

VILNIAUS UNIVERSITETAS
EKONOMIKOS IR VERSLO ADMINISTRAVIMO FAKULTETAS

KOKYBĖS VADYBOS MAGISTRO PROGRAMA

Magistrantės Vaivos Patamsytės
MAGISTRO BAIGIAMASIS DARBAS

DIRBTINIO INTELEKTO ĮTAKA SVEIKATOS PRIEŽIŪROS PASLAUGŲ KOKYBEI	THE IMPACT OF ARTIFICIAL INTELLIGENCE ON THE QUALITY OF HEALTHCARE SERVICES
--	--

Darbo vadovas: prof. Dalius Serafinas

Vilnius, 2024

TURINYS

<i>IVADAS</i>	5
<i>1. LITERATŪROS ANALIZĖ</i>	7
1.1. Dirbtinio intelekto taikymo būdai sveikatos priežiūros srityje.....	7
1.1.1. Dirbtinis intelektas klinikinėje diagnostikoje	9
1.1.2. Dirbtinio intelekto naudojimas personalizuotoje medicinoje.....	11
1.1.3. Dirbtinio intelekto naudojimas administracijoje	12
1.2. Dirbtinio intelekto pagalba sprendžiami sveikatos priežiūros iššūkiai	12
1.2.1. Sveikatos priežiūros darbuotojų trūkumas	13
1.2.2. Ligų valdymas ir prevencija	14
1.2.3. Psichinė sveikata ir gerovė	16
1.3. Sveikatos priežiūros paslaugų kokybė.....	17
1.4. Dirbtinis intelektas ir sveikatos priežiūros kokybė.....	19
<i>2. TYRIMO APRAŠYMAS IR METODOLOGIJA</i>	21
2.1. Empirinio tyrimo metodologija	21
2.2. Empirinio tyrimo metodika	22
2.3. Klausimyno sudarymo principas	23
2.4. Tyrimo imtis	26
2.5. Tyrimo eiga.....	27
<i>3. REZULTATAI IR JŲ ANALIZĖ</i>	28
3.1. Dirbtinio intelekto panaudojimo sritys	28
3.2. Dirbtinio intelekto poveikio tipai	30
3.3. Dirbtinio intelekto įtaka sveikatos priežiūros paslaugos kokybei	34
3.4. Tyrimo rezultatų apibendrinimas.....	38
<i>IŠVADOS IR PASIŪLYMAI</i>	42
<i>SANTRAUKA</i>	52
<i>SUMMARY</i>	54
<i>PRIEDAI</i>	56

Lentelių sąrašas

1 Lentelė. Ekspertų charakteristika.

2 Lentelė. Klausimynas pusiau struktūruotam interviu.

3 Lentelė. Respondentų charakteristika.

4 Lentelė. Kodų lentelė DI panaudojimo kategorijos konceptų sudarymui.

5 Lentelė. Kodų lentelė DI poveikio tipų konceptų sudarymui.

6 Lentelė. Kodų lentelė DI įtakos sveikatos priežiūros paslaugos kokybei konceptų sudarymui.

7 Lentelė. Kryžminis atvejų palyginimas

Paveikslų sąrašas

1 Paveikslas. Dirbtinis intelektas ir jo sritys.

2 Paveikslas. Dirbtinio intelekto panaudojimas sveikatos priežiūros paslaugas teikiančiose organizacijose.

3 Paveikslas. Tikslioji medicina.

4 Paveikslas. Dirbtinio intelekto įtaka gyventojų psichinei sveikatai.

5 Paveikslas. Sveikatos priežiūros paslaugų kokybės vertinimas iš sveikatos priežiūros įstaigos ir paciento perspektyvos.

6 Paveikslas. Tyrimo schema.

7 Paveikslas. Europoje diagnostikai naudojamų dirbtinio intelekto technologijų įtaka sveikatos priežiūros paslaugų kokybei.

ĮVADAS

Dirbtinis intelektas (DI) yra įvardinamas kaip vienas iš būdų padėsiančių spręsti šiuolaikinės sveikatos priežiūros sistemos iššūkius, tokius kaip: senstanti visuomenė, medicinos personalo trūkumas, efektyvumo spragos, išaugę kaštai sveikatos priežiūrai bei nevienodas sveikatos paslaugų prieinamumas (Karim Lekadir, Quaglio Gianluca, Tselioudis Anna, 2022). DI sistemų taikymas leidžia analizuoti didelius duomenų kiekius, atpažinti modelius, numatyti paciento sveikatos būklės pokyčius ir netgi automatizuoti tam tikrus sprendimų priėmimo procesus. Nors DI panaudojimo galimybės sveikatos priežiūroje sparčiai plečiasi, trūksta mokslinių duomenų apie DI įtaką sveikatos priežiūros paslaugų kokybei.

Viena iš svarbiausių ir daugiausia dėmesio sulaukiančių DI panaudojimo sričių yra ankstyva ligos diagnozė ir prognozė. DI algoritmai gali analizuoti didelius duomenų rinkinius, įskaitant pacientų įrašus, genetinę informaciją, medicininius vaizdus ir tiksliai nustatyti vėžinius susirgimus (Esteva et al., 2017) bei širdies ir kraujagyslių ligas (Zhou et al., 2021). Šie DI valdomi įrankiai gali padėti sveikatos priežiūros specialistams tiksliau ir greičiau parinkti diagnozę, o tai turėtų daryti teigiamą įtaką pacientų būklės gerinimui. DI taip pat gali prisidėti individualizuoto gydymo parinkimui: mašininio mokymosi algoritmai gali sėkmingai analizuoti paciento ligos istorijos duomenis, genetinę informaciją ir rekomenduoti efektyviausius gydymo būdus atsižvelgiant į individualias paciento savybes (Topol, 2019). Sveikatos priežiūros įstaigų administravimo srityje DI sprendimai supaprastina užduotis, tokias kaip susitikimų planavimas, sąskaitų išrašymas, pretenzijų apdorojimas, todėl specialistai gali sutelkti dėmesį į pacientų priežiūrą (Rajkomar et al., 2019). Didėjant nuotolinės medicinos poreikiui, DI gali prisidėti prie veiksmingo nuotolinio stebėjimo naudojant nešiojamus prietaisus su juose įdiegtomis programomis, leidžiančiomis stebėti gyvybines funkcijas ir dalytis duomenimis su sveikatos priežiūros paslaugų teikėjais realiuoju laiku, taip gerinant ligų valdymą bei mažinant asmeninių apsilankymų poreikį (Barnett et al., 2018). Vis dėlto, nepaisant šių privalumų, DI taikymas sveikatos priežiūroje susiduria su etiniais, teisiniais ir praktiniais iššūkiais, kurie gali apriboti jo veiksmingumą. DI sistemoms tampant vis labiau paplitusioms sveikatos priežiūros srityje, būtina įvertinti jų poveikį sveikatos priežiūros paslaugoms.

DI vertinimas sveikatos priežiūros paslaugų kokybės kontekste yra svarbus ne tik siekiant užtikrinti, kad naujosios technologijos būtų naudojamos veiksmingai, bet ir išlaikyti etinius standartus ir pacientų pasitikėjimą. Vertinimas turėtų būti atliekamas nuolat, nes DI

technologijos ir jų taikymas sparčiai vystosi. Jis turėtų apimti algoritmų tikslumą, jų priimamų sprendimų skaidrumą, galimą šališkumą ir poveikį paciento priežiūrai (Feng et al., 2022). Kokybės vertinimas taip pat turėtų atsižvelgti į tai, kokią įtaką DI sistemos daro darbo procesams ir darbuotojų darbo krūviui (Do et al., 2020), taip pat pacientų patirčiai ir pasitenkinimui sveikatos priežiūros paslaugomis (Kaidar-Person et al., 2023). Atsakingas DI naudojimas reiškia, kad technologijos diegiamos atsižvelgiant į visus aspektus - nuo pacientų saugumo iki duomenų apsaugos ir etinės atsakomybės.

Darbo problema – trūksta duomenų apie dirbtinio intelekto technologijų įtaką sveikatos priežiūros paslaugoms klinikinėje praktikoje.

Darbo tikslas – nustatyti kaip DI sistemų naudojimas daro įtaką sveikatos priežiūros paslaugų kokybei dėl diagnozės tikslumo, gydymo ir resursų optimizavimo.

Darbo uždaviniai :

1. Įvertinti DI panaudojimo poveikį diagnozės tikslumui, gydymui, bei resursų optimizavimui;
2. Įvertinti kaip DI naudojimo poveikis daro įtaką sveikatos priežiūros paslaugų kokybei.

Darbo metodai:

Tyrimo duomenys surinkti pusiau struktūruoto interviu metodu. Interviu turinio analizė atlikta iš pavienių nuomonių sukuriant konceptus ir pateikiant DI įtakos sveikatos priežiūros kokybei schemą.

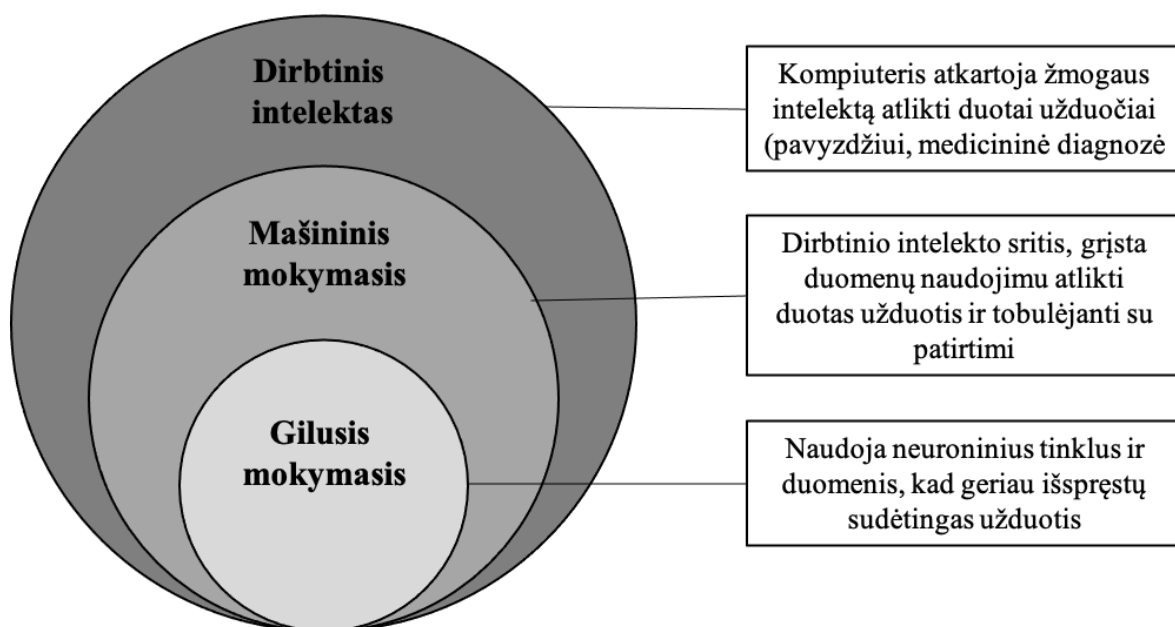
Darbo struktūra:

Darbas suskirstytas į tris dalis: pirmoje dalyje pateikiama literatūros analizė atsižvelgiant DI panaudojimą sveikatos priežiūros srityje ir sveikatos priežiūros paslaugų kokybės vertinimą, antroje dalyje yra pateiktas tyrimo modelis ir metodika, trečioje atlikta tyrimo analizė ir pateikti tyrimo rezultatai. Tyrimo rezultatai yra apibendrinti išvadose ir pasiūlymuose.

1. LITERATŪROS ANALIZĖ

1.1. Dirbtinio intelekto taikymo būdai sveikatos priežiūros srityje

Dirbtinis intelektas (DI) priklauso kompiuterinio mokslo disciplinai, kuri daugiausia dėmesio skiria programų, leidžiančių mašinoms suprasti ir imituoti žmogaus elgesį ir mąstymą, kūrimui. Dažniausiai tai reiškia „mašinos gebėjimą apibendrinti mokymąsi, kad būtų galima efektyviai savarankiškai atlikti sudėtingas užduotis“ ir apima dvi pagrindines sritis: mašininį mokymąsi (*ang. machine learning*) ir gilų mokymąsi (*ang. deep learning*) (Gupta et al., 2022) (Paveikslas 1).




Paveikslas 1. **Dirbtinis intelektas ir jo sritys.** Parengta pagal Europos Parlamento studiją „Dirbtinis intelektas medicinoje“ (Karim Lekadir, Quaglio Gianluca, Tselioudis Anna, 2022).

Mašininis mokymasis priskiriamas DI sričiai, kurioje kompiuteriai, naudodami sudėtingus skaičiavimo ir statistinius algoritmus, greitai ir efektyviai analizuoja duomenų rinkinius. Mašininis mokymasis gali būti suskirstytas į tris tipus pagal mokymosi būdą: (1) prižiūrimą mokymąsi (*ang. supervised learning*), grįstą anksčiau pažymėtų duomenų rinkinių analize, siekiant sukurti ateities įvykių prognozavimo modelius; (2) neprižiūrimą mokymąsi (*ang. unsupervised learning*), kai duomenų rinkinys anksčiau nebuvo suskirstytas į kategorijas ir modeliais siekiama nustatyti paslėptus ryšius; (3) mokymosi pastiprinimu (*ang. reinforcement learning*), grįstu atlygio sistema, kurioje sąveika su sistemos aplinka sukelia

teigiamą arba neigiamą pastiprinimą (Gupta et al., 2022). DI modelis išmoksta geriausiai veikti tam tikroje aplinkoje per bandymus ir klaidas, remiantis pasikartojančia sąveika su teigiamais pastiprinimais. Pastaruoju metu daugiausia dėmesio yra skiriama gilaus mokymosi sričiai, kai mokymasis yra panašus į žmogaus smegenų naudojamus neuroninius tinklus, kurie padėtų išskirti prasmingus modelius kompleksiniame duomenų rinkinyje. Neuroniniai tinklai, panašūs į žmogaus neuronų jungtis, sudaro gilaus mokymosi šerdį ir paverčia ją didelio našumo atpažinimo sistema. Giluminio mokymosi sistema yra dažnai laikoma vaizdų atpažinimo standartu ir naudoja funkciją kurti tinklus, reaguojančius į vizualinius įvedinius (Sermesant et al., 2021). Gilusis mokymasis šiuo metu yra labiausiai pažengusi mašininio mokymosi šaka, kuri gali automatiškai išmokti sudėtingų ir patikimų funkcijų iš neapdorotų duomenų, nereikalaujant inžinerinių algoritmų. Giluminis mokymasis turi akivaizdų pranašumą apjungiant ir visapusiškai išnaudojant biomedicininis duomenis, tokius kaip medicininiai vaizdai, elektroniniai sveikatos duomenys, genomo tyrimai, siekiant gerinti suteikiamų sveikatos priežiūros paslaugų kokybę (Yang et al., 2021).

Medicinos mokslų sukurta informacija apima labai platų spektrą ir sparčiai auga apimtimi ir įvairove. Lygiagrečiai auga ir DI technologijų pramonė medicinoje, kurios vystyme dalyvauja privatus verslas, akademinė bendruomenė bei vyriausybės. DI panaudojimas teikiant sveikatos priežiūros paslaugas yra labai platus: medicinos personalui padeda greičiau ir tiksliau interpretuoti vaizdus ar signalus, administracijai gerinti darbo procesus ir mažinti medicininių klaidų skaičių, o pacientams gauti personalizuotą gydymą (Topol, 2019). 2021 metų apklausos duomenimis, DI buvo naudojamas net 11-oje procentų Europos Sąjungoje veikiančių sveikatos priežiūros įstaigų, daugiausia ligų diagnostikai (30 %) ir pacientų stebėsenai (28 %) (Directorate-General for Communications Networks, 2022) (Paveikslas 2). Nors šio tyrimo duomenimis naudotojų skaičius yra pakankamai didelis, nustatyta, jog DI naudojimas apsiribojo tik keliais skyriais ir tam tikros kvalifikacijos specialistais. Tai rodo, kad Europos Sąjungos sveikatos priežiūros įstaigos palaipsniui tampa atviros DI technologijoms, tačiau jų naudojimas išlieka ribotas. Tikimasi, kad DI technologijų integracija į medicinos praktiką sukels esminių pokyčių sveikatos priežiūros srityje.



Paveikslas 2. **Dirbtinio intelekto panaudojimas sveikatos priežiūros paslaugas teikiančiose organizacijose.** Parengta pagal Europos Komisijos 2021 metų apklausos rezultatus (Directorate-General for Communications Networks, 2022).

1.1.1. Dirbtinis intelektas klinikinėje diagnostikoje

Klinikinės diagnostikos tikslas yra nustatyti medicininės problemos priežastį ir tikslią diagnozę, kad būtų paskirtas veiksmingas gydymas. Tai gali apimti įvairius diagnostinius tyrimus, tokius kaip medicininio vizualizavimo (rentgenas, kompiuterinė tomografija, magnetinis rezonansas), kraujo tyrimai, biopsijos ir t.t. Šiuo metu aktualiausias DI panaudojimas klinikinėje diagnostikoje yra automatizuojant vaizdo analizę dermatologijos, radiologijos, patologijos srityse bei signalų, tokių kaip elektrokardiogramos, apdorojime.

Radiologijoje viena iš svarbiausių DI taikymo sričių yra vaizdų analizė. DI yra laikomas optimizavimo priemone, padedančia radiologui aptikti įtartinus radinius, nustatyti diagnozę ir sukurti individualų paciento ligos išrašą siekiant sumažinti diagnostikos klaidų skaičių (Pesapane et al., 2018). 2019 metais publikuotoje meta-analizėje nustatyta, jog giluminio mokymosi programinės įrangos parodymai prilygo gydytojų radiologų interpretacijų rezultatams vaizdinės diagnostikos srityje (Liu et al., 2019). Tai rodo, kad DI technologijos gali būti naudojamos kiekybiniam medicinos vaizdų vertinimui. Automatizuotos DI sistemos gali

perimti dalį rutininių užduočių, tokių kaip pirminis vaizdų vertinimas arba standartinių ataskaitų ruošimas. Papildomai DI įrankiai gali identifikuoti galimai anomalius vaizdus, į kuriuos radiologas turėtų atkreipti dėmesį (Peng & Wang, 2021). Vienas iš tokių DI produktų yra cvi42 – širdies ir kraujagyslių vaizdo gavimo platforma, atliekanti medicininių vaizdų segmentavimą ir naudojama daugiau nei 90-yje šalių.

Skaitmeninėje patologijoje DI yra taikomas įvairių vaizdų apdorojimui ir klasifikavimui. Tai apima paprastas užduotis, tokias kaip objektų aptikimas ir atpažinimas, bei sudėtingesnes, tokias kaip ligų diagnozė ir prognozė (Corredor et al., 2019). DI algoritmai gali atpažinti vaizdus, kurie rodo konkrečias ligas, tokias kaip prostatos ar krūties vėžį panašiu tikslumu kaip ir patyrę patologai (Campanella et al., 2020). Skaitmeninėje patologijoje DI sistemos pagerina efektyvumą ir užkerta kelią išvengiamoms medicininėms klaidoms (Beck et al., 2011). Histologinių duomenų integravimas su kliniškai svarbia informacija yra naudojamas ligos eigos bei gydymo atsako prognozei (Bera et al., 2019). Šie DI modeliai yra kuriami siekiant prognozuoti pacientų išgyvenamumo rodiklius, remiantis skaitmeniniu būdu nustatytomis naviko savybėmis. Tokiu būdu gali būti pritaikomas personalizuotas gydymo būdas pagal patologinių rezultatų išvadas. DI taip pat atlieka svarbų vaidmenį gerinant darbo procesus patologijos laboratorijose. Automatizavus įprastas užduotis, tokias kaip preparatų skenavimas, vaizdų rūšiavimas ir pirminė diagnozė, gydytojais patologai gali skirti daugiau dėmesio sudėtingesniems atvejams (Litjens et al., 2017). DI integravimas į skaitmeninę patologiją žada revoliuciją šioje srityje, pagerindamas diagnostikos tikslumą, įvertinantis gydymo efektyvumą ir optimizuodamas laboratorijų darbo procesus.

Kardiologijos srityje perspektyviausias DI pritaikymas yra automatizuotas širdies vaizdo duomenų apdorojimas, naudojamas vertinti širdies struktūrai ir funkcijai (Johnson et al., 2018). Širdies vaizdavimo būdai: ultragarsas, širdies kompiuterinė tomografija, širdies ir kraujagyslių magnetinio rezonanso tyrimai suteikia galimybę įvertinti struktūras atliekant kompleksinius matavimus, tačiau jų žymėjimas rankiniu būdu ir vertinimas yra varginantis ir užima daug laiko. Nauji DI valdomi širdies vaizdo apdorojimo metodai leidžia gydytojams greičiau įvertinti vaizdus ir nustatyti anomalijas kasdienėje praktikoje (Sermesant et al., 2021). DI taikymas širdies ir kraujagyslių vaizdavime apima įvairių širdies struktūrų identifikavimą ir segmentavimą, pažeidimų nustatymą ir vaizdų klasifikavimą pagal skirtingas sąlygas (Seetharam et al., 2021). Automatizuota elektrokardiogramos analizė panaudojant DI palengvina ankstyvą įvairių aritmijų ir ST segmento anomalijų diagnostiką (Hannun et al., 2019). Tai leidžia pirminės sveikatos priežiūros gydytojams, kurie nėra kardiologai, užtikrintai ir greitai priimti sprendimą dėl siuntimo pas specialistą poreikio. Pažangesnės DI sistemos naudoja elektrokardiogramos rezultatus nustatyti tokias ligas kaip kairiojo skilvelio disfunkcija

ir tylus prieširdžių virpėjimas (Siontis et al., 2021). Jos remiasi gilaus mokymosi konvulciniu neuronų tinklu, sukurtu naudojant iš klinikinių įrašų gautą didelį skaitmeninių elektrokardiogramų duomenų rinkinį (Siontis et al., 2021).

Tikėtina, kad DI grįstų klinikinės diagnostikos sprendinių ateityje daugės. Mokslinių tyrimų lygmenyje yra diegiamos dar pažangesnės DI technologijos, tokios kaip kvantinis DI, siekiant pagreitinti įprastą mokymosi procesą ir pateikti greitus diagnostikos modelius (Al-Antari, 2023). Kvantiniai kompiuteriai pasižymi ženkliai didesne apdorojimo galia, todėl gali analizuoti daugybę medicininių parametrų realiuoju laiku, taip pagerindami diagnozės tikslumą. Sparčiai augant techniniam DI technologijų potencialui tampa ypatingai svarbu įvertinti jų teikiamą naudą vartotojams – klinikos personalui ir pacientui. Mokslinėje literatūroje randami tik keli tyrimai, kuriuose atkreipiamas dėmesys į tai, jog kvalifikuotų ekspertų patvirtinti DI įrankiai praktikoje neatitiko lūkesčių (Lebovitz et al., 2021). Šiuo tyrimu siekiama išsiaiškinti klinikos personalo nuomonę apie jų pačių naudojamąsias DI sistemas ir kaip jos veikia jų atliekamą darbą bei suteiktos paslaugos kokybę.

1.1.2. Dirbtinio intelekto naudojimas personalizuotoje medicinoje

Vienas iš personalizuotos medicinos tikslų yra pakeisti klinikinę praktiką iš reaktyvaus ligų gydymo į aktyvų sveikatos priežiūros valdymą, įskaitant prevencines patikras, ankstyvą gydymą bei ligų prevenciją. Naudojant mašininio mokymosi sistemas, kurios geba analizuoti elektroninius sveikatos įrašus, galima geriau numatyti diabeto, šizofrenijos bei onkologinių ligų atsiradimo tikimybę ir pagerinti klinikinės prognozes (Miotto et al., 2016). DI naudojimas personalizuotoje medicinoje siekia optimizuoti gydymo būdus pagal individualias paciento genetines savybes, gyvenimo būdą ir sveikatos istorijos duomenis. Tai ypatingai svarbu atvejais, kuomet paciento reakcija į paskirtą gydymą nėra pakankama arba pacientas kenčia nuo daugybinių lėtinių ligų. Norint parinkti personalizuotą gydymą, reikia apdoroti didelius kiekius skirtingų tyrimų rezultatų, kurie padėtų parinkti taikinius intervencijai ir individualizuotą gydymo strategiją (Parekh et al., 2023). Vienas tokių produktų yra IBM Watson kompiuterinė sistema, sveikatos priežiūros srityje naudojama analizuoti medicininius duomenis ir padėti gydytojams diagnozuoti bei priimti gydymo sprendimus (Jiang et al., 2017). Ši sistema gali būti naudinga priemone priimant sprendimus dėl krūties vėžio gydymo, ypač tuose sveikatos priežiūros centruose, kuriuose onkologijos specialistų išteklių yra riboti (Somashekhar et al., 2018). Plaučių vėžio terapijos veiksmingumo prognozavimo modeliai naudojantys gilųjį mokymąsi gali padėti onkologams individualizuoti gydymą naudojant kompiuterinės

tomografijos tyrimų nuotraukas (Li et al., 2021). Šie pavyzdžiai rodo, jog DI turi potencialą asistuoti onkologus bei radiologus onkologinių ligų gydymo gerinime.

1.1.3. Dirbtinio intelekto naudojimas administracijoje

Sveikatos priežiūros įstaigoms yra būdingas labai didelis administracinis darbo srautas, apimantis daugybę padalinių ir skirtingų specialistų. Daug laiko yra sugaištama suvedant duomenis: paciento, gydančiųjų specialistų, skirtingų tyrimų, medikamentų, administracijos, į įvairias neintegruotas informacines sistemas. Dėl organizacinės politikos ar sveikatos priežiūros draudimo reikalavimų medicinos darbuotojai turi užpildyti nemažai dokumentų, kurie yra reikalingi prieš atliekant klinikinę apžiūrą. DI naudojimas šioje srityje lyginant su pacientų gydymu ir priežiūra yra laikomas mažiau rizikingu ir gali prisidėti prie procesų efektyvinimo sveikatos priežiūros įstaigose automatizuojant medicininių įrašų valdymą ir apdorojant klinikinius duomenis (Davenport & Kalakota, 2019). Generatyvinis DI (gebantis kurti turinį) gali generuoti medicininius duomenis įskaitant elektroninius sveikatos įrašus, medicininių vaizdų aprašymus ir kitą aktualią informaciją, susijusią su sveikatos priežiūra (Singh, 2023). Šio modelio veikimo principas yra grįstas „sintetinių duomenų“ naudojimu, kurie yra gaunami apdorojant tikrus klinikinius duomenis siekiant apibendrinti tam tikras charakteristikas (Singh, 2023). Dideli kalbų modeliai, tokie kaip GPT-4, yra naudojami paruošti pacientų ligos istorijos išrašus (Patel & Lam, 2023). Šių modelių pagalba galima greitai ir tiksliai apdoroti bei interpretuoti didelius kiekius paciento duomenų, bei glaustai pateikti svarbiausią informaciją, tokią kaip paciento diagnozė ar medikamentinis gydymas. Automatizuodami šias užduotis sveikatos paslaugų teikėjai gali sutaupyti savo darbuotojų laiką bei pagerinti pacientų patirtį suteikiant paslaugas greičiau efektyviau.

1.2. Dirbtinio intelekto pagalba sprendžiami sveikatos priežiūros iššūkiai

2022 metų duomenimis, Europos Sąjungoje yra išskiriamos šios sveikatos priežiūros problemos: sveikatos priežiūros specialistų trūkumas, lėtinių ligų valdymas, vakcinacija ir prevencinė priežiūra, psichinė sveikata ir gerovė (OECD/European Union, 2022). DI technologijos gali būti naudojamos šioms problemoms spręsti ir padėti medicinos centrams teikti kokybiškas paslaugas. Tai atsispindi ir politiniame lygmenyje, nes dauguma Europos Sąjungos valstybių narių nurodo sveikatos priežiūrą kaip vieną iš pagrindinių sektorių, kuriam reikia teikti pirmenybę DI panaudojimo kontekste (Directorate-General for Communications

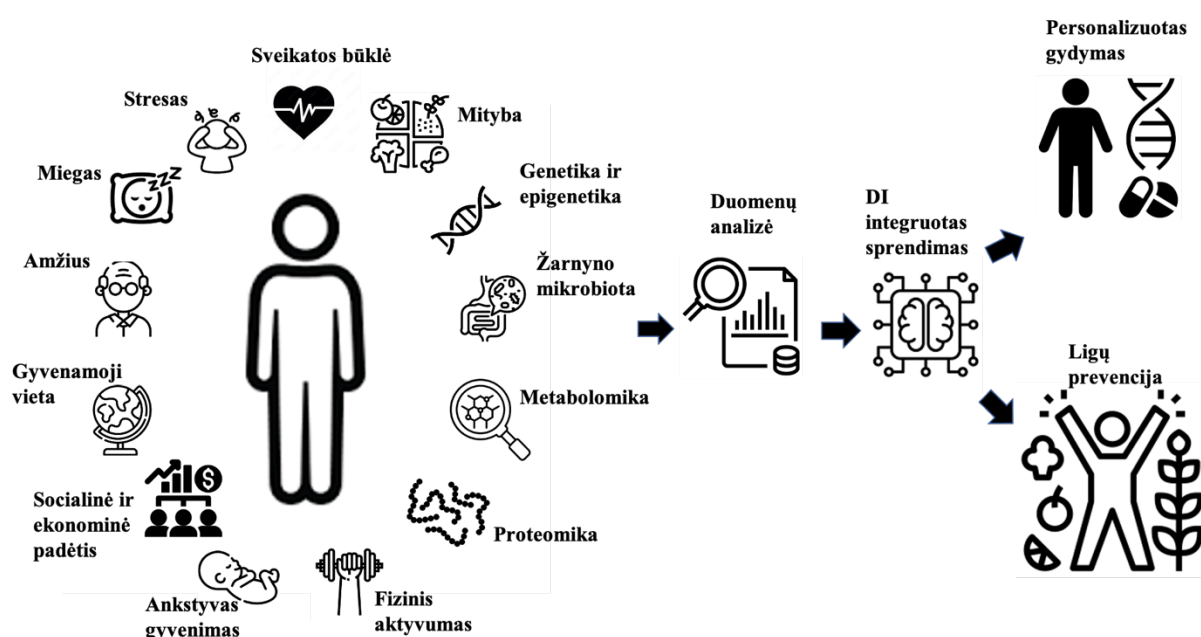
Networks, 2022). DI taikymas sveikatos priežiūros įstaigose gali padėti optimizuoti darbo procesus, sumažinti klaidų skaičių ir padidinti paslaugų kokybę (Rajkomar et al., 2019).

1.2.1 Sveikatos priežiūros darbuotojų trūkumas

DI technologijų poveikis sveikatos priežiūros specialistų darbo rinkai nebus darbo vietų suteikimas ar praradimas. Tikėtina, jog keisis pats darbo atlikimas. Pagrindinis siekis yra duoti galimybę gydytojui sutelkti dėmesį ir pagerinti pacientų priežiūrą sumažinant laiką, praleistą atliekant įprastines administracines užduotis, kurios gali užimti pusę sveikatos priežiūros specialisto darbo laiko (Tai-Seale et al., 2017). DI gali vystyti įvairią klinikinę veiklą padėsiančią sveikatos priežiūros specialistams gauti papildomą informaciją, kuri prisidėtų prie geresnių paciento gydymo rezultatų ir aukštesnės paciento priežiūros kokybės. Tai gali būti pasiekta gerinant diagnostikos greitį bei tikslumą. Taip pat padėti specialistams greičiau ir paprasčiau analizuoti duomenis, suteikti galimybę nuotoliniam stebėjimui. Visa tai pareikalaus į sveikatos priežiūros sektorių įtraukti naujų įgūdžių pakeičiant pačią medicinos darbuotojų švietimo programą - nukreipiant dėmesį nuo faktų įsiminimo ir pereinant prie mokėjimo įsisavinti naujoves, nuolatinio mokymosi ir daugiadisciplininio darbo. Šis pokytis yra aprašomas 2020-ųjų metų EIT Health ir McKinsey & Company studijoje (EIT Health and McKinsey & Company, 2020). Joje teigiama, kad skaitmeninio raštingumo, genomikos, DI mašininio mokymosi pagrindų įgūdžiai taps privalomi sveikatos priežiūroje dirbantiems specialistams. Tai bus reikalinga norint integruoti DI technologijas sveikatos priežiūros srityje, ypačingai „priekinės linijos“ darbuotojų. Tikėtina, jog atsiras naujų specialybių medicinos ir duomenų mokslo žinių sankirtoje, gebančių suformuoti kliniškai reikšmingas ir paaiškinamas DI sistemas, kuriose bus suprantamai pateikta informacija apie pacientus, padėsianti priimti klinikinius sprendimus. Taip pat reikės medicinos personalo, dalyvaujančio DI sistemų kūrime, dizainerių, besispecializuojančių žmogaus ir DI sąveikoje priimant klinikinius sprendimus ir kuriant DI integruotus procesus, duomenų architektų, kurie nustatytų kaip įrašyti, saugoti ir struktūrizuoti klinikinius duomenis, kad algoritmai galėtų pateikti reikiamą informaciją. Etikos specialistai turės apibrėžianti duomenų prieigą ir valdymą. Naujų specializacijų įvedimas iš duomenų mokslo ir inžinerijos į sveikatos priežiūros sritį taps būtinas. Sėkmingai DI integracijai bus reikalingas reikšmingas organizacijos kultūros ir pajėgumo pokytis, kuris pareikalaus plataus medikų bendruomenės, technologijų vystytojų ir politinių sprendimų priėmėjų įsitraukimo.

1.2.2. Ligų valdymas ir prevencija

Senstant visuomenei lėtinės ligos kelia susirūpinimą visame pasaulyje ir užkrauna didelę našą ne tik sveikatos priežiūros sistemai bet ir pačiai bendruomenei, todėl reikia naujos strategijos šių ligų prevencijai ir valdymui. Tikslioji medicina (*ang. precision medicine*) yra naujos kartos gyvenimo būdo modifikavimo modelis, grįstas sąveika tarp paciento biologijos, gyvenimo būdo, elgesio ir aplinkos (3 Paveikslas). Tiksliosios medicinos tikslas yra sukurti diagnozės, gydymo ir jo prognozės modelius naudojant didelius duomenų rinkinius, apimančius individualius genų funkcijų ir aplinkos pokyčius (Subramanian et al., 2020).



Paveikslas 3. **Tikslioji medicina.** Individo fiziologinės būklės ir molekulinio profilio parametrų analizė naudojama nustatyti pokyčius, vedančius prie ligos atsiradimo. Sistemine didelių duomenų analizė ir integracija sudarys sąlygas DI pagalba priimti klinikinius sprendimus, siekiant anksti nustatyti ligos riziką ir pasiūlyti prevencines priemones. Parengta pagal Subramanian ir kt. (Subramanian et al., 2020).

Tikėtina, jog DI iš esmės pakeis onkologinių ligų gydymą. Pasitelkiant DI technologijas galima paspartinti vaistų atradimą ir sėkmingai nuspėti vaistinio preparato poveikį žmogaus organizmui naudojant genominius ir cheminius duomenis (Ho, 2020). Atlygio ir bausmės principu mokomi algoritmai geba sėkmingai sukurti naują junginį vos per 21 dienas, nors įprastai šis procesas trunka maždaug metus (Zhavoronkov et al., 2019). Šiame tyrime DI

sistema buvo apmokyta naudojant taikomų cheminių struktūrų duomenų rinkinius receptoriui, kuris dalyvauja kelių tipų onkologinių ligų progresavime. Kompiuteris modeliavo prognozuojamas jungtis siekiant sumažinti nespecifinį vaistinio junginio prisijungimą prie kitų panašių receptorių. Nors tyrimo autoriai nurodė, jog reikalinga atlikti papildomą junginio optimizavimą, tai yra svarbus žingsnis link DI pagalba pagreitinto individualizuoto antivėžinio preparato kūrimo. DI atliks svarbų vaidmenį kuriant vaistų derinius ar nuspėjant kelių vaistų sinergiją bei parenkant dozių derinius visapusiškam gydymui (Ho, 2020). Tyrimai atlikti su gyvūnų modeliais parodė, jog DI geba parinkti kombinuotą terapiją daugybinės mielomos gydymui, kuri yra pastebimai geresnė lyginant su standartiniais vaistų deriniais (Rashid et al., 2018). Būtina pabrėžti, jog tik teisingai dozuojami ir derinami DI sukurti vaistiniai junginiai gali iš esmės pagerinti pacientų rezultatus, o tai reikalauja sklandaus DI diegimo visame atradimo, kūrimo ir administravimo spektre. Tai leistų integruoti personalizuotą gydymą ir pereiti prie individualizuotos sveikatos priežiūros ligų valdyme.

DI technologijos yra naudojamos infekcinių ligų prevencijai siekiant sumažinti viruso užkrečiamumo tarp žmonių tikimybę (Ashique et al., 2024). Infekcinių ligų stebėjimo bendrovė BlueDot, DI pagalba analizuojanti naujienų pranešimus, identifikavo neįprastą pneumonijos atvejų grupę Uhane, indikuojančią galimą infekcinės ligos protrūkį kelios dienos iki Pasaulinė Sveikatos Organizacija (PSO) paskelbė apie pandemiją (Eric, 2020). COVID-19 pandemijos metu šalys pasitelkė didelius duomenis ir išmaniąsias technologijas siekiant stebėti infekcijos plitimą ir sumažinti jos padarinius (Mehta & Shukla, 2022). Kinijos geležinkelio ir metro stotyse buvo įdiegti DI pagrindu sukurti temperatūros skaitytuvai, kurie naudoja kūno ir veido aptikimą bei identifikuoja žmones, kurių kūno temperatūra yra pakitusi (Mehta & Shukla, 2022). Pietų Korėjoje DI technologijų pagalba buvo siekiama stebėti COVID-19 plitimą, analizuojant veido atpažinimo duomenis bei naudojant geografinės vietos duomenis atsekant asmenis, kurie turėjo kontaktą su užsikrėtusiais žmonėmis (Cha, 2021). Jungtinės Karalystės Nacionalinė Sveikatos Tarnyba, bendradarbiaudama su Microsoft, Amazon Web Services, Google Faculty ir Palantir, sukūrė skaitmeninę platformą, pagrįstą dideliais duomenimis ir DI, siekiant teikti naujausią informaciją sprendimus priimantiems asmenims (Gould et al., 2020). Ši platforma išanalizuodavo su COVID-19 susijusius duomenis iš Nacionalinės Sveikatos Tarnybos bei Anglijos Visuomenės Sveikatos Centro ir pateikdavo įžvalgas bei rekomendacijas valdžios institucijoms realiu laiku. Brazilija, Jungtinės Amerikos Valstijos, Kinija ir Izraelis pasitelkė mašininį mokymą paspartinti COVID-19 diagnostiką (Huang et al., 2021). Kembridže įsikūrusi farmakologijos įmonė DI pagalba identifikavo vieną iš potencialių vaistų - deksametazoną, COVID-19 pacientų gydymui (Mehta & Shukla, 2022). Remiantis vėliau atliktų klinikinių tyrimų duomenimis buvo nustatyta, jog šis vaistas gelbsti sunkiai sergančiujų

COVID-19 pacientų gyvybes ir buvo įtrauktas į PSO rekomendacijas sunkių atvejų gydymui (World Health Organization, 2023). DI technologijos COVID-19 pandemijos metu buvo plačiai naudojamos protrūkių prognozavimui, užsikrėtusių pacientų nustatymui ir diagnozei, gydymo sprendimų taikyme bei veiksmų planavime valstybiniu mastu (Mehta & Shukla, 2022). DI sprendimai taip pat buvo naudingi ligoninėms planuoti ir paskirstyti sveikatos išteklių poreikius (Wu et al., 2023). Dideli duomenys ir DI suteikia aktualią informaciją, kuri padeda šalims ir atsakingoms institucijoms padėti efektyviai spręsti neatidėliotinus visuomenės sveikatos iššūkius.

1.2.3 Psichinė sveikata ir gerovė

DI technologijos gali prisidėti sprendžiant gyventojų psichikos sveikatos ir gerovės iššūkius. Ettman ir Galea siūlo DI poveikį psichikos sveikatai vertinti trim aspektais: tobulinant psichikos sveikatos priežiūrą, keičiant socialinį ir ekonominį kontekstą ir taikant politiką, kuri formuoja DI įrankių diegimą, naudojimą ir piktnaudžiavimą jais (Ettman & Galea, 2023). Autoriai tai pateikia piramidės modeliu (4 Paveikslas).

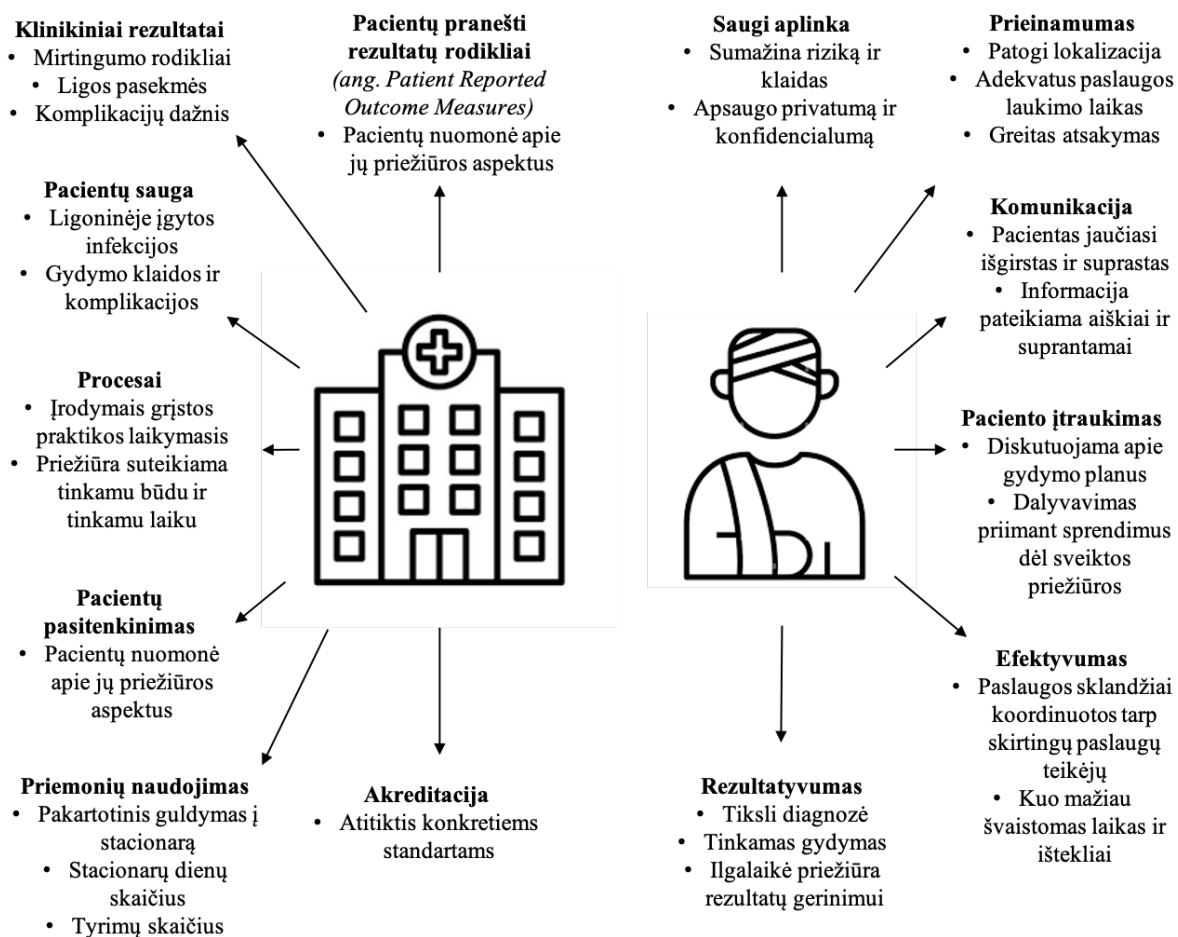


Paveikslas 4. Dirbtinio intelekto įtaka gyventojų psichinei sveikatai. Parengta pagal Ettman ir Galea (Ettman & Galea, 2023).

DI gali prisidėti prie psichikos sveikatos priežiūros užkertant kelią sunkesnių psichinių ligų vystymuisi. Mašininio mokymosi pagalba DI sugeba atskirti stresą esant normaliai smegenų būsenai lyginant su potrauminio streso sutrikimo būseną (Mentis et al., 2023). Ši DI sistema padėtų medikams atskirti stresą nuo kitų žmogaus smegenų būsenų ir tiksliau diagnozuoti potrauminio sutrikimo sindromą. Mašininio mokymosi pagalba yra bandoma identifikuoti lengvus pažinimo sutrikimus (*ang. mild cognitive impairment*), kurie padėtų anksti aptikti Alzheimerio ligos ir demencijos požymius (Penfold et al., 2022). Tai leistų sutelkti sveikatos priežiūros išteklius ir pasiūlyti pacientams bei jų artimiesiems mokomąsias ar intervencines priemones šių ligų valdymui ir taip sumažinti patiriamą naštą. Pastangos naudoti DI psichikos sveikatos priežiūros paslaugų teikimui kol kas yra pradinėse vystymo stadijose ir nėra aišku, kokios būtų ilgalaikės jų taikymo pasekmės. Kaip pavaizduota 4 paveiksle, DI įtaka psichikos sveikatai apims ne tik sveikatos paslaugų teikimą, bet ir gyventojų socialinį gyvenimą bei politiką. DI gali pakeisti žmonių tarpusavio bendravimą ir socialinius ryšius, sukelti poliarizaciją tarp gyventojų, o tai žlugdo socialinius tinklus, kurie yra reikalingi žmogaus psichinei sveikatai palaikyti (Santos et al., 2021). Šiuo metu yra ypatingai reikalingi politiniai sprendimai, kaip apsaugoti jautrią informaciją apie pacientus ir jų privatumą sparčiai besivystančių DI technologijų terpėje. Svarbu užtikrinti, kad pacientai būtų apsaugoti dalijantis jautriais psichikos sveikatos duomenimis, kad nebūtų galima pasinaudoti jų psichikos sveikatos duomenimis piktavališkais tikslais. DI psichikos sveikatos priežiūroje neabejotinai atveria naujas galimybes ir siūlo sprendimus įvairiems šių laikų iššūkiams, tačiau, norint pilnai išnaudoti DI technologijas, būtina atidžiai įvertinti tiek jų teikiamą naudą, tiek galimas rizikas. Tinkamas DI integravimas ir reguliavimas gali padėti pasiekti aukštesnę sveikatos priežiūros paslaugų kokybės lygį, tuo pačiu išlaikant pacientų pasitikėjimą ir užtikrinant jų saugumą.

1.3. Sveikatos priežiūros paslaugų kokybė

Kokybiškos sveikatos priežiūros pagrindas yra suteikti reikiamas paslaugas tinkamai ir laiku siekiant pasiekti geriausių įmanomų rezultatų. Paslaugų kokybės vertinimas apima įvairius aspektus, tokius kaip paslaugų prieinamumas, gydymo veiksmingumas, paslaugų teikimo efektyvumas, paciento patirtys (Paveikslas 5). Pastebima, jog medicinos paslaugų kokybės vertinimas tampa vis labiau orientuotas į pacientą ir į jo patirtį (Rockville & Agency for Healthcare Research and Quality, 2020). Pacientai pageidauja individualios, kokybiškos priežiūros, kuri taip pat yra pagrindinis medicinos personalo tikslas (Aiken et al., 2012).



Paveikslas 5. Sveikatos priežiūros paslaugų kokybės vertinimas iš sveikatos priežiūros įstaigos ir paciento perspektyvos. Sveikatos priežiūros paslaugų kokybė yra matuojama naudojant įvairias metrikas ir metodus, vertinančius skirtingus priežiūros teikimo aspektus (Rockville & Agency for Healthcare Research and Quality, 2020; World Health Organization. Regional Office for Europe et al., 2019).

Apibendrinant Europos ir Jungtinių Amerikos Valstijų agentūrų sveikatos priežiūros kokybės ataskaitas galima išskirti keturis pagrindinius kokybės vertinimo aspektus (Rockville & Agency for Healthcare Research and Quality, 2020; World Health Organization. Regional Office for Europe et al., 2019):

Paslaugų prieinamumas yra vienas iš pagrindinių sveikatos priežiūros kokybės matavimo kriterijų. Tai apima galimybę laiku gauti reikiamą gydymą ir paslaugas, kurios yra būtinos siekiant užtikrinti greitą ir veiksmingą pacientų sveikatos problemų sprendimą (Cabrera-Barona et al., 2017). Tiek sveikatos priežiūros įstaiga, tiek pacientas vertina trumpesnį laukimo laiką ir siekia suteikti greitą prieigą prie gydytojų konsultacijų ir gydymo procedūrų.

Gydymo veiksmingumas yra vertinamas remiantis paciento sveikatos būklės pagerėjimu po gydymo. Šis kriterijus apima gydymo rezultatus, pavyzdžiui, ligos simptomų sumažėjimą ar visišką pasveikimą, ir ilgalaikį paciento sveikatos stabilumą. Sveikatos priežiūros įstaigoms gydymo veiksmingumo vertinimas yra svarbus siekiant tobulinti gydymo protokolus, o pacientui – vertinant gydymo pasirinkimą ir kokybę.

Paslaugų teikimo *efektyvumas* įvertina, kaip gerai sveikatos priežiūros įstaigos naudoja turimus išteklius, įskaitant laiką, finansus ir personalą, siekiant teikti aukštos kokybės paslaugas. Tai svarbu ne tik dėl ekonominių veiksnių, bet ir dėl galimybės užtikrinti tvarų ir efektyvų paslaugų prieinamumą visiems pacientams.

Paciento patirtis yra kompleksinis sveikatos priežiūros kokybės vertinimo aspektas, kuris apima paciento bendravimą su sveikatos priežiūros personalu, patogumą ir pasitenkinimą teikiamomis paslaugomis. Tai apima viską: nuo gydymo plano aiškumo iki asmeninių pacientų poreikių atsižvelgimo ir emocinės paramos. Pacientų apklausos yra vienos iš įrankių, naudojamų paciento patirties vertinimui gauti.

Nors sveikatos priežiūros įstaigos dažniausiai sutelkia dėmesį į klinikinius sveikatos priežiūros kokybės aspektus, pacientų vertinimai gali atskleisti trūkumus, tokius kaip nepakankamas bendravimas ar nepalankus gydymo aplinkos vertinimas, kurie gali neigiamai paveikti bendrą gydymo patirtį ir rezultatus (Abidova et al., 2021). Todėl svarbu, jog sveikatos priežiūros įstaigos atsižvelgtų į pacientų atsiliepimus, siekiant optimizuoti paslaugų teikimą ir pagerinti bendrą sveikatos priežiūros kokybę. Sveikatos priežiūros kokybė yra kompleksinis reiškinys, kurį lemia tiek objektyvūs sveikatos priežiūros rezultatai, tiek subjektyvūs pacientų vertinimai, o jos gerinimas reikalauja nuolatinio dėmesio ir adaptacijos prie kintančių sveikatos priežiūros aplinkos sąlygų ir pacientų lūkesčių.

1.4. Dirbtinis intelektas ir sveikatos priežiūros kokybė

DI technologijų potencialas sveikatos priežiūros srityje yra labai didelis, tačiau informacijos apie klinikinę ar finansinę naudą, gautą iš realaus DI sistemų naudojimo klinikinėje praktikoje nėra daug. Dažnai DI technologijų tikslumas yra prilyginamas efektyvumui tiek moksliniuose straipsniuose, tiek naujienose ar oficialiose ataskaitose (Jongsma et al., 2024). Tai gali suklaidinti potencialius DI sistemos naudotojus ir nepateisinti organizacijų lūkesčių (Lebovitz et al., 2021). Tinkamai įdiegtos sprendimų palaikymo DI sistemos gali prisidėti prie pacientų saugumo mažinant klaidų tikimybes, tačiau trūksta tyrimų, analizuojančių realias klininkines situacijas (Choudhury & Asan, 2020). Didžioji dauguma DI

sistemų tyrimų yra retrospektyvūs – algoritmų tikrinimui yra naudojami istoriškai paženklininti duomenys. Tik atlikę perspektyvius tyrimus galime pradėti vertinti tikrąjį DI sistemų naudingumą, nes jų veikimas, tikėtina, bus prastesnis, kai yra susiduriama su „realaus pasaulio“ duomenimis, kurie ne visada atitinka duomenis, naudotus algoritmų mokymui (Kelly et al., 2019). Puikūs DI sistemų rezultatai kontroliuojamoje aplinkoje nebūtinai yra atkartojami klinikinėse situacijose (Lebovitz et al., 2021). Šiuo tyrimu yra siekiama išsiaiškinti DI technologijų poveikį sveikatos priežiūroje ir įtaką sveikatos priežiūros paslaugų kokybei iš medicinos personalo perspektyvos.

Vienas iš pagrindinių iššūkių yra DI sistemų klinikinis vertinimas. Norint, kad DI sistemos taptų kliniškai pritaikomos, būtina atsižvelgti į jų realią naudą, o kokybės rodikliai turėtų atspindėti tikrąjį klinikinį pritaikomumą ir būtų suprantami galutiniam vartotojui (Kelly et al., 2019). Godwin ir Melvin teigia, jog būtina tiesiogiai įtraukti medicinos darbuotojus į DI kokybės metrikų kūrimą (Godwin & Melvin, 2023). Medicinos personalo dalyvavimas yra ypatingai svarbus siekiant suderinti DI įrankius su klinikiniais lūkesčiais ir užtikrinti, kad DI technologijos būtų naudingos klinikinėje aplinkoje.

2. TYRIMO APRAŠYMAS IR METODOLOGIJA

2.1 Empirinio tyrimo metodologija

Empirinio tyrimo tikslas: Nustatyti kaip DI sistemų naudojimas daro įtaką sveikatos priežiūros paslaugų kokybei dėl diagnozės tikslumo, gydymo ir resursų optimizavimo.

Empirinio tyrimo uždaviniai:

3. Įvertinti DI panaudojimo poveikį diagnozės tikslumui, gydymui, bei resursų optimizavimui;
4. Įvertinti kaip DI naudojimo poveikis daro įtaką sveikatos priežiūros paslaugų kokybei.

Tyrimo ribos – Europoje veikiančios sveikatos priežiūros centrai

Pasirinkta atlikti **kokybinį tyrimą**, kuris galėtų suteikti vertingų įžvalgų apie DI poveikį sveikatos priežiūros centruose ir įtaką teikiamų paslaugų kokybei. Tyrimo metodologija pasirinkta atsižvelgiant į tyrimo specifiką:

Sudėtingi nuo konteksto priklausomi reiškiniai. Kokybiniai tyrimai padeda nagrinėti sudėtingus ir nuo konteksto priklausančius reiškinius, kuriems įtakos turi technologijų, žmogiškųjų išteklių, organizacinių struktūrų ir reguliacinių institucijų sąveika (Denzin & Lincoln, 2017).

Suinteresuotųjų šalių perspektyva. Kokybiniai tyrimai leidžia tyrėjui įtraukti įvairias suinteresuotas šalis, klinikos personalą, administratorius, informacinių technologijų specialistus ir užfiksuoti jų perspektyvas bei suvokimą apie DI poveikį sveikatos priežiūroje ir jo įtaką teikiamų paslaugų kokybei (Morse et al., 2002).

Etiniai klausimai. DI integravimas į sveikatos priežiūrą kelia etinių, teisinių ir visuomenės klausimų. Kokybiniai tyrimai leidžia tyrėjams nagrinėti etines dilemas, privatumo bei teises problemas, susijusias su DI taikymu sveikatos priežiūros srityje (Braun & Clarke, 2019).

Kokybės vadybos praktikos supratimas. Kokybiniai metodai gali atskleisti kokybės valdymo praktiką ir strategijas, kurias sveikatos priežiūros organizacijos taiko DI panaudojimo kontekste. Tyrėjas gali įvertinti kaip apibrėžiama, stebima ir užtikrinama kokybė sveikatos priežiūroje, pagrįstoje DI (Creswell & Creswell, 2018).

Nenumatytų pasekmių atskleidimas. Kokybiniai tyrimai yra tinkami nustatant nenumatytas pasekmes ir iššūkius, susijusius su DI sveikatos priežiūros srityje. Tai leidžia ištirti tokias problemas kaip algoritmų šališkumas, poveikis sprendimų priėmimui ir galimi skirtumai teikiant paslaugas.

Lankstumas. DI sritis sveikatos priežiūroje yra dinamiška, greitai kintanti. Kokybiniai tyrimo metodai suteikia lankstumo, leidžiančio tyrėjui identifikuoti kylančias problemas ir atitinkamai keisti tyrimo klausimus.

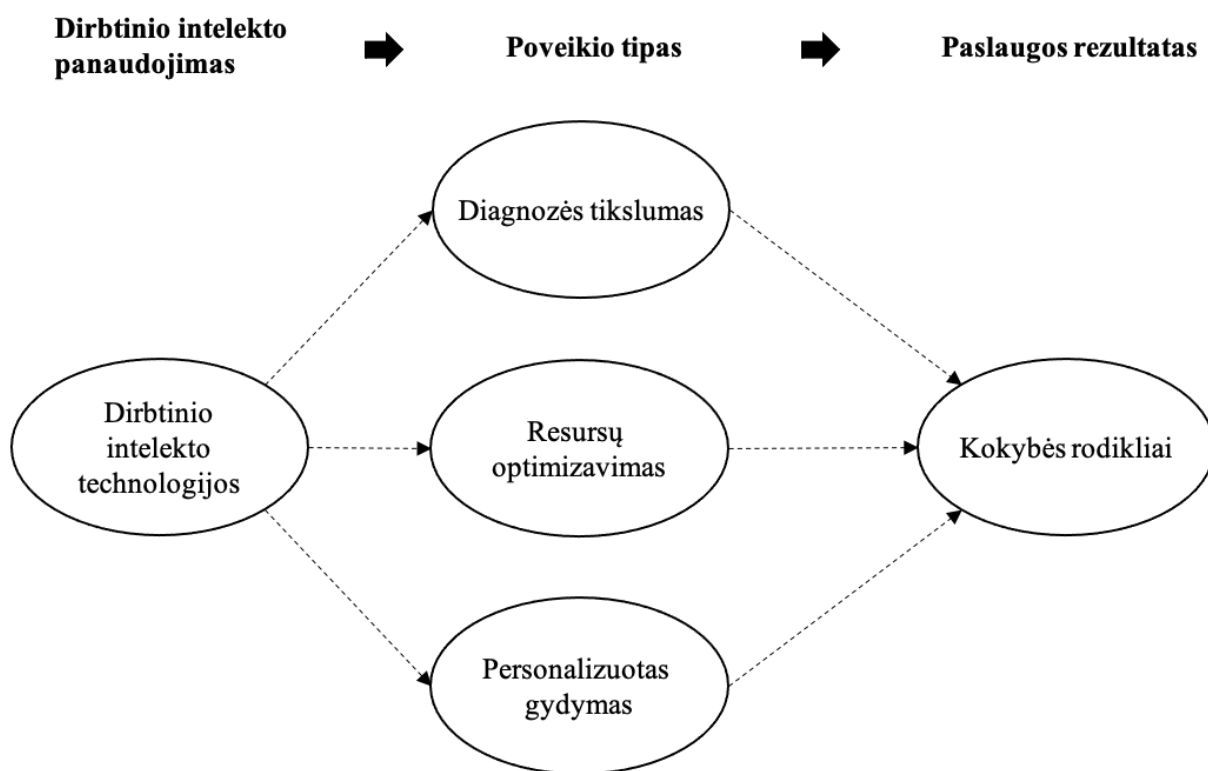
Politika ir praktika. Kokybinių tyrimų rezultatai gali būti naudingi kuriant strategiją, formuojant gaires ir DI kokybės valdymo praktiką sveikatos priežiūros srityje. Strategijos formuotojai gali pasinaudoti įžvalgomis, gautomis atliekant kokybinius tyrimus.

Holistinis supratimas. Kokybiniai tyrimai skatina holistinį ir nuodugnų tyrimą. Tyrėjas gali išnagrinėti visą DI ekosistemą sveikatos priežiūros srityje pradedant techniniais ir baigiant socialiniais bei etiniais, kultūriniais aspektais. Šis išsamus supratimas yra labai svarbus veiksmingam paslaugos kokybės valdymui.

2.2. Empirinio tyrimo metodika

Tyrimui atlikti pasirinktas *pusiau struktūruoto interviu* metodas, dažnai naudojamas sveikatos priežiūros srities tyrimuose (Jamshed, 2014). Tai interviu, kurių metu respondentai turi atsakyti į iš anksto numatytus atviro tipo klausimus, tačiau tyrėjui paliekama galimybė užduoti papildomus klausimus siekiant gauti kuo išsamesnį atsakymą. Šis tyrimo metodas buvo pasirinktas siekiant apklausti tikslinę populiaciją - iš anksto atrinktus ekspertus, kurie yra tiesiogiai susidūrę su DI panaudojimu sveikatos priežiūros įstaigose.

Atlikus literatūros analizę buvo suformuluotas tyrimo modelis (Paveikslas 5). Siekta nustatyti DI panaudojimo sritis sveikatos priežiūros įstaigose ir išsiaiškinti, kaip specialistai vertina DI naudojimą diagnozės tikslumo, resursų optimizavimo ir gydymo parinkimo kontekste bei įvertinti, kokią įtaką tai turi teikiamos gydymo paslaugos kokybei. Tyrimo duomenų analizė grįsta indukcinio požiūriu: interviu metu gautus duomenis siekta suskirstyti į kategorijas ar reikšmes, kurios leistų įvertinti tyrimo modelyje pateiktus ryšius tarp DI panaudojimo, poveikio tipo ir paslaugos rezultato.



Paveikslas 5. Tyrimo schema

2.3. Klausimyno sudarymo principas

Klausimai pusiau struktūruotam interviu buvo sudaryti remiantis tyrimo modeliu ir uždaviniais. Klausimais siekta surinkti ekspertų ir specialistų įžvalgas apie tai, kokiose sveikatos priežiūros srityse naudojamas DI, kaip tai veikia diagnozės tikslumą, darbo efektyvumą, pacientų gydymą bei kokią įtaką turi teikiamoms sveikatos priežiūros paslaugoms. Papildomi klausimai dažniausiai buvo užduodami siekiant patikslinti respondento nuomonę, tam, kad būtų galima priskirti išsakytus teiginius pasirinktoms kategorijoms ar išsiaiškinti požiūrio priežastis. Klausimus peržiūrėjo nepriklausomas sveikatos priežiūros specialistas, dirbantis klinikinio padalinio vadovu (E1) ir turintis ilgametės patirties kokybės valdymo srityje, bei tarptautinis ekspertas, profesorius, vadovaujantis Dirbtinio Intelektu Medicinoje padaliniui (E2). Ekspertų charakteristika pateikta 1 lentelėje.

1 lentelė. Ekspertų charakteristika.

Eksperto kodas	Organizacija	Pareigos	Patirtis kokybės valdyme (metais)	Patirtis su DI sistemomis
E1	Kauno miesto poliklinika	Padalinio vedėja	7	Minimali
E2	Universitat de Barcelona	Padalinio direktorius	0	Didelė

Atsižvelgiant į ekspertų pastabas, buvo pakeistos klausimų formuluotės. Klausimai lietuvių ir anglų kalba yra pateikti 2 lentelėje.

2 lentelė. Klausimynas pusiau struktūruotam interviu.

Kategorija	Klausimas anglų kalba	Klausimas lietuvių kalba
DI naudojimas	Can you describe your role in healthcare and your experience with AI technologies?	Apibūdinti savo vaidmenį sveikatos priežiūros srityje ir patirtį su DI technologijomis?
	Can you describe how AI has been integrated within your healthcare facility? What specific AI tools or systems are used?	Ar galite apibūdinti, kaip DI buvo integruotas jūsų sveikatos priežiūros įstaigoje? Kokie konkretūs AI įrankiai ar sistemos naudojami?
Poveikio tipas	Based on your experience, how has the use of AI in diagnosis improved the accuracy and speed of diagnosing patient conditions?	Remiantis jūsų patirtimi, kaip DI naudojimas diagnostikoje pagerino paciento diagnozės tikslumą ir diagnozės nustatymo laiką?
	How is AI utilized in developing treatment plans for patients? Can you provide examples where AI has significantly influenced treatment decisions?	Kaip DI yra naudojamas kuriant pacientų gydymo planus? Ar galite pateikti pavyzdžių, kai AI padarė didelę įtaką gydymo sprendimams?

Kategorija	Klausimas anglų kalba	Klausimas lietuvių kalba
	How has AI affected workflow and efficiency in your work environment?	Kaip DI paveikė darbo eigą ir efektyvumą jūsų darbo aplinkoje?
Paslaugos kokybė	How does your organization measure the impact of AI on healthcare quality, such as patient outcomes and treatment efficiency?	Kaip jūsų organizacijoje yra vertinamas DI poveikis sveikatos priežiūros kokybei, pvz., pacientų rezultatams ir gydymo efektyvumui?
	How do AI-driven diagnosis approaches compare to traditional methods in terms of patient outcomes and efficiency?	Kaip DI pagrįsti diagnostikos metodai skiriasi nuo tradicinių, gydymo rezultatų ir efektyvumo požiūriu?
	Have you observed any noticeable changes in patient outcomes since the implementation of AI? Could you share specific examples or metrics?	Ar pastebėjote pacientų gydymo rezultatų pokyčių po DI įdiegimo? Ar galėtumėte pasidalinti konkrečiais pavyzdžiais?
	In your opinion, how has AI impacted the quality of healthcare services in your organization?	Kaip, jūsų nuomone, DI paveikė sveikatos priežiūros paslaugų kokybę jūsų organizacijoje?

2.4. Tyrimo imtis

Tyrimui pasirinkta tikslinė imtis - sveikatos priežiūros įstaigose dirbantys specialistai, turintys medicininį išsilavinimą ir dirbantys su DI sistemomis. Kadangi Lietuvoje DI panaudojimas sveikatos priežiūros įstaigose nėra plačiai taikomas, tyrimo ribos buvo praplėtos įtraukiant kitas Europos šalis. Respondentų buvo ieškoma netikimybinės atrankos būdu tarp mokslinių publikacijų autorių, konferencijų dalyvių, FUTURE AI iniciatyvos narių, Europos mokslininkų platformoje (European Research Area Platform) registruotų narių, DI sprendimus tiekiančių įmonių klientų. Su potencialias respondentais buvo susisiekiama tiesiogiai elektroniniu paštu (N=68) arba per LinkedIn platformą (N=37) ir išsiunčiamas kvietimas dalyvauti interviu (Priedas 1). Kvietime nurodytas tyrimo pavadinimas ir trumpai papasakota apie tyrimą. Iš viso buvo gauti septyni atsakymai į išsiųstus kvietimus, tačiau interviu dalyvauti sutiko tik penki ekspertai. Respondentų charakteristika yra pateikta 3 lentelėje,

3 lentelė. Respondentų charakteristika.

Respondento kodas	Šalis	Įstaiga	Pareigos
R1	Olandija	Leideno Universiteto Medicinos Centras	Docentas ir Vaizdo gavimo radiologijoje grupės vadovas
R2	Švedija	Malmės klinikinės genetikos, patologijos ir molekulinės diagnostikos medicinos tarnyba	Laboratorijos vadovas
R3	Didžioji Britanija	Barts Health nacionalinė sveikatos tarnyba	Docentė, gydytoja radiologė
R4	Danija	Gødstrup regioninė ligoninės kardiologijos skyrius	Gydytoja kardiologė, doktorantė
R5	Didžioji Britanija	Škotijos nacionalinės sveikatos tarnyba	Gydytojas dermatologas, Medicinos technologijų konsultantas

2.5. Tyrimo eiga

Tyrimas buvo atliekamas 2024 metų vasario-balandžio mėnesiais. Su respondentais, parodžiusiais susidomėjimą dalyvauti tyrime, buvo susisiepta elektroniniu paštu ir glaustai papasakota apie tyrimą: tikslą, uždavinius, aptartas tyrimo metodus, trumpai pristatyti klausimai ir interviu trukmė. Gavus iš respondentų sutikimą dalyvauti tyrime buvo organizuojamas interviu nuotoliniu būdu MS Teams platformoje. Pokalbiai vyko anglų kalba ir buvo įrašomi. Pokalbių trukmė siekė nuo 25 iki 60 minučių.

Interviu analizė atlikta vadovaujantis Forman ir Damschroder rekomendacijomis (Forman & Damschroder, 2015). Interviu transkriptas buvo sudarinėjamas naudojantis „*transcribe*“ funkcija ir patikrintas tyrimo autorės. Transkripte buvo nurodyti pertraukimai [PERTRAUKIMAS], pasikeitimai respondento nuotaikoje [JUOKIASI, PIKTAS ir t.t.]. Taip pat pažymėti papildomi komentarai apie tai, kas įvyko konkretaus pokalbio metu. Parengus transkriptą, buvo atliekamas preliminarus kodavimas – teksto skaitymas pažymint ištraukas, kurios gali būti potencialiai svarbios ir susijusios su tyrimo klausimais, rašomos pastabos. Perskaičius pirmus kelis transkriptus buvo išgryninti pavadinimai tam tikriems conceptams ir sukurta kodų lentelė nurodant kodą, jo apibūdinimą ir pavyzdį (interviu ištrauką). Tuomet interviu transkriptas buvo analizuojamas naudojant kodus. Kryžminiam atvejų palyginimui panaudota matrica su horizontaliai išdėstytomis nustatytomis reikšmingomis kategorijomis, parinktais kodais ir vertikalčiai išvardintais atvejais. Kiekvienas matricos langelis buvo užpildomas tekstu siekiant apibendrinti tos kategorijos ypatybes. Gautos preliminarios tyrimo išvados buvo tikrinamos pakartotinai peržiūrint tyrimo duomenis. Tokiu būdu buvo siekiama verifikuoti tyrimo išvadas, taip pat aptarti atvejus, kurie nebūtinai sustiprina išvadas, tačiau yra prasmingi duomenys ir gali duoti papildomų įžvalgų.

3. REZULTATAI IR JŲ ANALIZĖ

Pusiau struktūruotų interviu analizė atlikta pagal empirinio tyrimo modelį (Paveikslas 2), kuriuo siekta išsiaiškinti, kaip DI technologijos daro poveikį diagnozės tikslumui, resursų optimizavimui bei personalizuotam gydymui, ir nustatyti, kokią įtaką tai turi teikiamų sveikatos priežiūros paslaugų kokybei. Įvertinus pokalbių transkriptus buvo išgryninti konceptai, pagal kuriuos susisteminta ir užkoduota interviu metu gauta informacija. Ji yra suskirstyta į tris kategorijas: (1) *DI panaudojimo sritis*, kurioje aprašoma, kokioje srityje ir koku tikslu respondentai naudoja DI technologijas; (2) *DI poveikio tipas*, kuriame respondentai kalba apie tai, kokį poveikį jų naudojamos DI technologijos daro diagnozės tikslumui, gydymui ir resursų optimizavimui; (3) *DI įtaka paslaugos kokybei*, kurioje siekiama sužinoti respondentų nuomonę apie taip, kaip jų naudojamos DI technologijos poveikis gali daryti įtaką suteikiamoms sveikatos priežiūros paslaugoms. Kiekvienos iš šių trijų kategorijų analizė yra pateikta 4-6 lentelėse detalčiai aprašyta atskiruose poskyriuose.

3.1 Dirbtinio intelekto panaudojimo sritys

Dirbtinio intelekto panaudojimo sričių konceptai yra pateikti 4 lentelėje. Visi tyrimo metu kalbinti respondentai DI sistemas naudojo *diagnostikos* srityje: radiologijoje (N=2), kardiologijoje (N=1), patologijoje (N=1), dermatologijoje (N=1). Respondentų praktikoje naudojamos DI sistemos atlieka vaizdų analizę. Radiologijoje bei kardiologijoje DI identifikuoja vaizduose matomas organų struktūras ir pateikia kiekybinius jų vertinimus. Patologijoje DI sistemų pagalba yra atliekamas skaitmeninis preparatų vertinimas, identifikuojamos ir suskaičiuojamos ląstelės, plotas kurį jos užima. Dermatologijoje odos darinių vaizdai yra vertinami ir priskiriami tam tikrai grupei. Galima teigti, jog medicinos sritys, kurios labiausiai priklauso nuo vaizdavimo, yra vienos labiausiai paveiktų dirbtinio intelekto technologijų pažangos. Respondentai nurodė, kad jų praktikoje DI technologijos yra naudojamos darbo automatizavimui: DI algoritmai atpažįsta tam tikras struktūras ir pateikia nustatytus matavimus, kurie anksčiau buvo atliekami medicinos specialistų rankiniu būdu. Galutinė diagnozė yra parengiama medicinos specialisto, atsižvelgiant į DI sistemų pagalba gautus kiekybinius duomenis.

4 lentelė. Kodų lentelė DI panaudojimo kategorijos konceptų sudarymui.

Kodas	Kodo apibūdinimas	Pavyzdys
[DIAGNOSTIKA]	Apibūdinama diagnostikoje naudojama DI sistema	<p>„atliekame vidaus organų vaizdus... kiekybiškai įvertinti specifines charakteristikas: kampą tarp dviejų kaulų, naviko tankį.“ (ang. „...make images of internal organs... to quantify specific characteristic e.g. the angle between two bones, the density of the tumour.“)</p> <p>R1</p> <p>„...skaitytuvai su DI automatizavimu...histologinių preparatų analizė, tokia kaip ląstelių skaičiavimas, ploto matavimas...skaitmeninė patologija“ (ang. „...scanners fitted with AI for automation... histological slide analysis like cell counting, area measurement...digital pathology“)</p> <p>R2</p> <p>...interpretuojami mediciniai vaizdai... automatizuoti rutininiai organų matavimai. “ (ang. „...interpreting medical images... automate routine measurements of organ dimensions“)</p> <p>R3</p> <p>„...echokardiografijoje integruota DI sistema padeda išmatuoti širdies kameros dydį ir sienos judesį.“ (ang. „AI system integrated with our echocardiography lab assists in measuring heart chamber sizes and wall motion“)</p> <p>R4</p> <p>„...naudojame analizuoti odos ligų vaizdus ir pasiūlyti diagnozę.“ (ang. ...analyse images of skin conditions and suggest possible diagnosis.)</p> <p>R5</p>

3.2 Dirbtinio intelekto poveikio tipai

Dirbtinio intelekto poveikio tipų konceptai yra pateikti 5 lentelėje. Sveikatos priežiūros įstaigose naudojamos DI sistemos didžiausią poveikį turi resursų *optimizavimui*: užduočių perskirstymui (R1, R5) ir diagnozei skirto laiko mažinimui (R2, R3, R4). Organizacijos pasitelkia DI technologijas spręsti gydytojų specialistų trūkumą („*radiologų mažėja, o darbo krūvis didėja*“) perskirstydamos užduotis kitos kvalifikacijos specialistams. Pavyzdžiui, Nyderlanduose tam tikros radiologų užduotys yra perduodamos radiografams, o Škotijoje bendrosios praktikos gydytojai DI pagalba vertina odos darinius, taip sumažindami gydytojų dermatologų krūvį. Kitose organizacijose DI sistemų pagalba siekiama sutrumpinti laiką diagnozės nustatymui automatizuojant matavimus, kuriuos medicinos specialistai įprastai atlieka rankiniu būdu. Tai padeda greičiau įvertinti paciento būklę ir duoti tyrimo atsakymą patologijos, kardiologijos bei radiologijos srityse. Respondentai tai įvardino kaip darbo efektyvinimą, tačiau efektyvumas buvo vertinamas tik iš skyriaus, kuris naudoja DI sistemą, perspektyvos. Nurodyta, jog DI sistemų palaikymui reikalingi didesni informacinių technologijų ištekliai („*kiekvienoje laboratorijoje turime po du pilnu etatu dirbančius IT specialistus, iš viso aštuonis*“). Tai gali tapti klaidinančiu faktoriumi efektyvumo vertinime organizacijos lygmenyje, nes žmogiškųjų resursų mažinimas viename skyriuje sąlygoja žmogiškųjų resursų didinimą kitame skyriuje.

Klinikinėje praktikoje DI sistemų diagnostinis *tikslumas* yra patikrinamas vertinant „jautrumą, specifiškumą ir kitas pasaulyje priimtinas metrikas“. Respondentų nuomone, naudojant DI sistemas diagnostinis tikslumas išlieka „toks pat“ arba pagerėja netiesiogiai, nes, sumažinus perrašymo elementų, pacientui „negali būti priskirta netinkama diagnozė“. Pokalbių metu susidarė įspūdis, jog diagnostinio tikslumo gerinimas nebuvo DI sistemų diegimo prioritetas. Naudojamos DI sistemos yra skirtos standartiškai atliekamų matavimų automatizavimui „atlikti lygiai tą patį ir įrodyti, kad tai tas pats, ką darome nuo 1948 metų rankiniu matavimu“. To priežastis nėra techninės DI sistemų galimybės, nes „algoritmu galima vietoj naviko skersmens pamatuoti tūrį, kuris yra tikslesnis...matavimų paklaida sumažėja, tačiau chirurgai puikiai žino, ką reikia daryti, kai naviko skersmuo padidėja dviem milimetrais, bet tūrio vienetų jie negali interpretuoti“. Tai rodo, jog DI sistemos tiesiogiai neprisideda prie diagnostinio tikslumo gerinimo dėl žinių, kaip tinkamai kliniškai interpretuoti gautus rezultatus, trūkumo.

Pagal DI sistemų pateiktus kiekybinius parametrus yra priimami *gydymo* sprendimai, tačiau tai daro gydantys gydytojai, chirurgai. Patologijos srityje dirbantis respondentas minėjo,

jog sekantis žingsnis diegiant DI technologijas bus orientuotas į „(aut. gydymo) sprendimo priėmimo dalį“. Sistema būtų orientuota į krūties vėžio bei prostatos vėžio diagnostiką ir naudotų algoritmus, kurie yra susieti su pacientų rezultatais (*ang. patient outcomes*). Nors tyrime aptartos DI sistemos tiesiogiai neprisideda prie paciento gydymo parinkimo, greitesnė diagnozė gali „išgelbėti gyvybę“ laiku suteikiant reikiamą pagalbą arba „sumažinant (gydymo) laukimo laiką“ onkologiniams pacientams.

5 lentelė. Kodų lentelė DI poveikio tipų konceptų sudarymui.

Kodas	Kodo apibūdinimas	Pavyzdys
[TIKSLUMAS]	Nurodoma, kaip naudojama sistema diagnozės tikslumą	<p>„Naudojame algoritmus, kad įvertintume tuos pačius dalykus, kuriuos vertiname 100 metų, tik tai automatizuojame. ...klinikinėje praktikoje reikia atlikti ilgamečius tyrimus, kad įrodytumėte, jog tai (aut. DI sistemų matavimai) iš tikrųjų yra geriau.“ (<i>ang. „We use algorithms to do the same stuff that we were doing for 100 years but then automate it. ...in clinical practice you need to do years and years of study in order to prove that this is actually better“</i>.) R1</p> <p>„Atlikome kokybės kontrolę... kad nepraleistume kliniškai svarbių atvejų, o antroji dalis... kai patologas nėra tikras dėl vaizdo išvadų, jis visada gali gauti preparatus... bet jis turi tai daryti aktyviai. ...turime aukšto lygio tikslų nuskaitymą... kokybė yra tokia pat“</p> <p>(<i>ang. „We did a quality control... so we don't see any clinical misses and the second part...when a pathologist is uncertain about the findings in the image they can always get the slides...but he has to do it actively. ...we have high level of accurate scanning... the quality is the same“</i>) R2</p>

Kodas	Kodo apibūdinimas	Pavyzdys
[OPTIMIZAVIMAS]	Nurodoma, kaip naudojama DI	<p>„Tai saugiau pacientams, nes ėminio ženklumas yra teisingas...paciento saugumas pagerėja, nes negali būti priskirta netinkama diagnozė.“ (ang. <i>“It is safer for patients, because you have a correct label... patient safety is highly improved because you cannot give the wrong diagnosis.”</i>) R2</p> <p>„Dalykas, kurį nori automatizuoti, turi būti tikslus, tačiau nėra papildomo žingsnio, kurį naudojant galėtumėte įtraukti daugiau matavimų, kurie galėtų būti siejami su pacientų rezultatais.“ (ang. <i>„The thing you want to automate needs to be accurate but there is no additional step saying with this technology you can also calculate more characteristics that might be correlated with patient outcome“</i>) R3</p> <p>Širdis yra dinamiška struktūra, kuri nuolat juda...DI algoritmai sumažina judesio artefaktus.“ (ang. <i>„...heart is a dynamic structure that constantly moves...AI algorithms reduce motion artefacts.”</i>) R4</p> <p>„...parodo sritis, į kurias reikėtų atkreipti dėmesį.“ (ang. <i>directs my attention to areas that may require a closer look</i>) R4</p> <p>„ Sistema pateikia rekomendaciją, grįstą požymių analize (asimetrija, kraštų nelygumas, skersmuo ir t.t.) ... diagnozę nustato gydytojas. (ang. <i>...system provides a recommendation based on feature analysis (asymmetry, border irregularity, diameter, etc.) ... a diagnosis is made by a doctor</i>) R5</p> <p>„...bandome perskirstyti radiologų užduotis radiografams. ...siekiamo mūsų skyrių padaryti</p>

Kodas	Kodo	Pavyzdys
sistema veikia resursų optimizavimą	apibūdinimas	<p>labiau efektyvų.“ (ang. <i>...trying to shift tasks ...from radiologists to radiographers. ...trying to make our department more efficient</i>“.) R1</p> <p>„Mums puikiai sekėsi su atsakymo pateikimo laiko rodikliu, ypatingai onkologiniams pacientams. ...mums nereikia archyvuoti (aut. preparatų), tai atliekama automatiškai“ (ang. <i>We had a great success in reacting times especially for cancer cases. ...we don't have to do archiving, it is done automatically</i>) R2</p> <p>„Pagerėjo diagnozės ir išvados parengimo laikas“ (ang. <i>...the speed of diagnosis and reporting has improved</i>“) R3</p> <p>„...greitesnis preliminarus vertinimas.“ (ang. <i>quicker preliminary assessments</i>) R4</p> <p>„Stebėseną gali būti atliekama bendrosios praktikos gydytojo...pagerėjo darbo eiga.“ (ang. <i>...monitoring can be done by a GP... the workflow has improved</i>“) R5</p>
[GYDYMAS]	Nurodoma, kaip naudojama DI sistema veikia gydymą	<p>„Žmonės turi skirtingus kojų ilgius... jei skirtumas yra didesnis nei du centimetrai, galima skirti operacinį gydymą.“ (ang. <i>People have a difference in leg length...if there is more than two centimetres difference then you can start the surgery</i>“) R1</p> <p>„Tiksloji medicina turi skirtingus algoritmus... mes atliekame masinę diagnostiką. Su skirtingais algoritmais galbūt galėtume sumažinti perdėtą gydymą ir gydyti pacientus, kurie būtų negavę gydymo.“ (ang. <i>precision medicine has different algorithms...we do a bulk diagnosis. ...with different algorithms maybe we</i></p>

Kodas	Kodo apibūdinimas	Pavyzdys
		<i>can reduce overtreatment and treat patients that would have missed treatment) R2</i>
		„Greita diagnozė yra labai svarbi kritinėse situacijose... ūminio insulto atveju krešulius ardančių vaistų skyrimas gali išgelbėti gyvybę.“ (ang. „A quick diagnosis is crucial in emergency situations... in cases of acute stroke... administration of a clot-busting drug can be life saving”) R3
		„Jei išstūmimo frakcija nesiekia tam tikros ribos, skiriami specifiniai vaistai.“ (ang. <i>specific medications are indicated if the ejection fraction is below a certain threshold</i>) R4
		„Melnomos pacientai greičiau gauna dermatologo apžiūrą... pacientai greičiau pradeda gydymą.“ (ang. <i>melanoma patients are referred to dermatologist faster. ...patients can start treatment faster.</i> ”) R5

3.3. Dirbtinio intelekto įtaka sveikatos priežiūros paslaugos kokybei

Dauguma respondentų nurodė, jog vertindami DI sistemas stebi „efektyvumo rodiklius“, tačiau tai daro „daugiau savo skyriui, ne už jo ribų“. Trys respondentai paminėjo „naudotojų atgalinį ryšį“ kaip vieną iš DI sistemų vertinimo aspektų. Tai rodo organizacijų siekį įtraukti savo darbuotojus į DI sistemų diegimą ir valdymą. Transkripto analizės metu buvo išskirti keli sveikatos priežiūros paslaugų kokybės aspektai: (1) *efektyvumas*, rodantis sveikatos priežiūros įstaigos veiklos pagerinimą, (2) *prieinamumas*, suprantamas kaip galimybių pacientams gauti sveikatos priežiūros paslaugas padidinimas ir (3) *veiksmingumas*, kai pasiekiami pacientui ir gydymo įstaigai užsibrėžti sveikatos priežiūros rezultatai (6 lentelė).

Galima teigti, jog DI sistemos daro įtaką sveikatos priežiūros paslaugų efektyvumui perleidžiant užduotis iš aukštos kvalifikacijos sveikatos priežiūros darbuotojų žemesnės kvalifikacijos sveikatos priežiūros darbuotojams, o tai sudaro galimybę veiksmingiau panaudoti

turimus žmogiškuosius išteklius. Vieno korespondento nuomone, „užduočių diferencijavimas turėtų būti siejamas su technologinėmis naujovėmis, kad būtų galima gauti kuo daugiau naudos iš šių technologijų ir tuo pačiu keisti darbo jėgą“. Pašnekovas nurodė, kad DI pradėjo taikyti prieš penkis metus, kaip vieną iš įrankių spręsti didėjančią darbo krūvį: „per metus patiriame apie 5-7 % medicininės vizualizacijos augimą, tai reiškia, kad darbo apimtys didėja“. DI technologijų sprendiniai padėjo „sumažinti logistiką“ patologijos srityje, kuomet „nereikia fiziškai eiti ir ieškoti preparatų peržiūrai, nes jie yra prieinami kompiuterių ekranuose“. DI technologijos leidžia sutrumpinti tyrimo atlikimo laiką. Vidaus organų matavimų automatizavimas leidžia gydytojui greičiau įvertinti matomus vaizdus ir priskirti diagnozę. Tam tikri matavimai „automatiškai pateikiami galutiniame išvados lange“ ir sutrumpina išvados rengimo laiką. Dermatologijos srityje DI vaizdo atpažinimo algoritmai padeda pacientui tinkamai nufotografuoti odos darinius, todėl „gydytojui nereikia skambinti pacientui ir paprašyti nufotografuoti sritį iš naujo“.

DI sistemos daro paslaugas labiau prieinamas pacientams. Pavyzdžiui, Švedijoje „įstatymiškai gydymas turi būti skirtas per tam tikrą laiką nuo diagnozės gavimo... sumažinus diagnozei skirtą laiką, gydymas yra suteikiamas greičiau“. Tai yra „ypatingai aktualu onkologiniams ligoniams“. Užduočių perskirstymas leidžia nuimti darbo krūvį nuo gydytojų specialistų ir padaro juos prieinamesnius pacientams radiologijos bei dermatologijos srityse.

Visi kalbinti respondentai nurodė, kad praktiškai pamatuoti DI sistemų itaką pacientui suteikto gydymo veiksmingumui būtų labai sudėtinga. Iš pateiktų atsakymų susidarė išpūdis, jog gydymo veiksmingumo analizė nėra prioritetinga diagnostikos skyriuose, kuriuose dirba respondentai. Taip pat nurodyta, jog gydymo veiksmingumą būtų sudėtinga tinkamai įvertinti klinikinėje aplinkoje dėl kintamųjų gausos bei atvejo kontrolės trūkumo.

6 lentelė. Kodų lentelė DI įtakos sveikatos priežiūros paslaugos kokybei konceptų sudarymui.

Kodas	Kodo apibūdinimas	Pavyzdys
[EFEKTYVUMAS]	Naudojant DI sistemas mažiau švaistomi ištekliai	„Pakeisime visą skyrių... darbo eigas ir kaip galime jas patobulinti naudodami DI.“ (ang. <i>„let’s change the whole department...workflows and how we can enhance them with AI.“</i>) R1 „Logistikos sumažinimas... sutrumpėjo atvejo įvertinimo trukmė“ (ang.

Kodas	Kodo apibūdinimas	Pavyzdys
		<p>„...<i>logistic savings...cut turnaround times for each case</i>“) R2</p> <p>„Matuojame laiko sutrumpinimą, naudotojų patirtį... bet daugiau savo skyriui, o ne už jo ribų.“ (ang. „<i>We measure time reduction, user experience... but more for our own department not really outside of it.</i>“) R3</p> <p>„Laikas, kurį praleidžiame išvados rengimui; pagerėjo laikas, per kurį chirurgas turi gauti atsakymą.“ (ang. „<i>The time that you spend on reporting, the turn-around times for a surgeon to receive a report have improved</i>“) R4</p> <p>Sumažėjo atvejų, kuriuos reikia peržiūrėti (aut. dermatologui) skaičius (ang. „<i>A reduction in a number of cases that need to be re-evaluated</i>“) R5</p>
[PRIEINAMUMAS]	<p>Naudojant DI sistemas diagnostikoje sveikatos priežiūros paslauga yra suteikiama greičiau, sumažėja atsakymo laukimo laikas</p>	<p>„<i>Mes tai vadiname užduočių perdavimu ir tai šiek tiek pakeitė darbo eigą... mes matome skirtumus.</i>“ (ang. „<i>We call it task shifting and it did change the workflow a bit... and we do see differences</i>“) R1</p> <p>„Reakcijos laikas... gydymas suteikiamas greičiau.“ (ang. „<i>The response time... to get a treatment is faster.</i>“) R2</p> <p>„Dabar turime daugiau antrinės priežiūros pajėgumų.“ (ang. „<i>We now have larger capacity in secondary care.</i>“) R5</p>
[VEIKSMINGUMAS]	<p>Naudojant DI sistemas diagnostikoje galima</p>	<p>„Teikiame vaizdo gavimą kaip paslaugą kitiems padaliniams. Mes nesame tie,</p>

Kodas	Kodo apibūdinimas	Pavyzdys
suteikti veiksmingesnį gydymą		<p data-bbox="906 215 1430 409">kurie gydo pacientus“ (ang. „<i>We provide imaging as a service for other departments. We are not the ones treating the patients</i>“) R1</p> <p data-bbox="906 439 1430 685">„Labai sunku pamatuoti tikrąjį sprendimo poveikį, nes viskas vyksta vėliau.“ (ang. „<i>The real impact of that decision is very hard to measure because it’s all downstream</i>“) R2</p> <p data-bbox="906 714 1430 1178">„Turime būti su onkologais kambaryje ir nuolat jų klausti, pavyzdžiui, kiek kompiuterinės tomografijos tyrimai prisideda prie jų sprendimo negydyti paciento“ (ang. „<i>We have to be with oncologists in the room and actually ask them constantly like how much CT scans contribute to your decision not to treat the patient for example.</i>“) R3</p> <p data-bbox="906 1207 1430 1671">„Tu žinai, kad pacientas negali gauti gydymo, bet galbūt tas pacientas vistiek nori ką nors patirti...mes norime, kad pacientams būtų geriau“ (ang. „<i>You know that the patient cannot get treatment anymore but maybe that patient still wants to experience something...we want to make patients better</i>“). R4</p> <p data-bbox="906 1700 1430 2007">„Tai beveik neįmanoma... nėra kontrolės (aut. atvejo)... nėra antro tokio žmogaus, kad būtų įmanoma patikrinti, kuris gyvens ilgiau.“ (ang. „<i>It is almost impossible... you never have control...there is no second person</i>“)</p>

Kodas	Kodo apibūdinimas	Pavyzdys
		<i>exactly like that you can test to see which one lives longer“) R5</i>

3.4. Tyrimo rezultatų apibendrinimas

Tyrimo rezultatai apibendrinti atliekant kryžminį atvejų palyginimą pagal priskirtus kodus kiekvienai kategorijai: (1) *DI panaudojimo sritis*, (2) *DI poveikio tipas*, ir (3) *DI įtaka paslaugos kokybei* (Lentelė 7). Tai suteikia galimybę palyginti atvejus tarpusavyje ir identifikuoti tendencijas, pagal kurias yra pateikiamas DI įtakos sveikatos priežiūros paslaugų kokybei modelis (Paveikslas 6).

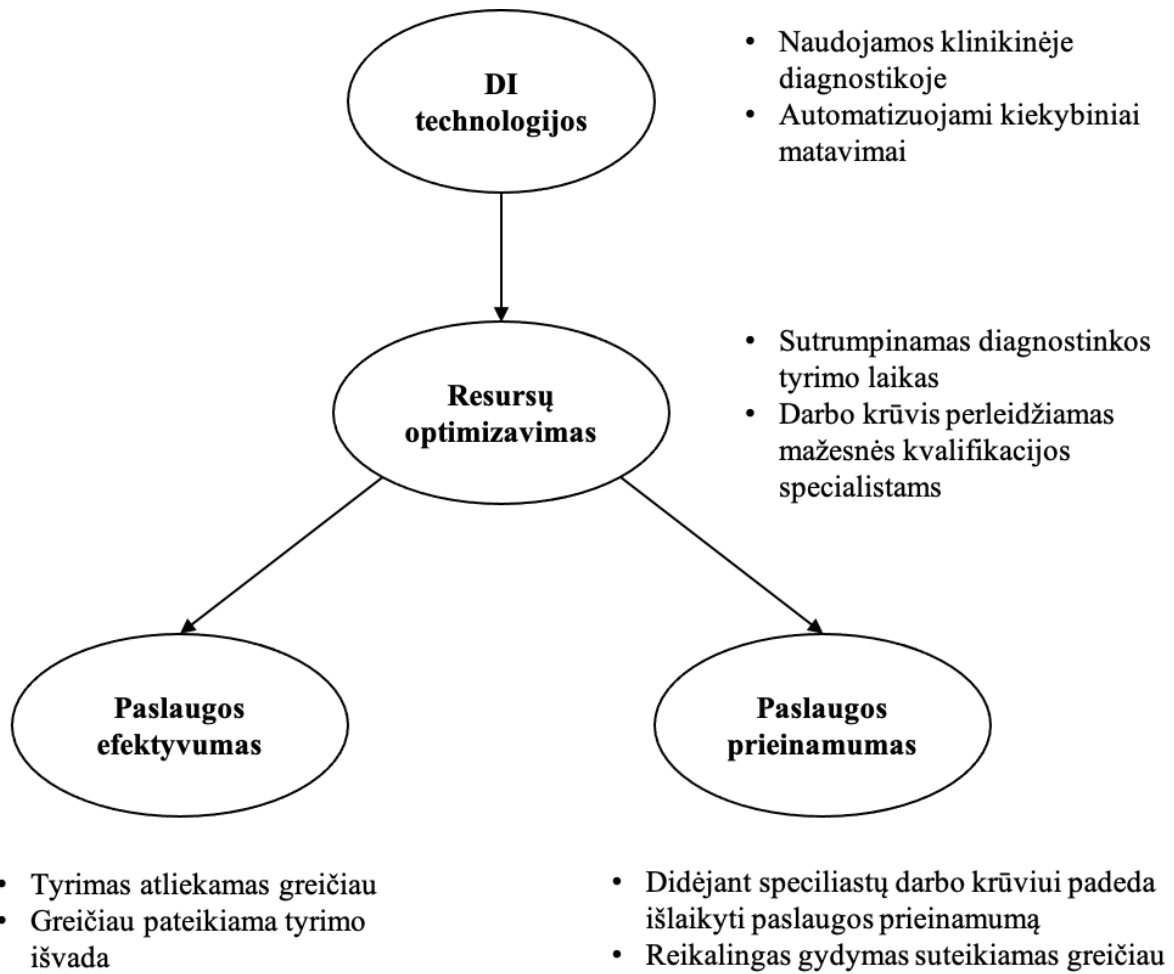
7 lentelė. Kryžminis atvejų palyginimas

RESPONDENTO NUMERIS	PANAUDOJIMO SRITIS	POVEIKIO TIPAS			ĮTAKA PASLAUGOS KOKYBEI		
	[DIAGNOSTIKA]	[TIKSLUMAS]	[OPTIMIZAVIMAS]	[GYDYMAS]	[EFEKTYVUMAS]	[PRIEINAMUMAS]	[VEIKSMINGUMAS]
R1	Radiologija	Neveikia	Veikia tiesiogiai per užduočių perskirstymą	Neveikia tiesiogiai	Pagerėja	Pagerėja	Nevertinama
R2	Patologija	Veikia netiesiogiai	Veikia tiesiogiai per atsakymo pateikimo laiką	Neveikia tiesiogiai	Pagerėja	Pagerėja	Nevertinama
R3	Radiologija	Neveikia	Veikia tiesiogiai per atsakymo pateikimo laiką	Neveikia tiesiogiai	Pagerėja	Nevertinama	Nevertinama
R4	Kardiologija	Veikia netiesiogiai	Veikia tiesiogiai per atsakymo pateikimo laiką	Neveikia tiesiogiai	Pagerėja	Nevertinama	Nevertinama
R5	Dermatologija	Veikia netiesiogiai	Veikia tiesiogiai per užduočių perskirstymą	Neveikia tiesiogiai	Pagerėja	Pagerėja	Nevertinama

Tyrimo metu nustatyta, jog radiologinėje diagnostikoje naudojamos DI sistemos neturi tiesioginio poveikio diagnostiniam tikslumui. Kiti respondentai nurodė, kaip DI gali netiesiogiai prisidėti prie klaidų mažinimo diagnostikoje, dėl sumažintos žmogiškųjų klaidų tikimybės, tačiau neatlieka matavimų, kad galėtų tai pagrįsti. Pavyzdžiui, skaitmeninėje patologijoje diagnozės tikslumas gali būti veikiamas dėl, tikėtina, sumažėjusio klaidų skaičius, kai diagnozė yra priskiriama ne tam pacientui, nes eliminuojamas preparatų žymėjimas ir archyvavimas rankiniu būdu. DI sistemos turi tiesioginį poveikį resursų optimizavime tam tikras užduotis perleidžiant kitos kvalifikacijos specialistams arba sutrumpinant diagnostinės išvados pateikimo laiką. Pacientų gydymas tiesiogiai nėra veikiamas DI sistemų, tačiau sutrumpintas diagnozės pateikimo laikas gali prisidėti prie laiku suteikiamo reikalingo gydymo. Remiantis DI sistemų kiekybiniais tyrimų rezultatais yra parenkama diagnozė ir skiriamas gydymas, todėl DI sistemos gali turėti netiesioginį poveikį paciento gydymui.

Šiuo metu Europos sveikatos priežiūros įstaigose naudojamos diagnostikoje integruotos DI sistemos tiesiogiai veikia sveikatos priežiūros paslaugų kokybę per vidinių skyriaus resursų optimizavimą. Tai daro įtaką sveikatos paslaugų efektyvumui ir prieinamumui. Diagnostikos paslauga yra atliekama greičiau, ligos išvados pateikimo laikas sutrumpėja, pacientas gali greičiau pradėti reikalingą gydymą. Didėjant gydytojų specialistų darbo krūviui DI pagalba vykdomas užduočių perskirstymas mažesnės kvalifikacijos specialistams leidžia išlaikyti paslaugą kuo labiau prieinamą.

Diagnostikoje naudojamų DI sistemų įtaka suteiktos gydymo paslaugos veiksmingumas nebuvo vertinamas, nes gydymas yra skiriamas gydančiojo gydytojo ir nėra aišku, kiek DI sistemų rodikliai prisideda prie gydymo parinkimo. Tačiau reikia pabrėžti, jog visi tyrimo respondentai naudojo DI sistemas integruotas diagnostikoje, o ne personalizuoto gydymo parinkimui, todėl nėra tiesiogiai susiję su gydymo parinkimu. Nustatyti DI sistemų įtaką gydymo veiksmingumui išlieka iššūkiu dėl tinkamos metodikos parinkimo, nes „kiekvienas klinikinis atvejis yra skirtingas“. Remiantis tyrimo analize buvo atnaujintas tyrimo modelis (Paveikslas 7).



Paveikslas 7. Europoje diagnostikai naudojamų dirbtinio intelekto technologijų įtaka sveikatos priežiūros paslaugų kokybei

IŠVADOS IR PASIŪLYMAI

Tyrimo metu buvo nustatyta, jog Europos sveikatos priežiūros įstaigose DI sistemos yra naudojamos radiologijos, patologijos, kardiologijos ir dermatologijos srityse automatizuoti medicininių vaizdų vertinimus, kurie įprastai būtų atliekami rankiniu būdu. Nors literatūroje aprašomos DI techninės galimybės yra daug platesnės, klinikinėje praktikoje tai dar nėra plačiai taikoma. Tikėtina, jog dauguma sveikatos priežiūros organizacijų susiduria su techninėmis diegimo ir palaikymo kliūtimis: klinikinų sprendimų palaikymo sistemos yra sunku prižiūrėti, sistemos negali susidoroti su didžiuliu duomenų ir žinių kiekiu. Taip pat labai svarbus darbuotojų įsitraukimo aspektas bei pakankama jų kvalifikacija darbui su DI sistemomis. Nors situacija keičiasi, tačiau nauji DI sistemų panaudojimo metodai, pagerinantys ligų diagnostiką ir gydymą, daugiausia sutinkami tyrimų laboratorijose arba naujų technologijų įmonėse (Davenport & Kalakota, 2019).

Tyrime dalyvavusiose organizacijose DI technologijos padeda optimizuoti resursus perskirstant užduotis arba sutrumpinant diagnozės pateikimo laiką. Dažnai pažadas, jog DI sumažins žmonių darbo krūvį ir padidins efektyvumą yra vertinamas labai siaurai, tik iš skyriaus, kuriame naudojama DI sistema, perspektyvos. Nėra atsižvelgiama į tai, jog darbuotojams reikia įgyti naujų žinių, kad mokėtų naudoti DI technologijas, pačioms DI sistemoms reikalinga infrastruktūra ir priežiūros sistema, kuriai palaikyti reikalingi nemaži resursai. Vokietijoje atliktas tyrimas parodė, jog didžioji dalis ligoninių nenaudoja ir neplanuoja diegti DI sistemų dėl neaiškaus atsiperkamumo ar modernios IT infrastruktūros, kuri būtų reikalinga integruoti DI įrankius tinkamu būdu (Weinert et al., 2022). Pačiai organizacijai vieno proceso su efektyvinimas ilgalaikės naudos atžvilgiu gali tapti neefektyvus, todėl yra svarbu išlaikyti sąmoningumą ir kritiškai vertinti tikėtinas DI naudas. Pavyzdžiui, patologijoje ir radiologijoje naudojamoms DI sistemoms yra reikalingas nuolatinis ekspertų anotuotų vaizdų srautas, užtikrinantis sistemos tikslumą (Maloca et al., 2019).

DI pagerina sveikatos priežiūros paslaugų efektyvumą ir prieinamumą. DI technologijų pagalba yra greičiau atliekami diagnostiniai tyrimai ir pradedamas reikiamas gydymas. Atsižvelgiant į augantį sveikatos priežiūros paslaugų poreikį ir medicinos personalo trūkumą, DI technologijų pagalba yra siekiama palaikyti diagnostinių paslaugų prieinamumą perleidžiant dalį aukštos kvalifikacijos darbuotojų darbo krūvio mažiau kvalifikuotiems specialistams. Šiame tyrime nepavyko įvertinti DI įtakos suteiktų paslaugų veiksmingumui. Tyrimo

respondentai DI sistemas naudojo diagnostikoje, o gydymo sprendimai yra priimami gydančiojo personalo. Gydomo veiksmingumo vertinimą komplikuoja papildomi kitų medicinos įrašų duomenys ir tinkamos kontrolinės grupės trūkumas, todėl tampa labai sunku tinkamai metodiškai įvertinti kiek DI sistemų sprendimai prisideda prie paciento gydymo sėkmės.

Šio tyrimo rezultatai yra grįsti tik penkių Europos šalių ekspertų nuomone. Nors ekspertų patirtys ir nuomonės daugelyje klausimų nesiskyrė, tyrimo rezultatai gali būti kitokie, jei į tyrimą būtų įtraukta daugiau ekspertų iš kitų šalių. Šis kokybinis, nedidelės apimties tyrimas gali būti traktuojamas kaip pilotinė studija, kuri galėtų prisidėti kuriant didesnės apimties, kiekybinių tyrimų metodus ir protokolus siekiant išsiaiškinti DI įtaką sveikatos priežiūros paslaugų kokybei.

Sisteminę DI technologijų poveikį sveikatos priežiūros paslaugų kokybei bus galima įvertinti praėjus keliems dešimtmečiams po jų diegimo ir to padaryti nebus įmanoma be empirinių įžvalgų apie pačių vartotojų kasdienę patirtį. Skatinant nuolatinį medicinos personalo ir DI kūrėjų bendradarbiavimą, būtų galima užtikrinti, kad DI įrankių vertinimas neapsiribotų jų techninėmis galimybėmis ir būtų suderintas su sveikatos priežiūros tikslais ir etikos standartais. Taip būtų siekiama optimizuoti DI naudą, kartu mažinant galimą riziką ir užtikrinti, kad DI pagerintų visą klinikinių sprendimų priėmimo procesą.

LITERATŪROS SĄRAŠAS

1. Abidova, A., Silva, P. A. Da, & Moreira, S. (2021). The mediating role of patient satisfaction and perceived quality of healthcare in the emergency department. *Medicine (United States)*, 100(11), E25133. <https://doi.org/10.1097/MD.00000000000025133>
2. Aiken, L. H., Sermeus, W., Van Den Heede, K., Sloane, D. M., Busse, R., McKee, M., Bruyneel, L., Rafferty, A. M., Griffiths, P., Moreno-Casbas, M. T., Tishelman, C., Scott, A., Brzostek, T., Kinnunen, J., Schwendimann, R., Heinen, M., Zikos, D., Sjetne, I. S., Smith, H. L., & Kutney-Lee, A. (2012). Patient safety, satisfaction, and quality of hospital care: Cross sectional surveys of nurses and patients in 12 countries in Europe and the United States. *BMJ (Online)*, 344(7851), 1–14. <https://doi.org/10.1136/bmj.e1717>
3. Al-Antari, M. A. (2023). Artificial Intelligence for Medical Diagnostics—Existing and Future AI Technology! *Diagnostics*, 13(4), 1–3. <https://doi.org/10.3390/diagnostics13040688>
4. Ashique, S., Mishra, N., Mohanto, S., Garg, A., Taghizadeh-Hesary, F., Gowda, B. H. J., & Chellappan, D. K. (2024). Application of artificial intelligence (AI) to control COVID-19 pandemic: Current status and future prospects. *Heliyon*, 10(4), e25754. <https://doi.org/10.1016/j.heliyon.2024.e25754>
5. Barnett, M. L., Ray, K. N., Souza, J., & Mehrotra, A. (2018). Trends in Telemedicine Use in a Large Commercially Insured Population, 2005-2017. *JAMA - Journal of the American Medical Association*, 320(20), 2147–2149. <https://doi.org/10.1001/jama.2018.12354>
6. Beck, A. H., Sangoi, A. R., Leung, S., Marinelli, R. J., Nielsen, T. O., Van De Vijver, M. J., West, R. B., Van De Rijn, M., & Koller, D. (2011). Imaging: Systematic analysis of breast cancer morphology uncovers stromal features associated with survival. *Science Translational Medicine*, 3(108), 1–12. <https://doi.org/10.1126/scitranslmed.3002564>
7. Bera, K., Schalper, K. A., Rimm, D. L., Velcheti, V., & Madabhushi, A. (2019). Diagnosis and Precision Oncology. *Nature Review Clinical Oncology*, 16(11), 703–715. <https://doi.org/10.1038/s41571-019-0252-y>.Artificial
8. Braun, V., & Clarke, V. (2019). Reflecting on reflexive thematic analysis. *Qualitative Research in Sport, Exercise and Health*, 11(4), 589–597.

<https://doi.org/10.1080/2159676X.2019.1628806>

9. Cabrera-Barona, P., Blaschke, T., & Kienberger, S. (2017). Explaining Accessibility and Satisfaction Related to Healthcare: A Mixed-Methods Approach. *Social Indicators Research*, 133(2), 719–739. <https://doi.org/10.1007/s11205-016-1371-9>
10. Campanella, G., Hanna, M. G., Geneslaw, L., Miraflor, A., Silva, W. K., Busam, K. J., Brogi, E., Reuter, V. E., Klimstra, D. S., & Fuchs, T. J. (2020). Deep Learning on Whole Slide Images. *Nature Medicine*, 25(8), 1301–1309. <https://doi.org/10.1038/s41591-019-0508-1>.Clinical-grade
11. Cha, S. (2021). S.Korea to test AI-powered facial recognition to track COVID-19 cases. REUTERS. <https://www.reuters.com/world/asia-pacific/skorea-test-ai-powered-facial-recognition-track-covid-19-cases-2021-12-13/>
12. Choudhury, A., & Asan, O. (2020). Role of artificial intelligence in patient safety outcomes: Systematic literature review. *JMIR Medical Informatics*, 8(7). <https://doi.org/10.2196/18599>
13. Corredor, G., Wang, X., Zhou, Y., Lu, C., Fu, P., Syrigos, K., Rimm, D. L., Yang, M., Romero, E., Schalper, K. A., Velcheti, V., & Madabhushi, A. (2019). Spatial architecture and arrangement of tumor-infiltrating lymphocytes for predicting likelihood of recurrence in early-stage non–small cell lung cancer. *Clinical Cancer Research*, 25(5), 1526–1534. <https://doi.org/10.1158/1078-0432.CCR-18-2013>
14. Creswell, J. W., & Creswell, J. D. (2018). *Mixed Methods Procedures. Research Defign: Qualitative, Quantitative, and Mixed M ethods Approaches.*
15. Davenport, T., & Kalakota, R. (2019). The potential for artificial intelligence in healthcare. *Future Healthcare Journal*, 6(2), 94–98. <https://doi.org/10.7861/futurehosp.6-2-94>
16. Denzin, N. K., & Lincoln, Y. S. (2017). *The Sage Handbook of Qualitative Research (5th leid.)*. SAGE Publications, Inc. <https://doi.org/10.1111/j.1467-839x.2007.00237.x>
17. Directorate-General for Communications Networks, C. and T. (2022). Study on eHealth, interoperability of health data and artificial intelligence for health and care in the European Union : final study report. Lot 2, Artificial Intelligence for health and care in the EU.
18. Do, H., Spear, L., Nikpanah, M., Mirmomen, M., Machado, L., Toscano, A., Turkbey, B., Bagheri, M., Gulley, J., & Folio, L. (2020). Augmented Radiologist Workflow Improves Report Value and Saves Time: A Potential Model for Implementation of Artificial Intelligence. *Physiology & behaviorAcademic Radiology*, 27(1), 96–105. <https://doi.org/10.1016/j.acra.2019.09.014>

19. EIT Health and McKinsey & Company. (2020). Transforming Healthcare with AI. The impact on the workforce and organisations (Numeris March). <https://doi.org/10.1002/9781119709183.ch3>
20. Eric, N. (2020). An AI Epidemiologist Sent the First Warnings of the Wuhan Virus. WIRED.
21. Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115–118. <https://doi.org/10.1038/nature21056>
22. Ettman, C. K., & Galea, S. (2023). The Potential Influence of AI on Population Mental Health. *JMIR Mental Health*, 10(1), 1–6. <https://doi.org/10.2196/49936>
23. Feng, J., Phillips, R. V., Malenica, I., Bishara, A., Hubbard, A. E., Celi, L. A., & Pirracchio, R. (2022). Clinical artificial intelligence quality improvement: towards continual monitoring and updating of AI algorithms in healthcare. *npj Digital Medicine*, 5(1), 1–9. <https://doi.org/10.1038/s41746-022-00611-y>
24. Forman, J., & Damschroder, L. (2015). Qualitative Content Analysis In Empirical Methods for Bioethics: A Primer. Emerald Group Publishing Limited, 11, 39–62. [https://doi.org/10.1016/S1479-3709\(07\)11003-7](https://doi.org/10.1016/S1479-3709(07)11003-7)
25. Godwin, R. C., & Melvin, R. L. (2023). the Role of Quality Metrics in the Evolution of Ai in Health Care and Implications for Generative Ai. *Physiological Reviews*, 103(4), 2873–2875. <https://doi.org/10.1152/PHYSREV.00029.2023>
26. Gould, M., Joshi, I., & Tang, M. (2020). The power of data in a pandemic. Department of Health and Social Care. <https://healthtech.blog.gov.uk/2020/03/28/the-power-of-data-in-a-pandemic/>
27. Gupta, M. D., Kunal, S., Girish, M. P., Gupta, A., & Yadav, R. (2022). Artificial intelligence in cardiology: The past, present and future. *Indian Heart Journal*, 74(4), 265–269. <https://doi.org/10.1016/j.ihj.2022.07.004>
28. Hannun, A. Y., Rajpurkar, P., Haghpanahi, M., Tison, G. H., Bourn, C., Turakhia, M. P., & Ng, A. Y. (2019). Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network. *Nature Medicine*, 25(1), 65–69. <https://doi.org/10.1038/s41591-018-0268-3>
29. Ho, D. (2020). Artificial intelligence in cancer therapy. *Science*, 367(6481), 982–983. <https://doi.org/10.1126/science.aaz3023>
30. Huang, S., Yang, J., Fong, S., & Zhao, Q. (2021). Artificial intelligence in the diagnosis of covid-19: Challenges and perspectives. *International Journal of Biological Sciences*, 17(6), 1581–1587. <https://doi.org/10.7150/ijbs.58855>

31. Jamshed, S. (2014). Qualitative research method-interviewing and observation. *Journal of Basic and Clinical Pharmacy*, 5(4), 87. <https://doi.org/10.4103/0976-0105.141942>
32. Jiang, F., Jiang, Y., Zhi, H., Dong, Y., Li, H., Ma, S., Wang, Y., Dong, Q., Shen, H., & Wang, Y. (2017). Artificial intelligence in healthcare: Past, present and future. *Stroke and Vascular Neurology*, 2(4), 230–243. <https://doi.org/10.1136/svn-2017-000101>
33. Johnson, K. W., Torres Soto, J., Glicksberg, B. S., Shameer, K., Miotto, R., Ali, M., Ashley, E., & Dudley, J. T. (2018). Artificial Intelligence in Cardiology. *Journal of the American College of Cardiology*, 71(23), 2668–2679. <https://doi.org/10.1016/j.jacc.2018.03.521>
34. Jongsma, K. R., Sand, M., & Milota, M. (2024). Why we should not mistake accuracy of medical AI for efficiency. *npj Digital Medicine*, 7(1), 2–4. <https://doi.org/10.1038/s41746-024-01047-2>
35. Kaidar-Person, O., Antunes, M., Cardoso, J. S., Ciani, O., Cruz, H., Di Micco, R., Gentilini, O. D., Gonçalves, T., Gouveia, P., Heil, J., Kabata, P., Lopes, D., Martinho, M., Martins, H., Mavioso, C., Mika, M., Montenegro, H., Oliveira, H. P., Pfof, A., ... Cardoso, M. J. (2023). Evaluating the ability of an artificialintelligence cloud-based platform designed to provide information prior to locoregional therapy for breast cancer in improving patient’s satisfaction with therapy: The CINDERELLA trial. *PLoS ONE*, 18(8 AUGUST), 1–12. <https://doi.org/10.1371/journal.pone.0289365>
36. Karim Lekadir, Quaglio Gianluca, Tselioudis Anna, G. C. (2022). Artificial intelligence in healthcare. Applications, risks, and ethical and societal impacts. <https://doi.org/10.2861/568473>
37. Kelly, C. J., Karthikesalingam, A., Suleyman, M., Corrado, G., & King, D. (2019). Key challenges for delivering clinical impact with artificial intelligence. *BMC Medicine*, 17(1), 1–9. <https://doi.org/10.1186/s12916-019-1426-2>
38. Lebovitz, S., Levina, N., & Lifshitz-Assaf, H. (2021). Is AI ground truth really true? The dangers of training and evaluating AI tools based on experts’ know-what. *MIS Quarterly: Management Information Systems*, 45(3), 1501–1525. <https://doi.org/10.25300/MISQ/2021/16564>
39. Li, J., Wu, J., Zhao, Z., Zhang, Q., Shao, J., Wang, C., Qiu, Z., & Li, W. (2021). Artificial intelligence-assisted decision making for prognosis and drug efficacy prediction in lung cancer patients: a narrative review. *Journal of Thoracic Disease*, 13(12), 7021–7033. <https://doi.org/10.21037/jtd-21-864>
40. Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., van der Laak, J. A. W. M., van Ginneken, B., & Sánchez, C. I. (2017). A survey on deep

- learning in medical image analysis. *Medical Image Analysis*, 42, 60–88. <https://doi.org/10.1016/j.media.2017.07.005>
41. Liu, X., Faes, L., Kale, A. U., Wagner, S. K., Fu, D. J., Bruynseels, A., Mahendiran, T., Moraes, G., Shamdas, M., Kern, C., Ledsam, J. R., Schmid, M. K., Balaskas, K., Topol, E. J., Bachmann, L. M., Keane, P. A., & Denniston, A. K. (2019). A comparison of deep learning performance against health-care professionals in detecting diseases from medical imaging: a systematic review and meta-analysis. *The Lancet Digital Health*, 1(6), e271–e297. [https://doi.org/10.1016/S2589-7500\(19\)30123-2](https://doi.org/10.1016/S2589-7500(19)30123-2)
 42. Maloca, P. M., Lee, A. Y., De Carvalho, E. R., Okada, M., Fasler, K., Leung, I., Hörmann, B., Kaiser, P., Suter, S., Hasler, P. W., Zarranz-Ventura, J., Egan, C., Heeren, T. F. C., Balaskas, K., Tufail, A., & Scholl, H. P. N. (2019). Validation of automated artificial intelligence segmentation of optical coherence tomography images. *PLoS ONE*, 14(8), 1–14. <https://doi.org/10.1371/journal.pone.0220063>
 43. Mehta, N., & Shukla, S. (2022). Pandemic Analytics: How Countries are Leveraging Big Data Analytics and Artificial Intelligence to Fight COVID-19? *SN Computer Science*, 3(1), 1–20. <https://doi.org/10.1007/s42979-021-00923-y>
 44. Mentis, A. F. A., Lee, D., & Roussos, P. (2023). Applications of artificial intelligence–machine learning for detection of stress: a critical overview. *Molecular Psychiatry*, April. <https://doi.org/10.1038/s41380-023-02047-6>
 45. Miotto, R., Li, L., Kidd, B. A., & Dudley, J. T. (2016). Deep Patient: An Unsupervised Representation to Predict the Future of Patients from the Electronic Health Records. *Scientific Reports*, 6(January), 1–10. <https://doi.org/10.1038/srep26094>
 46. Morse, J. M., Barrett, M., Mayan, M., Olson, K., & Spiers, J. (2002). Verification Strategies for Establishing Reliability and Validity in Qualitative Research. *International Journal of Qualitative Methods*, 1(2), 13–22. <https://doi.org/10.1177/160940690200100202>
 47. OECD/European Union. (2022). Health at a Glance: Europe 2022: State of Health in the EU Cycle. <https://doi.org/10.1787/2c161b2a-en>
 48. Parekh, A.-D. E., Shaikh, O. A., Simran, Manan, S., & Hasibuzzaman, M. Al. (2023). Artificial intelligence (AI) in personalized medicine: AI-generated personalized therapy regimens based on genetic and medical history: short communication. *Annals of Medicine & Surgery*, 85(11), 5831–5833. <https://doi.org/10.1097/ms9.0000000000001320>
 49. Patel, S. B., & Lam, K. (2023). ChatGPT: the future of discharge summaries? *The Lancet Digital Health*, 5(3), e107–e108. [https://doi.org/10.1016/S2589-7500\(23\)00021-](https://doi.org/10.1016/S2589-7500(23)00021-)

50. Penfold, R. B., Carrell, D. S., Cronkite, D. J., Pabiniak, C., Dodd, T., Glass, A. M., Johnson, E., Thompson, E., Arrighi, H. M., & Stang, P. E. (2022). Development of a machine learning model to predict mild cognitive impairment using natural language processing in the absence of screening. *BMC Medical Informatics and Decision Making*, 22(1), 1–13. <https://doi.org/10.1186/s12911-022-01864-z>
51. Peng, J., & Wang, Y. (2021). Medical image segmentation with limited supervision: A review of deep network models. *IEEE Access*, 9, 36827–36851. <https://doi.org/10.1109/ACCESS.2021.3062380>
52. Pesapane, F., Codari, M., & Sardanelli, F. (2018). Artificial intelligence in medical imaging: threat or opportunity? Radiologists again at the forefront of innovation in medicine. *European Radiology Experimental*, 2(1). <https://doi.org/10.1186/s41747-018-0061-6>
53. Rajkomar, A., Dean, J., & Kohane, I. (2019). Machine Learning in Medicine. *New England Journal of Medicine*, 380(14), 1347–1358. <https://doi.org/10.1056/nejmra1814259>
54. Rashid, M. B. M. A., Toh, T. B., Hooi, L., Silva, A., Zhang, Y., Tan, P. F., Teh, A. L., Karnani, N., Jha, S., Ho, C. M., Chng, W. J., Ho, D., & Kai-Hua Chow, E. (2018). Optimizing drug combinations against multiple myeloma using a quadratic phenotypic optimization platform (QPOP). *Science Translational Medicine*, 10(453). <https://doi.org/10.1126/scitranslmed.aan0941>
55. Rockville, M., & Agency for Healthcare Research and Quality. (2020). 2019 National Healthcare Quality and Disparities Report.
56. Santos, F. P., Lelkes, Y., & Levin, S. A. (2021). Link recommendation algorithms and dynamics of polarization in online social networks. *Proceedings of the National Academy of Sciences of the United States of America*, 118(50), e2102141118. <https://doi.org/10.1073/pnas.2102141118>
57. Seetharam, K., Shrestha, S., & Sengupta, P. P. (2021). Cardiovascular Imaging and Intervention Through the Lens of Artificial Intelligence. *Interventional Cardiology: Reviews, Research, Resources*, 16. <https://doi.org/10.15420/icr.2020.04>
58. Sermesant, M., Delingette, H., Cochet, H., Jaïs, P., & Ayache, N. (2021). Applications of artificial intelligence in cardiovascular imaging. *Nature Reviews Cardiology*, 18(8), 600–609. <https://doi.org/10.1038/s41569-021-00527-2>
59. Singh, J. P. (2023). The Impacts and Challenges of Generative Artificial Intelligence in Medical Education, Clinical Diagnostics, Administrative Efficiency, and Data

- Generation. *International Journal of Applied Health Care Analytics*, 8(May 2023).
60. Siontis, K. C., Noseworthy, P. A., Attia, Z. I., & Friedman, P. A. (2021). Artificial intelligence-enhanced electrocardiography in cardiovascular disease management. *Nature Reviews Cardiology*, 18(7), 465–478. <https://doi.org/10.1038/s41569-020-00503-2>
 61. Somashekhar, S. P., Sepúlveda, M. J., Puglielli, S., Norden, A. D., Shortliffe, E. H., Rohit Kumar, C., Rauthan, A., Arun Kumar, N., Patil, P., Rhee, K., & Ramya, Y. (2018). Watson for Oncology and breast cancer treatment recommendations: Agreement with an expert multidisciplinary tumor board. *Annals of Oncology*, 29(2), 418–423. <https://doi.org/10.1093/annonc/mdx781>
 62. Subramanian, M., Wojtusciszyn, A., Favre, L., Boughorbel, S., Shan, J., Letaief, K. B., Pitteloud, N., & Chouchane, L. (2020). Precision medicine in the era of artificial intelligence: implications in chronic disease management. *Journal of Translational Medicine*, 18(1), 1–12. <https://doi.org/10.1186/s12967-020-02658-5>
 63. Tai-Seale, M., Olson, C. W., Li, J., S., C. A., S., A., Morikawa, C., Durbin, M., Wang, W., & Luft, H. S. (2017). Re: Electronic Health Record Logs Indicate that Physicians Split Time Evenly between Seeing Patients and Desktop Medicine. *HEALTH AFFAIRS*, 36(4), 655–662. <https://doi.org/10.1016/j.juro.2017.09.105>
 64. Topol, E. J. (2019). High-performance medicine: the convergence of human and artificial intelligence. *Nature Medicine*, 25(1), 44–56. <https://doi.org/10.1038/s41591-018-0300-7>
 65. Weinert, L., Müller, J., Svensson, L., & Heinze, O. (2022). Perspective of Information Technology Decision Makers on Factors Influencing Adoption and Implementation of Artificial Intelligence Technologies in 40 German Hospitals: Descriptive Analysis. *JMIR Medical Informatics*, 10(6). <https://doi.org/10.2196/34678>
 66. World Health Organization. Regional Office for Europe, E. O. on H. S. and P., Busse, R., Klazinga, N., Panteli, D., & Quentin, W. (2019). Improving healthcare quality in Europe: Characteristics, effectiveness and implementation of different strategies. *Improving Healthcare Quality in Europe*.
 67. World Health Organization. (2023). Coronavirus disease (COVID-19): Corticosteroids, including dexamethasone. <https://www.who.int/news-room/questions-and-answers/item/coronavirus-disease-covid-19-dexamethasone>
 68. Wu, H., Lu, X., & Wang, H. (2023). The Application of Artificial Intelligence in Health Care Resource Allocation Before and During the COVID-19 Pandemic: Scoping Review. *Jmir Ai*, 2, e38397. <https://doi.org/10.2196/38397>

69. Yang, S., Zhu, F., Ling, X., Liu, Q., & Zhao, P. (2021). Intelligent Health Care: Applications of Deep Learning in Computational Medicine. *Frontiers in Genetics*, 12(April), 1–21. <https://doi.org/10.3389/fgene.2021.607471>
70. Zhavoronkov, A., Ivanenkov, Y. A., Aliper, A., Veselov, M. S., Aladinskiy, V. A., Aladinskaya, A. V., Terentiev, V. A., Polykovskiy, D. A., Kuznetsov, M. D., Asadulaev, A., Volkov, Y., Zholus, A., Shayakhmetov, R. R., Zhebrak, A., Minaeva, L. I., Zagribelnyy, B. A., Lee, L. H., Soll, R., Madge, D., ... Aspuru-Guzik, A. (2019). Deep learning enables rapid identification of potent DDR1 kinase inhibitors. *Nature Biotechnology*, 37(9), 1038–1040. <https://doi.org/10.1038/s41587-019-0224-x>
71. Zhou, J., Du, M., Chang, S., & Chen, Z. (2021). Artificial intelligence in echocardiography: detection, functional evaluation, and disease diagnosis. *Cardiovascular Ultrasound*, 19(1), 1–11. <https://doi.org/10.1186/s12947-021-00261-2>

DIRBTINIO INTELEKTO ĮTAKA SVEIKATOS PRIEŽIŪROS PASLAUGŲ KOKYBEI

Vaiva PATAMSYTĖ
Magistro baigiamasis darbas
Kokybės vadybos magistro programa

Vilniaus universiteto Ekonomikos ir verslo administravimo fakultetas

Darbo vadovas: **Prof. D. Serafinas**

Vilnius, 2024

SANTRAUKA

56 puslapiai, 7 lentelės, 7 paveikslai, 71 šaltinių nuoroda

Šiame magistro darbe yra nagrinėjama dirbtinio intelekto (DI) įtaka sveikatos priežiūros paslaugų kokybei. DI turi didžiulį potencialą sprendžiant šiuolaikinius sveikatos priežiūros iššūkius, tokius kaip visuomenės senėjimas, medicinos personalo trūkumas ir augančios sveikatos priežiūros išlaidos. Sveikatos priežiūroje DI yra naudojamas klinikinėje diagnostikoje, personalizuotoje medicinoje ir atliekant įvairias administracines užduotis.

Empirinis tyrimas buvo atliekamas naudojant kokybinį tyrimo metodą – pusiau struktūruotą interviu. Tyrimas buvo atliktas apklausiant Europos šalių sveikatos priežiūros specialistus medikus, dirbančius su DI sistemomis. Tyrimo metu siekta išsiaiškinti DI naudojimo sritis sveikatos priežiūros įstaigose, įvertinti jų panaudojimo poveikį diagnozės tikslumui, gydymui, bei resursų optimizavimui ir nustatyti kokią įtaką tai daro sveikatos priežiūros paslaugų kokybei.

Tyrimo metu nustatyta, jog sveikatos priežiūros sistemoje DI daugiausia naudojamas klinikinėje diagnostikoje: radiologijos, kardiologijos, onkologijos ir patologijos srityse. DI sistemų pagalba yra automatizuojami matavimai, kurie gydytojų specialistų būtų atliekami rankiniu būdu. Tai leidžia perskirstyti resursus ir greičiau atlikti diagnostines užduotis. Sveikatos priežiūros paslaugos teikiamos efektyviau, jos tampa labiau prieinamas pacientams: galima greičiau atlikti tyrimą, pradėti paskirtą gydymą. DI sistemų įtakos gydymo veiksmingumui nustatyti nepavyko, nes šie rodikliai nebuvo vertinami tyrime dalyvavusių respondentų.

Nors DI sistemos sveikatos priežiūros įstaigose yra naudojamos darbo efektyvinimui, dažniausiai kokybės rodikliai yra matuojami tik tame skyriuje, kuriame yra įdiegtos DI sistemos, o tai gali neįtraukti resursų, reikalingų DI technologijų palaikymui. Norint įvertinti tikrąjį DI sistemų efektyvumą sveikatos priežiūroje reikia vertinti rodiklius ne skyriaus, o visos organizacijos kontekste. Šio tyrimo rezultatai galėtų būti naudojami didesnės apimties kokybinio tyrimo dizainui ar kiekybinio tyrimo klausimyno sudarymui. Šie tyrimai padėtų valdyti DI naudotojų lūkesčius ir numatyti reikalingus resursus organizacijoms, siekiančioms diegti DI sistemas.

THE IMPACT OF ARTIFICIAL INTELLIGENCE ON THE QUALITY OF HEALTHCARE SERVICES

Vaiva PATAMSYTĖ

Paper for Master's Program

Quality Management Master's Program

Vilnius University Faculty of Economics and Business Administration

Supervisor: **Prof. D. Serafinas**

Vilnius, 2024

SUMMARY

56 pages, 7 tables, 7 pictures, 71 references.

This master's thesis examines the impact of artificial intelligence (AI) on the quality of healthcare services. AI has great potential to address contemporary healthcare challenges such as an aging population, a shortage of medical staff, and rising healthcare costs. In healthcare, AI is used in clinical diagnosis, personalized medicine, and various administrative tasks.

The empirical research was conducted using a qualitative research method: semi-structured interviews. The study involved interviewing healthcare professionals from European countries who work with AI systems. The research aimed to identify areas of AI usage in healthcare facilities, assess their impact on diagnostic accuracy, treatment, and resource optimization, and determine their influence on the quality of healthcare services.

The study found that AI is primarily used in clinical diagnosis within the healthcare system, particularly in radiology, cardiology, oncology, and pathology. AI systems automate measurements that would otherwise be manually performed by specialists. This allows resources to be redistributed and diagnostic tasks to be completed more quickly, making healthcare services more accessible to patients and enabling quicker diagnosis and treatment initiation.

The influence of AI systems on treatment effectiveness could not be determined, as these indicators were not evaluated by the respondents involved in the study. Although AI systems are used for work efficiency in healthcare institutions, quality indicators are often measured only in the department where the AI systems are implemented, excluding the resources required to maintain the technology.

To accurately assess the effectiveness of AI systems in healthcare, the indicators should be evaluated in the context of the entire organization, not just a department. These research findings could be used to design larger-scale qualitative research or to create questionnaires for quantitative studies. Such studies would help manage user expectations and predict the necessary resources for organizations planning to implement AI systems.

PRIEDAI

1 Priedas. Kvietimas dalyvauti tyrime

Dear Sir/Madam,

I am a postgraduate student at Vilnius University, conducting a study "The Impact of Artificial Intelligence on the Quality Healthcare Services" I'm seeking healthcare experts who are integrating AI tools into their practice and are willing to share their insights.

...I find your expertise invaluable to my study and would like to send an invitation for you to join me in a 30-minute interview to discuss your use of AI in healthcare and its impact on quality metrics.

Please feel free to reach out if you have any inquiries or require further information.