

VILNIAUS UNIVERSITETAS
MEDICINOS FAKULTETAS

Baigiamasis darbas

Dirbtinio intelekto pritaikymas akių ligų diagnostikoje

Artificial Intelligence Assisted Diagnostic Procedures in Ophthalmology

Studentas, grupė: Artur Bobin, 4 gr.

Katedra/ Klinikos kurioje ruošiamas ir ginamas darbas:

Klinikinės medicinos institutas – ausų, nosies, gerklės ir akių ligų klinika

Darbo vadovas

Asistentė. dr. Rasa Strupaitė-Šileikienė
(pedagoginis vardas, mokslo laipsnis, vardas, pavardė)

Katedros arba Klinikos vadovas

Prof. dr. Eugenijus Lesinskas
(pedagoginis vardas, mokslo laipsnis, vardas, pavardė)

2022-05-19

Studento elektroninio pašto adresas - artur.bobin@mf.stud.vu.lt

SANTRAUKA

DIRBTINIO INTELEKTO PRITAIKYMAS AKIŲ LIGŲ DIAGNOSTIKOJE

Dirbtinis intelektas, tinkamai jį pritaikius, turi didelį potencialą transformuoti medicinoje atliekamas diagnostines procedūras. Šio įrankio panaudojimas labai tinkamas oftalmologijai, nes akių ligų diagnostika yra paremta akių apžiūra plyšine lempa ir vaizdiniais tyrimais.

Šios apžvalgos tikslas įvertinti dirbtiniu intelektu paremtų diagnostikos prietaisų tikslumą, apžvelgti dirbtinio intelekto veikimo principus ir aptarti šio diagnostikos būdo privalumus ir trūkumus. Publikacijų paieška buvo atlikta PubMed duomenų bazėje, kurios metu atrinktos 38 publikacijos sisteminei ir 27 publikacijos literatūros apžvalgai. Sisteminės apžvalgos metu aptartos: 20 publikacijų diabetinės retinopatijos tema, 8 publikacijos glaukomos, 5 publikacijos amžinės geltonosios dėmės degeneracijos ir 5 publikacijos kitų akių ligų tema.

Diagnostinis tikslumas buvo analizuotas naudojant AUC (angl. *area under the curve*), jautrumo ir specifiškumo rodiklius. Taip pat dalyje publikacijų lygino diagnostinį tikslumą tarp dirbtiniu intelektu paremtu prietaisų ir gydytojų specialistų. Diabetinės retinopatijos AUC rodiklio vidurkis siekė 0,940, jautrumas 93,82 procentų ir specifiškumas 90,48 procentų. Glaukomos AUC rodiklio vidurkis siekė 0,933, jautrumas 86,90 procentų ir specifiškumas 90,16 procentų. Amžinės geltonosios dėmės degeneracijos AUC rodiklio vidurkis siekė 0,960, jautrumas 90,02 procentų ir specifiškumas 91,00 procentų.

Taigi, dirbtinis intelektas yra sparčiai tobulėjanti technologija, kuri turi didelį potencialą įsiterpti į klinikinę praktiką oftalmologijos srityje. Sisteminės analizės duomenimis dirbtiniu intelektu paremtų diagnostikos sistemų tikslumas buvo pakankamai geras, kad šie įrenginiai būtų naudojami klinikinėje praktikoje. Taip pat publikacijų duomenimis dirbtiniu intelektu paremtų prietaisų diagnostikos tikslumas buvo lygus arba didesnis už gydytojų specialistų.

Raktažodžiai: Dirbtinis intelektas, Gilusis mokymasis, AUC, jautrumas, specifiškumas.

ABSTRACT

ARTIFICIAL INTELLIGENCE ASSISTED DIAGNOSTIC PROCEDURES IN OPHTHALMOLOGY

Artificial intelligence has the potential to transform diagnostic procedures in medicine. The use of this tool is applicable in ophthalmology since the diagnosis of eye diseases is based on image or visual tests.

This review aims to assess the accuracy of artificial intelligence-based diagnostic tools, provide an overview of the principles of artificial intelligence, and discuss the advantages and disadvantages of this diagnostic modality. A search of the PubMed database was carried out and 38 publications were selected for the systematic review and 27 publications for the literature review. The systematic review included 20 publications on diabetic retinopathy, 8 publications on glaucoma, 5 publications on age-related macular degeneration, and 5 publications on other eye diseases.

Diagnostic accuracy was analyzed using the area under the curve (AUC), sensitivity and specificity. In some of the publications scientists also compared diagnostic accuracy between artificial intelligence-based devices and medical specialists. For diabetic retinopathy, the mean AUC was 0.940, with a sensitivity of 93.82 per cent and a specificity of 90.48 per cent. Glaucoma had a mean AUC of 0.933, a sensitivity of 86.90 per cent, and a specificity of 90.16 per cent. Age-related macular degeneration had a mean AUC of 0.960, a sensitivity of 90.02 per cent, and a specificity of 91.00 per cent.

Thus, artificial intelligence is a rapidly advancing technology that has great potential to enter clinical practice in ophthalmology. The accuracy of the artificial intelligence-based diagnostic systems in this analysis was good enough to use these devices in clinical practice. Publications have also shown that the diagnostic accuracy of artificial intelligence-based devices has been equal to or better than that of medical specialists.

Keywords: artificial intelligence, deep learning, machine learning, AUC, sensitivity, specificity.

SANTRUMPOS

AGDD – amžinė geltonosios dėmės degeneracija

CD – cukrinis diabetas

DGDE – diabetinės geltonosios dėmės edema

DI – dirbtinis intelektas

DM – duomenų mokslas

DNT – dirbtiniai neuroniniai tinklai

DR – diabetinė retinopatija

GM – gilusis mokymasis

GNV – gyslainės neovaskuliarizacija

NNR – neišnešiotų naujagimių retinopatija

OKT – optinė koherentinė tomografija

SĄVOKOS

Duomenų mokslas (angl. *data science*) – tai tarpdisciplininė, duomenų analizės sritis, jungianti statistinius metodus su pažangiomis informacinėmis technologijomis.

Dirbtinis intelektas (angl. *artificial intelligence*) – kompiuterių mokslo šaka, kurianti sistemas, kurios gali atkartoti žmogaus elgesį.

Kompiuterio mokymasis (angl. *machine learning*) – dirbtinio intelekto tipas, kuriam pateikus duomenų bazę (pvz.: akių dugno nuotraukas) sistema geba automatiškai apdoroti naują informaciją, tokiu būdu analizuojant atliktas klaidas ir tikslinti savo veikimą.

Gilusis mokymasis (angl. *deep learning*) – kompiuterio mokymosi tipas, naudojantis didelį dirbtinių neuroninių tinklų kiekį. Jie sukurti tokiu principu kaip žmogaus smegenų neuroniniai tinklai. Šie tinklai analizuoja duomenis ir patys suformuoja spėjimą apie pateiktus duomenis.

Dirbtiniai neuroniniai tinklai (angl. *artificial neural networks*) – pagrindinė šių tinklų funkcija yra apibendrinti ir transformuoti vaizdinius į algoritmui suprantamą informaciją.

Prižiūrimas mokymas (angl. *supervised learning*) – kompiuterio mokymosi algoritmas, klasifikuojantis specialistų pažymėtus duomenis į norimas kategorijas (pvz.: norma ir patologinis variantas). Šis mokymo tipas dažniausiai taikomas medicinoje.

Neprižiūrimas mokymas (angl. *unsupervised learning*) – algoritmas klasifikuojantis duomenis į grupes, pagal jo pačio pastebimus radinius duomenyse (1,2).

IVADAS

2019 metais Pasaulio Sveikatos Organizacijos (PSO) ekspertai išleido publikaciją, kurioje aptariami pasaulio populiacijos regėjimo duomenys, akių ligų sukeliama našta ir aptariami būdai, kurie galėtų gerinti situaciją. Šiuo metu apie 2,2 milijardo žmonių patiria regėjimo sutrikimus arba aklumą. Jei liga būtų tinkamai ir laiku diagnozuota, paskirtas tinkamas stebėjimo ir gydymo planas, maždaug 1 milijardas žmonių galėtų šių sutrikimų išvengti (3). Daugiausiai naštos žmonėms sukianti akių ligų pasekmė yra pablogėjęs matymas arba aklumas. Pagrindinės ligos sukeliančios regėjimo sutrikimus yra katarakta, amžinė geltonosios dėmės degeneracija, diabetinė retinopatija ir glaukoma. Pagal PSO prognozes, išlikus 2019 m. sergamumo rodikliams, glaukomos atvejų skaičius didės kasmet 1,3 karto ir sieks 76 milijonus žmonių, o 2030 m. gali siekti apie 95,4 milijonus. Numatomas amžinės geltonosios dėmės degeneracijos atvejų skaičius 2030 m. yra apie 243,3 milijono žmonių (3). Remiantis Jungtinės Amerikos valstijų (JAV) diabeto asociacijos duomenimis 2012 m. diabetine retinopatija sergančių žmonių populiacija siekė 93 milijonus, o sergant diabetu diabetinės retinopatijos pasireiškimas buvo 34,6 proc. (4). Profilaktinė apžiūra, tiksli diagnostika ir laiku pradėtas gydymas yra svarbiausi veiksniai, padedantys užkirsti kelią komplikacijų išsivystymui. Vienas iš metodų, galinčių prisidėti prie greitos akių ligų diagnostikos, efektyvaus medicinos resursų panaudojimo ir šios problemos sprendimo yra dirbtinio intelekto (DI) pritaikymas atliekant akių apžiūrą (5).

Pastaraisiais metais sparčiai išaugo DI panaudojimo galimybės ir išleidžiamų mokslinių publikacijų skaičius, DI ir ligų diagnostikos tema. Pagrindine to priežastimi yra duomenų mokslo pažanga ir šių inovatyvių algoritmų naudojimas, kuriant diagnostikos ir gydymo programas. Šis įrankis labiausiai įsitvirtino specialybėse, kuriose ligos yra diagnozuojamos tam tikrais vaizdiniais tyrimais arba toms ligoms būdingu klinikiu vaizdu. Tos specialybės yra radiologija, patologija ir oftalmologija (6).

Šiuo metu JAV Maisto ir Vaistų Administracija (FDA) yra patvirtintusi 6 DI paremtas akių ligų diagnostikos sistemas (7). Europoje DI patvirtinimą lemia Europos komisijos sukurtas

Conformité européenne (CE) žymėjimas. Europos sąjungoje parduodamų oftalmologinių DI sistemų yra 14 rūšių (8). Didžioji dalis diagnostikai kurtų DI sistemų yra naudojamos diagnozuoti ar vykdyti profilaktinę apžiūrą diabetinės retinopatijos, glaukomos, amžinės geltonosios dėmės degeneracijos ir neišnešiotų naujagimių retinopatijos atveju (9).

Šio darbo tikslas yra išanalizuoti pagrindinius DI paremtus diagnostinius metodus, įvertinti šio diagnostinio įrankio privalumus ir trūkumus bei apžvelgti atliktus tyrimus, kuriuose lyginami sveikatos apsaugos specialistų ir DI paremtų sistemų diagnostikos tikslumas.

METODAI

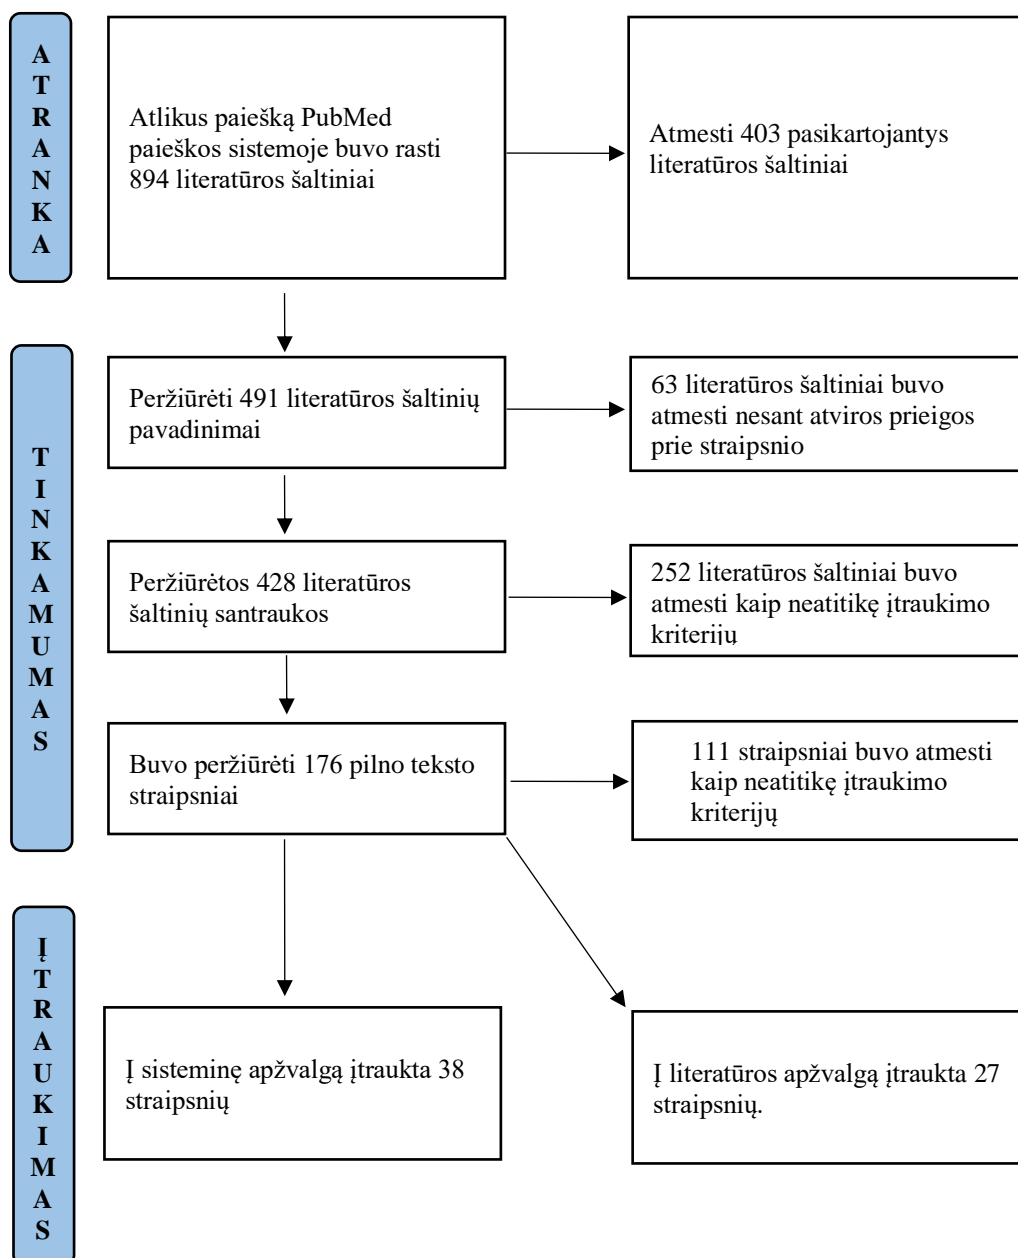
Literatūros paieškos strategija: literatūros paieška buvo atlikta naudojant PubMed duomenų bazę, įvedant raktažodžius anglų kalba: *artificial intelligence, deep learning, machine learning, AUC, sensitivity, specificity*. Paieška PubMed duomenų bazėje buvo tikslinta naudojant MeSH terminus.

Straipsnių įtraukimo kriterijai:

- 1) tekste aptariamas diagnostinis metodas susijęs su akių ligomis ir dirbtiniu intelektu.
- 2) Moksliniai straipsniai publikuoti nuo 2016 m. iki 2022 m.
- 3) Moksliniai straipsniai anglų kalba.
- 4) Tinka viso pasaulio šalių atlikti tyrimai.

Straipsnių neįtraukimo kriterijai:

- 1) nepateikta detali informacija apie dirbtinio intelekto panaudojimą diagnostikoje.
- 2) Nepateikti rodikliai, parodantys dirbtinio intelekto diagnostinį efektyvumą (AUC, jautrumas, specifiškumas).
- 3) Publikacija ne anglų kalba.



1 paveikslas. PRISMA – sisteminės literatūros šaltinių paieškos ir atrankos schema.

DIRBTINIO INTELEKTO VEIKIMO PRINCIPAI

Dirbtinis intelektas (angl. *artificial intelligence*) 1956 m. pirmą kartą buvo apibūdintas kaip technologija, kuri panaudojus algoritmus, gebanti atkartoti žmogaus elgesį (10). Pirmą kartą medicinoje DI panaudotas 1970 metais, kai Stanfordo universitete buvo sukurta MYCIN programa, padedanti parinkti tinkamą antibakterinį gydymą pacientams. Nors ši programa nebuvo įtraukta į klinikinę praktiką, teigiama, kad lyginant su gydytojais infektologais, gydymą pacientams parinkdavo teisingiau (11). Kompiuterio mokymasis (KM) yra DI tipas, kurio algoritmas pristatytas 1959 metais.

Ši sistema veikimo metu geba automatiškai apdoroti naują informaciją, tokiu būdu analizuodama atliktas klaidas ir tikslindama savo veikimą (12). 2012 metais KM veikimo mechanizmas buvo patobulintas - jo metu buvo naudojami dirbtiniai neuroniniai tinklai (DNT). Šie tinklai stipriai padidino sistemos sugebėjimą efektyviau mokytis, analizuoti duotus duomenis. Mokslo pasaulyje tai sukėlė stiprų susidomėjimą DI ir taip atsirado dar vienas mechanizmas - gilusis mokymasis. Tai smulkesnis KM tipas, naudojantis programuotą neuroninį tinklą, kuris leidžia sistemai savarankiškai priimti sprendimus be žmogaus įsitraukimo. Prie dar spartesnio neuroninių tinklų tobulėjimo prisidėjo konvoliuciniai neuronų tinklai (angl. *convolutional neural networks*). Šis įrankis pamėgdžioja žinduolių neuronų struktūrą, kuri susideda iš daugelio sujungtų, dirbtinio neuroninio tinklo sluoksnių. Tai leidžia analizuoti vaizdinius elementus ir galimus patologinius pokyčius, veikiant tokiu pat principu kaip žmonių gebėjimas atskirti akimi matomus pokyčius. 2015 metais buvo organizuotos DI sistemų varžybos, kurių metu sistema turėjo suskirstyti 1,2 milijono nuotraukų į 1000 kategorijų. Teigiama, kad tais metais DI aplenkė žmogų ir sugebėjo geriau suskirstyti vaizdus į skirtingas kategorijas. Tai lėmė dar didesnę duomenų mokslo tobulėjimą, ypač vaizdinių tyrimų DI tema (5).



2 paveikslas. Duomenų mokslo metodų schema, adaptuota pagal Choi ir kt. *Neural Networks* 2020 (6).

Kompiuterio mokymasis turi keturis pagrindinius mokymosi metodus: prižiūrimas, neprižiūrimas, pusiau prižiūrimas ir pastiprinimo mokymas (angl. *reinforcement learning*) (6). Dažniausiai medicinos diagnostikoje naudojamas metodas yra prižiūrimas mokymas. Algoritmui suteikus prieigą prie duomenų bazės pvz. akių dugno nuotraukų, kurios buvo peržiūrėtos gydytojų

specialistų ir pažymėti normos variantai bei patologiniai radiniai. Po duomenų bazės apdorojimo DI sistema geba pati nustatyti, kurios iš pateiktų akių dugno nuotraukų turi patologinių pokyčių. Neprižiūrimas mokymas vyksta pateikus duomenų bazę, kuri nebuvo išskirstyta į patologinių ar normalių variantų kategorijas. Dėl šios priežasties, lyginant su prižiūrimu metodu, diagnostika naudojant šį metodą nebūtų tokia tiksli.

DIRBTINIO INTELEKTO DUOMENŲ BAZĖS SUDARYMAS

Medicinos diagnostikoje dažniausiai naudojamas DI tipas yra gilusis mokymasis, naudojant prižiūrimą mokymo metodą. Naudojant šį mokymosi metodą, prieš algoritmo sudarymą reikalingas vaizdų įvertinimas. Akių ligų diagnostikoje šią funkciją atlieka specialistai, galintys tiksliai interpretuoti vaizdinius tyrimus (pvz. gydytojai oftalmologai). Geros kokybės standartu pasižyminti vaizdų bazė, sudaroma vaizdus įvertinus dviejų ar daugiau specialistų (2,13). Norint sudaryti kuo tikslesnę diagnostikos sistemą, naudojamas kiek įmanoma didesnis vaizdinių tyrimų kiekis. Jeigu liga sukelia ryškius pokyčius, programai užteks mažesnės duomenų bazės, o siekiant nustatyti subtilius pokyčius – prireiks didesnės vaizdinės bazės.

Vaizdinių duomenų bazė turi būti suskirstyta į treniravimo, validacijos ir testavimo grupes tam tikromis proporcijomis (6). DI tyrimuose svarbu išlaikyti nešališką skirstymą į grupes, norint turėti kuo tikslesnę, žmonių populiaciją atitinkančią, bazę. Kitu atveju tyrimo rezultatai gali būti geri, tačiau pradėjus naudoti DI sistemą klinikinėje praktikoje rezultatai bus prasti. Svarbu pabrėžti, kad identiškų vaizdinių negalima naudoti algoritmo kūrimo ir testavimo grupėse, nes rezultatai bus geresni nei iš tikrųjų yra (14). Nuo 2018 m. pradėta diskutuoti apie mokslinių tyrimų, susijusių su DI, pateikimą moksliniuose darbuose. Taip pat nutarta sukurti standartizuotas gaires, kurios padės tiksliau atlikti ir aprašyti tyrimus susijusius su DI sistemomis. 2020 metais sukurtos gairės skirtos tyrimams naudojantiems DI medicinos diagnostikoje – CONSORT-AI ir SPIRIT-AI (15,16). Teigiama, kad šios gairės padės 3 būdais:

- 1) užtikrins sistemos validavimą, tyrimų pakartojamumą ir padidins tyrimo naudą
- 2) palengvins ir pagreitins šių DI sistemų patvirtinimo procesą JAV Maisto ir Vaistų Administracijoje (FDA) ir Europos Komisijos Comformité européenne (CE)
- 3) užtikrins diagnostinį tikslumą ir paciento saugumą naudojant šią diagnostinę sistemą (17,18).

Didžioji dalis medicinos diagnostikoje naudojamų algoritmų yra sudaryti naudojant konvoliucinius dirbtinius neuroninius tinklus, kurie susideda iš trijų pagrindinių elementų:

- 1) duomenų įvesties (angl. *input*) sluoksnio pvz. akių dugno nuotraukos
- 2) paslėptų sluoksnių

3) duomenų išėjties sluoksnio (angl. *output*) pvz. tikimybė, kuriai kategorijai priklauso akių dugno nuotrauka – diabetinės retinopatijos ar normos (2,19).

Paslėptus sluoksnius sudaro įvairūs sluoksniai, tokie kaip konvoliucijos, kurie atlieka konvoliucijos veiksmą – apdoroja pradinį vaizdą. Šie algoritmai kuriami anksčiau minėtais etapais: treniravimas, validacija ir testavimas. Pagal pirminius duomenis koreguojami DI sistemos parametrai, kad būtų sumažinta klaidos atlikimo rizika. Validavimo metu įvyksta tikrinimas, kurio metu algoritmas vertina naujus, nematytus vaizdus. Testavimo metu įvertinamas diagnostinis tikslumas (2,20).

DIAGNOSTIKOS TIKSLUMO VERTINIMAS

DI diagnostikos sistemos tikslumas gali būti vertinami pagal du parametrus – diskriminaciją ir kalibraciją (2).

Diskriminacija vertinama pagal 3 pagrindinius parametrus: jautrumą, specifiškumą ir AUROC (angl. *area under the receiver's operator characteristics curve*) arba AUC (angl. *area under the curve*). Jautrumas – tai tikimybė, kad tyrimas bus teigiamas, kai pacientas turi ligą ar patologinius pokyčius. Specifiškumas – tai tikimybė, kad tyrimas bus neigiamas, kai pacientas neturi ligos ar patologinių pokyčių. Naudojant jautrumo ir specifiškumo rodiklius, išvedama ROC kreivė, kuri demonstruoja jautrumo ryšį su specifiškumu. Dažniausias būdas demonstruoti ROC kreivės išvestus rezultatus yra AUC rodiklis. Šis rodiklis gali būti apibūdinamas kaip vidutinė jautrumo reikšmė esant kintančiam specifiškumo rodikliui arba vidutinė specifiškumo reikšmė esant kintančiam jautrumo rodikliui. AUC reikšmė svyruoja nuo 0 iki 1. Skaičiui artėjant arčiau vieneto gerėja diagnostinis tikslumas, o rodikliui siekiant 0,50 tikimybė tiksliai diagnostikai yra 50 proc. (14).

Kalibracija yra parametras, parodantis ar diskriminacijos metu nustatytas tikslumas atitinka kliniškai nustatomą diagnozę. Kalibracija nustatoma braižant grafiką, kuriame x ašis žymima diskriminacijos metu nustatyta tikimybė, o y ašis tikroji tikimybė. Tobulos kaligrafijos grafiko rodmuo būtų tiesė einanti 45 laipsnių kampū. Tai parodytų, kad diskriminacijos metu nustatyta tikimybė atitinka kliniškai nustatytus rezultatus (2,14,20).

DIRBTINIO INTELEKTO PRITAIKYMAS AKIŲ LIGŲ DIAGNOSTIKOJE

DI ir gilusis mokymasis yra pritaikytas šiuose vaizdiniuose akių ligų tyrimuose: atliekant akių dugno ar kitų akies dalių nuotraukas ir optinės koherentinės tomografijos metu (OKT). Pagrindinės akių ligos, kurios tiriamos pritaikant DI sistemas yra diabetinė retinopatija, glaukoma, amžinė geltonosios dėmės degeneracija ir neišnešiotų naujagimių retinopatija (21). DI pritaikymo akių ligų diagnostikoje privalumas yra susijęs su anksčiau minėtomis ligomis, kurioms reikalingas pastovus profilaktinis ištyrimas. Tačiau profilaktinis ištyrimas, sisteminiu lygmeniu, reikalauja didelių žmogiškųjų bei finansinių sveikatos apsaugos sistemos išteklių išsivysčiusiose ir besivystančiose šalyse (21). Todėl šios inovatyvios technologijos panaudojimas galėtų būti ilgalaikis sprendimas palengvinti profilaktinio ištyrimo procesą pacientams.

DIRBTINIO INTELEKTO PANAUDOJIMAS OFTALMOLOGIJOJE

DIABETINĖ RETINOPATIJA

Cukrinis diabetas gali sukelti įvairių organų sistemų pažeidimus. Vienas iš pažeidžiamų žmogaus organų yra žmogaus akis. Diabetinė retinopatija (DR) yra dažniausia darbingo amžiaus aklumo priežastis. Jos metu pasireiškia abiejų akių tinklainių pokyčiai, kurie pasireiškia progresuojančia mikroangiopatija, kapiliarų deformacijos procesais ir neovaskuliarizacija. 2019 metų sisteminės apžvalgos ir metaanalizės duomenimis pasaulinis cukrinio diabeto pasireiškimas siekė 9,3 proc. (463 milijonai pasaulio populiacijos) ir pagal dabartinės situacijos apskaičiavimus iki 2030 metų sieks 10,2 proc. (578 milijonai pasaulio populiacijos), trečdaliui (34,6 proc) iš jų yra pasireiškusi DR (4). Remiantis 2018 m. Amerikos Diabeto Asociacijos gairėmis, susirgus 1 tipo cukriniu diabetu pirma apžiūra turi būti atlikta per 5 metus nuo simptomų atsiradimo. Susirgus 2 tipo cukriniu diabetu apžiūra atliekama diagnozės nustatymo metu. Nesant diagnozuotai retinopatijai atlikti akių apžiūrą reikia kas 1 metus. Progresuojant DR arba blogėjant matymui apžiūrų atlikimas turi būti dažnesnis (22).

Profilaktinis ištyrimas dėl DR, laiku paskirtos specialistų konsultacijos ir gydymas gali padėti išvengti suprastėjusio matymo ar aklumo. Profilaktinis ištyrimas susideda iš tiesioginės oftalmoskopijos, biomikroskopijos naudojant papildomą lęšį, akių dugno fotografijos ar filmavimo (23).

Didžioji dalis DI diagnostinių sistemų yra orientuotos į DR atrankinį ištyrimą, kurio metu nustatoma DR ir pacientui rekomenduojama gydytojo oftalmologo konsultacija arba ši diagnozė

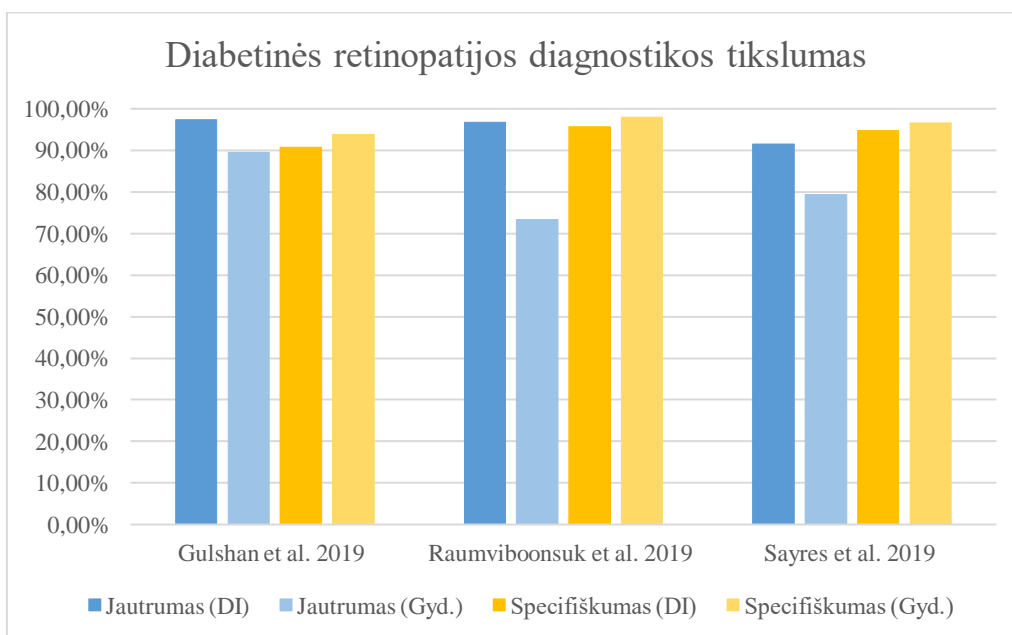
paneigiama. Per paskutinį dešimtmetį, daugelis sukurtų DI diagnostikos sistemų diabetinei retinopatijai rodo puikius rezultatus (1 lentelė).

1 lentelė. Diabetinės retinopatijos ir dirbtinio intelekto sistemos tyrimų charakteristikos.

Autoriai ir publikacijos metai	Prospektyvinis tyrimas	Duomenų bazės vaizdinių kieki (n)	Klinikinis įrenginio validavimas	Diagnostinis vaizdinio tipas	DI modelis	DI palyginimas su specialistu	AUC	Jautrumas (%)	Specifiškumas (%)	Tyrimo tikslas
Abramoff ir kt. 2016 (24)	Ne	1748	Ne	Akių dugno nuotraukos	AlexNet VGG	Ne	0,98	96,8	87,0	DR
Gargeya ir kt. 2017 (25)	Ne	a) 15000 b) 1748 c) 463	Taip	Akių dugno nuotraukos	CNN	Ne	0,97	94,0	98,0	DR
Abramoff ir kt. 2018 (26)	Taip	819	Taip	Akių dugno nuotraukos	AlexNet VGG	Ne	0,98	87,2	90,7	DR
Chan ir kt. 2018 (27)	Ne	4096	Taip	OKT	AlexNet, VGGNet, GoogleNet	Ne	-	87,5	93,8	Diabetinės geltonosios dėmės edema (DGDE)
Keel ir kt. 2018 (28)	Taip	21777	Taip	Akių dugno nuotraukos	Inception-v3	Ne	0,97	100,0	93,4	Rekomendavimas tolimesniam ištyrimui dėl DR
Krause ir kt. 2018 (29)	Ne	1958	Taip	Akių dugno nuotraukos	CNN	Ne	0,98	97,0	91,7	Rekomendavimas tolimesniam ištyrimui dėl DR
Ramachandran ir kt. 2018 (30)	Ne	a) 485 b) 1200	Taip	Akių dugno nuotraukos	Visiona	Ne	a) 0,90 b) 0,98	a) 84,6 b) 96,0	a) 79,7 b) 90,0	Rekomendavimas tolimesniam ištyrimui dėl DR
Sandhu ir kt. 2018 (31)	Taip	160	Ne	Akių dugno nuotraukos	Deep fusion SNCAE	Ne	-	92,5	95,0	Neproliferacinė DR
Alqudah ir kt. 2019 (32)	Ne	1250	Taip	OKT	AOCT-NET	Ne	0,98	97,1	99,3	AGDD ir DGDE
Arcadu ir kt. 2019 (33)	Ne	a) 1237 b) 1798	Ne	Akių dugno nuotraukos	Inception-v3	Ne	0,52	79,0	72,0	DGDE
Bellemo ir kt. 2019 (34)	Taip	3093	Taip	Akių dugno nuotraukos	VGG/ResNet	Ne	a) 0,97	a) 92,3 b) 99,4 c) 97,2	a) 89,0	a) DR nustatymas b) sunki DR c) DGDE
Gulshan ir kt. 2019 (35)	Taip	3049	Taip	Akių dugno nuotraukos	Inception-v3	Taip	0,98	97,4	90,7	DR
Li ir kt. 2019 (36)	Ne	1000	Ne	OKT	VGG-16	Ne	0,99	96,8	99,4	Gyslainės neovaskuliarizacija, DGDE

Raumviboonsuk ir kt. 2019 (37)	Ne	a-c) 25348 d) 24332	Taip	Akių dugno nuotraukos	Inception-v4	Taip	a-c) 0,98 d) 0,99	a-c) 96,8 d) 95,3	a-c) 95,6 d) 98,2	a) Neproliferacinė, vidutinio sunkumo DR b) Neproliferacinė, sunki DR c) Proliferacinė DR d) DGDE
Sayres ir kt. 2019 (38)	Ne	2000	Taip	Akių dugno nuotraukos	Inception-v4	Taip	-	91,5	94,7	Rekomendavimas tolimesniam ištyrimui dėl DR
Ting ir kt. 2019 (20)	Ne	85902	Taip	Akių dugno nuotraukos	VGGNet	Ne	0,93	90,5	91,6	DR nustatymas
Heydon ir kt. 2021 (39)	Taip	30405	Ne	Akių dugno nuotraukos	EyeArt v2.1	Ne	-	95,7	98,3	DR nustatymas
Vaghefi ir kt. 2021 (40)	Ne	63843	Taip	Akių dugno nuotraukos	THEIA	Ne	-	94,0	63,0	DR nustatymas
Ipp ir kt. 2021 (41)	Taip	1786	Taip	Akių dugno nuotraukos	EyeArt	Ne	-	96,0	88,0	DR nustatymas
Pei ir kt. 2022 (42)	Ne	1768	Ne	Akių dugno nuotraukos	EyeWisdom®	Taip	0,86	91,0	81,3	DR nustatymas

Sisteminės analizės duomenimis DI sistemų AUC rodiklio efektyvumo vidurkis siekia 0,940 (95 proc. PI 0,885 – 0,995). Jautrumo vidurkis 93,82 proc. (95 proc. PI 91,85 proc. – 95,78 proc.), specifiškumo vidurkis 90,48 proc. (95 proc. PI 86,75 proc. – 94,21 proc.). Iš 20 tyrimų 7 buvo atlikti prospektyviai kas galėjo lemti tikslesnį rezultatų ir vaizdinės imties sudarymą. 14 tyrimų metu atliktas sistemos prietaiso validavimas pagal sukurtas gaires (išorinis validavimas) arba atliekamas pačių tyrėjų (vidinis validavimas). 3 tyrimuose buvo atliktas DI sistemos diagnostinis palyginimas su gydytojais: Gulshan ir kt. 2019 DI jautrumas 97,4 proc. (gydytojai 89,5 proc.), specifiškumas 90,7 proc. (gydytojai 93,8 proc.), Raumviboonsuk ir kt. 2019 DI jautrumas 96,8 proc. (gydytojai 73,4 proc.), specifiškumas 95,6 proc. (gydytojai 98,0 proc.) Sayres ir kt. 2019 DI jautrumas 91,5 proc. (gydytojai 79,4 proc.), specifiškumas 94,7 proc. (gydytojai 96,6 proc.) (3 paveikslas). Apžvelgiant šiuos tyrimus stebima, kad DI sistemų diagnostikos jautrumas yra didesnis, o specifiškumas mažesnis lyginant su gydytojais.



3 paveikslas. Diabetinės retinopatijos diagnostikos tikslumo diagrama.

GLAUKOMA


Pasaulio Sveikatos Organizacijos (PSO) ataskaitoje teigiama, kad sergamumo rodikliams išliekant tokiems, kokie yra dabar, glaukomos atvejų skaičius didės 1,3 karto (iki 76 milijonų) ir 2030 m. gali siekti 95,4 milijonus (3). Glaukoma tai lėtinė, progresuojanti optinė neuropatija, kuriai būdingas periferinio, o vėliau centrinio regėjimo praradimas. Įtariant šią ligą DI sistema analizuoja tuos pačius 3 pagrindinius pokyčius, kuriuos analizuoja ir gydytojas oftalmologas biomikroskopijos metu: E/D santykis (angl. *C/D ratio*), kuris parodo regos nervo disko ekskavacijos bei regos nervo disko skersmens santykį, taip pat stebimi neuroretinalinio krašto pokyčiai ir pakitęs neuroretinalinio krašto plotis. Viename iš tyrimų DI sistemą apmokė pastebėti tik šiuos 3 vaizdinius pokyčius ir šio tyrimo tikslumas siekė 94 proc., jautrumas ir specifiškumas 94 proc.. Didžioji dalis apžvelgtų tyrimų yra atlikti naudojant akių dugno nuotraukas. Tačiau norint tiksliai diagnozuoti glaukomą svarbus ir perimetrijos, taip pat ir OKT tyrimas (5).

Sisteminės analizės duomenimis (2 lentelė) DI sistemų AUC rodiklio efektyvumo vidurkis siekia 0,933 (95 proc. PI 0,898 – 0,968). Jautrumo vidurkis 86,9 proc. (95 proc. PI 80,37 proc. – 93,43 proc.). Specifiškumo vidurkis 90,16 proc. (95 proc. PI 86,12 proc. - 94,2 proc.). Visi 8 tyrimai buvo atlikti retrospektyviai, šie tyrimai gali turėti didesnę paklaidą dėl tyrimo standartizavimo trūkumo ir skirtingai surinktų vaizdinių duomenų.

2 lentelė. Glaukomos ir dirbtinio intelekto sistemos tyrimų charakteristikos.


Autoriai ir publikacijos metai	Prospektyvinis tyrimas	Duomenų bazės vaizdinių kiektis (n)	Klinikinis įrenginio validavimas	Diagnostinis vaizdinio tipas	DI modelis	DI palyginimas su specialistu	AUC	Jautrumas (%)	Specifiškumas (%)	Tyrinio tikslas
Asaoka ir kt. 2016 (43)	Ne	279	Ne	Perimetrija	Deep feed-forward neural network with stacked denoising autoencoder	Ne	0,92	77,8	90,0	Preperimetrinė atvirojo kampo glaukoma
Li ir kt. 2018 (44)	Ne	8000	Ne	Akių dugno nuotraukos	Inception-v3	Ne	0,98	95,6	92,0	Glaukominė optinė neuropatija
Liu ir kt. 2018 (45)	Ne	a) 754 b) 30	Taip	Akių dugno nuotraukos	ResNet50	Taip	0,89	86,7	86,7	Glaukominė optinė neuropatija
Shibata ir kt. 2018 (46)	Ne	110	Ne	Akių dugno nuotraukos	a) ResNet b) VGG-16	Taip	0,96	-	-	Glaukominė optinė neuropatija
Al-Aswad ir kt. 2019 (47)	Ne	110	Ne	Akių dugno nuotraukos	Pegasus (ResNet50)	Taip	0,92	83,7	88,2	Glaukominė optinė neuropatija
Gomez-Valverde ir kt. 2019 (48)	Ne	494	Ne	Akių dugno nuotraukos	VGG-19	Taip	0,94	87,0	89,0	Glaukomos diagnozavimas arba įtarimas
MacCormick ir kt. 2019 (49)	Ne	a) 130 b) 159	Taip	Akių dugno nuotraukos	DenseNet	Ne	0,99	96,6	99,0	Glaukominė optinė neuropatija
Rogers ir kt. 2019 (50)	Ne	94	Taip	Akių dugno nuotraukos	ResNet50	Taip	0,87	80,9	86,2	Glaukominė optinė neuropatija

3 tyrimų metu atliktas sistemos prietaiso validavimas pagal sukurtas gaires (išorinis validavimas) arba atliekamas pačių tyrėjų (vidinis validavimas). 5 tyrimuose buvo atliktas DI sistemos diagnostinis palyginimas su gydytojais: Liu ir kt. 2018 tyrime DI jautrumas proc. 86,7 (gydytojai 75,6 proc.), specifiškumas 86,7 proc. (gydytojai 77,8 proc.). Rogers ir kt. 2019 DI jautrumas 80,9 proc. (gydytojai 74,7 proc.), specifiškumas 86,2 proc. (gydytojai 87,4 proc.) (4 paveikslas).




4 paveikslas. Glaukomos diagnostikos tikslumo lyginimo diagrama.

Shibata ir kt. 2018 tyrime DI AUC rodiklis 0,96, pirmų metų rezidentas 0,73, trečių metų rezidentas 0,88 ir ketvirtų metų rezidentas 0,91 (5 paveikslas).



5 paveikslas. Glaukomos diagnostikos tikslumo lyginimo diagrama (AUC).

Al-Aswad ir kt. 2019 tyrimo DI AUC rodiklis 0,92 ir gydytojų oftalmologų 0,89 (6 paveikslas). Apžvelgiant šiuos tyrimus stebima, kad DI sistemų diagnostinis tikslumas prilygsta arba yra didesnis nei gydytojų oftalmologų diagnozuojant glaukominius pokyčius.



6 paveikslas. Glaukomos diagnostikos tikslumo lyginimo diagrama (AUC).

AMŽINĖS GELTONOSIOS DĖMĖS DEGENERACIJA

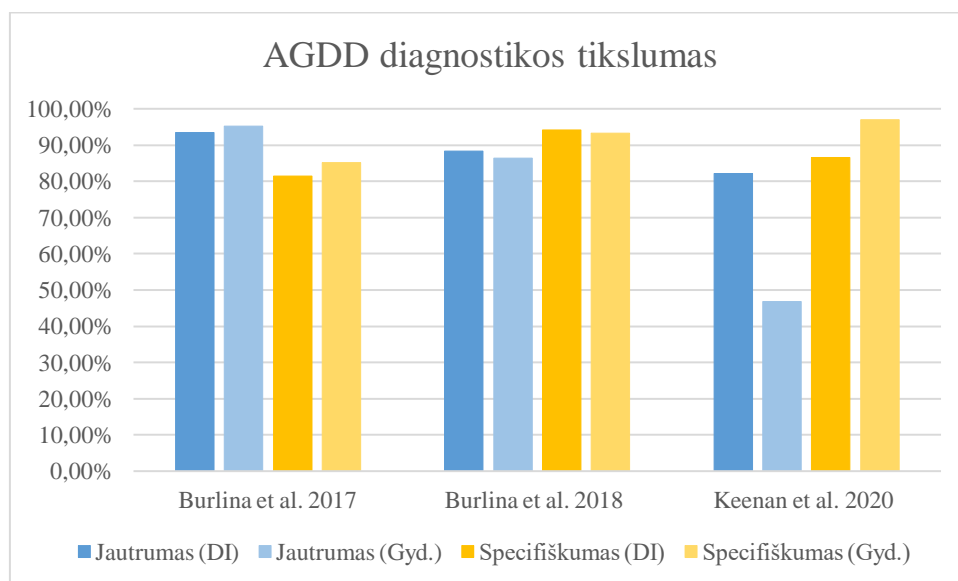
Amžinė geltonosios dėmės degeneracija (AGDD) – dažniausia vyresnio nei 50 metų žmonių centrinės regos netekimo priežastis išsivysčiusiose šalyse (51). AGDD labiausiai paveikia vyresnius žmones ir dėl šio ligos aklumas išsivysto 8,7 proc. žmonių išsivysčiusiose šalyse. Šios ligos paplitimas Europoje yra 8,69 proc. dažnesnis nei Azijos ar Afrikos valstybių gyventojams (52). Dėl sparčiai vykstančio populiacijos senėjimo DI pritaikymas diagnostikoje galėtų padėti vykdyti ir užtikrinti kokybišką, visiems prieinamą profilaktinę apžiūrą. Pateikiamos įvairios AGDD klasifikacijos. Dažnai naudojama yra AREDS (angl. *Age-related Eye Disease Study*) klasifikacija. AGDD skirstoma į pradinę, vidutinę ir vėlyvąją: sausoji – geografinė atrofija ir šlapioji (eksudacinė) – gyslainės neovaskuliarizacija. DI sistemos diagnozuojančios AGDD remiasi AREDS klasifikacija nustatant šią diagnozę.

Pagal sistemų tyrimų charakteristiką buvo rasti 5 prieinami straipsniai susiję su AGDD diagnostika (3 lentelė). Sisteminės analizės duomenimis DI sistemų AUC rodiklio efektyvumo vidurkis siekia 0,960 (95 proc. PI 0,926 – 0,994). Jautrumo vidurkis 90,02 proc. (95 proc. PI 83,04 proc. - 97,00 proc.). Specifiškumo vidurkis 91,00 proc. (95 proc. PI 82,31 proc. – 99,69 proc.). Vienas tyrimas buvo atliktas prospektyviai ir keturi retrospektyviai. Dviejų tyrimų metu atliktas DI prietaiso validavimas pagal sukurtas gaires (išorinis validavimas) arba atliekamas pačių tyrėjų (vidinis validavimas).

3 lentelė. Amžinės geltonosios dėmės degeneracijos ir dirbtinio intelekto sistemos tyrimų charakteristikos.

Autoriai ir publikacijos metai	Prospektyvinis tyrimas	Duomenų bazės vaizdinių kiekiš (n)	Klinikinis įrenginio valdymas	Diagnostinis vaizdinio tipas	DI modelis	DI palyginimas su specialistu	AUC	Jautrumas (%)	Specifiškumas (%)	Tyrimo tikslas
Burlina ir kt. 2017 (53)	Ne	5664	Ne	Akių dugno nuotraukos	DCNN	Taip	-	93,4	81,5	AGDD
Burlina ir kt. 2018 (54)	Ne	5000	Ne	Akių dugno nuotraukos	ResNet50	Ne	0,97	89,0	93,6	AGDD pagal AREDS klasifikaciją
Burlina ir kt. 2018 (55)	Ne	13480	Ne	Akių dugno nuotraukos	AlexNet	Taip	0,96	88,4	94,1	AGDD pagal AREDS klasifikaciją
Alqudah ir kt. 2019 (32)	Ne	1250	Taip	OKT	AOCT-NET	Ne	0,98	97,1	99,3	AGDD ir DGDE
Keenan ir kt. 2020 (56)	Taip	1127	Taip	OKT	Notal OCT Analyzer (NOA)	Taip	0,93	82,2	86,5	AGDD ir skysčio nustatymas tinklainėje

3 tyrimuose buvo atliktas DI sistemos diagnostinis palyginimas su gydytojais: Burlina ir kt. 2017 tyrime DI jautrumas 93,4 proc. (gydytojai 95,2 proc.), specifiškumas 81,5 proc. (gydytojai 85,2 proc.). Burlina ir kt. 2018 tyrime DI jautrumas proc. 88,4 (gydytojai 86,4 proc.), specifiškumas 94,1 proc. (gydytojai 93,2 proc.). Keenan ir kt. 2020 tyrime DI jautrumas proc. 82,2 (gydytojai 46,8 proc.), specifiškumas 86,5 proc. (gydytojai 97,0 proc.) (7 paveikslas). Apžvelgiant šiuos tyrimus pastebima, kad DI sistemų diagnostinis tikslumas yra panašus lyginant su gydytojais. Keenan ir kt. 2020 tyrime gydytojų jautrumo rodiklis buvo labai mažas, tačiau tyrime nepatikslinkta ar šiuos vaizdinius tyrimus vertino gydytojas oftalmologas ar kitos srities specialistas.



7 paveikslas. AGDD diagnostikos tikslumo lyginimo diagrama (AUC).

NEIŠNEŠIOTŲ NAUJAGIMIŲ RETINOPATIJA IR KITOS NAGRINĖTOS PATOLOGIJOS

Kiekvienais metais 32000 vaikų tampa akli dėl neišnešiotų naujagimių retinopatijos (NNR) sukeltų komplikacijų ir tai yra pagrindinė aklumo priežastis vaikų amžiuje (57). Tikslus epidemiologinius duomenis sunku pateikti dėl skirtingo neišnešiotų naujagimių gimstamumo, mirtingumo skirtinguose pasaulio regionuose. Ši patologija nustatoma atliekant oftalmoskopiją, jeigu gydytojams specialistams neužtenka žinių šioje srityje, šios naujagimių akių dugno fotografijos gali būti vertinamos telemedicinos pagalba kitų specialistų (21). Laiku pradėjus gydymą didžioji dalis pacientų gali išvengti aklumo komplikacijos. Norint išvengti aklumo susijusio su NNR, svarbu atlikti naujagimių patikrą. Tačiau išlieka daug medicininių centrų, kurie negali suteikti tinkamos apžiūros NNR atveju, todėl telemedicina ir DI diagnostinės sistemos išlieka svarbiu įrankiu šios problemos sprendimui (5).

Sisteminės analizei NNR atvirai prieinamų straipsnių, atitinkančių atrankos kriterijus buvo 2 (4 lentelė). DI sistemų AUC rodiklio efektyvumas siekia 0,98. Jautrumas nuo 93,0 iki 100 proc., specifiškumas 78,0 iki 93,0.

Atliekant straipsnių atranką sisteminei apžvalgai liko pavienių straipsnių, kurie negali būti sugrupuoti į atskiras grupes, tačiau tai parodo, kad DI panaudojimas diagnostikoje neapsiriboja vien tik anksčiau minėtomis ligomis. Didelis potencialas išlieka kuriant sudėtingas diagnostines sistemas

apimančias įvairias tinklainės ligų grupes kaip De Fauw ir kt. 2018 metų straipsnis. Taip pat sudaryti DI modeliai, kurie nustato centrinės tinklainės venos nepraeinamumą, įgimtą kataraktą.

4 lentelė. Neišnešiotų naujagimių retinopatijos, kitų patologijų ir dirbtinio intelekto sistemos tyrimų charakteristikos.

Autoriai ir publikacijos metai	Prospektyvinis tyrimas	Duomenų bazės vaizdinių kiekių (n)	Klinikinis įrenginio validavimas	Diagnostinis vaizdinio tipas	DI modelis	DI palyginimas su specialistu	AUC	Jautrumas (%)	Specifiškumas (%)	Tyrimo tikslas
Brown ir kt. 2018 (58)	Ne	100	Ne	Akių dugno nuotraukos	Inception-v1 UNet	Taip	0,98	93,0	93,0	NNR
De Fauw ir kt. 2018 (59)	Ne	a) 997 b) 116	Ne	OKT	a) U-Net b) customised CNN	Taip	0,99	-	-	Tinklainės ligų nustatymas
Lin ir kt. 2019 (60)	Taip	350	Ne	Akių dugno nuotraukos	CC-Cruiser	Taip	-	89,7	86,4	Įgimtos kataraktos nustatymas
Nagasato ir kt. 2019 (61)	Ne	322	Ne	OKT	DNN	Taip	0,98	93,7	97,3	Centrinės tinklainės venos nepraeinamumas
Campbell ir kt. 2021 (62)	Ne	4175	Taip	Akių dugno nuotraukos	ROP Deep Learning system	Ne	0,98	100,0	78,0	NNR

APTARIMAS

Šiame darbe išanalizuoti dirbtinio intelekto veikimo principai, tikslumo nustatymo metodai ir išnagrinėtos publikacijos susijusios su šio diagnostinio įrankio tikslumu. Duomenų bazėse rastos dvi sisteminės apžvalgos, kuriose nagrinėjamas dirbtinio intelekto sistemų diagnostikos tikslumas. Šio tyrimo metu atliktos sisteminės apžvalgos metu diabetinės retinopatijos diagnostikos AUC vidurkis 0,940 (95 proc. PI 0,885 - 0,995), lyginant su R. Aggarwal ir kt. 2021 tyrimo duomenimis 0,939 (95 proc. PI 0,920 – 0,958). Glaukomos diagnostikos AUC vidurkis 0,933 (95 proc. PI 0,898 - 0,968), lyginant su R. Aggarwal ir kt. 2021 tyrimo duomenimis 0,933 (95 proc. PI 0,924–0,942). AGDD

diagnostikos AUC vidurkis 0,960 (95 proc. PI 0,926 - 0,994), lyginant su R. Aggarwal ir kt. 2021 tyrimo duomenimis 0,963 (95 proc. PI 0,948–0,979) ir L. Dong ir kt. 2021 tyrimo duomenimis 0,983 (95 proc. PI 0,978–0,988) (63,64). Sisteminės apžvalgos duomenimis dirbtinio intelekto algoritmai turi aukštą ir klinikinėje praktikoje naudoti tinkamą diagnostinį tikslumą, nustatant akių ligų sukeltus pokyčius. Taip pat lyginant gydytojų ir dirbtinio intelekto sistemų diagnostikos tikslumą pastebima, kad dirbtinio intelekto sistemos akių ligų pokyčius nustato taip pat tiksliai arba dar tiksliau nei gydytojai (Paveikslas 3-7).

Nors diagnostinio tikslumo rezultatai parodo didelį šio technologinio įrankio potencialą, tačiau išlieka abejonių kaip ši technologija įsiterps į klinikinę praktiką ir kyla baimių, kad dirbtinio intelekto sistemos gali fiziškai pakeisti gydytojus oftalmologus. T. M. Aslam ir kt. 2022 straipsnyje teigiama, kad šiuo metu žmogaus intelektas yra daug pažangesnis nei dabartinės, pažangiausios dirbtinio intelekto sistemos. Nors dirbtinio intelekto sistemos parodo tokį patį ar didesnę diagnostinį tikslumą nei gydytojai, tačiau gydytojai sugeba daug geriau interpretuoti gautus duomenis ir nuspręsti kaip elgtis su diagnostikos metu gauta informacija. Galima teigti, kad šiuo metu ši technologija nesugebės pakeisti gydytojo oftalmologo klinikinėje praktikoje. Dirbtinio intelekto sistemų panaudojimas gali būti tik papildomas įrankis pagerinti sveikatos apsaugos sistemos paslaugų prieinamumą ir kokybę pacientams (65).

Taip pat susiduriama su išankstine nuomone, kad dirbtinio intelekto prietaisai yra per daug brangūs naudoti klinikinėje praktikoje, tačiau 2020 m. Singapūre atlikta ekonominė analizė atliekant diabetinės retinopatijos profilaktinę apžiūrą. Palyginti 3 skirtingi apžiūros modeliai:

- 1) apžiūra atliekama gydytojo oftalmologo.
- 2) Apžiūra pusiau automatiniu būdu. Pirminį atrankinį tyrimą atlieka dirbtiniu intelektu paremtas prietaisas. Nustatyti, ar įtariamai diabetinės retinopatijos atvejai apžiūrimi gydytojo oftalmologo.
- 3) Apžiūra automatiniu būdu. Apžiūra atliekama tik dirbtiniu intelektu paremtu prietaisu.

Apskaičiuota, kad per vienerius metus, vienam pacientui paslaugos kainuotų atitinkamai: pusiau automatiniu būdu – 62 doleriai, apžiūra automatiniu būdu 66 doleriai ir gydytojo oftalmologo apžiūra 77 doleriai. Nustatyta, kad naudojant pusiau automatinį apžiūros modelį Singapūro sveikatos apsaugos sistemoje būtų sutaupyta 20 proc. kiekvienais metais metais dėl diabetinės retinopatijos apžiūros išleidžiamų pinigų (48900 dolerių). Iki 2050 m. Singapūras pakeitęs diabetinės retinopatijos profilaktinės apžiūros modelį sutaupytų iki 15 milijonų dolerių (66). Ši finansinė analizė parodo, kad dirbtinio intelekto panaudojimas ilgalaikėje perspektyvoje, būtų finansiškai naudingas pasirinkimas.

Taigi, svarbu suprasti, kad vykstant technologijų pažangai, ypač dirbtinio intelekto srityje, gydytojams svarbu domėtis naujais atradimais, populiariomis tendencijomis, kurios gali prisidėti prie

geresnių klinikinės praktikos rezultatų, tinkamo resursų išnaudojimo. Dirbtinio intelekto panaudojimas medicinoje išlieka viena iš potencialių ir daug žadančių naujovių dabartiniu metu.

IŠVADOS

- 1) Dirbtinis intelektas yra tobulėjanti ir potencialiai naudinga technologija, turinti didelį potencialą įsiterpti į klinikinę praktiką oftalmologijoje.
- 2) Dirbtinio intelekto aparatų tikslumas nustatant ligas yra panašus lyginant su gydytojais oftalmologais, o kai kurių publikacijų duomenimis diagnostikos tikslumas yra didesnis.
- 3) Dirbtiniu intelektu paremtos diagnostinės sistemos negali pakeisti gydytojo oftalmologo, tačiau tai būtų vertingas įrankis užtikrinti kokybiškas diagnostikos paslaugas pacientui ir tinkamai išnaudoti resursus sveikatos apsaugos sistemoje.

LITERATŪROS IR DUOMENŲ ŠALTINIŲ NUORODOS

1. Yu KH, Beam AL, Kohane IS. Artificial intelligence in healthcare. *Nat Biomed Eng.* 2018 Oct;2(10):719–31.
2. Zykutė D. Application of artificial intelligence models in age related macular degeneration. 2020;8(15):7.
3. World report on vision, Available from: <https://www.who.int/publications-detail-redirect/9789241516570>
4. Global Prevalence and Major Risk Factors of Diabetic Retinopathy | *Diabetes Care* | American Diabetes Association. Available from: <https://diabetesjournals.org/care/article/35/3/556/28568/Global-Prevalence-and-Major-Risk-Factors-of>
5. Schmidt-Erfurth U, Sadeghipour A, Gerendas BS, Waldstein SM, Bogunović H. Artificial intelligence in retina. *Progress in Retinal and Eye Research.* 2018 Nov;67:1–29.
6. Choi RY, Coyner AS, Kalpathy-Cramer J, Chiang MF, Campbell JP. Introduction to Machine Learning, Neural Networks, and Deep Learning. *Neural Networks.* :12.
7. Health C for D and R. Artificial Intelligence and Machine Learning (AI/ML)-Enabled Medical Devices. FDA. 2021 Sep 22; Available from: <https://www.fda.gov/medical-devices/software-medical-device-samd/artificial-intelligence-and-machine-learning-aiml-enabled-medical-devices>
8. Muehlematter UJ, Daniore P, Vokinger KN. Approval of artificial intelligence and machine learning-based medical devices in the USA and Europe (2015–20): a comparative analysis. *The Lancet Digital Health.* 2021 Mar;3(3):e195–203.
9. Li JPO, Liu H, Ting DSJ, Jeon S, Chan RVP, Kim JE, et al. Digital technology, tele-medicine and artificial intelligence in ophthalmology: A global perspective. *Progress in Retinal and Eye Research.* 2021 May;82:100900.

10. McCarthy J, Minsky ML, Rochester N, Shannon CE. A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence, August 31, 1955. *AI Magazine*. 2006 Dec 15;27(4):12–12.
11. Yu VL, Fagan LM, Wraith SM, Clancey WJ, Scott AC, Hannigan J, et al. Antimicrobial selection by a computer. A blinded evaluation by infectious diseases experts. *JAMA*. 1979 Sep 21;242(12):1279–82.
12. Moraru A, Costin D, Moraru R, Branisteanu D. Artificial intelligence and deep learning in ophthalmology - present and future (Review). *Exp Ther Med*. 2020 Aug 12; Available from: <http://www.spandidos-publications.com/10.3892/etm.2020.9118>
13. TING DS, Lee AY, WONG TY. An Ophthalmologist’s Guide to Deciphering Studies in Artificial Intelligence. *Ophthalmology*. 2019 Nov;126(11):1475–9.
14. Park SH, Han K. Methodologic Guide for Evaluating Clinical Performance and Effect of Artificial Intelligence Technology for Medical Diagnosis and Prediction. *Radiology*. 2018 Mar;286(3):800–9.
15. Liu X, Cruz Rivera S, Moher D, Calvert MJ, Denniston AK, SPIRIT-AI and CONSORT-AI Working Group. Reporting guidelines for clinical trial reports for interventions involving artificial intelligence: the CONSORT-AI extension. *Nat Med*. 2020 Sep;26(9):1364–74.
16. Cruz Rivera S, Liu X, Chan AW, Denniston AK, Calvert MJ, The SPIRIT-AI and CONSORT-AI Working Group, et al. Guidelines for clinical trial protocols for interventions involving artificial intelligence: the SPIRIT-AI extension. *Nat Med*. 2020 Sep;26(9):1351–63.
17. Current Challenges and Barriers to Real-World Artificial Intelligence Adoption for the Healthcare System, Provider, and the Patient | TVST | ARVO Journals. Available from: <https://tvst.arvojournals.org/article.aspx?articleid=2770632>
18. Campbell JP, Lee AY, Abramoff M, Keane PA, Ting DSW, Lum F, et al. Reporting Guidelines for Artificial Intelligence in Medical Research. *Ophthalmology*. 2020 Dec;127(12):1596–9.
19. Esteva A, Robicquet A, Ramsundar B, Kuleshov V, DePristo M, Chou K, et al. A guide to deep learning in healthcare. *Nat Med*. 2019 Jan;25(1):24–9.
20. Ting DSW, Peng L, Varadarajan AV, Keane PA, Burlina PM, Chiang MF, et al. Deep learning in ophthalmology: The technical and clinical considerations. *Prog Retin Eye Res*. 2019 Sep;72:100759.
21. Ting DSW, Pasquale LR, Peng L, Campbell JP, Lee AY, Raman R, et al. Artificial intelligence and deep learning in ophthalmology. *Br J Ophthalmol*. 2019 Feb;103(2):167–75.
22. American Diabetes Association. Standards of Medical Care in Diabetes-2018 Abridged for Primary Care Providers. *Clin Diabetes*. 2018 Jan;36(1):14–37.
23. Ting DSW, Tay-Kearney ML, Constable I, Lim L, Preen DB, Kanagasingam Y. Retinal video recording a new way to image and diagnose diabetic retinopathy. *Ophthalmology*. 2011 Aug;118(8):1588–93.
24. Abramoff MD, Lou Y, Erginay A, Clarida W, Amelon R, Folk JC, et al. Improved Automated Detection of Diabetic Retinopathy on a Publicly Available Dataset Through Integration of Deep Learning. *Invest Ophthalmol Vis Sci*. 2016 Oct 1;57(13):5200–6.
25. Gargeya R, Leng T. Automated Identification of Diabetic Retinopathy Using Deep Learning. *Ophthalmology*. 2017 Jul;124(7):962–9.
26. Abramoff MD, Lavin PT, Birch M, Shah N, Folk JC. Pivotal trial of an autonomous AI-based diagnostic system for detection of diabetic retinopathy in primary care offices. *npj Digital Med*. 2018 Dec;1(1):39.

27. Chan GCY, Kamble R, Muller H, Shah SAA, Tang TB, Meriaudeau F. Fusing Results of Several Deep Learning Architectures for Automatic Classification of Normal and Diabetic Macular Edema in Optical Coherence Tomography. *Annu Int Conf IEEE Eng Med Biol Soc.* 2018 Jul;2018:670–3.
28. Keel S, Li Z, Scheetz J, Robman L, Phung J, Makeyeva G, et al. Development and validation of a deep-learning algorithm for the detection of neovascular age-related macular degeneration from colour fundus photographs. *Clin Exp Ophthalmol.* 2019 Nov;47(8):1009–18.
29. Krause J, Gulshan V, Rahimy E, Karth P, Widner K, Corrado GS, et al. Grader Variability and the Importance of Reference Standards for Evaluating Machine Learning Models for Diabetic Retinopathy. *Ophthalmology.* 2018 Aug;125(8):1264–72.
30. Ramachandran N, Hong SC, Sime MJ, Wilson GA. Diabetic retinopathy screening using deep neural network. *Clin Exp Ophthalmol.* 2018 May;46(4):412–6.
31. Sandhu HS, Eltanboly A, Shalaby A, Keynton RS, Schaal S, El-Baz A. Automated Diagnosis and Grading of Diabetic Retinopathy Using Optical Coherence Tomography. *Invest Ophthalmol Vis Sci.* 2018 Jun;59(7):3155–60.
32. Alqudah AM. AOCT-NET: a convolutional network automated classification of multiclass retinal diseases using spectral-domain optical coherence tomography images. *Med Biol Eng Comput.* 2020 Jan 1;58(1):41–53.
33. Arcadu F, Benmansour F, Maunz A, Willis J, Haskova Z, Prunotto M. Deep learning algorithm predicts diabetic retinopathy progression in individual patients. *npj Digit Med.* 2019 Sep 20;2(1):1–9.
34. Bellemo V, Lim ZW, Lim G, Nguyen QD, Xie Y, Yip MYT, et al. Artificial intelligence using deep learning to screen for referable and vision-threatening diabetic retinopathy in Africa: a clinical validation study. *The Lancet Digital Health.* 2019 May;1(1):e35–44.
35. Gulshan V, Rajan RP, Widner K, Wu D, Wubbels P, Rhodes T, et al. Performance of a Deep-Learning Algorithm vs Manual Grading for Detecting Diabetic Retinopathy in India. *JAMA Ophthalmol.* 2019 Sep 1;137(9):987–93.
36. Li F, Chen H, Liu Z, Zhang X dian, Jiang M shan, Wu Z zheng, et al. Deep learning-based automated detection of retinal diseases using optical coherence tomography images. *Biomed Opt Express.* 2019 Nov 11;10(12):6204–26.
37. Raumviboonsuk P, Krause J, Chotcomwongse P, Sayres R, Raman R, Widner K, et al. Deep learning versus human graders for classifying diabetic retinopathy severity in a nationwide screening program. *NPJ Digit Med.* 2019;2:25.
38. Sayres R, Taly A, Rahimy E, Blumer K, Coz D, Hammel N, et al. Using a Deep Learning Algorithm and Integrated Gradients Explanation to Assist Grading for Diabetic Retinopathy. *Ophthalmology.* 2019 Apr;126(4):552–64.
39. Heydon P, Egan C, Bolter L, Chambers R, Anderson J, Aldington S, et al. Prospective evaluation of an artificial intelligence-enabled algorithm for automated diabetic retinopathy screening of 30 000 patients. *Br J Ophthalmol.* 2021 May;105(5):723–8.
40. Vaghefi E, Yang S, Xie L, Hill S, Schmiedel O, Murphy R, et al. THEIA™ development, and testing of artificial intelligence-based primary triage of diabetic retinopathy screening images in New Zealand. *Diabet Med.* 2021 Apr;38(4):e14386.

41. Ipp E, Liljenquist D, Bode B, Shah VN, Silverstein S, Regillo CD, et al. Pivotal Evaluation of an Artificial Intelligence System for Autonomous Detection of Referrable and Vision-Threatening Diabetic Retinopathy. *JAMA Network Open*. 2021 Nov 15;4(11):e2134254.
42. Pei X, Yao X, Yang Y, Zhang H, Xia M, Huang R, et al. Efficacy of artificial intelligence-based screening for diabetic retinopathy in type 2 diabetes mellitus patients. *Diabetes Research and Clinical Practice*. 2022 Feb 1;184. Available from: [https://www.diabetesresearchclinicalpractice.com/article/S0168-8227\(22\)00002-X/abstract](https://www.diabetesresearchclinicalpractice.com/article/S0168-8227(22)00002-X/abstract)
43. Asaoka R, Murata H, Iwase A, Araie M. Detecting Preperimetric Glaucoma with Standard Automated Perimetry Using a Deep Learning Classifier. *Ophthalmology*. 2016 Sep;123(9):1974–80.
44. Li Z, He Y, Keel S, Meng W, Chang RT, He M. Efficacy of a Deep Learning System for Detecting Glaucomatous Optic Neuropathy Based on Color Fundus Photographs. *Ophthalmology*. 2018 Aug;125(8):1199–206.
45. Liu S, Graham SL, Schulz A, Kalloniatis M, Zangerl B, Cai W, et al. A Deep Learning-Based Algorithm Identifies Glaucomatous Discs Using Monoscopic Fundus Photographs. *Ophthalmol Glaucoma*. 2018 Aug;1(1):15–22.
46. Shibata N, Tanito M, Mitsuhashi K, Fujino Y, Matsuura M, Murata H, et al. Development of a deep residual learning algorithm to screen for glaucoma from fundus photography. *Sci Rep*. 2018 Oct 2;8(1):14665.
47. Al-Aswad LA, Kapoor R, Chu CK, Walters S, Gong D, Garg A, et al. Evaluation of a Deep Learning System For Identifying Glaucomatous Optic Neuropathy Based on Color Fundus Photographs. *J Glaucoma*. 2019 Dec;28(12):1029–34.
48. Gómez-Valverde JJ, Antón A, Fatti G, Liefers B, Herranz A, Santos A, et al. Automatic glaucoma classification using color fundus images based on convolutional neural networks and transfer learning. *Biomed Opt Express*. 2019 Jan 25;10(2):892–913.
49. MacCormick IJC, Williams BM, Zheng Y, Li K, Al-Bander B, Czanner S, et al. Accurate, fast, data efficient and interpretable glaucoma diagnosis with automated spatial analysis of the whole cup to disc profile. *PLoS One*. 2019;14(1):e0209409.
50. Rogers TW, Jaccard N, Carbonaro F, Lemij HG, Vermeer KA, Reus NJ, et al. Evaluation of an AI system for the automated detection of glaucoma from stereoscopic optic disc photographs: the European Optic Disc Assessment Study. *Eye (Lond)*. 2019 Nov;33(11):1791–7.
51. R. Žemaitienė, D. Žaliūnienė, I. Janulevičienė, L. Kuzmienė, A. Gelžinis, D. Stanislovaitienė, G. Miniauskienė, E. Puodžiuvienė. *Oftalmologijos pagrindai*, 2021 m.
52. Wong WL, Su X, Li X, Cheung CMG, Klein R, Cheng CY, et al. Global prevalence of age-related macular degeneration and disease burden projection for 2020 and 2040: a systematic review and meta-analysis. *Lancet Glob Health*. 2014 Feb;2(2):e106-116.
53. Burlina P, Pacheco KD, Joshi N, Freund DE, Bressler NM. Comparing Humans and Deep Learning Performance for Grading AMD: A Study in Using Universal Deep Features and Transfer Learning for Automated AMD Analysis. *Comput Biol Med*. 2017 Mar 1;82:80–6.
54. Burlina P, Joshi N, Pacheco KD, Freund DE, Kong J, Bressler NM. Utility of Deep Learning Methods for Referability Classification of Age-Related Macular Degeneration. *JAMA Ophthalmology*. 2018 Nov 1;136(11):1305–7.

55. Burlina PM, Joshi N, Pekala M, Pacheco KD, Freund DE, Bressler NM. Automated Grading of Age-Related Macular Degeneration From Color Fundus Images Using Deep Convolutional Neural Networks. *JAMA Ophthalmol.* 2017 Nov;135(11):1170–6.
56. Keenan TDL, Clemons TE, Domalpally A, Elman MJ, Havalio M, Agrón E, et al. Retinal Specialist versus Artificial Intelligence Detection of Retinal Fluid from OCT. *Ophthalmology.* 2021 Jan;128(1):100–9.
57. Blencowe H, Moxon S, Gilbert C. Update on Blindness Due to Retinopathy of Prematurity Globally and in India. *Indian Pediatr.* 2016 Nov 7;53 Suppl 2:S89–92.
58. Brown JM, Campbell JP, Beers A, Chang K, Ostmo S, Chan RVP, et al. Automated Diagnosis of Plus Disease in Retinopathy of Prematurity Using Deep Convolutional Neural Networks. *JAMA Ophthalmol.* 2018 Jul 1;136(7):803–10.
59. De Fauw J, Ledsam JR, Romera-Paredes B, Nikolov S, Tomasev N, Blackwell S, et al. Clinically applicable deep learning for diagnosis and referral in retinal disease. *Nat Med.* 2018 Sep;24(9):1342–50.
60. Lin H, Li R, Liu Z, Chen J, Yang Y, Chen H, et al. Diagnostic Efficacy and Therapeutic Decision-making Capacity of an Artificial Intelligence Platform for Childhood Cataracts in Eye Clinics: A Multicentre Randomized Controlled Trial. *EClinicalMedicine.* 2019 Mar;9:52–9.
61. Nagasato D, Tabuchi H, Masumoto H, Enno H, Ishitobi N, Kameoka M, et al. Automated detection of a nonperfusion area caused by retinal vein occlusion in optical coherence tomography angiography images using deep learning. *PLoS One.* 2019;14(11):e0223965.
62. Campbell JP, Singh P, Redd TK, Brown JM, Shah PK, Subramanian P, et al. Applications of Artificial Intelligence for Retinopathy of Prematurity Screening. *Pediatrics.* 2021 Mar;147(3):e2020016618.
63. Dong L, Yang Q, Zhang RH, Wei WB. Artificial intelligence for the detection of age-related macular degeneration in color fundus photographs: A systematic review and meta-analysis. *EClinicalMedicine.* 2021 May 8;35:100875.
64. Aggarwal R, Sounderajah V, Martin G, Ting DSW, Karthikesalingam A, King D, et al. Diagnostic accuracy of deep learning in medical imaging: a systematic review and meta-analysis. *NPJ Digit Med.* 2021 Apr 7;4(1):65.
65. Aslam TM, Hoyle DC. Translating the Machine: Skills that Human Clinicians Must Develop in the Era of Artificial Intelligence. *Ophthalmol Ther.* 2022 Feb;11(1):69–80.
66. Xie Y, Nguyen QD, Hamzah H, Lim G, Bellemo V, Gunasekeran DV, et al. Artificial intelligence for teleophthalmology-based diabetic retinopathy screening in a national programme: an economic analysis modelling study. *The Lancet Digital Health.* 2020 May;2(5):e240–9.