelligence technologies supporting nurses' clinical decision-making: a systematic review. J Clin Nurs. 2025;35(4):1525-1540. doi:10.1111/jocn.70156.
16. Shah N, Bala J, Sharma A, Parmar JS, Singh D. Challenges and implications of the use of artificial intelligence in health care, with an emphasis on nursing: scoping review. Invest Educ Enferm. 2025;43(3):e15. doi:10.17533/udea.iee.v43n3e15.
17. Lee RY, Cato KD, Dykes PC, Lowenthal G, Tuteja S, Rossetti SC. Understanding clinicians' usage patterns of the CONCERN early warning system: insights from a multi-site pragmatic cluster randomized controlled trial. Stud Health Technol Inform. 2025;329:1256-1260. doi:10.3233/SHTI251040.
18. Li X, Hu X, Xu H, Guo J, Ju H, Yu P. Intention to use large language models among clinical nurses in China with prior familiarity with or experience using LLMs: a qualitative study. J Nurs Manag. 2026;2026:7972792. doi:10.1155/jonm/7972792.
19. Soddu M, De Vito A, Madeddu G, Nicolosi B, Provenzano M, Ivziku D, et al. Assessing the accuracy, completeness and safety of ChatGPT-4o responses on pressure injuries in infants: clinical applications and future implications. Nurs Rep. 2025;15(4):130. doi:10.3390/nursrep15040130.
20. Abu Assab M, Al Bahar F, Abu Dayyih W, Alazazmeh BM, Assaf SW, Abed A, et al. Healthcare professionals' perceptions of AI-assisted clinical decision-making in Jordan: a qualitative study of trust, accountability, system readiness, and professional practice. Healthcare (Basel). 2026;14(12):1724. doi:10.3390/healthcare14121724.
21. Yildirim D, Çiriş Yildiz C, Ergin E. Perceptions of intensive care nurses toward artificial intelligence technologies: a qualitative study. Nurs Health Sci. 2026;28:e70332. doi:10.1111/nhs.70332.
22. Awad NHA, Aljohani W, Yaseen MM, Awad WHA, Abou Elala RASA, Ashour HMA. When machines decide: exploring how trust in AI shapes the relationship between clinical decision support systems and nurses› decision regret: a cross-sectional study. Nurs Crit Care. 2025;30(5):e70157. doi:10.1111/nicc.70157.
23. Amin SM, Almagharbeh WT, Alrimawi I, El-Gazar HE, Hamash KI, Zoromba MA, et al. Exploring the ethical dimensions of AI-driven patient monitoring in critical care nursing: a systematic review. Nurs Crit Care. 2026;31(2):e70384. doi:10.1111/nicc.70384.
24. Cant R, Ryan C, Chugh R. Artificial intelligence technologies in nursing clinical decision-making: an umbrella review. J Adv Nurs. 2026;[Epub ahead of print]. doi:10.1111/jan.70579.
25. Rony MKK, Das A, Khalil MI, Peu UR, Mondal B, Alam MS, et al. The role of artificial intelligence in nursing care: an umbrella review. Nurs Inq. 2025;32(2):e70023. doi:10.1111/nin.70023.
26. Hassanein S, El Arab RA, Abdrbo A, Abu-Mahfouz MS, Gaballah MKF, Seweid MM, et al. Artificial intelligence in nursing: an integrative review of clinical and operational impacts. Front Digit Health. 2025;7:1552372. doi:10.3389/fdgth.2025.1552372.
27. Park Y, Chang SJ, Kim E. Artificial intelligence in critical care

nursing: a scoping review. Aust Crit Care. 2025;38(4):101225. doi:10.1016/j.aucc.2025.101225.

28. O'Connor S, Gasteiger N, Stanmore E, Wong DC, Lee JJ. Artificial intelligence for falls management in older adult care: a scoping review of nurses' role. J Nurs Manag. 2022;30(8):3787-3801. doi:10.1111/jonm.13853.
29. Kirkland-Kyhn H, Sengul T, Karadag A, Yilmaz Akyaz D, Cevizci T, Teleten O. Exploring nurses› acceptability and readiness for patient-centered artificial intelligence systems in pressure injury prevention. Adv Skin WoundCare. 2025;38(9):488-495. doi:10.1097/ASW.0000000000000348.
30. Nasiri AM, Alsalman NA, Aljandabi FA, Alsomali SA. AI in hematology: a new frontier for nursing practice and patient care. J Family Med Prim Care. 2026;15(1):45-50. doi:10.4103/jfmpc.jfmpc_1527_25.
31. Zhou Y, Xie H, Hu M, Luo G. Precision nursing device management and artificial intelligence-integrated early warning systems for central nervous system infections in the neurocritical care unit: a scoping review. Cureus. 2026;18(6):e111026. doi:10.7759/cureus.111026.
32. Alruwaili MF, Paul-Chima UO, Nneoma UC. Integrating clinical decision support systems, nursing vigilance, and physician prescribing patterns to reduce preventable adverse drug events: a structured evidence-based narrative review on human-AI interface in medication safety. Front Digit Health. 2026;8:1831150. doi:10.3389/fdgth.2026.1831150.
33. Alqaraleh M, Almagharbeh WT, Ahmad MW. Exploring the impact of artificial intelligence integration on medication error reduction: a nursing perspective. Nurse Educ Pract. 2025;86:104438. doi:10.1016/j.nepr.2025.104438.
34. Samy R, Ramadan OME, Elsayed GEA. Trusting the algorithm or trusting the nurse? Critical care nurses' experiences of automation bias and professional autonomy in AI-assisted early warning. Nurs Crit Care. 2026;31(5):e70620. doi:10.1111/nicc.70620.
35. Park YE, Ock M, Lee JH, Ko DH, Lee HJ, Park T, et al. Assessing health care professionals' perceptions of a new system in clinical workflows: Systems Engineering Initiative for Patient Safety-based consensual qualitative research. J Med Internet Res. 2026;28:e86166. doi:10.2196/86166.
36. Wang J, Yang Y, Marshall D, Shucoski P, Gross T, Frederick R, et al. System-level AI governance in nursing: a practical framework for safe and scalable adoption. Nurs Adm Q. 2026;50(4):208-213. doi:10.1097/NAQ.0000000000000772.
37. Ibrahim FM, Shahrour G, Abuijlan IAM, Abdallah AM, Alsuwayed A, Alanazi AR. NAIL-G: a conceptual best-fit framework for nursing AI literacy and governance anchored in socio-technical safety science. BMC Nurs. 2026;25:370. doi:10.1186/s12912-026-04555-6.
38. Pereira SCA, Ferreira RA, Ventura-Silva JM, Santos EJF, Fassarella CS, Ribeiro OMPL. The effect of artificial intelligence in promoting positive nursing practice environments: mixed methods systematic review. J Clin Nurs. 2026;35:4066-4080. doi:10.1111/jocn.70127.
39. Bose S, Prakash A, Prusty AK, Verma R, Padmavathy K, Iragamreddy VR. Artificial intelligence supported decision-making in intensive care units: implications for nursing and medical practice. Cureus. 2026;18(2):e104266. doi:10.7759/cureus.104266.
40. Connor M, Kagan O. Emerging technologies in oncology nursing: integrating informatics competencies to advance safe, high-quality, and compassionate care. Semin Oncol Nurs. 2026;42(5):152307. doi:10.1016/j.soncn.2026.152307.
41. Schultz MA, Kim HJ, Chou FY, Flores SL, Fangonil-Gagalang E. Digital innovations improving nursing practice through artificial intelligence: the state of the science. Nurs Adm Q. 2026;50(1):44-67. doi:10.1097/NAQ.0000000000000721.
42. Uchmanowicz I, Aldossary HM, Lee CS, Figura M, Jędrzejczyk M, De Maria M, et al. ChatGPT and large language models in contemporary nursing. J Clin Nurs. 2026;[Epub ahead of print]. doi:10.1111/jocn.70490.
43. Ball Dunlap PA, Marquard J, Delaney C, Aliferis C, Chappell K, Coleman TM, et al. Artificial intelligence can replace nursing tasks, but not nurses: examining artificial intelligence's supports and threats to nursing practice through the lens of the 2025 Nursing Code of Ethics. Nurs Outlook. 2026;74(4):102808. doi:10.1016/j.outlook.2026.102808.

Dopunska tablica S1. Sažetak značajki uključenih publikacija

Autor, godina; država	Dizajn; uzorak ili br.studija	UI tehnologija/funkcija	Domene	Glavni nalazi	Metodološka kvaliteta / interpretativna težina
[S1] Alves i sur., 2026; Portugal	Pretražni pregled ; n = 11 studies	Prediktivni modeli, sustavi za podršku odlučivanju i druge tehnologije UI-ja relevantne za kliničku procjenu	Upravljanje implementacijom i vodstvo; sekundarno: Ljudski nadzor; Sigurnost pacijenata; Kliničko donošenje odluka i procjena	Trenutna istraživanja daju prioritet računalnom prepoznavanju obrazaca, ali zanemaruju refleksivne faze ključne za razvoj stručnosti.	Umjerena do dobra kvaliteta. Velika težina za teorijsko mapiranje kliničke procjene i identificiranje nedostataka; umjerena težina za implikacije na sigurnost i implementaciju.
[S2] Martinez-Ortigosa i sur., 2023; Španjolska	Sustavni pregled ; n = 21	Strojno učenje, obrada prirodnog jezika, neuronske mreže / prediktivni algoritmi, sustavi upozorenja i podrške, chatbotovi / konverzacijski agenti, fizički roboti i virtualna simulacija	Sigurnost pacijenata; sekundarno: Upravljanje implementacijom i vodstvo; Kliničko donošenje odluka i procjena	Primjene su se odnosile na ranu dijagnostiku/kliničke odluke, praćenje i optimizaciju radnog procesa te obrazovanje medicinskih sestara i tehničara. UI obećava kao podrška kliničarima, menadžerima i nadzornicima, ali ne zamjenjuje kliničku procjenu i zahtijeva pažljivu implementaciju.	Umjerena kvaliteta. Općenito adekvatna sustavna struktura i izvještavanje, ali heterogenost, ograničena sinteza rezultata procjene i nedostatak ocjene pouzdanosti dokaza smanjuju povjerenje u zaključke.
[S3] Mikkonen i sur., 2025; Finska/ Singapur	Sustavni pregled intervencijski studija s narativnom sintezom; n = 8	D2S2 alat za otpust pacijenata, algoritam za prepoznavanje pogoršanja stanja, NeoCue alat za reanimaciju novorođenčadi, algoritam za napadaje, APREDEL-ICU alat za delirij, ML-CDSS za dekubitus, sučelje za dokumentaciju temeljeno na strojnom učenju i ontologijama te klinička podrška odlučivanju	Kliničko donošenje odluka i procjena; sekundarno: Sigurnost pacijenata; Upravljanje implementacijom i vodstvo; Ljudski nadzor	Proizašle su tri kategorije: specijalizirani i opći alati za podršku, prediktivne tehnologije te upotrebljivost/učinkovitost radnog procesa. Koristi su bile obećavajuće, ali ne i potpuno dokazane.	Umjerena kvaliteta; niska ili vrlo niska pouzdanost dokaza. Velika težina za identificiranje intervencijskih studija i karakteristika implementacije; niska do umjerena težina za procjene učinkovitosti i mogućnost generalizacije.
[S4] Shah i sur., 2025; Indija	Narativni pregled	Umjetna inteligencija u zdravstvu, veliki jezični modeli, robotika, prediktivni sustavi, elektronički zdravstveni kartoni, virtualni asistenti u sestrinstvu, sestrinstvo na daljinu, chatbotovi i simulacija; tehnologije nisu bile sustavno klasificirane	Sigurnost pacijenata; sekundarno: Upravljanje implementacijom i vodstvo; Ljudski nadzor; Kliničko donošenje odluka i procjena	UI nudi potencijalne koristi, ali zahtijeva robusno upravljanje kako bi se ublažili diskriminacija, manjak transparentnosti, narušavanje privatnosti i druge štetne posljedice. Medicinskim sestrama potrebni su UI pismenost i sposobnost prepoznavanja pristranosti.	Niska kvaliteta za pregledni rad; uglavnom kontekstualna i konceptualna korisnost. Niska do umjerena interpretativna težina. Prikladno za mapiranje etičkih tema i implikacija na sestrinstvo, ali ne i za procjenu učinaka, učestalosti ili pouzdanosti dokaza.
[S5] Lee i sur., 2025; Sjedinjene Države	Multicentrična retrospektivna opservacijska analiza zapisa elektroničkih zdravstvenih kartona povezana s pragmatičnim klaster randomiziranim kontroliranim ispitivanjem; n = 393 jedinstvena korisnika i 2.572 otvaranja detaljnog prikaza	CONCERN sustav ranog upozoravanja, koji analizira obrasce u sestrinskoj dokumentaciji kako bi predvidio kliničko pogoršanje stanja i podržao situacijsku svjesnost	Sigurnost pacijenata; sekundarno: Upravljanje implementacijom i vodstvo; Kliničko donošenje odluka i procjena; Ljudski nadzor	Korištenje sustava CONCERN variralo je ovisno o profesionalnoj ulozi, ustanovi, smjeni, odjelu i karakteristikama pacijenta. Prikaze su otvarale uglavnom medicinske sestare, tijekom dnevnih smjena te na odjelima za akutnu skrb. Rezultati idu u prilog integraciji u radne procese i implementaciji koja je osjetljiva na kontekst.	Umjerena kvaliteta; umjeren rizik od pristranosti i bez mogućnosti uzročnog zaključivanja. Velika težina za primjenu u stvarnom svijetu, radne procese i upravljanje implementacijom; umjerena za odluke i nadzor; niska za uzročnu učinkovitost i ishode sigurnosti.

Autor, godina; država	Dizajn; uzorak ili br.studija	UI tehnologija/funkcija	Domene	Glavni nalazi	Metodološka kvaliteta / interpretativna težina
[S6] Li i sur., 2026; Kina	Kvalitativna studija; n = 17	Veliki jezični modeli: Doubao, DeepSeek, ChatGPT, Gemini, Qwen i ERNIE Bot; podrška za dokumentaciju, rutinske zadatke, pristup znanju i sintezu znanja, edukaciju, istraživanje i menadžment	Upravljanje implementacijom i vodstvo; sekundarno: Kliničko donošenje odluka i procjena; Sigurnost pacijenata; Ljudski nadzor	Namjera korištenja velikih jezičnih modela bila je pozitivna, ali uvjetovana. Percipirana korisnost, jednostavnost korištenja i organizacijska podrška išle su u prilog prihvaćanju, dok su rizici, odgovornost i profesionalne granice zahtijevali oprez. Veliki jezični modeli smatrani su najprikladnijima za standardizirane, niskorizične zadatke te ne mogu zamijeniti kliničku procjenu, odgovornost ili ljudsku komunikaciju.	Općenito dobra kvaliteta, uz ograničenu prenosivost i moguću pristranost pri odabiru. Umjerena do velika težina za percepcije i uvjete usvajanja; nije prikladno za izvođenje zaključaka o kliničkoj učinkovitosti ili sigurnosti velikih jezičnih modela.
[S7] Soddu i sur., 2025; Italija; međunarodni panel	Deskriptivna presječna studija; pet stručnjaka procijenilo je n = 60 odgovora	ChatGPT-4o generativni veliki jezični model; stručne informacije i moguća podrška pri odlučivanju/edukaciji za prevenciju, procjenu i zbrinjavanje dekubitusa kod novorođenčadi	Kliničko donošenje odluka i procjena; sekundarno: Sigurnost pacijenata; Ljudski nadzor	Više od 90% odgovora dobilo je relativno visoke ocjene za točnost, potpunost i sigurnost, iako su performanse varirale ovisno o temi te su bile slabije u područjima upravljanja medicinskim proizvodima i tehnoloških inovacija. Stručna provjera i ljudski nadzor ostaju nužni prije kliničke uporabe.	Umjerena kvaliteta: transparentan postupak i korisni evaluacijski rezultati, ali uz rizik od pristranosti mjerenja i ograničenu mogućnost generalizacije. Umjerena težina za informacijske performanse i percipiranu sigurnost.
[S8] Abu Assab i sur., 2026; Jordan	Interpretativno-deskriptivna kvalitativna studija uz primjenu refleksivne tematske analize; n = 22	AI/CDSS za probir, označavanje rizika, slikovnu dijagnostiku, upozorenja, propisivanje lijekova, doziranje, interakcije, praćenje i organizaciju informacija	Upravljanje implementacijom i vodstvo; sekundarno: Kliničko donošenje odluka i procjena; Sigurnost pacijenata; Ljudski nadzor	Stavovi su bili oprezni, ali konstruktivni. Povjerenje je ovisilo o točnosti, transparentnosti, lokalnoj validaciji, institucionalnoj podršci i jasno definiranoj odgovornosti. UI je prihvaćen kao podrška, a ne kao zamjena za profesionalnu procjenu; sigurna i održiva implementacija zahtijevala je ljudski nadzor, edukaciju, upravljanje podacima i organizacijsku spremnost.	Dobra kvaliteta; nizak do umjeren rizik od pristranosti za kvalitativno pitanje, ali uz ograničenu prenosivost (transferabilnost) i relevantnost za sestrinstvo ograničenu na jednu podskupinu. Umjerena do velika težina za upravljanje, povjerenje, odgovornost, nadzor i spremnost.
[S9] Yildirim i sur., 2026; Turska	Kvalitativna studija; n = 22	UI definiran kao strojno učenje, duboko učenje, LLM-ovi i CDSS podržan UI-jem; također su spomenuti ChatGPT, alati za izračun doza te percipirani pametni alarmi, monitori i respiratori	Upravljanje implementacijom i vodstvo; sekundarno: Kliničko donošenje odluka i procjena; Sigurnost pacijenata; Ljudski nadzor	Znanje o UI-ju bilo je ograničeno i fragmentirano, uz uglavnom neizravnu izloženost. Medicinske sestre i tehničari prepoznali su potencijalne koristi za kliničke odluke i skrb, ali su identificirali i rizike za autonomiju, sigurnost podataka, pouzdanost uređaja i odgovornost. Profesionalna procjena i ljudska prisutnost smatrane su nezamjenjivima; strukturirana edukacija i institucionalna podrška bili su ključni.	Općenito dobra kvaliteta za istraživanje percepcija, uz važna ograničenja u pogledu stvarne izloženosti UI-ju i prenosivosti. Umjerena do velika težina za percepcije, barijere, edukaciju, upravljanje i nadzor.
[S10] Awad i sur., 2025; Egipat	Korelacijska presječna studija; n = 250	Sustavi kliničke podrške odlučivanju temeljeni na UI-ju koji se koriste u intenzivnoj skrbi; specifičan proizvod ili algoritam nisu navedeni	Sigurnost pacijenata; sekundarno: Upravljanje implementacijom i vodstvo; Kliničko donošenje odluka i procjena; Ljudski nadzor	Veće oslanjanje na AI-CDSS bilo je povezano s manjim žaljenjem zbog donesenih odluka i većim povjerenjem u umjetnu inteligenciju. Povjerenje je također bilo povezano s manjim žaljenjem zbog odluke te je osnažilo odnos između oslanjanja na sustav i smanjenog žaljenja zbog odluka.	Umjerena kvaliteta. Dobra analitička koherentnost, ali uz rizike od pristranosti pri odabiru, informacijske pristranosti i utjecaja skrivenih čimbenika; ograničena mogućnost generalizacije. Umjerena težina za povezanost (asocijacije) između oslanjanja, povjerenja i žaljenja zbog odluke.

Autor, godina; država	Dizajn; uzorak ili br.studija	UI tehnologija/funkcija	Domene	Glavni nalazi	Metodološka kvaliteta / interpretativna težina
[S11] Amin i sur., 2026; Saudijska Arabija/ Sjedinjene Države/ Jordan/Egipat	Sustavni pregled ; n = 6	AI-CDSS, prediktivno praćenje / praćenje radi ranog upozoravanja, sveprisutno senzorsko praćenje pomoću nosivih uređaja, kamera i okolišnih senzora, duboko učenje, algoritmi za podatke s infuzijskih pumpi te UI alati za praćenje, radne procese i donošenje odluka	Sigurnost pacijenata; sekundarno: Upravljanje implementacijom i vodstvo; Kliničko donošenje odluka i procjena; Ljudski nadzor	Identificirane su četiri teme: autonomija, privatnost, odgovornost i pravednost. Odgovorna integracija zahtijeva transparentnost, upravljanje, edukaciju i procjenu nejednakosti; empirijska baza bila je mala i heterogena.	Dobra metodološka kvaliteta, s malom, heterogenom empirijskom bazom temeljenom uglavnom na percepciji. Velika težina za mapiranje autonomije, privatnosti, odgovornosti i pravednosti; umjerena do niska za kliničke učinke, štetne posljedice i ishode pacijenata.
[S12] Cant, Ryan, i Chugh, 2026; Australija	Krovni pregled; n = 16 pregleda	Strojno učenje, prediktivna analitika, klinička podrška odlučivanju, praćenje i potpomognuto dokumentiranje	Kliničko donošenje odluka i procjena; sekundarno: Upravljanje implementacijom i vodstvo; Sigurnost pacijenata; Ljudski nadzor	UI tehnologije obećavaju za sestrinsko donošenje odluka, ali dokazi i dalje ostaju heterogeni te imaju ograničenu validaciju u rutinskoj kliničkoj primjeni.	Umjerena do dobra kvaliteta; općenito umjeren rizik od pristranosti. Velika težina za mapiranje primjena i domena odlučivanja; umjerena za sigurnost i implementaciju; niska do umjerena za uzročnu kliničku učinkovitost.
[S13] Rony i sur., 2025; Bangladeš/ Saudijska Arabija/ Norveška	Krovni pregled; n = 13	Strojno učenje, duboko učenje, NLP, RPA, prediktivna analitika, AI-CDSS, upozorenja unutar elektroničkih zdravstvenih kartona, nosivi uređaji, telemedicina, slikovna dijagnostika rana i sustavi praćenja	Sigurnost pacijenata; sekundarno: Kliničko donošenje odluka i procjena; Upravljanje implementacijom i vodstvo; Ljudski nadzor	UI nudi prilike za donošenje odluka, praćenje i radne procese, ali usvajanje zahtijeva edukaciju, upravljanje podacima, odgovorne politike, infrastrukturu i ravnotežu sa skrbi usmjerenom na čovjeka.	Umjerena kvaliteta: čvrsta opća struktura, ali s važnim nedostacima u izvještavanju o procjeni kvalitete studija, preklapanju i pouzdanosti dokaza. Umjerena do velika težina za mapiranje primjena i ponavljajućih zabrinutosti.
[S14] Hassanein i sur., 2025; Saudijska Arabija/Egipat (afilijacije autora)	Integrativni pregled; n = 18	Strojno učenje i prediktivni algoritmi, slikovna dijagnostika potpomognuta UI-jem, nosivi uređaji i kontinuirano praćenje, telemedicina, sustavi za praćenje pacijenata nakon otpusta, mobilne aplikacije, klasifikatori opterećenja radom te modeli za kućnu njegu i prehranu	Kliničko donošenje odluka i procjena; sekundarno: Upravljanje implementacijom i vodstvo; Ljudski nadzor; Sigurnost pacijenata	UI može poboljšati kliničke ishode, učinkovitost i dobrobit osoblja, ali održiva i pravedna implementacija zahtijeva sigurno upravljanje, UI pismenost, interdisciplinarnu suradnju i longitudinalne studije u različitim okruženjima.	Umjerena kvaliteta. Pregledni rad je strukturiran i informativan, ali heterogenost, rizik od pristranosti u izvorima i metodološke dosljednosti ograničavaju pouzdanost dokaza.
[S15] Park i sur., 2025; Južna Koreja	Pretražni pregled; n = 35	Strojno učenje, duboko učenje, CNN, NLP, XAI, ekspertni sustavi, LLM, prediktivna analitika i algoritmi za optimizaciju	Sigurnost pacijenata; sekundarno: Kliničko donošenje odluka i procjena; Ljudski nadzor; Upravljanje implementacijom i vodstvo	Prediktivna analitika bila je dominantno područje. Dokumentiranje i raspodjela resursa mogu smanjiti opterećenje radom, ali klinička implementacija i uzročni učinak i dalje su slabo utvrđeni.	Umjerena kvaliteta. Velika težina za mapiranje primjena i nedostataka; niska do umjerena za učinkovitost, sigurnost u stvarnom svijetu, radni proces i sestrinske ishode.
[S16] O'Connor i sur., 2022; Ujedinjeno Kraljevstvo i Hong Kong	Pretražni pregled, n = 14 empirijskih studija	Nadzirano strojno učenje, uključujući stabla odlučivanja, metode potpornih vektora, umjetne neuronske mreže, Bayesove mreže i druge prediktivne modele; NLP primijenjen na sestrinsku dokumentaciju	Kliničko donošenje odluka i procjena; sekundarno: Ljudski nadzor; Sigurnost pacijenata; Upravljanje implementacijom i vodstvo	UI, posebice strojno učenje, pokazuje potencijal za predviđanje rizika od pada, ali dokazi su ograničeni i uglavnom se odnose na razvoj i validaciju. Potrebne su eksperimentalne studije i studije implementacije kako bi se dokazale klinička korisnost i utjecaj na skrb.	Umjerena kvaliteta. Prisutni su rizici od publikacijske pristranosti i pristranosti prema određenoj disciplini te nesigurnost u pogledu kvalitete uključenih studija; klinička učinkovitost nije dokazana. Umjerena težina za mapiranje tehnologija, sestrinskih uloga, nedostataka i uvjeta implementacije.

Autor, godina; država	Dizajn; uzorak ili br.studija	UI tehnologija/funkcija	Domene	Glavni nalazi	Metodološka kvaliteta / interpretativna težina
[S17] Kirkland-Kyhn i sur., 2025; Sjedinjene Države i Turska	Deskriptivna kvalitativna studija; n = 202 medicinske sestre	Budući sustavi UI-ja usmjereni na pacijenta za predviđanje rizika od dekubitusa, automatizirano praćenje i rano upozoravanje; nijedan specifičan algoritam nije implementiran niti testiran	Kliničko donošenje odluka i procjena; sekundarno: Sigurnost pacijenata; Upravljanje implementacijom i vodstvo; Ljudski nadzor	Medicinske sestre i tehničari uočili su ograničenja u tradicionalnim alatima za procjenu rizika te su pokazali otvorenost prema UI-ju za naprednu stratifikaciju, praćenje u stvarnom vremenu, automatizirano dokumentiranje, rano upozoravanje i personalizirane intervencije. Usvajanje je, unatoč tome, zahtijevalo pouzdane podatke, zaštitu sigurnosti, edukaciju i upravljanje etičkim pitanjima.	Umjerena kvaliteta. Dovoljna vjerodostojnost za percepcije, potrebe i uvjete usvajanja; prenosivost i potvrđivanje ograničeni su načinom izvještavanja i nedostatkom iskustva sa stvarnim sustavom.
[S18] Nasiri i sur., 2026; Saudijska Arabija	Sustavni pretražni pregled s narativnom sintezom; broj studija nije naveden u tekstu	Duboko učenje za hematološke slikovne zapise, prediktivni ML, EHR alati za rano upozoravanje, terapeutski CDSS sustavi, NLP), chatbotovi/aplikacije te alati za raspoređivanje i trijažu	Sigurnost pacijenata; sekundarno: Upravljanje implementacijom i vodstvo; Ljudski nadzor; Kliničko donošenje odluka i procjena	Proizašla su četiri područja: dijagnostika; praćenje i predviđanje; terapeutska podrška i podrška radnom procesu; te angažman i edukacija. Medicinske sestre i tehničari opisani su kao prevoditelji, donositelji odluka, interventni kadar i sudizajneri.	Umjereno niska kvaliteta. Umjerena težina za sestrinske uloge, upravljanje i ljudski nadzor; niska težina za kliničku učinkovitost, agregiranu točnost i ishode pacijenata.
[S19] Zhou i sur., 2026; Kina	Pretražni pregled; n = 24 studija: 17 iz primarnog pretraživanja i sedam iz dodatnog pretraživanja	Random Forest, XGBoost, SHAP, nomogrami, automatizirano klasteriranje i ML prikazi valnih oblika intrakranijalnog tlaka te sustavi ranog upozoravanja koji koriste statičke čimbenike i dinamičko praćenje	Kliničko donošenje odluka i procjena; sekundarno: Sigurnost pacijenata; Upravljanje implementacijom i vodstvo; Ljudski nadzor	Integracija preciznog sestrinskog menadžmenta i UI-ja može podržati prijelaz s reaktivnog odgovora na proaktivnu prevenciju, ali klinički zaključci zahtijevaju oprez: nijedan od uključenih UI modela nije bio prospektivno implementiran uz bolesnički krevet niti evaluiran u rutinskoj skrbi.	Umjereno niska kvaliteta. Visoka nesigurnost u pogledu težine pojedinačnih izvora, moguća pristranost pri objavljivanju/ odabiru te rizik od pretjerivanja u tumačenju retrospektivnih performansi kao kliniči korisnih.
[S20] Alruwaili, Paul-Chima, i Nneoma, 2026; Saudijska Arabija i Uganda	Strukturirani narativni pregled s konceptualnim okvirom; n = 75 studija	CPOE, EHR-CDSS, adaptivni sustavi, strojno učenje, NLP, sustavi upozorenja, prediktivni modeli i nadzor nad štetnim događajima uzrokovanim lijekovima	Kliničko donošenje odluka i procjena; sekundarno: Ljudski nadzor; Upravljanje implementacijom i vodstvo; Sigurnost pacijenata	Sigurnost primjene lijekova zahtijeva integrirani sociotehnički pristup. CSIL okvir povezuje podatke, Ui analizu, sučelje/ kogniciju, djelovanje/ishod te povratne informacije koje se odnose na učenje, upravljanje i pravednost	Umjerena do dobra kvaliteta; umjeren rizik od pristranosti, posebice pri tematskom odabiru i interpretaciji. Velika težina za mapiranje sigurnosti, ljudskih čimbenika i upravljanja; umjerena do velika za implikacije na sestrinstvo; umjerena za učinkovitost.
[S21] Alqaraleh i sur., 2025; Jordan, Saudijska Arabija, i Kina	Mješoviti sustavni pregled sa značajnim metodološkim nedostacima; n = 12 izvora	CDSS, CPOE, BCMA, pametne infuzijske pumpe, automatizirano izdavanje lijekova, prediktivna analitika, rudarenje teksta, učenje s potkrijepljenjem i farmakovigilancija	Kliničko donošenje odluka i procjena; sekundarno: Upravljanje implementacijom i vodstvo; Ljudski nadzor; Sigurnost pacijenata	Zaključci su išli u prilog UI-ju, ali su tvrdnje o učinkovitosti oslabljene metodološkim i bibliografskim nedosljednostima.	Vrlo niska ukupna kvaliteta; kritičan rizik od pristranosti pri odabiru, klasifikaciji, ekstrakciji i sintezi podataka. Dodijeliti minimalnu težinu. Prikladno isključivo za opisivanje percipiranih tema, alata i barijera
[S22] Samy i sur., 2026; Saudijska Arabija	Interpretativna deskriptivna kvalitativna studija; n = 23	Sustav ranog upozoravanja potpomognut UI-jem integriran u elektronički zdravstveni karton; probabilistička procjena općeg rizika od pogoršanja stanja s vizualnim i zvučnim upozorenjima	Sigurnost pacijenata; sekundarno: Kliničko donošenje odluka i procjena; Upravljanje implementacijom i vodstvo; Ljudski nadzor	Rezultati AI-EWS sustava smatrani su korisnima, ali nedovoljnima te su se morali interpretirati usporedo s kliničkom procjenom i kontekstualnim znanjem. Povjerenje i odluke o odbacivanju kalibrirali su se kroz iskustvo; nedokumentirane izmjene razotkrile su jaz u upravljanju. Sustav je reorganizirao, ali nije zamijenio sestrinsku procjenu i autonomiju.	Umjerena do visoka kvaliteta. Velika težina za donošenje odluka, kalibraciju povjerenja, odbacivanje, autonomiju, nadzor i upravljanje; niska za kliničku učinkovitost.

Autor, godina; država	Dizajn; uzorak ili br.studija	UI tehnologija/funkcija	Domene	Glavni nalazi	Metodološka kvaliteta / interpretativna težina
[S23] Park i sur., 2026; Južna Koreja	Kvalitativna studija konsenzusa prije implementacije temeljena na modelu SEIPS 101; n = 14	pMSBOS-TS, CDSS temljen na ML-u koji preporučuje personalizirani maksimalni nalog za narudžbu eritrocita u torakalnoj kirurgiji; preoperativna potpora za naručivanje i planiranje krvnih pripravaka	Sigurnost pacijenata; sekundarno: Kliničko odlučivanje i prosuđivanje; Upravljanje implementacijom i vođenje; Ljudski nadzor	Sustav je procijenjen kao potencijalno koristan za smanjenje varijabilnosti u planiranju krvnih pripravaka, pod uvjetom da je pouzdan i integriran u tijekove rada elektroničkih zdravstvenih kartona. Sudionici su predvidjeli opterećenje zbog potrebe za verifikacijom, poteškoće u neočekivanim scenarijima te komunikacijske probleme između kliničkih odjela i banke krvi. Upravljanje, organizacijska kultura i lokalna logistika bili su presudni za sigurnu implementaciju.	Umjerena do visoka kvaliteta. Velika važnost pridana je tijeku rada, upravljanju, spremnosti i sociotehničkim rizicima; mala važnost učinkovitosti, stvarnoj sigurnosti i ponašanju nakon uvođenja sustava.
[S24] Wang i sur., 2026; Sjedinjene Države	Konceptualni okvir	Alati UI-ja za podršku odlučivanju, dokumentiranje i kliničko-organizacijske procese; sestrinski upravljački okvir za sigurnu procjenu, implementaciju, nadzor i skaliranje temeljen na kliničkoj korisnosti, pouzdanosti, pravednosti, transparentnosti, privatnosti i odgovornosti	Kliničko odlučivanje i prosuđivanje; sekundarno: Sigurnost pacijenata; Ljudski nadzor; Upravljanje implementacijom i vođenje	Sestrinski upravljački okvir za UI na razini sustava.	Dobra konceptualna kvaliteta i velika praktična korist; neizvjesnost u pogledu učinkovitosti do provođenja prospektivne validacije. Velika interpretativna važnost pridana je upravljanju, implementaciji i nadzoru.
[S25] Ibrahim i sur., 2026; Egipat, Jordan, Ujedinjeni Arapski Emirati i Saudijska Arabija	Konceptualni okvir	Generativni i prediktivni UI za edukaciju, kliničko zaključivanje, dokumentiranje i znanstvenu komunikaciju; okvir za pismenost i upravljanje za kritičku upotrebu, verifikaciju izlaznih podataka, upravljanje rizicikom, transparentnost, sigurnost i pravednost	Kliničko odlučivanje i prosuđivanje; sekundarno: Sigurnost pacijenata; Ljudski nadzor; Upravljanje implementacijom i vođenje	NAIL-G, upravljački okvir i okvir za pismenost u području umjetne inteligencije u sestrinstvu, obuhvaća pet domena primjenjivih u edukaciji, kliničkoj praksi i znanstvenoj komunikaciji.	Umjerena do dobra konceptualna kvaliteta i unutarnja koherentnost; umjerena neizvjesnost u pogledu sveobuhvatnosti izvora i velika neizvjesnost u pogledu učinkovitosti/primjenjivosti do provođenja empirijske validacije.
[S26] Pereira i sur., 2026; Portugal/ Brazil	Mješoviti sustavni pregled s konvergentnom segregiranom sintezom; n = 11	Nadzirani i nenadzirani ML, BERT-NER, Random Forest, SVM, stabla odlučivanja, objašnjivi UI, ChatGPT, uslužni roboti te modeli za rješavanje pogrešaka u primjeni lijekova, stresa i profesionalnog sagorijevanja	Kliničko odlučivanje i prosuđivanje; sekundarno: Ljudski nadzor; Sigurnost pacijenata; Upravljanje implementacijom i vođenje.	Moguća poboljšanja u pogledu radnog opterećenja, profesionalnog sagorijevanja, skrbi usmjerene na pacijenta, autonomije, suradnje i učinkovitosti bila su uvjetovana odgovornom implementacijom.	Umjerena do visoka kvaliteta. Velika važnost pridana je mapiranju praktičnog okruženja i implementacije; umjerena do mala važnost uzročnoj učinkovitosti i ishodima za pacijente.
[S27] Bose i sur., 2026; Indija	Strukturirani narativni pregled	Strojno učenje, duboko učenje, NLP, CDSS, prediktivna analitika, sustavi ranog upozoravanja, učenje s potkrepljenjem, nadzorne ploče i inteligentno praćenje	Kliničko odlučivanje i prosuđivanje; sekundarno: Sigurnost pacijenata; Upravljanje implementacijom i vođenje; Ljudski nadzor.	Održivo usvajanje ovisi o objašnjivim i kontekstualno osjetljivim sustavima, uključenosti kliničara, pismenosti u području umjetne inteligencije UI-ja te integraciji računalne preciznosti s kliničkim prosuđivanjem i empatijom.	Umjerena do niska kvaliteta; umjeren do visok rizik od pristranosti pri odabiru i interpretaciji. Korisno za mapiranje, tematsku konvergenciju i profesionalne implikacije; smanjena važnost pridana je tvrdnjama o učinkovitosti i kliničkim ishodima.

Autor, godina; država	Dizajn; uzorak ili br.studija	UI tehnologija/funkcija	Domene	Glavni nalazi	Metodološka kvaliteta / interpretativna težina
[S28] Connor i Kagan, 2026; Sjedinjene Države	Narativni pregled	UI, telemedicina, virtualno sestrinstvo, udaljeno praćenje pacijenata, integracija medicinskih uređaja te paketi alata i okviri za procjenu tehnologije	Sigurnost pacijenata; sekundarno: Upravljanje implementacijom i vođenje; Kliničko odlučivanje i prosuđivanje; Ljudski nadzor	Voditelji u sestrinstvu trebali bi prijeći iz uloge pasivnih primatelja u ulogu zagovornika i arhitekata digitalnog ekosustava, osiguravajući pritom prisutnost, pravednost i individualiziranu skrb.	Umjerena do niska kvaliteta s obzirom na to da se radi o narativnom preglednom radu. Umjerena važnost pridana je informatičkim kompetencijama, vođenju, upravljanju i implementaciji usmjerenoj na čovjeka; mala važnost učinkovitosti i ishodima za pacijente.
[S29] Schultz i sur., 2026; Sjedinjene Države	Pretražni pregled; n = 49	LLM-ovi, ML, NLP, prediktivna analitika, AI-CDSS, nosiva tehnologija i senzori, udaljeno praćenje, robotika, proširena stvarnost, aplikacije i mrežni alati, klinički algoritmi te upravljački okviri	Sigurnost pacijenata; sekundarno: Upravljanje implementacijom i vođenje; Kliničko odlučivanje i prosuđivanje; Ljudski nadzor	Proizišlo je pet tema: sigurnost pacijenata; povjerenje, prihvaćanje i integracija; obrazovna spremnost; kliničko odlučivanje i postavljanje dijagnoze; te angažman pacijenata, autonomija i etika. Potrebna je oprezna, participativna implementacija kako bi se održali sigurnost, kvaliteta i povjerenje.	Umjerena do niska kvaliteta: opsežno izvještavanje i mapiranje podataka, ali ograničeno pretraživanje, permisivni kriteriji i izostanak kritičke procjene smanjuju robusnost. Umjerena važnost pridana je mapiranju tema, primjena i nedostataka u istraživanjima.
[S30] Uchmanowicz i sur., 2026; međunarodno	Strukturirani narativni pregled	ChatGPT i veliki jezični modeli	Kliničko odlučivanje i prosuđivanje; sekundarno: Upravljanje implementacijom i vođenje; Sigurnost pacijenata; Ljudski nadzor.	LLM-ove treba koristiti kao pomoćne alate, uz obvezno upravljanje i verifikaciju.	Umjerena do niska kvaliteta. Umjerena važnost pridana je upravljanju i nadzoru; mala važnost učinkovitosti.
[S31] Ball Dunlap i sur., 2026; Sjedinjene Države	Strukturirana normativna etička analiza	Strojno učenje, generativni UI, NLP i robotika; prediktivna analitika, podrška odlučivanju, dokumentiranje, obrada informacija, fizička asistencija i edukacijska simulacija, dok kliničko prosuđivanje te moralna i relacijska odgovornost ostaju na medicinskoj sestri	Kliničko odlučivanje i prosuđivanje; sekundarno: Ljudski nadzor; Sigurnost pacijenata;Upravljanje implementacijom i vođenje;	Rad razlikuje tehničke zadatke od moralne i humanističke biti sestrinstva te postavlja medicinsku sestru kao moralnog arbitra UI-ja	Umjerena do dobra kvaliteta s obzirom na to da se radi o normativnoj analizi; umjeren rizik od pristranosti pri odabiru izvora i ovisnosti o stručnom prosuđivanju. Velika važnost pridana je etici, upravljanju, ljudskom nadzoru i implikacijama; umjerena tvrdnjama o kliničkoj učinkovitosti.
[S32] Honda i sur., 2026; Japan	Konceptualni okvir	UI za predviđanje rizika, podršku odlučivanju, komunikaciju, udaljeno praćenje i dokumentiranje; rano prepoznavanje potreba obitelji, personalizirana edukacija i upućivanje na daljnju obradu, rutinska digitalna potpora te procjena ishoda usmjerenih na obitelj.	Kliničko odlučivanje i prosuđivanje; sekundarno: Ljudski nadzor; Sigurnost pacijenata;Upravljanje implementacijom i vođenje;	Politika i strateški okvir za integraciju UI-ja u zdravstvenu njegu obitelji.	Dobra konceptualna kvaliteta; razumna metodološka transparentnost za analizu politika, ali uz rizik od interpretativne selekcije i neutvrđene empirijske valjanosti. Velika važnost pridana je domenama politike, upravljanju, pravednosti i nadzoru.
[S33] Uygun Ilikhan i sur., 2026; Turska	Deskriptivna komparativna presječna studija; n = 260	Klinički UI i sustavi podržani UI-jem bez bližih specifikacija; podrška za dijagnozu, liječenje, upravljanje lijekovima, radno opterećenje i donošenje odluka.	Kliničko odlučivanje i prosuđivanje; sekundarno: Sigurnost pacijenata; Upravljanje implementacijom i vođenje; Ljudski nadzor.	Stavovi prema UI-ju općenito su bili pozitivni, ali ambivalentni, usprkos ograničenom znanju i praktičnom iskustvu. Većina sudionika zatražila je edukaciju te je umjetnu inteligenciju vidjela kao podršku, a ne kao zamjenu za ljudsko prosuđivanje. Privatnost, sigurnost podataka, pogrešna dijagnoza i pravna odgovornost bili su glavni razlozi za zabrinutost.	Umjerena kvaliteta. Umjerena do velika važnost pridana je stavovima i spremnosti; mala važnost ishodima.

Autor, godina; država	Dizajn; uzorak ili br.studija	UI tehnologija/funkcija	Domene	Glavni nalazi	Metodološka kvaliteta / interpretativna težina
[S34] Takeuchi i sur., 2025; Japan	Strateški usmjeren strukturirani narativni pregled; n = 31	Strojno učenje, NLP, prediktivni modeli, dokumentiranje i simulacija	Upravljanje implementacijom i vođenje; sekundarno: Kliničko odlučivanje i prosuđivanje; Ljudski nadzor; Sigurnost pacijenata	Ui bi trebao integrirati aspekte prešutnog znanja, a ne ih svoditi isključivo na podatke koji se mogu kodificirati.	Umjerena do niska kvaliteta. Umjerena važnost pridana je upravljanju i prešutnom znanju; mala važnost ishodima.
[S35] Si and Kwon, 2026; Južna Koreja	Pretražni pregled; n = 42	Chatbotovi, LLM-ovi, digitalna terapeutika i sustavi za podršku kliničkom odlučivanju	Upravljanje implementacijom i vođenje; sekundarno: Ljudski nadzor; Kliničko odlučivanje i prosuđivanje; Sigurnost pacijenata	Potencijalne koristi za pristup skrbi, upravljanje simptomima i rizicima bile su uvjetovane upravljanjem i zaštitom odnosa pružanja skrbi.	Umjerena kvaliteta. Umjerena do velika važnost pridana je mapiranju i implikacijama; nije prikladno za tvrdnje o učinkovitosti bez verifikacije cjelokupnog korpusa pregledanih radova.
[S36] Odame i sur., 2026; Gana/ Njemačka/ Sjedinjene Države	Krovni pregled sustavnih pregleda; n = 27	Strojno učenje, duboko učenje, umjetne neuronske mreže, NLP, chatbotovi, konverzacijski agenti, LLM-ovi, nosivi/mobilni UI, i algoritamski sustavi za donošenje odluka	Upravljanje implementacijom i vođenje; sekundarno: Sigurnost pacijenata Ljudski nadzor; Kliničko odlučivanje i prosuđivanje;	Proizišle su četiri teme: detekcija i stratifikacija rizika; digitalni pristup i angažman; etičke i strukturne ranjivosti; te veća vrijednost hibridnih modela usmjerenih na čovjeka. Okvir etike skrbi naglasio je odnose, dostojanstvo, pravednost i osjetljivost na potrebe korisnika.	Umjerena do niska kvaliteta. Umjerena važnost pridana je konvergenciji, upravljanju, etici skrbi i ljudskom nadzoru; mala važnost kvantitativnoj učinkovitosti, zbirnim podacima i usporedbama među tehnologijama.
[S37] Šimunic i sur., 2026; Hrvatska	Struktirurani narativni pregled; n = 14	Ui i strojno učenje; simulacija, virtualna stvarnost i mikro-učenje kao obrazovni pristupi povezani s pismenošću u području UI-ja	Kliničko odlučivanje i prosuđivanje; sekundarno: Upravljanje implementacijom i vođenje; Sigurnost pacijenata; Ljudski nadzor.	Integracija digitalnih i UI kompetencija u obrazovanje medicinskih sestara ključna je za kvalitetu i sigurnost u onkologiji. Fleksibilni, verificirani i interdisciplinarni programi trebali bi podupirati kritičko razmišljanje, kontinuiranu evaluaciju i etički odgovornu primjenu.	Umjerena do niska kvaliteta. Umjerena do mala važnost. Prikladno za mapiranje kompetencija, prepreka i preporuka za implementaciju.
[S38] Mohammed i sur., 2025; Saudijska Arabija/Egipat /Japan	Sustavni pregled s tematskom sintezom; n = 17	Umjetna inteligencija i strojno učenje primijenjeni na kliničko odlučivanje, operativnu učinkovitost i zadatke pružanja skrbi	Upravljanje implementacijom i vođenje; sekundarno: Ljudski nadzor; Kliničko odlučivanje i prosuđivanje; Sigurnost pacijenata	Proizišlo je pet tema: kliničko odlučivanje, etička svijest, rutinski sestrinski zadaci, algoritamska pristranost i uključivanje javnosti u regulaciju.	Privremena metodološka kvaliteta: umjerena / nije je moguće u potpunosti utvrditi. Umjerena važnost pridana je etičko-regulatornom mapiranju; važnost za snagu dokaza i preporuka tek se treba utvrditi.
[S39] Gong i sur., 2026; Kina	Pretražni pregled; n = 72	Prediktivna analitika, računalni vid, podrška odlučivanju i praćenje u stvarnom vremenu, automatizirano dokumentiranje, robotika i udaljeno praćenje; stratifikacija rizika, rano otkrivanje komplikacija, nadzor tijeka rada i sterilnosti, perioperativna potpora i postoperativno praćenje.	Kliničko odlučivanje i prosuđivanje; sekundarno: Sigurnost pacijenata; Upravljanje implementacijom i vođenje; LJudski nadzor	Primjene UI-ja pokazale su potencijalne koristi za rano otkrivanje komplikacija, učinkovitost tijeka rada i perioperativne sestrinske odluke. Dokazi su se uglavnom temeljili na pilot-studijama ili opservacijskim istraživanjima s ograničenom validacijom na velikom uzorku. Upravljanje podacima, profesionalna spremnost, integracija procesa i sestrinski nadzor bili su nužni.	Izvještavanje u skladu s PRISMA-ScR smjernicama i cjelovita strategija pretraživanja. Ograničenja: izostanak formalne kritičke procjene, izražena heterogenost i nekoliko narativnih tvrdnji koje nisu uvijek potkrijepljene primarnim podacima.

Autor, godina; država	Dizajn; uzorak ili br.studija	UI tehnologija/funkcija	Domene	Glavni nalazi	Metodološka kvaliteta / interpretativna težina
[S40] Gleasman-DeSimone, 2025; Sjedinjene Države	Narativni pregled	CDSS, prediktivna analitika i dokumentiranje podržano Ui-jem; podrška za procjenu i kliničke odluke, predviđanje rizika, pojednostavljenje dokumentiranja te edukaciju pacijenata u naprednoj sestrinskoj praksi	Kliničko odlučivanje i prosuđivanje; sekundarno: Sigurnost pacijenata; Upravljanje implementacijom i vođenje; Ljudski nadzor	UI može podržati točnost dijagnoze, dokumentiranje i edukaciju pacijenata, ali nosi rizike od pristranosti, povrede privatnosti i depersonalizacije. Odgovorna integracija, edukacija, interdisciplinarna suradnja te očuvanje kliničkog prosuđivanja i ljudskih odnosa bili su nužni.	Eksplicitna metoda [pretraživanja], ali bez formalne kritičke procjene; iznimna relevantnost za upravljanje, etiku, privatnost i ljudski nadzor.
[S41] El Arab i sur., 2025; međunarodno	Integrativni pregled; n = 25	Strojno učenje, prediktivni modeli, LLM-ovi, algoritmi za uzbunjivanje, nosivi senzori, simulacije i slikovna dijagnostika podržana UI-jem; podrška odlučivanju, rano otkrivanje pogoršanja stanja pacijenta, praćenje, edukacija, personalizirano praćenje, automatizacija zadataka i predviđanje radnog opterećenja	Kliničko odlučivanje i prosuđivanje; sekundarno: Sigurnost pacijenata; Upravljanje implementacijom i vođenje; Ljudski nadzor	UI je pokazao potencijalne koristi za edukaciju, rano otkrivanje pogoršanja stanja, podršku odlučivanju, praćenje i smanjenje repetitivnih aktivnosti. Razlozi za zabrinutost uključivali su kognitivno radno opterećenje, privatnost, pristranost, pretjerano oslanjanje na tehnologiju i osiromašenje odnosa pružanja skrbi. Edukacija, etičko upravljanje, infrastruktura i profesionalni nadzor bili su nužni.	Korišteni su PRISMA, MMAT, i ROBINS-I. Dvadeset i jedna od 25 studija imala je umjeren rizik od pristranosti; heterogenost je bila velika, ali je relevantnost za sestrinstvo bila iznimno snažna.
[S42] Ozbay i sur., 2026; Turska	Deskriptivna fenomenološka kvalitativna studija; n = 18	Nespecificirane tehnologije UI-ja za praćenje, predviđanje rizika, podršku odlučivanju i personalizaciju pedijatrijske onkološke skrbi; niti jedan sustav ili algoritam nije izravno implementiran niti evaluiran	Kliničko odlučivanje i prosuđivanje; sekundarno: Sigurnost pacijenata; Upravljanje implementacijom i vođenje; Ljudski nadzor	Medicinske sestre prepoznale su potencijalne koristi UI-ja u pedijatrijskoj onkologiji, ali su istaknule implementacijske i etičke probleme te rizik od slabljenja humane komponente skrbi. Edukacija, specifične kompetencije, suradnja medicinske sestre i umjetne inteligencije te kontinuirani profesionalni nadzor bili su nužni za odgovorno usvajanje.	COREQ smjernice, namjerno uzorkovanje, zasićenje [podataka], dvostruko kodiranje, k = 0,88. Ograničenja: jednocentrična studija i samoprocjena percepcija.
[S43] Alruwaili i Paul-Chima, 2026; Saudijska Arabija i Uganda	Konceptualni okvir sa strukturiranom narativnom sintezom	Prediktivni sustavi i sustavi za podršku odlučivanju temeljeni na ML-u za stratifikaciju rizika majki i djece, rano prepoznavanje komplikacija, određivanje prioriteta intervencija te sestrinsku podršku odlučivanju u okruženjima s ograničenim resursima	Ljudski nadzor; sekundarno: Sigurnost pacijenata; Kliničko odlučivanje i prosuđivanje; Upravljanje implementacijom i vođenje	Okvir postavlja pravednost, lokalnu validaciju i odnos između medicinske sestre i pacijenta kao preduvjete za implementaciju UI-ja. Upravljanje na razini sestrinstva i zajednice, suoblikovanje, digitalna inkluzija, transparentnost podataka, razvoj kompetencija i longitudinalno praćenje nužni su za sigurnu i održivu primjenu u okruženjima s ograničenim resursima.	Umjerena metodološka kvaliteta za konceptualni okvir; umjeren do visok rizik od pristranosti pri odabiru izvora, ali dobra konceptualna transparentnost. Velika važnost pridana je upravljanju, pravednosti, implementaciji i nadzoru; umjerena izgradnji teorije.
[S44] Alanazi, 2026; Saudijska Arabija	Deskriptivna fenomenološka kvalitativna studija	Klinička podrška odlučivanju omogućena UI-jem za trijažu, pogoršanje stanja, sepsu i eskalaciju skrbi; fokus na kliničkom prosuđivanju, eskalaciji, profesionalnoj odgovornosti, identitetu i etičkom sukobu	Kliničko odlučivanje i prosuđivanje; sekundarno: Sigurnost pacijenata; Upravljanje implementacijom i vođenje; Ljudski nadzor	UI sustavi doživljeni su kao korisni, ali opterećujući: upozorenja su se morala interpretirati usporedo s kliničkom procjenom i nisu zamijenila sestrinsko prosuđivanje. UI je intenzivirao rad na interpretaciji podataka, odgovornost pri donošenju odluka o eskalaciji skrbi te etički sukob u situacijama kada su algoritamske preporuke bile u sukobu s procjenom usmjerenom na pacijenta.	Umjerena kvaliteta. Umjerena do velika važnost pridana je iskustvima, odgovornosti, ljudskom nadzoru i upravljanju; nije prikladno za procjenu učinkovitosti ili sigurnosti.

Napomena

NR = nije navedeno. Interpretativna važnost označava prikladnu upotrebu doprinosa u narativnoj sintezi i ne predstavlja uobičajeni kvantitativni bodovni sustav primjenjiv na različite nacrte studija.

S = sekvencijski identifikator uključene publikacije (S1–S44); ne odgovara numeraciji referenci u samom rukopisu

Dopunska tablica S2. Integrativna sinteza analitičkih domena

Domena	Br.	Podudarajući dokazi	Uvjeti / odstupanja	Rizici i razlozi za zabrinutost	Nedostatci	Implikacije
Kliničko odlučivanje i prosuđivanje	44	Podrška za prikupljanje, sintezu i interpretaciju informacija; predviđanje i određivanje prioriteta; rano upozoravanje i podrška za situacijsku svjesnost	Korist ovisi o kvaliteti i potpunosti podataka, razumljivosti izlaznih rezultata, integraciji u tijek rada te verifikaciji u odnosu na kliničku sliku.	Pristranost automatizacije, pogreške ili halucinacije, pretjerano oslanjanje, gubitak vještina i neprimjereno prenošenje odgovornosti	Mali broj studija mjeri stvarne odluke, prikladnost, komparativnu točnost ili učinke na kliničko zaključivanje tijekom vremena.	Koristiti umjetnu inteligenciju kao provjerljivu, kontekstualiziranu podršku uz očuvanje profesionalnog prosuđivanja i mogućnosti odbacivanja izlaznih rezultata.
		Relevantne publikacije				
		[S1] Alves i sur., 2026; [S2] Martinez-Ortigosa i sur., 2023; [S3] Mikkonen i sur., 2025; [S4] Shah i sur., 2025; [S5] Lee i sur., 2025; [S6] Li i sur., 2026; [S7] Soddu i sur., 2025; [S8] Abu Assab i sur., 2026; [S9] Yildirim i sur., 2026; [S10] Awad i sur., 2025; [S11] Amin i sur., 2026; [S12] Cant, Ryan and Chugh, 2026; [S13] Rony i sur., 2025; [S14] Hassanein i sur., 2025; [S15] Park i sur., 2025; [S16] O'Connor i sur., 2022; [S17] Kirkland-Kyhn i sur., 2025; [S18] Nasiri i sur., 2026; [S19] Zhou i sur., 2026; [S20] Alruwaili, Paul-Chima and Nneoma, 2026; [S21] Alqaraleh i sur., 2025; [S22] Samy i sur., 2026; [S23] Park i sur., 2026; [S24] Wang i sur., 2026; [S25] Ibrahim i sur., 2026; [S26] Pereira i sur., 2026; [S27] Bose i sur., 2026; [S28] Connor & Kagan, 2026; [S29] Schultz i sur., 2026; [S30] Uchmanowicz i sur., 2026; [S31] Ball Dunlap i sur., 2026; [S32] Honda i sur., 2026; [S33] Uygun Ilikhan i sur., 2026; [S34] Takeuchi i sur., 2025; [S35] Si & Kwon, 2026; [S36] Odame i sur., 2026; [S37] Simunic i sur., 2026; [S38] Mohammed i sur., 2025; [S39] Gong i sur., 2026; [S40] Gleasman-DeSimone, 2025; [S41] El Arab i sur., 2025; [S42] Ozbay i sur., 2026; [S43] Alruwaili and Paul-Chima, 2026; [S44] Alanazi, 2026.				
Sigurnost pacijenata	44	Potencijal za rano prepoznavanje pogoršanja stanja, kontinuirano praćenje, identifikaciju rizika te smanjenje propusta ili kašnjenja	Koristi zahtijevaju lokalnu validaciju, kvalitetu podataka, odgovarajuće granične vrijednosti, organizacijski odgovor na upozorenja te praćenje nakon uvođenja sustava	lažno pozitivni i lažno negativni rezultati, zamor od alarma, pristranost podataka, netransparentnost, nepravednost i lažni osjećaj sigurnosti	Ograničeni uzročno-posljedični dokazi o štetnim događajima, smrtnosti, pogreškama u primjeni lijekova i drugim ishodima osjetljivim na sestrinsku skrb	Procijeniti i tehničku i sociotehničku sigurnost, uključujući pogreške, radno opterećenje, nenamjerne posljedice i pravednost
		Relevantne publikacije				
		[S1] Alves i sur., 2026; [S2] Martinez-Ortigosa i sur., 2023; [S3] Mikkonen i sur., 2025; [S4] Shah i sur., 2025; [S5] Lee i sur., 2025; [S6] Li i sur., 2026; [S7] Soddu i sur., 2025; [S8] Abu Assab i sur., 2026; [S9] Yildirim i sur., 2026; [S10] Awad i sur., 2025; [S11] Amin i sur., 2026; [S12] Cant, Ryan and Chugh, 2026; [S13] Rony i sur., 2025; [S14] Hassanein i sur., 2025; [S15] Park i sur., 2025; [S16] O'Connor i sur., 2022; [S17] Kirkland-Kyhn i sur., 2025; [S18] Nasiri i sur., 2026; [S19] Zhou i sur., 2026; [S20] Alruwaili, Paul-Chima and Nneoma, 2026; [S21] Alqaraleh i sur., 2025; [S22] Samy i sur., 2026; [S23] Park i sur., 2026; [S24] Wang i sur., 2026; [S25] Ibrahim i sur., 2026; [S26] Pereira i sur., 2026; [S27] Bose i sur., 2026; [S28] Connor & Kagan, 2026; [S29] Schultz i sur., 2026; [S30] Uchmanowicz i sur., 2026; [S31] Ball Dunlap i sur., 2026; [S32] Honda i sur., 2026; [S33] Uygun Ilikhan i sur., 2026; [S34] Takeuchi i sur., 2025; [S35] Si & Kwon, 2026; [S36] Odame i sur., 2026; [S37] Simunic i sur., 2026; [S38] Mohammed i sur., 2025; [S39] Gong i sur., 2026; [S40] Gleasman-DeSimone, 2025; [S41] El Arab i sur., 2025; [S42] Ozbay i sur., 2026; [S43] Alruwaili i Paul-Chima, 2026; [S44] Alanazi, 2026.				
Upravljanje implementacijom i vođenje	43	Edukacija, pismenost u području umjetne inteligencije, uključenost medicinskih sestara, upravljanje podacima, integracija u tijek rada i jasna podjela odgovornosti ponavljaju se kao uvjeti za usvajanje.	Varijabilna profesionalna i organizacijska spremnost; prihvaćanje je uvjetovano korisnošću, povjerenjem, resursima, interoperabilnošću i podrškom vodstva	Implementacija odozgo prema dolje, neodređena odgovornost, neadekvatna edukacija, ograničena transparentnost, povećano radno opterećenje i neusklađenost s praksom	Mali broj modela implementacije prospektivno je evaluiran; podaci o troškovima, održivosti, pravednosti i dugoročnom održavanju su ograničeni.	Dodijeliti sestrinskom vodstvu aktivnu ulogu u odabiru sustava, suoblikovanju, evaluaciji, edukaciji i nadzoru.
		Relevantne publikacije				
		[S1] Alves i sur., 2026; [S2] Martinez-Ortigosa i sur., 2023; [S3] Mikkonen i sur., 2025; [S4] Shah i sur., 2025; [S5] Lee i sur., 2025; [S6] Li i sur., 2026; [S8] Abu Assab i sur., 2026; [S9] Yildirim i sur., 2026; [S10] Awad i sur., 2025; [S11] Amin i sur., 2026; [S12] Cant, Ryan and Chugh, 2026; [S13] Rony i sur., 2025; [S14] Hassanein i sur., 2025; [S15] Park i sur., 2025; [S16] O'Connor i sur., 2022; [S17] Kirkland-Kyhn i sur., 2025; [S18] Nasiri i sur., 2026; [S19] Zhou i sur., 2026; [S20] Alruwaili, Paul-Chima and Nneoma, 2026; [S21] Alqaraleh i sur., 2025; [S22] Samy i sur., 2026; [S23] Park i sur., 2026; [S24] Wang i sur., 2026; [S25] Ibrahim i sur., 2026; [S26] Pereira i sur., 2026; [S27] Bose i sur., 2026; [S28] Connor & Kagan, 2026; [S29] Schultz i sur., 2026; [S30] Uchmanowicz i sur., 2026; [S31] Ball Dunlap i sur., 2026; [S32] Honda i sur., 2026; [S33] Uygun Ilikhan i sur., 2026; [S34] Takeuchi i sur., 2025; [S35] Si & Kwon, 2026; [S36] Odame i sur., 2026; [S37] Simunic i sur., 2026; [S38] Mohammed i sur., 2025; [S39] Gong i sur., 2026; [S40] Gleasman-DeSimone, 2025; [S41] El Arab i sur., 2025; [S42] Ozbay i sur., 2026; [S43] Alruwaili and Paul-Chima, 2026; [S44] Alanazi, 2026.				

** Publikacija može doprinijeti više od jedne domene; stoga se dobiveni zbrojevi međusobno ne isključuju. Relevantnost je utvrđena na temelju dostupnog kodiranja središnjosti za svaku domenu.*

Napomena. S = sekvencijski identifikator uključene publikacije (S1–S44); ne odgovara numeraciji referenci u samom rukopisu.