

LIETUVOS SVEIKATOS MOKSLŲ UNIVERSITETAS

Arnas Karužas

**GILIŲJŲ NEURONINIŲ TINKLŲ
PRITAIKYMAS AUTOMATIZUOTAI
ECHOKARDIOGRAFINEI ŠIRDIES
NEPAKANKAMUMO IR AORTOS
POKYČIŲ DIAGNOSTIKAI RAMYBĖS
IR KRŪVIO METU**

Daktaro disertacija
Medicinos ir sveikatos mokslai,
medicina (M 001)

Kaunas, 2026

Disertacija rengta 2021–2025 metais Lietuvos sveikatos mokslų universiteto Kardiologijos instituto Kardiologinių tyrimų automatizacijos laboratorijoje.

Mokslinė vadovė

prof. habil. dr. Vaiva Lesauskaitė (Lietuvos sveikatos mokslų universitetas, medicinos ir sveikatos mokslai, medicina – M 001).

Konsultantė

prof. dr. Jurgita Plisienė (Lietuvos sveikatos mokslų universitetas, medicinos ir sveikatos mokslai, medicina – M 001).

Disertacija ginama Lietuvos sveikatos mokslų universiteto Medicinos mokslo krypties taryboje:

Pirmininkas:

prof. dr. Juozas Kupčinskas (Lietuvos sveikatos mokslų universitetas, medicinos ir sveikatos mokslai, medicina – M 001).

Nariai:

prof. dr. Andrius Macas (Lietuvos sveikatos mokslų universitetas, medicinos ir sveikatos mokslai, medicina – M 001);

prof. dr. Pranas Šerpytis (Vilniaus universitetas, medicinos ir sveikatos mokslai, medicina – M 001);

prof. dr. Agnė Paulauskaitė-Tarasevičienė (Kauno technologijos universitetas, gamtos mokslai, informatika – N 009);

prof. dr. Alexander Schlaefel (Hamburgo technologijos universitetas, gamtos mokslai, informatika – N 009).

Disertacija bus ginama viešajame Medicinos mokslo krypties tarybos posėdyje 2026 m. vasario mėn. 11 d. 13.00 val. Lietuvos sveikatos mokslų universiteto ligoninės Kauno klinikų Kardiologijos klinikos 356 auditorijoje.

Disertacijos gynimo vietos adresas: Eivenių g. 2, LT-50161 Kaunas, Lietuva.

LITHUANIAN UNIVERSITY OF HEALTH SCIENCES

Arnas Karužas

**APPLICATION OF DEEP NEURAL
NETWORKS TO AUTOMATED
ECHOCARDIOGRAPHIC
DIAGNOSTICS OF HEART FAILURE
AND AORTIC CHANGES
AT REST AND DURING STRESS**

Doctoral Dissertation
Medical and Health Sciences,
Medicine (M 001)

Kaunas, 2026

Dissertation has been prepared in 2021–2025 at the Laboratory of Automation of Cardiovascular Investigation of the Institute of Cardiology, Lithuanian University of Health Sciences.

Scientific Supervisor

Prof. Habil. Dr. Vaiva Lesauskaitė (Lithuanian University of Health Sciences, Medical and Health Sciences, Medicine – M 001).

Consultant

Prof. Dr. Jurgita Plisienė (Lithuanian University of Health Sciences, Medical and Health Sciences, Medicine – M 001).

Dissertation is defended at the Medical Research Council of the Lithuanian University of Health Sciences:

Chairperson:

Prof. Dr. Juozas Kupčinskas (Lithuanian University of Health Sciences, Medical and Health Sciences, Medicine – M 001).

Members:

Prof. Dr. Andrius Macas (Lithuanian University of Health Sciences, Medical and Health Sciences, Medicine – M 001);

Prof. Dr. Pranas Šerpytis (Vilnius University, Medical and Health Sciences, Medicine – M 001);

Prof. Dr. Agnė Paulauskaitė-Tarasevičienė (Kaunas University of Technology, Natural Sciences, Informatics – N 009);

Prof. Dr. Alexander Schlaefer (Hamburg University of Technology, Natural Sciences, Informatics – N 009).

Dissertation will be defended at the open session of the Medical Research Council of the Lithuanian University of Health Sciences on the 11th of February, 2026 at 1 p.m. in the 356 Auditorium of the Department of Cardiology of the Hospital of Lithuanian University of Health Sciences Kauno klinikos.

Address: Eivenių 2, LT-50161 Kaunas, Lithuania.

TURINYS

SANTRUMPOS.....	7
ĮVADAS	8
1. DARBO TIKSLAS IR UŽDAVINIAI	10
1.1. Tikslas	10
1.2. Uždaviniai	10
1.3. Darbo mokslinis naujumas	10
2. LITERATŪROS APŽVALGA.....	12
2.1. Širdies nepakankamumas: priežastys ir klasifikacija.....	12
2.2. Dvimatės echokardiografijos svarba diagnozuojant aortos ligas bei ŠN.....	13
2.3. Krūvio echokardiografija KS sistolinės funkcijos ir išeminės širdies ligos vertinime	15
2.4. Dirbtinis intelektas širdies vaizdiniuose tyrimuose: DI apibrėžtis, taikymai.....	16
2.5. Dirbtinis intelektas vertinant KS tūrius ir sistolinę funkciją.....	20
2.6. Dirbtinis intelektas vertinant diastolinę KS funkciją	22
2.7. Dirbtinis intelektas vertinant aortos diametrus ir pokyčius	26
2.8. Dirbtinis intelektas krūvio echokardiografijoje.....	29
3. DARBO METODIKA.....	34
3.1. Bendrieji tyrimo etapai ir kriterijai.....	34
3.2. Aortos ir kairiojo skilvelio diastolinių parametrų vertinimo metodika.....	35
3.2.1. Tiriamųjų kontingentas	35
3.2.2. Dvimatė echokardiografija ir automatinė analizė.....	35
3.2.3. Statistinė analizė	38
3.3. Kairiojo skilvelio ir prieširdžio parametrų vertinimo ramybės ir krūvio echokardiografijos metu metodika.....	40
3.3.1. Tiriamųjų kontingentas	40
3.3.2. Dvimatė ramybės ir krūvio echokardiografija ir automatinė analizė.....	40
3.3.3. Dvimatės echokardiografijos vaizdų kokybės įvertinimas	41
3.3.4. Statistinė analizė	42
4. REZULTATAI.....	43
4.1. Aortos ir kairiojo skilvelio diastolinių parametrų vertinimo rezultatai.....	43
4.1.1. Tiriamųjų charakteristika	43

4.2. Automatizuoto diastolinės funkcijos parametrų vertinimo rezultatai	44
4.2.1. Diastolinės disfunkcijos klasifikavimo tikslumas.....	45
4.3. Automatizuoto aortos diametrų vertinimo rezultatai	46
4.4. Kairiojo skilvelio ir prieširdžio parametrų vertinimo ramybės ir krūvio echokardiografijos metu rezultatai.....	47
4.4.1. Tiriamųjų charakteristika	47
4.4.2. Dirbtinio intelekto diagnostinės gebos vertinimas.....	48
4.4.3. Dirbtinio intelekto ir ekspertų atliktų matavimų ramybės ir krūvio metu palyginimas	48
4.4.4. Dirbtinio intelekto ir ekspertų atliktų matavimų atitikimas ir palyginimas tarp skirtingų centrų	50
4.4.5. Skirtingos kokybės vaizdų vertinimas	56
4.4.6. Dirbtinio intelekto ir ekspertų atliktų matavimų atitikimas ir palyginimas, esant skirtingos kokybės vaizdams	57
5. REZULTATŲ APTARIMAS	60
6. TYRIMO RIBOTUMAI	67
6.1. Diastolinės funkcijos ir aortos parametrų vertinimo ribotumai	67
6.2. Kairiojo skilvelio ir prieširdžio parametrų vertinimo ramybės ir krūvio metu ribotumai	67
IŠVADOS	68
PRAKTINĖS REKOMENDACIJOS	69
SUMMARY	70
LITERATŪROS SĄRAŠAS	96
DOKTORANTO INDĖLIS.....	109
PASKELBTOS PUBLIKACIJOS.....	110
CURRICULUM VITAE.....	112
PRIEDAS.....	114

SANTRUMPOS

AoŽ	–	aortos žiedas
AoS	–	aortos ančiai
AVAJO	–	aortos vainikinių arterijų jungčių operacija
AR	–	atitikties rodiklis
BIĮ	–	bendroji išilginė įtampa
DI	–	dirbtinis intelektas
Dec	–	ankstyvosios diastolinės prisipildymo bangos greičio lėtėjimo laikas
DG	–	diagnostinė geba
DKT	–	daugiasluoksnė kompiuterinė tomografija
EKD	–	Europos kardiologų draugija
IŠL	–	išeminė širdies liga
GNT	–	gilieji neuroniniai tinklai
KAo	–	kylančioji aorta
KE	–	krūvio echokardiografija
KK	–	koreliacijos koeficientas
KLR	–	krūtinės ląstos rentgenograma
KMI	–	kūno masės indeksas
KP	–	kairysis prieširdis
KPTi	–	kairiojo prieširdžio tūrio indeksas
KPT	–	kairiojo prieširdžio tūris
KPP	–	kairiojo prieširdžio plotas
KSIF	–	kairiojo skilvelio išstūmio frakcija
KSDD	–	kairiojo skilvelio diastolinė disfunkcija
KSDF	–	kairiojo skilvelio diastolinė funkcija
KSGDT	–	kairiojo skilvelio galinis diastolinis tūris
KSGST	–	kairiojo skilvelio galinis sistolinis tūris
MI	–	miokardo infarktas
MM	–	mašininis mokymasis
PI	–	pasikliautinasis intervalas
SE2030	–	Stress Echo 2030
SR	–	suderinamumo riba
STJ	–	antinė-vamzdinė (sinotubulinė) jungtis
ŠMR	–	širdies magnetinis rezonansas
ŠN	–	širdies nepakankamumas
ŠV	–	šališkumo vertinimas
TNRD	–	tikrasis neigiamų rezultatų dažnumas
TN	–	tikrasis neigiamas
TRMG	–	didžiausias triburio vožtuvo regurgitacijos gradientas
TRMV	–	didžiausias triburio vožtuvo regurgitacijos greitis
VKP	–	vidutinė kvadratinė paklaida
VKK	–	vidinis koreliacijos koeficientas
VAP	–	vidutinė absoliučioji paklaida
2D TTE	–	dvimatė echokardiografija
2K	–	dvi kameros
4K	–	keturios kameros

IVADAS

Širdies nepakankamumas (ŠN) išlieka viena svarbiausių visuomenės sveikatos problemų, kuri susijusi su dideliu sergamumu ir mirtingumu bei didelėmis sveikatos sistemos sąnaudomis. 2021 m. Europos kardiologų draugijos (EKD) gairės rekomenduoja echokardiografiją kaip pirminį vaizdinį ŠN diagnostikos tyrimą, nes jis leidžia vienu metu įvertinti kairiojo skilvelio (KS) sistolinę ir diastolinę funkciją, vožtuvų būklę ir hemodinamiką [1]. Kai kuriose šalyse ŠN dažnumas stabilizuojasi, tačiau pacientų daugėja dėl visuomenės senėjimo ir geresnio išgyvenamumo po ūminių širdies įvykių (pvz., miokardo infarkto). Pastarųjų trejų metų vertinimai rodo ~1–3 proc. ŠN turinčiųjų paplitimą populiacijoje ir dešimtis milijonų pacientų visame pasaulyje [2, 3].

Diagnostika tampa vis sudėtingesnė: daug tyrimų, priklausomumas nuo tyrėjų ir skirtingi tyrimų vertinimai skatina ieškoti automatizuotų sprendimų. Pastaraisiais metais į šią sritį greitai integruojami giliojo mokymosi metodai – nuo vaizdų kokybės kontrolės ir projekcijų atpažinimo iki ertmių segmentavimo, tūrių, kairiojo skilvelio išstūmio frakcijos (KSIF), sienelių judesių bei kraujotakos per vožtuvus vertinimo. 2023 m. JACC darbai ir mokslo straipsniai pabrėžia, kad gilieji neuroniniai tinklai (GNT) gali sumažinti darbo krūvį ir pagerinti tyrimų rezultatų tikslumą, jei užtikrinama aukšta vaizdų kokybė ir algoritmai tinkamai validuojami [4, 5].

KS diastolinė funkcija ypač paranki automatizacijai – reikia integruoti kelis dvimačius echokardiografijos (2D TTE) ir Doplerio rodiklius. Daugelio šalių 2022 m. tyrimai parodė, kad GNT geba automatiškai įvertinti vaizdus ir Doplerio signalus – nustato sistolinę ir diastolinę disfunkciją panašiu tikslumu kaip ekspertai. Vėliau, 2024 m., publikuotuose darbuose aprašytas pusiau arba visiškai automatizuotas realių pacientų kohortų diastolinės funkcijos įvertinimas [6, 7]. 2025 m. atnaujintoje Amerikos echokardiografijos draugijos diastolinės funkcijos vertinimo metodikoje pabrėžtas standartizuotas, daug parametų jungiantis požiūris – tai suteikia tvirtą pagrindą dirbtinio intelekto (DI) sprendimų validacijai klinikinėje praktikoje [8].

Kaip jau žinoma, ŠN gali būti susijęs su gretutinėmis kraujagyslių ligomis. Aortos šaknies ir kylančiosios aortos dydžių pokyčiai dažni sergant hipertenzija ir senstant, todėl struktūrinė aortos analizė svarbi ŠN sergant gretutinėmis ligomis (komorbidiskumo požiūriu). Žinoma, DI pritaikymas taip pat plečiasi. 2023 m. publikuoti darbai pademonstravo giliojo mokymosi tinklų galimybes automatiškai įvertinti su aorta susijusius echokardiografinius matmenis, pavyzdžiui, KS nutekamojo trakto skersmenį. Tačiau 2024 m. apžvalgos apibendrina algoritmus, automatiškai matuojančius dalį aortos

skersmenų [9, 10]. Dalis sprendimų šiuo metu dar tikrinami ir lyginami su kompiuterinės tomografijos duomenimis. Tendencija aiški – vis dažniau siekiama tiesioginės validacijos echokardiografijoje, taikant standartizuotus gairėse apibrėžtus matavimo principus [9, 10].

DI pritaikymas plečiasi ne tik ramybės, bet ir krūvio echokardiografijoje (KE). Ankstyvieji tyrimai rodo, kad modeliai gali padėti nustatyti subtilius sienelių judesių sutrikimus, pagreitinti projekcijų atpažinimą ir standartizuoti tyrimo ataskaitas, tačiau plačiai pritaikytų algoritmų dar yra mažai [5, 6].

Pažanga didelė, tačiau lieka esminių spragų: daugumai modelių trūksta daugiacentrės, perspektyvinės, įrenginių įvairovę atspindinčios išorinės validacijos; neretai stinga tiesioginių palyginimų su ekspertų atliktais matavimais ir klinikinių sprendimų poveikio analizės. 2024–2025 m. apžvalgose patariama ankstyvos stadijos DI sprendimus, susijusius su sprendimų priėmimu, naudoti atsakingai (pvz., CONSORT-AI/DECIDE-AI) ir integruoti DI į darbo srautus taip, kad matavimai būtų tikrinami eksperto, o duomenų kokybė – kontroliuojama [4, 9]. Tai pagrindžia šio mokslinio darbo tikslą – įvertinti DI galimybes, pritaikymą ir tikslumą vertinant ŠN ir aortos parametrus realioje klinikinėje praktikoje.

1. DARBO TIKSLAS IR UŽDAVINIAI

1.1. Tikslas

Pritaikyti GNT ir įvertinti jų galimybes bei tikslumą automatizuotai echokardiografiniai širdies nepakankamumo ir aortos pokyčių diagnostikai ramybėje ir krūvio metu.

1.2. Uždaviniai

1. Įvertinti GNT tikslumą ir koreliaciją su ekspertų įvertinimais automatizuotai analizuojant KS diastolinės funkcijos parametrus ir nustatant diastolinę disfunkciją.
2. Įvertinti GNT tikslumą ir koreliaciją su ekspertų įvertinimais automatizuotai analizuojant aortos šaknies ir kylančios aortos diametrus.
3. Įvertinti GNT tikslumą ir koreliaciją su ekspertų įvertinimais automatizuotai analizuojant KS ir kairiojo prieširdžio (KP) tūrius ir KS sistolinę funkciją ramybės ir krūvio metu.
4. Įvertinti GNT tikslumą ir pritaikomumą vertinant skirtingos kokybės echokardiografijos vaizdus ramybėje ir krūvio metu.

1.3. Darbo mokslinis naujumas

Šiame tyrime dalyvavo iš viso virš 500 pacientų, iš 6 skirtingų pasaulio centrų, išanalizuota virš 5000 dvimatės echokardiografijos vaizdų ir iš kitų atliktų tyrimų išsiskyrė šiomis savybėmis:

- Pirmą kartą DI pritaikomumas ir tikslumas buvo išbandytas tokiam plačiam spektrui 2D TTE įvairių parametrų standartinėje ramybės echokardiografijoje bei krūvio echokardiografijos metu:
 - Pagrindiniai KS diastolinės funkcijos vertinimo parametrai
 - Aortos šaknies ir kylančiosios aortos parametrai
 - KS ir KP tūrių ir KS sistolinės funkcijos parametrai ramybės ir krūvio metu
- Tai vienas pirmųjų tyrimų pasaulyje, kuriame DI išbandytas farmakologinio krūvio echokardiografijos analizėje.
- Vienas pirmųjų tyrimų, kuriame DI pritaikytas skirtingos kokybės echokardiografinių vaizdų pritaikomumui ir analizei.

- Iki šiol buvo labai nedaug DI paremtų 2D TTE tyrimų, kuriuose naudota pilnai automatizuota darbo eiga, t. y. nuo vaizdo, ciklo, kadro parinkimo iki matavimų atlikimų, jų įvertinimų ir pirminės išvados pateikimo.
- Kritiškam ir tiksliam DI vertinimui išlaikyti jo darbo rezultatai buvo lyginami su ekspertų atliktų 2D TTE rezultatų įvertinimais.

2. LITERATŪROS APŽVALGA

2.1. Širdies nepakankamumas: priežastys ir klasifikacija

ŠN – tai klinikinis sindromas, atsirandantis dėl struktūrinių ar funkcinų širdies pokyčių, sutrikdančių skilvelių gebėjimą tinkamai prisipildyti arba išstumti kraują, kad būtų patenkinti organizmo metaboliniai poreikiai ramybės ir fizinio krūvio metu [1, 11]. ŠN – tai plačiai paplitusi patologija, kuri nustatoma apie 1–2 proc. gyventojų. Ši diagnozė dažnėja senstant: iki 55 metų – ŠN nustatoma tik apie 1 proc., o vyresniems nei 75 metų pacientų tarpe >10 proc. [1, 2]. Diagnozė nustatoma esant struktūrinei širdies ligai, tipiniams simptomams, tokiems kaip dusulys, fizinio krūvio netoleravimas, nuovargis, objektyviems požymiams (periferinėms edemoms, veninei stazei plaučiuose) ir pakitimams širdies vaizdiniuose bei laboratoriniuose tyrimuose [1, 12]. Svarbiausias laboratorinis rodiklis ŠN diagnostikai – tai natriureziniai peptidai (BNP, NT-proBNP), kurių padidėjusios reikšmės yra jautrus ir specifinis ŠN žymuo [13]. Vienas pagrindinių širdies funkcijos vertinimo rodiklių vaizdiniuose tyrimuose yra kairiojo skilvelio išstūmio frakcija (KSIF), kuri nurodo procentinę kraujo dalį, kuri yra išstumiama iš KS susitraukimo metu. Normali KSIF vertė laikoma ≥ 50 proc., tačiau daugelyje šaltinių nurodoma, kad ji dažniausiai svyruoja tarp 50–65 proc. [14].

Remiantis EKD gairėmis, ŠN pagal KSIF skirstomas į tris tipus [1]:

- širdies nepakankamumas su sumažėjusia išstūmio frakcija (ŠNsIF) – $KSIF \leq 40$ proc.;
- širdies nepakankamumas su vidutiniškai sumažėjusia išstūmio frakcija (ŠNvsIF) – $KSIF 41\text{--}49$ proc.;
- širdies nepakankamumas su išsaugota išstūmio frakcija (ŠNiIF) – $KSIF \geq 50$ proc.

Šis klasifikavimas leidžia diferencijuoti pacientų fenotipus, jų rizikos profilius bei individualizuoti gydymą. ŠNvsIF dažnai laikomas tarpine būkle, tačiau vis daugiau tyrimų rodo, kad šis tipas turi savitų klinikinių ir prognozinų savybių [15].

ŠNsIF būdingas kairiojo skilvelio sistolinės funkcijos sutrikimas, pasireiškiantis sumažėjusiu kontraktiliškumu, skilvelio sienelės išplonėjimu ir susitraukimo jėgos sumažėjimu. Dėl šios priežasties KS negeba išstumti pakankamai kraujo į aortą ir periferinę kraujotaką, o tai lemia sumažėjusią sistolinę funkciją. Nors nustatyta daug ŠNsIF priežasčių, dažniausios iš jų: išeminė širdies liga, blogai kontroliuojama arterinė hipertenzija, miokardo ligos (pvz., dilatacinė kardiomiopatija), toksinių medžiagų poveikis (alkoholis, tam tikri medikamentai), vožtuvų ligos [11, 16].

ŠNiIF atveju kairiojo skilvelio sistolinė funkcija išlieka normali, tačiau būdingas diastolinės funkcijos sutrikimas, kuris dažniau nustatomas vyresnio amžiaus pacientams, ypač moterims, sergančioms arterine hipertenzija, cukriniu diabetu, nutukimu ar kai yra prieširdžių virpėjimas. Vienas pagrindinių šios būklės bruožų – normali kairiojo skilvelio sistolinė funkcija, tačiau sutrikęs jo atsipalaidavimas ir prisipildymas diastolės metu. Diastolinės funkcijos sutrikimas padidina spaudimą kairiajame prieširdyje ir plaučių kraujagyslėse, sukelia veninę stazę plaučiuose ir dusulį [17, 18]. Svarbiausios ŠNiIF priežastys yra hipertenzinė širdies liga, miokardo fibrozė, sukelta senėjimo procesų ar lėtinio uždegimo, infiltracinės miokardo ligos (pvz.: širdies amiloidozė, Fabry liga), perikardo ligos (pvz., konstriktinis perikarditas) [1, 17].

2.2. Dvimatės echokardiografijos syarba diagnozuojant aortos ligas bei ŠN

2D TTE – tai neinvazinis širdies vaizdinis tyrimo metodas, leidžiantis įvertinti tiek morfologinius pakitimus (širdies ertmių dydžius, sienelių storius, vožtuvų būklę), tiek ir funkcinis širdies pokyčius. Šis metodas pagrįstas ultragarsinių bangų generavimu ir registravimu, naudojant pjezoelektrinius kristalus, kurie mechaninį impulsą paverčia elektriniu signalu, transformuojamu į realaus laiko vaizdą. Tyrimo metu taikomi įvairūs režimai: B režimas - struktūrų vizualizavimui, M režimas – sienelių judėjimo analizei, o spalvinis ir spektrinis Dopleris – kraujotakos greičiui ir kryptčiai įvertinti [19, 20]. Dėl plataus prieinamumo, santykinai nedidelės kainos ir jonizuojančios spinduliuotės nebuvimo, 2D TTE išlieka dažniausiai klinikinėje praktikoje taikomu širdies vaizdiniu tyrimu.

Šis tyrimas yra neatsiejama ŠN diagnostikos, stebėsenos ir gydymo efektyvumo vertinimo dalis. Remiantis EKD gairėmis, echokardiografija rekomenduojama kaip pirminis vaizdinis tyrimas kiekvienam pacientui, kuriam įtariamas ŠN [1]. Ji padeda įvertinti kairiojo ir dešiniojo skilvelių funkciją, vožtuvų būklę, perikardo patologiją bei galimą struktūrinę miokardo patologiją. Tyrimo metu nustatomi rodikliai, tokie kaip KSIF, diastolinės funkcijos parametrai, prieširdžių tūriai ir vožtuvų būklė, kurie leidžia ne tik patvirtinti diagnozę, bet ir suskirstyti pacientus pagal ŠN fenotipą bei planuoti tolimesnį gydymą [21, 22].

Jau ilgą laiką KSIF yra pagrindinis sistolinės funkcijos vertinimo rodiklis. Kasdienėje 2D TTE ji apskaičiuojama iš dviejų širdies projekcijų disko metodu (modifikuotas Simpsono metodas), žymint endokardą galinės diastolės ir galinės sistolės metu standartiniuose keturių ir dviejų širdies kamerų projekcijų vaizduose. Tiksliam matavimui būtina vengti viršūnės

sutrumpinimo, o esant ribotam endokardo matomumui rekomenduojama naudoti ultragarsą stiprinančias medžiagas (kontrastą), gerinančias endokardo ribų matomumą [22–24]. 2D metodu nustatytos normos yra specifinės lyčiai ir plačiai taikomos klinikinėje praktikoje [22]. Kai įmanoma, KSIF ir tūrius tikslinga matuoti naudojant 3D echokardiografiją, nes ji sumažina paklaidas, atsirandančias dėl supaprastinto skilvelio modelio taikymo, rodo geresnį atitikimą širdies magnetinio rezonanso rezultatams ir geresnį pakartojamumą nei 2D TTE. Visa tai ypač svarbu ilgalaikiai stebėsenai ir rezultatui keičiant klinikinių veiksmų sprendimą (pvz., kardioverterio implantavimas) [25–27]. Vis dėlto 3D echokardiografija dažnai nepakankamai įvertina absoliučius KS tūrius, todėl tiksliam vertinimui būtina kokybiška pilno tūrio registracija ir patikima, validuota analizės programinė įranga [25]. Todėl praktinės rekomendacijos pažymi, jog pirmiausia reikia atlikti kokybišką 2D dviejų projekcijų analizę, o tik vėliau, esant galimybei, nuosekliai KSIF ir tūrių stebėjimui, teikti pirmenybę 3D echokardiografijai [22–27].

Echokardiografija leidžia įvertinti ne tik KS sistolinę, bet ir diastolinę funkciją, kurios sutrikimai būdingi pacientams, sergantiems ŠNiIF. Diastolinės funkcijos vertinimas yra kompleksinis – įvertinami kraujotakos per dviburį vožtuvą greičiai (E, A), pertvarinės ir šoninės sienelės e' greičiai, E/e' santykis, KP tūrio indeksas (KPTi) ir triburio vožtuvo nesandarumo maksimalus greitis [18]. Šių parametrų visuma leidžia įvertinti KS prispildymo spaudimą ir identifikuoti pacientus su sutrikusia KS diastoline funkcija [28].

Be KS funkcijos vertinimo, echokardiografija yra neatsiejama pacientų, sergančių aortos ligomis, diagnostikos ir ilgalaikės stebėsenos dalis. Europos širdies vaizdinių tyrimų asociacija ir Amerikos echokardiografijos asociacija rekomenduoja įtraukti aortos anatominių struktūrų vertinimą į standartinį 2D TTE protokolą. Šis tyrimas įprastai leidžia vizualizuoti bent kelis aortos segmentus, tačiau tiksliausiai įvertinama aortos šaknis bei proksimalinė kylančiosios aortos dalis [29, 30]. Nors aorta gali būti vertinama iš kelių projekcijų, didžiausias matavimo tikslumas, lyginant su kompiuterine tomografija ar širdies magnetinio rezonanso tomografija, pasiekiamas naudojant priekrūtinkaulinės ilgosios ašies projekciją [31, 32]. TTE pasižymi geru prieinamumu įvairiose gydymo įstaigose bei gali būti atliekamas prie paciento lovos, o tai leidžia greitai ir efektyviai atlikti pirminį aortos įvertinimą [11]. Nepaisant šių tyrimo privalumų, 2D TTE jautrumas ir specifiskumas vertinant visus aortos segmentus yra ribotas. Tyrimo tikslumas priklauso nuo tyrėjo patirties, tiriamojo anatominių ypatybių ir tinkamos akustinių langų vizualizacijos. Be to, literatūroje aprašomas reikšmingas matavimų kintamumas tiek tarp skirtingų tyrėjų, tiek tarp to paties tyrėjo pakartotinių matavimų [33, 34].

2.3. Krūvio echokardiografija KS sistolinės funkcijos ir išeminės širdies ligos vertinime

KE – plačiai taikomas neinvazinis vaizdinis tyrimo metodas, skirtas įtariamoms išeminės širdies ligos (IŠL) bei kitų struktūrinių ir funkcinių širdies sutrikimų diagnostikai. Tyrimo metu vertinami širdies hemodinamikos, kontraktiliškumo bei vožtuvų funkcijos pokyčiai, atsirandantys krūvio metu. Atsižvelgiant į paciento galimybes, galima skirtinga tyrimo atlikimo metodika – taikant fizinį krūvį (bėgtakis, dviratis) arba farmakologinius mėginus (dobutaminas, dipiridamolis ar adenozinas). Nors fizinio krūvio echokardiografija laikoma pirmo pasirinkimo metodu, farmakologinis krūvis turi privalumų – leidžia išvengti hiperventiliacijos, papildomų krūtinės ląstos judesių, kurie turi neigiamos įtakos vaizdų kokybei. Taip pat farmakologinis krūvio mėginys leidžia tyrimą atlikti pacientams, turintiems ribotą judėjimą, sąnarių ar neurologinių ligų [35–37].

Vienas svarbiausių KE pritaikymo aspektų – IŠL diagnostika [38]. Fizinio ar farmakologinio krūvio metu padidėja miokardo metabolizmas ir atitinkamai – deguonies poreikis. Jei vainikinės arterijos nepajėgia užtikrinti adekvataus aprūpinimo deguonimi, išsivysto miokardo išemija. Šią būklę gali lemti tiek aprūpinimo sutrikimas, tiek ženkliai padidėjęs poreikis, o kai kuriais atvejais ir kraujotakos nukreipimas nuo pažeistų segmentų vadina muoju „apvogimo“ (angl. *steal*) fenomenu [36, 38, 39]. Šie patofiziologiniai pokyčiai sąlygoja regioninius sienelių judesių sutrikimus, kurie laikomi vienu jautriausių ir specifiskiausių obstrukcinės vainikinių arterijų ligos požymių. Pagal atsaką krūvio metu galima diferencijuoti, ar išemijos pažeistas miokardas yra priblokštas, prisnūdęs ar jau nebegyvybingas, o tai svarbu vertinant revaskuliarizacijos galimybę ir prognozę [36, 40, 41].

Remiantis 2024 m. EKD Lėtinių vainikinių arterijų sindromų gydymo gairėmis, krūvio echokardiografija rekomenduojama pacientams, kuriems nustatoma vidutinė arba aukšta obstrukcinės vainikinių arterijų ligos tikimybė. Tai padeda optimizuoti tolesnę diagnostikos ir gydymo eigą [42]. Visgi, tradicinė KE metodika grindžiama tik regioninės miokardo kontrakcijos sutrikimų vertinimu nėra pakankamai informatyvi vertinant alternatyvias vainikinių arterijų ligos formas, pavyzdžiui mikrovaskulinę disfunkciją [36, 38, 43]. Atsižvelgiant į tai, kuriami ir į klinikinę praktiką integruojami nauji multiparametriniai KE protokolai. Vienas jų – ABCDE-SE protokolai, apimantis ne tik regioninės kontrakcijos vertinimą, bet ir plaučių veninės stazės (B linijų) nustatymą, vainikinių arterijų tekės greičio rezervo analizę, kairiojo skilvelio kontraktilinių rezervą (apie tai detaliau 8 literatūros apžval-

gos poskyryje) [44, 45]. Šių papildomų parametrų integravimas leidžia išsamiau įvertinti širdies funkciją krūvio metu ir pagerinti diagnostinę bei prognozinę KE vertę.


KE klinikinė nauda neapsiriboja vien išeminės širdies ligos diagnostika. Šis metodas plačiai taikomas vertinant įvairią širdies patologiją, ypač tais atvejais, kai ramybės echokardiografijos duomenų nepakanka išsamiam širdies funkcinės būklės įvertinimui. KE naudinga vertinant neišeminę kardiomiopatiją, širdies vožtuvų patologiją, diastolinės funkcijos pokyčius krūvio metu, plautinę hipertenziją, sportininkų širdies adaptacinius pokyčius bei įgimtas širdies ydas [46–48]. KE taip pat taikoma stebėti širdies transplantacijos recipientus bei stebėti gydymo efektyvumą [49]. Tyrimo metu vertinama kairiojo ir dešiniojo skilvelių kontraktilinė funkcija, jų tūriai, vožtuvų gradientai, regurgitacinės srovės, sistolinis spaudimas plaučių arterijoje bei bendri hemodinaminiai rodikliai, kintantys priklausomai nuo krūvio intensyvumo.

Nepaisant visų diagnostinių ir prognozinų privalumų, krūvio echokardiografijos rezultatų patikimumas glaudžiai susijęs su tyrimą atliekančio specialisto patirtimi, vaizdų kokybe bei nuosekliu standartizuotų protokolų laikymusi. Vis dėlto, KE išlieka vertingu diagnostikos metodu daugelyje situacijų, ypač tais atvejais, kai būtinas objektyvus širdies funkcijos įvertinimas krūvio metu.

2.4. Dirbtinis intelektas širdies vaizdiniuose tyrimuose: DI apibrėžtis, taikymai

DI pritaikymas širdies ir kraujagyslių vaizdiniuose tyrimuose greitai tobulėja – nuo vaizdo gavimo ir jo rekonstrukcijos iki automatizuotos analizės, diagnostikos bei rizikos prognozės. Praktikoje dominuoja mašininis mokymasis (MM) ir ypač giliaji neuroniniai tinklai (GNT) [50, 51]. MM tai yra metodų rinkinys, leidžiantis algoritmams mokytis dėsningumų iš duomenų be aiškiai suprogramuotų taisyklių. GNT yra MM poskyris, naudojantis daugiasluoksnius dirbtinius neuroninius tinklus (konvoliucinius, rekurentinius, transformerius) vaizdų ir vaizdo sekų ypatybių išgavimui [51]. Prižiūrimojo mokymosi atveju modelis mokomas su sužymėtais duomenimis, t. y. kiekvienam pavyzdžiui yra priskirta žinoma išvestis (pvz., KSIF skaitinė reikšmė, KS segmentacija ar vožtuvų ydos klasė), o tikslas – sumažinti prognozės ir tikrosios reikšmės skirtumą. Neprižiūrimojo mokymosi atveju naudojami nepažymėti duomenys (be žinomų išvesčių), siekiant atskleisti jų vidinę duomenų struktūrą, suformuoti klasterius ir aptikti anomalijas, taip identifikuojant paslėptus fenotipus [51]. Pastaraisiais metais plačiai taikomas

ir „savaiminis“ (angl. *self-supervised*) DI mokymasis, kai modelis išmoksta generuoti rezultatus sprendamas pagalbines užduotis iš pačių vaizdų (pvz., kadru eiliškumo rekonstrukcija), o vėliau šie rezultatai pritaikomi klinikinėms užduotims su mažesniu duomenų kiekiu [50, 52, 53].




2.4.1 pav. Įvairios dirbtinio intelekto rūšys ir jų galimybės integruotis į pagrindinius širdies ir kraujagyslių tyrimus [15, 50, 51]

MRT – magnetinio rezonanso tomografija; SPECT – vieno fotono emisijos kompiuterinė tomografija; 2D TTE – dvimatė transtorakalinė echokardiografija; KLR – krūtinės ląstos rentgenograma; VA DKTA – vainikinių arterijų daugiasluoksnė kompiuterinė tomografija su angiografija.

Širdies vaizdiniai tyrimai yra neatsiejama kardiologinės diagnostikos ir gydymo planavimo dalis. Praktikoje naudojama transtorakalinė ir transezofaginė echokardiografija (TEE), krūtinės ląstos rentgenograma (KLR), širdies magnetinis rezonansas (ŠMR), širdies kompiuterinė tomografija (KT) bei branduoliniai metodai (SPECT/PET) (2.4.1 pav.). Kiekvienas jų teikia unikalios informacijos apie anatomiją, funkciją ir audinių savybes [15].

TTE dėl plataus prieinamumo, realaus laiko hemodinamikos vertinimo, saugumo ir sąnaudų efektyvumo išlieka pirmos eilės tyrimu daugeliui kliniškinių situacijų, įskaitant ŠN diagnostiką ir stebėseną (detaliau apie šio tyrimo principus buvo aptarta 2-ame literatūros apžvalgos skyriuje „Ramybės echokardiografija struktūrinių širdies ir aortos ligų bei ŠN diagnostikoje“) [15].

TTE srityje GNT įrodė efektyvumą matavimų automatizavimo ir kokybės kontrolės grandyse [54]. Be ir kt. atsitiktinių imčių, aklo vertinimo, randomizuotoje studijoje DI sistema ne tik nenusileido ultragarso technologams vertinant KSIF, bet ir reikšmingai sutrumpino analizės laiką bei sumažino pakartotinių matavimų poreikį [54]. Daugiacentriame tyrime su kelių ultragarso aparatų gamintojų duomenimis pademonstruota, kad vieno širdies viršūninio keturių kamerų vaizdo analizė GNT pagalba gali tiksliai nustatyti ŠNiIF ir pagerinti klinikinių sprendimų naudą lyginant su vien gairėse rekomenduojamais diagnostiniais balais [55]. TTE yra kompleksinis tyrimas ir mašininio mokymosi algoritmai turi platų pritaikomumą įvairiuose šio tyrimo dalyse ir segmentuose (2.4.2 pav.).



2.4.2 pav. Dirbtinio intelekto algoritmų taikymo echokardiografijoje spektras

Žvelgiant į kitus svarbius vaizdinius tyrimus, paprasčiausia KLR tampa vis patrauklesnė kaip plataus masto patikros priemonė. 2023 m. daugia-instituciniame tyrime GNT pagal KLR klasifikavo vožtuvų ydas ir širdies funkcijos būklės demonstruodami klinikinio pritaikomumo potencialą resursų stokojančiose aplinkose (ambulatorija, regioninės ligoninės) [56].

TEE tai pusiau invazinis ultragarsinis tyrimas, atliekamas įvedant daviklį į stemplę. Dėl artimos daviklio ir širdies padėties suteikiama aukšta širdies kamerų erdvinė raiška bei detali vožtuvų, prieširdžių pertvaros ir kairiojo prieširdžio ausytės vizualizacija. TEE yra esminė diagnostikos priemonė infekcinio endokardito diagnostikoje, patikima trombų paieškai kairiojo prieširdžio ausytėje ir protezuotų vožtuvų būklės vertinime. Šis tyrimas taip pat plačiai naudojamas intraoperacinei ir intraprocedūrinei struktūrinių intervencijų kontrolei [57, 58]. Naujausias 3D TEE susitarimas rekomenduoja sistemingą ištyrimą, standartizuotus pjūvius ir nuoseklų vaizdų pateikimą, kas didina diagnostinę kokybę bei suderinamumą tarp centrų [58]. Pastaraisiais metais TEE integruojama su dirbtinio intelekto metodais: GNT modeliai patikimai atpažįsta standartines intraoperacines TEE projekcijas ir tolesnei automatinei analizei struktūrizuoja skirtingų įstaigų vaizdų srautus [59].

ŠMR pasižymi didele audinių charakterizacijos verte (pvz., vėlyvas gadolinio kaupimas, T1/T2 žemėlapiai) ir laikoma aukso standarto metodu vertinant skilvelių tūrius bei masę. DI spartina rekonstrukcijų kūrimą, gerina tyrimo vaizdų triukšmo kontrolę ir automatizuoja širdies kamerų bei randų segmentavimą [50, 60, 61]. Vis dėlto ŠMR yra mažiau prieinama, brangesnė ir netinka pacientams sergantiems klaustrofobija ar su tam tikrais implantais, kurie gali apsunkinti tyrimą ir skleisti ryškius vaizdo artefaktus [50].

Širdies KT, arba būtent daugiasluoksni vainikinių arterijų (VA) KT (DKT) su angiografija yra pirmos eilės tyrimas, kai yra įtariamas VA susiaurėjimas mažos-vidutinės rizikos pacientams. Šis metodas vis dažniau taikomas VA aterosklerozinių plokštelių kiekybiniam vertinimui. DI įrankiai automatizuoja aterosklerozinių plokštelių tūrio ir jų sudėties vertinimą ir leidžia pasiekti aukštą prognozinę vertę [62–64]. Daugiacentriuose tyrimuose DI pagrįsti VA DKT analizės rezultatai gerai sutapo su intravaskulinio ultragarso rezultatais ir tiksliai prognozavo nepageidaujamus įvykius (pavyzdžiui, miokardo infarktą ar insultą), kas dar labiau sustiprina įrodymus apie DI prognozės vertinimo potencialą [62–64].

Branduoliniai metodai (SPECT/PET) kardiologijoje leidžia įvertinti širdies raumens kraujotaką, metabolizmą ir uždegimą. DI čia taikomas triukšmo slopinimui, rekonstrukcijai bei automatizuotai perfuzijos žemėlapių analizei, kas gali sumažinti spinduliuotės dozę ir sutrumpinti tyrimo laiką [65–67].

Nepaisant multimodalinės ekosistemos, būtent 2D TTE išlieka pagrindinis tyrimas rutininėje ŠN diagnostikoje ir fenotipavime. Visą tai lemia tyrimo prieinamumas, dinaminis funkcijos vertinimas ir aiškūs gairėse apibrėžti rodikliai (pvz.: KSIF, diastolinės funkcijos kriterijai ir pan.) [15].

Kartu su augančiomis galimybėmis išlieka ir iššūkiai – būtina duomenų įvairovė ir reprezentatyvumas, modeliavimo skaidrumas ir skirtingų įrenginių bei centrų klinikinis validavimas, prospektyvinių randomizuotų tyrimų stoka. Europos širdies vaizdinių tyrimų asociacijos ir Amerikos echokardiografijos draugijų dokumentai pabrėžia standartizacijos, kokybės kontrolės ir personalo rengimo svarbą, siekiant sumažinti variaciją tarp skirtingų centrų [68, 69].

Teisinė ir reguliavimo aplinka vis labiau adaptuojasi prie DI paremtų medicininių sprendimų – JAV Maisto ir vaistų administracija (FDA) jau patvirtino daugiau kaip 100 kardiologijoje naudojamų DI algoritmų, daugiausia skirtų vaizdų segmentacijai ir matavimams, o tai didina jų klinikinio pritaikymo galimybes [70].

Vis dėlto įdiegimas turi atitikti kokybės ir skaidrumo standartus. Sisteminga JAMA (*Journal of the American Medical Association*) Network Open apžvalga parodė, kad nors DI pagrįstų intervencijų atsitiktinių imčių kontroliuojamų tyrimų skaičius auga, jų vis dar per mažai. Be to, atitiktis „Consolidated Standards of Reporting Trials – Artificial Intelligence extension“ (CONSORT-AI) gairėms išlieka netolygi. Tai rodo, kad realios klinikinės naudos įrodymai turi plėstis ir kokybiškai stiprėti [71]. Praktiniam darbui padeda „European Heart Journal – Digital Health“ siūlomas ROBUST-ML kontrolinis sąrašas [72]. Jis moko atpažinti dažniausius DI tyrimų šališkumo šaltinius, tokius kaip duomenų rinkinio pokyčiai, perteklinis pritaikymas ar duomenų nutekėjimas [72]. Be to, šis sąrašas ragina tikrinti modeliavimo ir ataskaitų kokybę. Svarbiausi klinikinio DI taikymo kokybės principai yra išdėstyti „npj Digital Medicine“ gairėse [72, 73].

2.5. Dirbtinis intelektas vertinant KS tūrius ir sistolinę funkciją

Automatizuoti GNT paremti echokardiografijos sprendimai pirmausia atsirado tam, kad būtų galima greičiau nustatyti KS tūrius ir KSIF, tai mažiau priklausytų nuo tyrėjų gebėjimų ir būtų lengviau palyginti kartotinius tyrimus. Naujausios sistemos dirba su standartiniais 2D širdies viršūniniais vaizdais ir ultragarso fiksuotais vaizdo ciklais: automatiškai atpažįsta sistolės/diastolės fazes, segmentuoja endokardą ir iš dviejų projekcijų apskaičiuoja KS galinį diastolinį tūrį (KSGDT), galinį sistolinį tūrį (KSGST) bei KSIF. DI pakartotiniai matavimai tikslesni nei skirtingų tyrėjų ir ne prastesni nei vieno tyrėjo pakartotiniai matavimai skirtingu laikotarpiu [74]. Tuo pat metu

sukurti modeliai, kurie tiesiogiai iš ultragarso vaizdų prognozuoja KSIF, apeidami tarpinius tūrių skaičiavimus ir imituodami eksperto vizualinį KSIF įvertinimą, reikšmingai sutrumpina matavimų laiką, kai kurių studijų duomenimis net 77 proc. [74]. Toks būdas mažiau jautrus KS segmentavimo klaidoms ir ypač tinka realaus laiko klinikinėms užduotims [74, 75].

Didelės apimties aklas randomizuotas tyrimas parodė, kad DI atlikta KSIF interpretacija yra ne prastesnė, o tam tikrais atvejais net pranašesnė už ultragarso technologo pradinį įvertį: >5 proc. atvejų rečiau prireikė galutinės kardiologo ataskaitos korekcijų, o bendra darbo trukmė sutrumpėjo abiem specialistams (technologui ir kardiologui) [76]. Jau kuris laikas populiarėja greitoji, tikslinga širdies echoskopija (FoCUS), kai tyrimas naudojamas pirminėje diagnostikoje dėmesį sutelkiant į tam tikrą širdies struktūrą [77]. Tačiau net ir tokiuose scenarijuose DI pagalba pasiteisino: prospektyvūs tyrimai parodė aukštą tikslumą klasifikuojant sumažėjusią KSIF nepriklausomai nuo tyrėjo patirties bei gerą sutarimą su modifikuotu Simpson metodu [54, 78].

Technologiškai dažnai naudojama U-Net konvolucinių neuroninių tinklų architektūra ir jos patobulinimai: automatiškai atskiria endokardo ribą kiekviename kadre arba visoje vaizdo kilpoje. Naujesni sprendimai išnaudoja laikiną vaizdo kilpos informaciją ir stabilizuoja kontūrus per visą širdies ciklą. Be to, kuriamos skaičiavimo sąnaudas tausojančios segmentavimo technikos (pvz., SimLVSeg), kurios yra savarankiškesnės, joms reikia ženkliai mažiau rankinio paaikškinimo, bet yra išlaikomas nuoseklus endokardo ribų sekimas ir išgaunamos mažesnės skaičiavimo sąnaudos [79]. Kitas požiūris – vadinamieji „tiesioginiai vaizdo regresoriai“, kurie iš karto pateikia KSIF prognozę iš ultragarsinio vaizdo, neskačiuodami tarpinių tūrių. Tai mažina galimų endokardo segmentavimo klaidų įtaką, ypač prastesnės kokybės vaizduose [75].

Dirbtinio intelekto naudojimo klinikinė nauda yra akivaizdi keliais aspektais:


- Pirma, efektyvumas ir standartizacija. DI padeda greitai įvertinti KSIF ir bendrąją išilginę įtampą (BIĮ), mažina subjektyvumą ir suvienodina matavimus tarp skirtingų operatorių bei laikotarpių. Tai patvirtinama ir atsitiktinių imčių kontroliuojamuose tyrimuose, ir realios praktikos studijose [74, 76, 80–82].
- Antra, prieinamumas: DI asistuojamas FoCUS leidžia patikimai atpažinti sumažėjusią KSIF net mažiau patyrusiems tyrėjams, kas ypač naudinga skubios pagalbos skyriuose ar kitose situacijose, kai širdies echoskopijas atliekantis specialistas neprieinamas [54, 78].

- Trečia, stebėsenos kokybė: patikimesnis, mažiau kintantis BII, KS tūrio ir KSIF vertinimas padeda geriau vertinti vartojamo medikamentinio gydymo ar skirtos kardiotoksinės chemoterapijos poveikį – tai svarbu priimant sprendimus dėl gydymo intensyvinimo ar keitimo [80–82].

Žinoma, yra ir praktinių ribojimų. Algoritmų našumas vis dar priklauso nuo vaizdo kokybės ir standartinių projekcijų laikymosi - netinkami pjūviai ar artefaktai gali mažinti tyrimo tikslumą. Todėl abejotinais atvejais rekomenduojama peržiūrėti specialistui [74]. Taip pat svarbi išorinė validacija įvairiose populiacijose ir aparatų tipuose bei periodinis kokybės auditas, kad būtų išvengta sisteminių šališkumų (pvz., esant labai dilatuotam KS ar neįprastai geometrijai) [80–82]. Vis dėlto, kaupiantis duomenims ir tobulėjant architektūroms, šie ribojimai nuosekliai mažėja [74, 75, 79].

2.6. Dirbtinis intelektas vertinant diastolinę KS funkciją

Diastolinės KS funkcijos vertinimas echokardiografijoje – vienas metodologiškai sudėtingiausių etapų, nes reikia kelių hemodinamikai ir amžiui jautrių rodiklių. Senstant E bangos dydis mažėja, o A bangos didėja, todėl E/A santykis mažėja [83]. Galutinis vertinimas neretai išlieka neapibrėžtas, ypač tada, kai rodikliai pateikia prieštarinę informaciją arba širdies echo-skopijos vaizdų kokybė yra nepakankama [83]. Detalus KS diastolinės funkcijos vertinimo algoritmas pagal 2016 metų rekomendacijas, kuris naudotas ir šiame tyrime, pateiktas 2.6.1 pav. [83]. Šioje vietoje didelę pridėtinę vertę gali kurti DI. Jis diastolinės KS funkcijos echokardiografinius rodiklius matuoja visiems vienodais algoritmais, taip sumažindamas žmogaus klaidų ar interpretacijų skirtumus [6, 84]. Dažnai skirtingi rodikliai gali rodyti prieštarinę informaciją. Pavyzdžiui, E/A santykis rodo diastolinės funkcijos sutrikimą, bet E/e' – normą. Tokioje situacijoje gydytojas turi nuspręsti kurį parametą labiau vertinti, o DI gali automatiškai visus rodiklius sujungti į bendrą modelį ir pateikti nuoseklų, įrodymais grįstą sprendimą [83, 84].



2.6.1 pav. KS diastolinės funkcijos vertinimo algoritmas pacientams su normalia (≥ 50 proc.) ir sumažėjusia KS išstūmimo frakcija (< 50 proc.) [8]

KSIF – kairiojo skilvelio išstūmimo frakcija; TR $V_{\max}$ – triburio vožtuvo regurgitacijos maksimalus greitis; KPr – kairysis prieširdis; KSDD – kairiojo skilvelio diastolinė disfunkcija; KSDF – kairiojo skilvelio diastolinė funkcija; TSP – tarpkilvelinė pertvara.

Pastarojo dešimtmečio darbai rodo, kad pilnai automatizuoti giliojo mokymosi darbo srautai geba iš standartinių echokardiografijos projekcijų ir Doplerio bangų automatiškai išmatuoti esminius diastolinės funkcijos rodiklius (E ir A bangas, šoninės sienos ir pertvaros e' , E/e' santykį, KP tūrį, triburio vožtuvo regurgitacijos maksimalų greitį) ir remiantis gautais duomenimis suformuoti ataskaitą, kurioje DI algoritmų ir echokardiografijos eksperto matavimų nesutapimas yra ne didesnis, o daugeliu atvejų – mažesnis, nei tarp skirtingų ekspertų aukščiausio lygio centre [84]. Šioje studijoje, 23 echokardiografijos parametrų individualaus ekvivalentiškumo koeficiento (IEK) 95 proc. pasikliautinio intervalo (PI) viršutinė riba buvo $<0,25$ (iš anksto nustatytas sėkmės kriterijus) [84]. Tai rodo, kad automatizuoti matavimai yra pakankamai tikslūs, kad būtų naudojami vietoje žmogaus atliktų matavimų [84]. Tas pats giliojo mokymosi algoritmas daugiacentrinėje studijoje parodė DI diagnostinę vertę tiek KS sistolinei, tiek diastolinei funkcijai, o našumas siejosi su trumpesniu analizės laiku ir panašios kokybės rezultatais – labai svarbi savybė DI integravimui į kasdienę praktiką [6].

Vienas svarbiausių pastarųjų metų pokyčių – KP įtampos analizė. Anksčiau buvo vertinama pikinė KP įtampa, tačiau dabar naudojama visa fazinė KP įtampos kreivė. Remiantis šiuo principu, MM metodais sukurtas KP įtampos indeksas (KPI_i), kuris kurtas lyginant su invaziškai pamatuotu KS galiniu diastoliniu spaudimu ($KSGDS \geq 15$ mm Hg). Tyrimai parodė, kad KPI_i tiksliau nustato padidėjusį užpildymo spaudimą nei vien pikinė KP įtampa. Tai sumažino atvejų, kai diastolinės funkcijos vertinimas pagal standartinius kriterijus lieka neapibrėžtas, dalį [85]. Naujausi duomenys perspektyviai parodė, kad pilnai automatizuotas giliojo mokymosi modelis patikimai įvertina pagrindinius diastolinės funkcijos parametrus (E , A , E/A , e' , E/e' , KP tūrio indeksą), gerai sutampančius su echokardiografiniais eksperto matavimais, ir tiksliai atskiria normalias bei sunkias KS diastolinės funkcijos formas [86]. Tai dar labiau pagrindžia praktinį šių metodų potencialą [86]. Gruca ir kt. studijos komentaras pabrėžė, kad naudoti visą KP įtampos kreivę yra fiziologiškai prasmingiau nei tik vieną piko tašką. Tokiu būdu galima tiksliau atspindėti skilvelio atsipalaidavimą ir elastingumo sumažėjimą, todėl ši metodika patikimiau pakeičia invazinį $KSGDS$ matavimą [87]. Be to, daugėja multimodalinių DI sprendimų, kurie sujungia skirtingus tyrimų metodus. Viena didelio masto tyrime DI pagrindu sukurtas elektrokardiogramos (EKG) modelis patikimai nustatė padidėjusį KS prisipildymo slėgį (AUC 0,91) ir diastolinės funkcijos laipsnius. Pacientai, kuriems DI paremta EKG analizė prognozavo padidėjusį slėgį, turėjo didesnę mirtingumo riziką (HR 1,7). Tai rodo, kad tokie modeliai prognozuose vertė prilygsta širdies echoskopijai ir gali būti ypač naudingi tais atvejais, kai echokardiografijos vertinimas išlieka neapibrėžtas [88].

Atnaujintos 2025 m. Amerikos echokardiografijos draugijos gairės pateikia aiškesnį, keliais rodikliais pagrįstą diastolinės funkcijos nustatymo algoritmą. Jose pabrėžiama KP įtamos matavimų reikšmė ir pateikiamos išimtys specialioms populiacijoms. Gairėse taip pat apibrėžiamos DI taikymo sritys: akcentuojama automatizuotų matavimų atlikimo, disfunkcijos laipsnių nustatymo svarba ir raginama DI modelius tikrinti aukso standartu laikomais invaziniais hemodinaminiais tyrimais bei klinikinėmis baigtimis [83].

Tuo tarpu, DI modelis, kuris analizuoja vieną viršūninį keturių kamerų vaizdą, buvo patikrintas sudėtingose klinikinėse pacientų grupėse. Rezultatai parodė, kad įprastoje praktikoje jis padeda tiksliau nustatyti ŠNiIF ir prognozuoti svarbias baigtis (pvz., hospitalizacijas ar mirtingumą), lyginant su tradiciniais diagnostiniais metodais ir skaičiuoklėmis (pvz., H2FPEF ir HFA-PEFF) [89].

Kartu svarbi ir darbo eigos standartizacija: DI gali suvienodinti BIĮ ir KP įtamos analizę tarp skirtingų tyrėjų bei gamintojų, sutrumpinti vertinimo laiką ir pateikti papildomą informaciją apie matavimo patikimumą [90]. Tai ypač svarbu centrams atliekantiems echokardiografijas, kuriose diastolinės funkcijos interpretaciją gali iškreipti dideli skirtumai tarp skirtingų tyrėjų atliktų matavimų ar įvairių gamintojų įrangos gautų rezultatų [90]. DI taikymas, kaip rodo naujausi tyrimai, reikšmingai sumažina tiek tarp tyrėjų, tiek tarp skirtingų platformų variaciją, taip užtikrindamas deformacijos rodiklių rezultatų nuoseklumą ir pakartojamumą [90].

ŠN srityje bendrinė apžvalga parodė, kur DI jau yra naudingas – pavyzdžiui, fenotipavimui, ankstyvai diagnostikai ir rizikos nustatymui [91]. Tačiau ji taip pat pabrėžė, kad vis dar trūksta aiškaus reglamentavimo bei pakankamo išorinio validavimo, ir šios problemos tiesiogiai aktualios KS diastolinės funkcijos vertinimui [91, 92].

Apibendrinant, DI diastolinės KS funkcijos vertinime jau peržengė teorines ribas ir remiasi tvirtais įrodymais. Automatizuotos echokardiografijos analizės yra ne mažiau tikslios lyginant su atliktomis širdies echoskopijų eksperto. Pilna KPI analizė patikimiau atspindi KSGDS nei pavieniai rodikliai. DI pagrįstos EKG interpretacijos tam tikrais atvejais leidžia įvertinti KSGDS ir prognozę. Naujausios gairės pabrėžia atsakingą šių metodų taikymą bei būtinybę DI modelius tikrinti invaziniais hemodinaminiais tyrimais [83–85, 88]. Praktikoje DI diegimą turėtų lydėti nuolatinis kalibravimas, šališkumo kontrolė bei skaidrus duomenų ir rezultatų auditas. Tik tokiu būdu DI taps patikimu klinikinį sprendimų partneriu [71].

2.7. Dirbtinis intelektas vertinant aortos diametrus ir pokyčius

Automatizuotas aortos diametrų vertinimas 2D TTE pastaraisiais metais tapo viena aktyviausių DI taikymo sričių, nes aortos šaknies ir kylančiosios aortos matavimai yra kliniškai labai svarbūs, t. y. minimalios paklaidos gali keisti paciento stebėjimo ar intervencinio gydymo taktiką [93, 94]. Tačiau būtent šie matavimai pasižymi didele priklausomybe nuo širdies echoskopiją atliekančio gydytojo, jo patirties ir žymia variacija tarp skirtingų tyrėjų [93, 94]. Šiuolaikinės gairės pabrėžia būtinybę standartizuoti matavimus (pvz., kylančiosios aortos matavimas nuo artimosios sienelės išorinio krašto iki tolimosios sienelės vidinio krašto, angliškai vadinama „leading-edge to leading-edge“), tačiau kasdieninėje praktikoje nuokrypiai nuo protokolų ir vaizdo kokybės skirtumai išlieka pagrindine paklaidos priežastimi [22, 94]. Būtent šioje vietoje DI gali suteikti pridėtinę vertę [22, 94]. Esminis argumentas taikyti DI matuoti aortos dydžius – galimybė užtikrinti nuoseklų, atkuriamą ir greitą matavimą, nepriklausomai nuo individualaus echoskopuotojo patirties [95, 96]. Tokiu atveju sprendimų pagrindas yra segmentacijos, orientacinių taškų ir matavimo vietos automatiškas parinkimas [95, 96]. Naujausios daugiafunkcės DI sistemos, tokios kaip PanEcho, publikuota JAMA, ir atvirojo kodo EchoNet-Measurements, publikuota JACC (*Journal of the American College of Cardiology*), parodė, kad vienas pilno ciklo (angl. *end-to-end*) kelių užduočių giliojo mokymosi apdorojimo formatas gali atlikti daugelį užduočių: nuo projekcijų atpažinimo ir patologijų klasifikavimo iki linijinių anatominų matavimų [95, 96]. Šių modelių tikslumas ir patikimumas išlieka aukštas lyginant studijas, atliktas skirtinguose centruose ir skirtingais laikotarpiais [95, 96]. Specifiškai aortai atlikti naujausi klinikiniai darbai parodė, kad automatiniai 2D TTE matavimai yra įmanomi ir praktiškai pritaikomi, o ankstyvieji rezultatai rodo gerą sutapimą su ekspertų vertinimais ir net geresnį pakartojamumą [10, 97, 98]. 2025 m. JASE (*Journal of the American Society of Echocardiography*) publikacijoje pateikta trumpa ataskaita apie MM technologiją, automatizuojančią krūtininės aortos skersmens matavimus echokardiografijoje, kuri patvirtina, kad problema sprendžiama, tačiau dar būtinas platesnis prospektyvinis vertinimas [98]. Matavimo tikslumas reikšmingai priklauso nuo vaizdo kokybės ir naudojamo vaizdo lango. Pavyzdžiui, automatizuoto KS nutekamojo trakto skersmens (tiesiogiai susijusio su aortos šaknies anatomija ir aortos vožtuvo angos ploto skaičiavimu) matavimų palyginime vidutinė absoliuti paklaida siekė apie 1,0 mm, o pašalinus prastos kokybės vaizdus – ~0,87 mm. Taip pat pažymima, kad naudojant priartintą priekrūtinkaulinę ilgiosios ašies projekciją, matavimo paklaida sumažėjo. Šioje studijoje Bland–Altman sutarimo ribos buvo 2,8–2,9 mm, t. y. daugumos skirtumų tarp DI ir eksperto matavimų

dydžiai neviršijo 3 mm, o tai atitinka tipines klinikinės praktikos matavimo paklaidas [10]. Šie duomenys rodo, kad net ir palyginti nedidelėmis intimis apmokyti giliojo mokymosi modeliai geba tiksliai identifikuoti matavimo vietą ir dviejų taškų geometriją, o tai yra būtina norint patikimai sekti net minimalius diametro pokyčius stebėjimo etape [10].

Kitas svarbus aspektas – vaizdų dalinimasis tarp skirtingų centrų ir generalizacija tarp skirtingų gamintojų sistemų, nes aortos ligų stebėjimas dažnai vyksta skirtinguose padaliniuose, naudojant skirtingų gamintojų echoskopus ir programinę įrangą [93, 95, 96]. PanEcho atliko plačią išorinę keturių nepriklausomų kohortų validaciją ir parodė, kad regresinės užduotys, t. y. parametrų įvertinimas, išlaiko žemą normalizuotą vidutinę absoliučiąją paklaidą. Tuo pat metu klasifikacijos užduotims (pvz., didelio laipsnio aortos vožtuvo stenozės atpažinimas) pasiektos labai aukštos AUC reikšmės, o tai netiesiogiai patvirtina ir visos matavimų apdorojimo sekos patikimumą [96]. EchoNet-Measurements JACC darbe pademonstruota gera modelio generalizacija tarp skirtingų institucijų ir laikotarpių, o aprašytas atvirojo kodo gilaus mokymosi semantinės segmentacijos modelis palengvina metodikos standartizavimą ir nepriklausomą patikrą [95]. Ilgalaikio sekimo klausimas (pvz., ar DI patikimai aptinka ≥ 2 –3 mm metinį aortos plėtimąsi ir kada tas pokytis tampa kliniškai svarbus) dar nėra standartizuotai vertinamas [93–96]. Skirtinguose centruose nusistovėjusios skirtingos matavimų tvarkos – vienur taikomas „leading-edge“ (artimojo krašto išorė iki tolumojo krašto vidaus), kitur „inner-edge“ (vidinis kraštas–vidinis kraštas). Dėl šių skirtumų gali atsirasti sistemingas kelių milimetrų poslinkis, kuris klaidingai atrodytų kaip aortos patologijos progresavimas [22, 94]. Šią metodinę riziką privalu panaikinti prieš diegiant DI sekimo algoritmus į klinikinę praktiką [93, 94]. Nors Amerikos echokardiografijos draugija ir Europos širdies vaizdinių tyrimų asociacija rekomenduoja aortos žiedą matuoti „inner-edge“ stiliumi sistolės viduryje, o ančius, sinotubulinę jungtį ir proksimalinę kylančiosios aortos dalį „leading-edge“ stiliumi diastolės pabaigoje, tačiau studijos dar pabrėžia šių metodų išsiskyrimą skirtinguose centruose.

Studijos, kuriose tiesiogiai lyginami DI ir ekspertų matavimai tarp skirtingų centrų, šiuo metu dažniau atliekamos platesnio spektro echokardiografinių užduočių kontekste, tačiau jų išvados taikytinos ir aortos matavimams [95, 96]. PanEcho daugiacentrėje analizėje normalizuotos vidutinės absoliučios paklaidos medianos buvo nedidelės, o modelio diagnostinė geba išliko aukšta jį vertinant ir skubių ar sutrumpinto protokolo širdies echoskopijų (pvz., FoCUS) atvejais, kas neabejotinai turi svarbią reikšmę aortos diametrų sekimui regioniniuose centruose [96]. Analogiškai, EchoNet-Measurements pateikė pilno ciklo apdorojimo sekos (nuo segmentacijos iki automatinio ataskaitų generavimo) validaciją. Tai leidžia manyti, kad ir aortos skersmenys

galės būti pateikiami kaip patikima standartinės ataskaitos dalis be papildomo žmogaus įsikišimo [95]. Kalbant apie diagnostinę sąsają su aortos vožtuvo (AoV) patologija, automatizuoti skersmens matavimai yra tik vienas komponentas – aortos stenozei sunkumo klasė priklauso ir nuo Doplerio parametrų bei tėkmės modelio (pvz., mažos tėkmės ir mažo gradiento aortos vožtuvo stenozė). Įrankiai 2023 m. aprašyti Amerikos echokardiografijos asociacijos žurnale (JASE) jau demonstruoja visiškai automatinę tėkmės per AoV ir kitų su aorta susijusių parametrų apskaičiavimą, todėl mažėja variacija tarp dviejų skirtingu laiku ir skirtingais echoskopijos aparatais atliktų to paties paciento tyrimų [99]. Tai svarbu, nes čia galioja sena Einšteino taisyklė „garbage-in, garbage-out“ (t. y., jei įvedami klaidingi matmenys, klaidingas bus ir rezultatas). Šiuo atveju jei KS nutekamojo trakto skersmuo bus išmatuotas ir įvestas mažesnis nei iš tikrųjų yra, tai AoV angos plotas bus klaidingai mažas, o stenozė – pervertinta. Todėl DI sprendimai tiek geometrijoje, tiek hemodinamikoje turi būti validuoti bendrai [10, 94, 99].

Vis dėlto, vaizdo kokybė išlieka svarbiu ribojančiu veiksniu, ypač turint omenyje stambesnio kūno sudėjimo pacientus, plaučių hiperinfliaciją sergant plaučių ligomis (pvz., lėtinė obstrukcinė plaučių liga) ar ribotą akustinį langą dėl krūtinės ląstos deformacijų, pooperacinių randų, krūtų implantų ir pan. Tačiau čia taip pat padeda DI – jis realiu laiku įvertina projekcijos teisingumą ir vaizdo kokybę, pateikia konkrečias nuorodas kaip pakoreguoti daviklio padėtį ir kitus echoskopo parametrus, bei automatiškai atmeta prastos kokybės vaizdus, taip sumažindamas netinkamų vaizdų kiekį [96]. Studijoje, kurioje DI automatiškai matavo KS nutekamojo trakto skersmenį, kokybės filtravimas savaime sumažino vidutinę absoliučiąją paklaidą nuo ~1,04 iki ~0,87 mm, o tai yra svarbus žingsnis, kurio reikia tiksliam ilgalaikių pokyčių fiksavimui [10]. Tačiau būtina suplanuoti tyrimus, kurie modeliuoja mažo signalo ir triukšmo santykio (SNR) scenarijus (nutukimas, emfizema, pooperacinės būklės ir pan.) ir vertina, kiek naudos gali duoti integruoti kokybės tikrinimo moduliai ar echoskopiją atliekančiam nurodomos realaus laiko gairės [93, 96]. Svarbu atskirti atsitiktines matavimo klaidas nuo sisteminių, kurios gali atsirasti dėl mokymo duomenų sudėties (vienas centras, vienas gamintojas, panaši populiacija) ar dėl anotavimo taisyklių. Vėlgi, šie klausimai ypač aktualūs aortos diametrų atveju, kur kelių milimetrų poslinkis gali pakeisti klinikinę taktiką [94, 95, 97]. Naujose publikacijose rekomenduojama prie duomenų pateikti ne tik koreliacijas, bet ir Bland–Altman ribas, sisteminių poslinkių, bei suprasti, ar DI klaida yra sistemiška per visą aortos skersmens spektrą (pvz., DI linkęs pervertinti didelius diametrus ir nuvertinti mažus) [10, 95]. Nors skaičius DI įrankių echokardiografijoje sparčiai auga, tačiau reglamentavimo ir įdiegimo požiūriu gairės išlieka konservatyvios [93, 94]. Jos nurodo, ką ir kaip matuoti, tačiau nenurodo, kuo galima „pasitikėti“

automatizuoto vertinimo atvejais. Todėl vis dar trūksta daugiacentrinių, perspektyvinių tyrimų su iš anksto apibrėžtu ne prastesnio veiksmingumo (*non-inferiority*) formatu [93, 94].

Apibendrinant, 2025 metais DI aortos matavimuose jau leidžia:

- Automatiškai ir atkartojamai matuoti aortos šaknį bei proksimalinę kylančiąją aortą priekrūtinkauliniame ilgosios ašies vaizde;
- Sumažinti tarp matuotojų variaciją ir pagreitinti darbą;
- Išlaikyti našumą tarp centrų ir skirtingų protokolų, kai modeliai mokomi daugiamodaliai ir daugiašalėse kohortose.

Didžiausi likę iššūkiai:


- Sisteminio šališkumo valdymas (matavimų metodikos suvienodinimas, anotavimo kokybė);
- Žemos kokybės vaizdų scenarijų kontrolė;
- Prospektyvūs tyrimai, kurie nurodytų klinikinės baigtis (pvz., tikslus aortos aneurizmos plėtimosi nustatymas ir savalaikis sprendimas dėl intervencijos) [93–96].

2.8. Dirbtinis intelektas krūvio echokardiografijoje.

KE išlieka universali funkcinė IŠL diagnostikos ir rizikos vertinimo priemonė. Tačiau šio tyrimo interpretacija labai priklauso nuo tyrėjo patirties ir vaizdo kokybės, o tai lemia variaciją tarp skirtingų echoskopijos specialistų bei skirtingą diagnostinį tikslumą tarp centrų [36, 44]. 2016 metais siekiant formuoti naują KE standartą buvo pradėtas Stress Echo 2020 tyrimas, kuris vėliau tęstas kaip Stress Echo 2030 (SE2030). Bendrai šie tyrimai yra tarptautinė, daugiacentrė KE programa, kuri įtvirtino ABCDE protokolą kaip plataus pritaikomumo, standartizuotą funkcinį testą, kuris taikomas skirtingoms krūvį sukeliamoms formoms ir klinikinėms situacijoms, neapsiribojant tik vainikinių arterijų liga (2.8.1 pav.) [44]. SE2030 numatyta kaip >10000 pacientų prospektyvinė kohorta iš ≥ 50 centrų ir ≥ 20 šalių, su vienodais indikacijų, atlikimo, ataskaitų ir archyvavimo kriterijais, kad rezultatus būtų galima lyginti tarp skirtingų echoskopijos aparatų ir centrų [100]. SE2030 koncepcija perkelia KE nuo vien regioninių sienelės judesių įvertinimo prie standartizuoto ABCDE protokolo:

- A – regioninių sienelės judesių įvertinimas (RSJJ). Krūvio metu atsirandanti ar progresuojanti regioninė hipokinezija, akinezija ar diskinezija yra pagrindinis epikardinių vainikinių arterijų nepakankamumo ženklas [38].

- B – plaučių ultragarsas vertinant B linijų dinamiką krūvio metu, kaip intersticinės plaučių edemos/diastolinio rezervo nepakankamumo ženklą [44, 101].
- C – KS kontraktinis rezervas, esant krūviui. Vertinami KS galinio sistolinio ir diastolinio tūrio santykiai ramybės, maksimalaus krūvio ir atsistatymo metu [38, 44].
- D – vainikinių širdies kraujagyslių mikrocirkuliacijos rezervas. Vertinamas tėkmės greičio rezervas vidurinėje-distalinėje priekinės tarpskilvelinės šakos dalyje. Taip papildoma A dalies informacija [38, 102].
- E – chronotropinis rezervas. Adekvatus širdies susitraukimo dažnio padidėjimas krūvio metu atspindi autonominį atsaką į krūvį, sinuozinio mazgo būklę ir vaistų įtaką [38, 44].



2.8.1 pav. ABCDE krūvio echokardiografijos protokolą pagal SE2030 [44]

UG – ultragarsas; KS – kairysis skilvelis; sAKS – sistolinis arterinis kraujo spaudimas; GST – galinis sistolinis tūris; KSKR – kairiojo skilvelio kontraktinis rezervas; VA – vainikinės arterijos; VATGR – vainikinių arterijų tėkmės greičio rezervas; ŠSD – širdies susitraukimų dažnis; max ŠSD – maksimalus širdies susitraukimų dažnis.

Šis protokolą integruoja hemodinaminį vertinimą, plaučių ultragarsą ir miokardo deformaciją, todėl tinka DI moduliui automatizuoti atskirus žingsnius [44]. Naujausios Europos širdies vaizdinių tyrimų asociacijos ir Amerikos echokardiografijos draugijos rekomendacijos ir 2023–2024 m. klinikinio taikymo dokumentai pabrėžia standartizacijos svarbą ir poreikį mažinti subjektyvumą, kas atitinka ir DI tikslų kryptis [36, 38]. Šiame

kontekste DI kuriami moduliai taikomi vaizdų kokybės kontrolei, automatinei vaizdų atrankai, segmentacijai, taip siekiant suvienodinti skirtingų centrų ir echoskopijos aparatų KE rezultatų vertinimą [103, 104]. Standartizuojant protokolus ir daugėjant kiekybinių rodiklių, DI tampa natūralia sąsaja tarp vaizdo gavimo, analizės ir klinikinių sprendimų, o tai labai svarbu DI pritaikymui klinikinėje praktikoje [38, 44].

PROTEUS buvo pirmoji didelė prospektyvinė, daugiafunkcinė ir daugiacentrinė atsitiktinių imčių kontroliuojama studija, tiesiogiai vertinusi DI pritaikymą KE klinikiniam darbe, kurios protokolas 2023 m. publikuotas *American Heart Journal* [105]. PROTEUS (įtraukti 20 Jungtinės Karalystės centrai) tikrino ar taikant DI kartu su įprasta priežiūra galima ne prasčiau nei įprastai atrinkti pacientus, kurių KE patloginė ir reikalinga tolimesnė invazinė diagnostika ir atitinkamas gydymas [105]. Protokole galutinis baigties rodiklis apibrėžtas paprastai – ar sprendimas dėl tolesnės invazinės diagnostikos buvo teisingas realioje klinikinėje praktikoje [105]. Tuo pat metu Mahdavi ir kt. pristatė nepriklausomą EASE programą, kuri lygina DI sugeneruotas KE ataskaitas su trijų ekspertų vertinimu ir papildomai nagrinėjo diegimo barjerus, naudotojų patirtį bei sveikatos ekonomikos aspektus [106]. Tokie prospektyvūs projektai atitinka didžiausią klinikinį poreikį – ne tik teorinį algoritmo tikslumą bandymuose, bet ir praktinį naudingumą, kai DI dirba su skirtingos kokybės vaizdais, skirtingais protokolais ir įvairių gamintojų echoskopijos aparatais [105, 106]. Tokios krypties tyrimai sudaro pagrindą sistemingai įvertinti, ar DI sumažina sprendimų variaciją tarp mažesnę patirtį turinčių ir ekspertinių centrų [105, 106].

Nors būtent KE vaizdais mokytų algoritmų patirtis dar tik bręsta, yra aukštos kokybės studijų, kurios tiesiogiai lygina DI ir ekspertų gebėjimą atpažinti RSJĮ [107]. 2024 m. JASE publikacijoje Slivnick ir kt. parodė, kad GNT, dirbančiam su tiesioginiu echokardiografijos vaizdu, RSJĮ atpažinimo tikslumas buvo ne prastesnis už patyrusių kardiologų, pabrėžiant potencialą sumažinti subjektyvumą [107]. Būtent šio darbo redakcinis komentaras akcentavo, kad svarbiausi iššūkiai yra vaizdo kokybė, kontrolinių kokybės žingsnių įdiegimas ir aiškus algoritmų veikimo ribų deklaravimas prieš perkeliant į klinikinę KE aplinką [108]. Klinikiniu požiūriu tai rodo, kad RSJĮ automatizavimas įmanomas ir gali būti naudojamas KE protokoluose, kur regioninių sienelės judesių sutrikimai tampa ryškesni, bet tuo pačiu ir jautresni artefaktams bei greitiems geometrijos pokyčiams [107, 108]. Taigi, net jei duomenų bazė formaliai sudaryta ramybės echokardiografijai, technologinis principas – automatinė regioninių judesių analizė – yra tiesiogiai pritaikomas KE [107, 108].

Tarpcentrinis ir skirtingų ultragarso gamintojų duomenų atkartojamumas yra vienas esminių DI diegimo kriterijų ir KE, nes klinikinėje praktikoje

naudojami skirtingi aparatai ir programinių įrangų versijos [38]. *European Heart Journal Digital Health* išorinio validavimo darbai ir klinikinės apžvalgos pabrėžia, kad DI modelių generalizaciją stiprina plataus spektro (tarpcentriniai, skirtingų gamintojų) mokymo duomenys ir standartizuoti kokybės kontrolės kriterijai, o tai tiesiogiai atitinka KE poreikius [82, 103, 104]. SE2030 tinklas (≥ 50 centrų, ≥ 20 šalių) suvienodino efektyvumo įrodymus ir pateko į 2024 m. Europos širdies vaizdinių tyrimų asociacijos klinikinį susitarimą, sudarydamas diegimo platformą, kur DI gali būti vertinamas pagal realaus pasaulio standartus [38, 44, 109]. 2023 m. dokumentuose aiškiai įvardyta, kad įprastinės klinikinės įvairovės (skirtingų centrų, aparatų ir vaizdo kokybės) įtraukimas į analizę tampa norma, todėl DI kokybės kontrolė ir tarpcentrinė validacija yra būtinybė, o ne priedas [44]. Taip pat 2024 m. EKD gairės apie lėtinius vainikinių kraujagyslių sindromus nurodo svarbų KE vaidmenį ir skatina skaitmeninę standartizaciją, prie kurios DI prisideda automatinio segmentavimo ir kiekybiniais rodikliais [38].

Vėlgi, vaizdo kokybė išlieka vienas iš kertinių momentų algoritmui, todėl būtina integruota kokybės kontrolė ir vaizdo gerinimo strategijos [108]. 2024 m. JASE redakcinė apžvalga pabrėžė, kad DI RSJĮ našumas labai priklauso nuo pakankamos endokardo vizualizacijos, o klaidos dažniau kyla periferiniuose, sunkiai išvedamuose segmentuose ir skubaus darbo sąlygomis [108]. 2025 m. apžvalgos apie kontrastines ultragarso medžiagas KE primena, kad kontrastas pagerina endokardo ribų apibrėžimą ir padidina regioninių sienelės judesių sutrikimų aptikimą. Tai turėtų gerinti ir DI segmentacijos bei RSJĮ klasifikatorių stabilumą, nors tiesioginių perspektyvių DI KE su kontrastu studijų dar trūksta [110]. 2025 m. metodologinės apžvalgos DI echokardiografijoje rekomenduoja diegti automatinę vaizdo kokybės patikrą, kad būtų atranką ir žemo patikimumo išspėjimus, kad būtų išvengta klaidingo pasitikėjimo algoritmu prastos kokybės sąlygomis [103, 104]. Todėl atrodo, kad geras praktinis žingsnis atliekant KE būtų standartiškai naudoti kontrastą, ypač kai planuojama automatizuota analizė, ir įdiegti standartizuotus kokybės kontrolės kriterijus, kurie blokuotų nepatikimas ataskaitas ar reikalautų žmogaus peržiūros [103, 110].

Svarbi paralelė – gairės ir klinikinė kultūra [36, 38]. EKD ir Amerikos echokardiografijos draugijos dokumentai aprašo tai, kokia metodika DI turi vadovautis KE metu – nuoseklus vaizdų protokolai, laiku pasiektas ir užfiksuotas širdies susitraukimų dažnis, vienodas krūvio sukėlėjas ir tinkamas dobutamino titravimas su aiškiais nutraukimo kriterijais [36, 38]. DI įrankiai turi būti prijungti ne tik retrospektyviai prie archyvinių vaizdų, bet ir realaus laiko darbo eigos, kur jie gali būti labai naudingi atpažįstant netinkamai išvestas projekcijas ir pasiūlant pakartotinį vaizdų išvedimą siekiant geresnės kokybės [103, 104]. 2025 m. JACC pristatyti atviro kodo segmentacijos

modeliai (automatiniai KS tūriai, KSIF ir pagrindiniai matmenys) sudaro pagrindą nuo tiekėjo nepriklausomai (angl. *vendor-agnostic*) modulinei integracijai ir palengvina tarpcentrinę validaciją, o tai ypač svarbu KE, kur krūvio metu keičiasi akustiniai langai ir vaizdas yra dinamiškas [95]. Tai atveria kelią aparatuose integruoti DI paketus, kurie automatiškai po vaizdo įrašymo paskaičiuoja pagrindinius kiekybinius rodiklius (RSJ, BI, B linijų skaičių ir pan.) ir parodo kokybės įspėjimus (pvz., žemas patikimumas) ir tai fiksuojama klinikiniam protokole [95, 103].

2025 m. publikuoti duomenys leidžia aiškiau matyti tolimesnius DI plėtros ir tyrimų žingsnius:

1. Akcentuojami „foundation“ modeliai (tai dideli, iš anksto plačiai išmokyti DI modeliai, kurie adaptuojami konkrečioms užduotims) ir vaizdo architektūros, integruojančios kelis pjūvius ir laiko seką kartu su klinikiniais duomenimis. Viso to reikia KE, nes sprendimai priimami greitai ir pagal kelių projekcijų informaciją [103, 104].
2. Išorinės validacijos su griežtai nustatytais klinikinėmis baigtimis. 2025 m. *Nature Communications* publikacija parodė, kad pilnai automatinis echokardiogramų GNT modelis ŠNiIF atpažinimui ne tik prilygsta daugiaparametriniams klinikiniais balams, bet ir mažina neapibrėžtų atvejų dalį, kas rodo brandesnę DI integraciją į sprendimų grandinę [89]. Ateityje analogiškas kelias laukia ir KE [89].
3. Bibliometrinės ir metodinės 2025 m. apžvalgos aiškiai rekomenduoja naudoti keliose ligoninėse, su skirtingų gamintojų aparatais surinktus duomenis, kartu kuriant standartizuotą atviro kodo įrankių sistemą, kad būtų užtikrintas praktinis rezultatų perkeliamumas tarp aparatų ir centrų [103, 104].
4. Pabrėžiamas DI potencialas atrankai ir greitam funkcijos įvertinimui mažiau patyrusių tyrėjų rankose. Tai yra ypač svarbu KE laboratorijose kas gali sąlygoti trumpesnį tyrimo laiką ir ankstesnį invazinių sprendimų priėmimą [103].

Apibendrinant, DI KE jau pereina nuo metodo demonstravimo prie organizuoto perspektyvinio, daugiacentrio pritaikymo, kuris orientuotas į kliniskus sprendimus, variacijos mažinimą ir ekonominį efektyvumą [105, 106]. RSJ automatizavimas pasiekė ekspertinį lygį kontroliuojamose sąlygose, o tai atitinka tikruosius KE poreikius [81, 82, 103, 107]. 2025 m. apžvalgose ir tarptautinėse programose nurodoma kryptis yra „foundation“ klasės modeliai [95, 103, 104, 109]. Artimiausias prioritetas – realaus laiko DI pritaikymas KE darbo eigoje, kur DI padeda ne tik po atliktos echokardioskopijos, bet ir suteikia pagalbą gauti geresnę vaizdų kokybę, laikytis protokolo ir pateikti patikimus rezultatus [95, 103].

3. DARBO METODIKA

3.1. Bendrieji tyrimo etapai ir kriterijai

Tyrimas atliktas 3 etapais:

1. Pirmojo etapo metu pacientai įtraukti į tyrimą ir jiems atliekamas įprastas kardiologinis ištyrimas (klinikinis paciento vertinimas, laboratoriniai tyrimai, vaizdiniai tyrimai – 2D TTE tyrimas bei, esant indikacijoms, krūvio echokardiografinis, DKT VAA arba ŠMR). Visi pacientai, susipažinę su tyrimu, pasirašė informuoto asmens sutikimą.
2. Antrojo etapo metu gauti pacientų 2D TTE ramybės ir krūvio vaizdai buvo analizuojami pasitelkiant MM ir GNT ((taikomi konvoliuciniai tinklai (KNT) bei skirtingos jų architektūros (YOLO, ResNet, U-Net) ir transformerio tinklai (TransFuse)). Neuroninių tinklų architektūrų sluoksnių skaičius varijavo nuo 335 iki 1054. Vaizdo kokybės vertinimui buvo sukurtas dublikuotas duomenų rinkinys.
3. Trečiojo etapo metu buvo atliekama duomenų analizė. Gauti vaizdinių tyrimų duomenys buvo analizuojami ir įvertinamas GNT pritaikomumas ir tikslumas aortos, KS ir KP tūrių, ŠN parametrų apskaičiuoti ir nustatyti echokardiografinę ŠN diagnozę. Neuroninių tinklų rezultatai palyginti su gydytojų kardiologų atliktais vertinimais.

Bendrasis tiriamųjų įtraukimo į biomedicininį tyrimą kriterijus:

1. Suaugę (18 metų ir vyresni) vyrai ir moterys, kuriems dėl įvairių indikacijų planuojamas atlikti transtorakalinės 2D TTE. Tiriamųjų atrankos laikotarpis: 2021.09–2024.09.

Bendrieji neįtraukimo į biomedicininį tyrimą kriterijai:

1. Anatominės ir funkcinės širdies charakteristikos, kurios trukdytų automatizuotai širdies echoskopijos vaizdų analizei naudojant GNT.
2. Nustatyta hemodinamiškai reikšminga įgimta širdies yda ar jau buvusi atlikta chirurginė širdies ydos korekcija.
3. Implantuoti širdies prietaisai: bet kokio tipo elektrokardiostimuliatorius, kardioverteris-defibriliatorius, resinchronizatorius.
4. Prieširdžių virpėjimas ar plazdėjimas širdies echoskopijos tyrimo metu.

3.2. Aortos ir kairiojo skilvelio diastolinių parametru vertinimo metodika

3.2.1. Tiriamųjų kontingentas

Šiame prospektyviniame tyrime dalyvavo 302 pacientai, kuriems buvo registruoti 4120 dvimačiai echokardiografiniai vaizdai. Įtraukti pacientai buvo tirti Lietuvos sveikatos mokslų universiteto ligoninės Kauno klinikose (Kauno klinikose) ir jiems buvo atliktas 2D TTE tyrimas nuo 2021 m. spalio 1 d. iki 2024 m. liepos 10 d. Šį tyrimą patvirtino Lietuvos bioetikos komitetas (Nr. L-21-09/1).

Įtraukimo kriterijai:

1. Suaugę pacientai (> 18 metų), kuriems tyrimo metu buvo sinusinis ritmas ir kurie nurodė dusulį.

Neįtraukimo kriterijai:

1. Pacientai, kuriems tyrimo metu buvo sumažėjusi KS IF (< 50 proc.).
2. Prieširdžių virpėjimas arba prieširdžių plazdėjimas.
3. Hemodinamiškai reikšmingos struktūrinės širdies ligos.
4. Implantuoti širdies prietaisai.


3.2.2. Dvimatė echokardiografija ir automatinė analizė

Echokardiografiniai tyrimai atlikti naudojant „GE Vivid E9“, „Philips Affiniti 70“ ir „Philips EPIQ 7“ ultragarso sistemas. Tyrimai buvo anonimiizuoti ir perkelti iš ligoninės vaizdų archyvavimo ir saugojimo sistemos (PACS) DICOM formatu į „Ligence Heart“ serverį per saugų vietinį tinklą. Kiekvienas tyrimas buvo analizuojamas rankiniu būdu ir automatiškai. Automatiniai matavimai buvo atlikti naudojant visiškai automatizuotą „Ligence Heart“ programinę įrangą (3.32.0 versija; UAB „Ligence“). Programinė įranga atkartojo procesus ir žingsnius, kuriuos paprastai atlieka gydytojas kardiologas: vaizdų identifikavimą, širdies ciklą nustatymą, kadru pasirinkimą, aortos (sistolės viduryje – aortos žiedas, diastolės pabaigoje – ančiai, sinotubulinė jungtis, kylančioji aorta) ir kairiojo skilvelio diastolinės funkcijos vertinimo parametru matavimą (3.2.2.1 lentelė). Širdies ciklas buvo nustatomas pagal kairiojo skilvelio dydį, matavimai atliekami naudojant segmentavimo algoritmus ir orientyrų aptikimą. Analizuodami DICOM vaizdo failus ir jų duomenis, KNT ir transformerio neuroniniai tinklai klasifikuoja širdies vaizdo plokštumą, atpažįsta širdies ciklo fazę ir pasirenka tinkamą kadrą analizei. Galiausiai mišri neuroninių tinklų kombinacija atlieka segmentavimą ir orientyrų aptikimą, kad sukurtų anotacijas, kurios naudojamos reikiamiems matavimams apskaičiuoti. Rankinius matavimus atliko kardiologas ekspertas.

3.2.2.1 lentelė. KS diastolinės funkcijos vertinimo kategorijos ir parametrai


Matavimai	Parametrai
Pulsinės bangos Dopleriu užfiksuotas kraujo tekėjimas per mitralinį vožtuvą	Ankstyvo diastolinio prisipildymo bangos greitis (E)
	Vėlyvo diastolinio prisipildymo bangos greitis (A)
	Ankstyvojo ir vėlyvojo diastolinio prisipildymo bangos greičių santykis (E/A)
	Ankstyvosios diastolinės prisipildymo bangos greičio lėtėjimo laikas
Pulsinės bangos Dopleriu užfiksuotas kraujo tekėjimas per triburį vožtuvą	Didžiausias triburio regurgitacijos greitis
Mitralinio žiedo judėjimo greitis, užfiksuotas pulsiniu audinių Dopleriu	Didžiausias ankstyvojo mitralinio žiedo šoninio segmento judėjimo greitis (Le')
	Didžiausias ankstyvojo mitralinio žiedo pertvaros segmento judėjimo greitis (Se')
	Ankstyvosios diastolinės prisipildymo bangos ir maksimalaus ankstyvojo mitralinio žiedo judėjimo greičio santykis (E/e')
Viršūninis keturių kamerų vaizdas	Kairiojo prieširdžio galinis sistolinis tūris
	Kairiojo prieširdžio galinis sistolinis plotas
	Kairiojo prieširdžio tūrio indeksas (KPTi)
Viršūninis dviejų kamerų vaizdas	Kairiojo prieširdžio galinis sistolinis tūris
	Kairiojo prieširdžio galinis sistolinis plotas
	Kairiojo prieširdžio tūrio indeksas (KPTi)

Diastolinės funkcijos vertinimas buvo atliktas remiantis 2016 m. Amerikos echokardiografijos draugijos/Europos širdies vaizdinių tyrimų asociacijos rekomendacijose apibrėžtomis algoritminėmis taisyklėmis, taikant atitinkamą parametų derinį, kaip nurodyta gairėse [8]. DI modelis veikė tik su vaizdo duomenimis ir nebuvo susijęs nei su rankiniais matavimais, nei su bet koku klinikiu kontekstu. Svarbu tai, kad DI ir rankiniai vertinimai buvo atliekami nepriklausomai. Spektrinio Doplerio vaizdai buvo vieno kadro, todėl DI turėjo atpažinti vaizdo tipą ir atlikti reikiamus matavimus. Dvimačiai echokardiografiniai vaizdai buvo sudaryti iš daugiau nei vieno kadro, todėl DI turėjo atlikti papildomą užduotį, kad nustatytų teisingą širdies ciklą. 3.2.2.1 pav. pavaizduoti rankiniai ir automatiniai KSDF parametų matavimai, 3.2.2.2 pav. – rankiniai ir automatiniai aortos matavimai.



3.2.2.1 pav. Automatiniai (kairėje) ir rankiniai (dešinėje) KSFDF parametrų matavimai

(A) Ankstyvasis diastolinis prisipildymo bangos greitis (E) ir vėlyvasis diastolinis prisipildymo bangos greitis (A); (B) didžiausias ankstyvojo mitralinio žiedo šoninio segmento judėjimo greitis (Le'); (C) kairiojo prieširdžio tūris (KPT); (D) didžiausias triburio vožtuvo regurgitacijos greitis.



3.2.2.2 pav. Automatinis (kairėje) ir rankinis (dešinėje) aortos matavimų įvertinimas, kurį atliko kardiologas ekspertas

(A) Aortos žiedo (AoŽ) matavimai sistolės viduryje; (B) Aortos ančių (AoS) ir sinotubulinės jungties (STJ) matavimai diastolės pabaigoje; (C) Proksimalinės kylančiosios aortos (KAo) matavimai diastolės pabaigoje.

3.2.3. Statistinė analizė

DI modelio (kombinuojant skirtingas architektūras: YOLO, ResNet, M-RCNN, TransFuse) tikslumas buvo įvertintas lyginant automatinius ir rankinius echokardiografinių parametru, naudojamų aortos ir diastolinės funkcijos vertinimui, matavimus. Naudoti statistiniai parametrai:

- Diagnostinė geba (angl. *yield*) atspindi procentinę atvejų dalį, kai DI tiksliai ir tinkamai atliko matavimą, kurį atliko ir kardiologas.

- Vidutinė kvadratinė paklaida (VKP) (angl. *root mean square error* (RMSE)) yra vidutinis skirtumas tarp DI ir rankiniu būdu nustatytų verčių. Ji apskaičiuojama traukiant kvadratinę šaknį iš prognozuotų ir faktinių verčių kvadratinių skirtumų vidurkio. Mažesnė VKP vertė rodo geresnį modelio atitikimą duomenims.
- Šališkumo vertinimas (ŠV) (angl. *bias*) rodo tendenciją pervertinti arba nepakankamai įvertinti rezultatus. Jis apskaičiuojamas vidurkinant skirtumus tarp kiekvienos prognozuojamos vertės ir atitinkamos faktinės vertės. Teigiama vertė (nuokrypis) rodo, kad DI linkęs pervertinti, o neigiama – nepakankamai įvertinti.
- Suderinamumo ribos (SR) (angl. *limits of agreement* (LoA)) apibūdina tipinę variacijos diapazoną tarp rankinių ir automatinų matavimų (formulė: $\text{ŠV} \pm 1,96 \times \text{standartinis nuokrypis}$).
- Pirono (angl. *Pearson*) koreliacijos koeficientas (r) buvo naudojamas linijinio sutarimo stiprumui įvertinti. Silpnas koreliacinis ryšys nustatytas, kai $r < 0,3$, vidutinis – kai $0,3 \leq r \leq 0,7$, stiprus – kai $r > 0,7$.

Šie rodikliai atspindi DI modelio tikslumą ir klinikinį patikimumą. p reikšmė $< 0,05$ laikyta statistiškai reikšminga. Statistika atlikta naudojantis Python programine įranga (versija 3.10).

Klasifikuojant kairiojo skilvelio diastolinę disfunkciją (KSDD) ir vertinant DI modelius naudoti statistiniai metodai:

- preciziškumas (angl. *precise*), kuris apskaičiuotas pagal formulę: $\text{tikras teigiamas rezultatas} / (\text{tikras teigiamas} + \text{netikras teigiamas})$;
- tikslumas (angl. *accuracy*), kuris apskaičiuotas pagal formulę: $\text{tikras teigiamas rezultatas} / (\text{tikras teigiamas} + \text{netikras teigiamas} + \text{netikras neigiamas})$;
- tikrasis neigiamų rezultatų dažnumas (TNRD) (angl. *true negative rate* (TNR)), kuris atspindi DI patikimumą teisingai identifikuojant sveikus asmenis;
- atitikties rodiklis (AR) (angl. *recall*) – parodo kiek iš visų tai kategorijai priklausančių pavyzdžių buvo atpažinti kaip tai kategorijai priklausančys;
- F1 balas – atitikties rodiklio ir preciziškumo išvestinis matmuo, parodantis balansą tarp jų.

3.3. Kairiojo skilvelio ir prieširdžio parametrų vertinimo ramybės ir krūvio echokardiografijos metu metodika

3.3.1. Tiriamųjų kontingentas

Šią tyrimo dalį sudarė daugiacentrė kohorta, kurioje įtraukti penki akredituoti pasaulio centrai (3 Italijos, 1 Argentinos, 1 Lenkijos), kurie dalyvavo ir SE2030 tyrime. Šioje tyrimo dalyje dalyvavo 240 dalyvių, kuriems nuo 2023 m. lapkričio 1 d. iki 2024 m. birželio 21 d. buvo atlikti farmakologiniai KE tyrimai. Tyrimo trukmė nurodo bendrą daugiacentrio tyrimo laikotarpį. Kiekviename dalyvaujančiame centre įtraukimas buvo apribotas iš anksto nustatytais laikotarpiais (iki 1 mėnesio vienam centrui). Pacientai buvo įtraukti į kiekvieną centrą pagal SE2030 įtraukimo protokolą [44]. Įtraukti pacientai, vyresni nei 18 m., kuriems buvo klinikinių indikacijų farmakologiniam KE, siekiant įvertinti išprovokuojamą išemiją, esant žinomai arba įtariamai išeminei širdies ligai. Atmetimo kriterijai:

1. Pacientai, kuriems buvo labai bloga ultragarsinio vaizdo kokybė ramybėje.
2. Kliniškai reikšminga vožtuvų ar įgimta širdies liga.
3. Prieširdžių virpėjimas arba prieširdžių plazdėjimas.
4. Implantuoti širdies prietaisai.
5. Prognoziškai reikšmingos ne širdies ligos, tokios kaip išplitęs vėžys, galutinės stadijos inkstų liga arba sunki obstrukcinė plaučių liga.

Tyrimo protokolą patvirtino institucijų etikos komitetai, kaip išsamesnio SE2030 tyrimo 291/294/295 Comitato Etico Lazio-1, 2021 m. kovo 8 d., dalį. Visi pacientai pasirašė informuotą sutikimo formą.

3.3.2. Dvimatė ramybės ir krūvio echokardiografija ir automatinė analizė


KE buvo atlikta naudojant įvairių gamintojų ultragarso aparatus. Iš viso 228 pacientams (95 proc.) buvo taikyta dipiridamolio echokardiografija, o 12 pacientų (5 proc.) – dobutamino echokardiografija. Nebuvo taikomi jokie fizinio krūvio protokolai. Visos analizės buvo atliktos naudojant vaizdus be kontrasto. Tyrimas buvo baigtas pagal gairių kriterijus [38].

Vaizdo duomenys buvo gauti DICOM formatu ir anonimizuoti vėlesnei analizei. Tuomet kardiologas, apmokytas atlikti KE, peržiūrėjo tyrimus, pasirinkdamas viršūninius keturių kamerų ir dviejų kamerų vaizdus krūvio ir ramybės fazėse. Kardiologai identifikavo ir pažymėjo galinės sistolinės ir galinės diastolinės vaizdus. Tada nubrėžė endokardo ribas KP galinės sistolės metu, KS galinės sistolės ir galinės diastolės metu. Išsamesnė matavimų metodika pateikta priede.

Tie patys dubliktuoti galinės diastolės ir galinės sistolės kadrai buvo apdoroti ir įvertinti DI algoritmu, apmokytų atskiru vaizdų rinkiniu. Kiekvienas vertintojas (kardiologas ir DI algoritmas) nežinojo vienas kito matavimų atlikimo ir verčių. Visi rankiniai ir automatiniai matavimai buvo atlikti naudojant tą pačią programinę įrangą (*Ligence Heart*). DI algoritmas buvo apmokytas naudojant nepriklausomą, atskirą daugiacentrį duomenų rinkinį, apimantį 21 539 pacientų tyrimus su 24 632 sužymėtais viršūniniais keturių ir dviejų kamerų echokardiografiniais vaizdais iš Vokietijos, Prancūzijos, Lietuvos ir JAV centrų. Nė vienas šios tyrimo kohortos pacientas nebuvo įtrauktas į mokymo duomenų rinkinį, užtikrinant išorinį validavimą.

3.3.3. Dvimatės echokardiografijos vaizdų kokybės įvertinimas

Vaizdo kokybės vertinimui buvo sukurtas dublikuotas duomenų rinkinys. Remiantis Europos širdies vaizdinių tyrimų asociacijos gairėmis [111], vaizdo kokybė buvo suskirstyta į vieną iš keturių kategorijų: optimali, gera, patenkinama arba prasta (3.3.3.1 pav.). Kardiologas ekspertas, nežinodamas matavimų, įvertino visų matomų širdies kamerų (kairiojo ir dešiniojo skilvelių bei prieširdžių) kokybę anksčiau pasirinktuose galinės diastolės ir sistolės kadruose. Kardiologo užduotis buvo tik įvertinti vaizdo kokybę iš anksto pažymėtuose kadruose. Vėliau tyrėjas, nežinodamas ankstesnių matavimų, įvertino kairiojo skilvelio ir prieširdžio vaizdo kokybę. Kiekvienos kameros vaizdo kokybė galinės diastolės ir sistolės kadre buvo suskirstyta į vieną iš keturių kategorijų: optimali, gera, patenkinama arba prasta.



3.3.3.1 pav. Kairiojo skilvelio viršūninio keturių kamerų vaizdo kokybės įvertinimai

A – prasta; B – patenkinama; C – gera; D – optimali.

3.3.4. Statistinė analizė

Duomenų analizė apėmė aprašomąją statistiką, apibendrinančią dalyvių charakteristikas, ir porinius t testus arba Wilcoxon testus, skirtus palyginti kintamuosius tarp ramybės ir krūvio fazių. Statistinis reikšmingumas nustatytas, kai $p < 0,05$. Kai kurių klinikinių kintamųjų verčių trūko, todėl procentai buvo apskaičiuoti pagal turimas charakteristikas. Statistika atlikta naudojantis Python programine įranga (versija 3.10).

Tolimesnis vertinimo parametras buvo klasės vidinis koreliacijos koeficientas (VKK) (angl. *intraclass Correlation Coefficient* (ICC)), naudojant dvipusį mišrų modelį su fiksuotais vertintojais. VKK kiekybiškai įvertino DI matavimų ir žmonių vertintojų rezultatų atitikimo laipsnį. Paciento vidinis variacijos koeficientas buvo naudojamas matavimų kintamumui atskirų pacientų ribose įvertinti.

Be to, atliktas Bland-Altmano (angl. *Bland-Altman*) testas, siekiant įvertinti šališkumo buvimą ir nustatyti atitikimo ribas. Šis testas padėjo nustatyti sisteminius skirtumus (šališkumą) ir pateikti bendrą DI ir žmonių vertintojų rezultatų atitikimo vertinimą. Taip pat nustatė diapazoną, kuriame gali atsirasti dauguma skirtumų, taip pateikiant išsamų DI veikimo įvertinimą.

4. REZULTATAI

4.1. Aortos ir kairiojo skilvelio diastolinių parametru vertinimo rezultatai

4.1.1. Tiriamųjų charakteristika

Atliktame prospektyviniame tyrime dalyvavo 302 dalyviai, kuriems atlikta 2D TTE ambulatorinėmis sąlygomis. Tarp dalyvių visi buvo baltaodžiai, 58,3 proc. (n = 176) buvo moterys, o vidutinis dalyvių amžius – 60,07 metų. Dauguma dalyvių turėjo gretutinių ligų: 76,2 proc. dalyvių sirgo arterine hipertenzija, 43,0 proc. – išemine širdies liga, iš kurių 10,6 proc. buvo patyrę miokardo infarktą, o 13,9 proc. buvo atlikta perkutaninė koronarinė intervencija, 9,6 proc. – diagnozuotas paroksizminis prieširdžių virpėjimas, 7,9 proc. sirgo plaučių ligomis (įskaitant astmą ir lėtinę obstrukcinę plaučių ligą), o 13,6 proc. sirgo vėžiu. Vidutinė KSIF buvo $54,72 \pm 2,5$ proc. Išsamios tyrimo populiacijos charakteristikos pateiktos 4.1.1.1 lentelėje.

4.1.1.1 lentelė. Tiriamųjų klinikinė charakteristika

Kintamieji	Vertė
Amžius, metais	$60,07 \pm 16,14$
Ūgis, cm	$169,94 \pm 9,63$
Svoris, kg	$79,74 \pm 18,06$
KMI, kg/cm ²	$27,50 \pm 5,25$
Išstūmimo frakcija, proc.	$54,72 \pm 2,50$
Pacientai, n	302
Moterys, proc. (n)	58,3 (176)
Vyrų, proc. (n)	41,7 (126)
Ligos anamnezėje, proc. (n)	
Arterinė hipertenzija	76,2 (230)
Išeminė širdies liga	43,0 (130)
Miokardo infarktas	10,6 (32)
Perkutaninė vainikinių arterijų intervencija	13,9 (42)
AVAJO	1,3 (4)
Paroksizminis prieširdžių virpėjimas	9,6 (29)
Plaučių ligos (astma, LOPL)	7,9 (24)
Vėžys	13,6 (41)
Aortos šaknies dilatacija	16,2 (49)
Kylančiosios aortos dilatacija	17,5 (53)

KMI – kūno masės indeksas, AVAJO – aortos vainikinių arterijų jungčių operacija, LOPL – lėtinė obstrukcinė plaučių liga.

4.2. Automatizuoto diastolinės funkcijos parametru vertinimo rezultatai

DI modelis pasiekė labai gerą visų spektrinių Doplerinių parametru, susijusių su diastoline funkcija, tikslumą, įskaitant mitralinio vožtuvo įtekėjimo greičius (E, A, E/A santykis) ir mitralinio žiedo greičius bei jų santykius (Le', Se', E/e', E/Le', E/Se'). Vertinant E greitį ir E/A santykį, pastebėta stipri koreliacija tarp DI ir rankinio matavimo rezultatų (atitinkamai $r = 0,93$ ir $0,94$), rodanti puikų atitikimą. A greitis taip pat gerai koreliavo ($r = 0,88$), patvirtindama modelio tikslumą vertinant mitralinio vožtuvo įtekėjimo greičius.

Audinių Doplerio matavimų vertinimas parodė panašų tikslumą. DI gauti Le', Se' ir E/e' santykio greičiai parodė stiprų tiesinį atitikimą su rankiniais vertinimais ($r \geq 0,87$). Santykių įvertinimai (E/Le' ir E/Se') parodė šiek tiek mažesnes, bet stiprias koreliacijas (atitinkamai $r = 0,89$ ir $0,75$). Vertinant šiuos Doplerinius parametrus, nebuvo aptikta sisteminės paklaidos, o variacijos diapazonas tarp automatinų ir rankinių matavimų buvo gana siauras, o tai rodo kliniškai priimtina kintamumą (4.2.1 lentelę).

KP ploto matavimai parodė didelę diagnostinę gebą (82–95 proc.) ir stiprią koreliaciją su rankiniu vertinimu ($r = 0,86$ – $0,88$). KP tūrio keturių ir dviejų kamerų matavimai parodė šiek tiek mažesnę koreliaciją (atitinkamai $r = 0,87$ ir $0,84$) bei didesnę kintamumą, o KP tūrio indeksas, nepaisant stiprios koreliacijos ($r = 0,92$), turėjo mažiausią diagnostinę gebą (73 proc.). Tačiau DI parodė sistemingą tendenciją pervertinti KP tūrio indekso parametą.

Triburio vožtuvo regurgitacijos maksimalus greitis ir gradientas (TRMV ir TRMG) parodė puikią diagnostinę gebą, tačiau tik vidutinę koreliaciją su rankiniais matavimais (atitinkamai $r = 0,55$ ir $0,56$).

4.2.1 lentelė. Automatinų ir rankinių echokardiografinių diastolinių parametru palyginimas

Matavimas	N	DG, proc.	VKP	ŠV	Apatinė SR	Viršutinė SR	Pirsono r
KPTi	70	73	12,25	7,11	–12,62	26,85	0,92
KPP 2K	91	95	2,91	1,12	–4,16	6,41	0,88
KPT 2K	91	95	16,79	5,95	–25,00	36,89	0,84
KPT 4K	238	82	2,85	1,11	–4,05	6,27	0,86
KPT 4K	238	82	13,47	5,56	–18,54	29,66	0,87
E	218	100	6,97	0,64	–12,99	14,28	0,93
A	221	100	8,94	2,29	–14,68	19,26	0,88

4.2.1 lentelės tęsinys

Matavimas	N	DG, proc.	VKP	ŠV	Apatinė SR	Viršutinė SR	Pirsono r
E/A	217	100	0,14	-0,04	-0,30	0,22	0,94
Le'	204	100	1,85	0,11	-3,52	3,74	0,87
Se'	215	100	1,36	0,21	-2,43	2,84	0,89
E/e'	196	100	1,58	-0,11	-3,21	3,00	0,87
E/Le'	196	100	1,33	-0,10	-2,70	-2,50	0,89
E/Se'	196	100	3,15	-0,15	-6,33	6,03	0,75
Dec	175	100	34,92	5,50	-62,28	73,27	0,61
TRMG	243	100	8,12	1,94	-13,54	17,43	0,56
TRMV	259	100	0,43	0,12	-0,69	0,93	0,55

N – tyrimų skaičius; DG – diagnostinė geba; VKP – vidutinė kvadratinė paklaida; SR – suderinamumo riba; r – koreliacijos koeficientas; KPT – kariojo prieširdžio tūris; KPTi – kairiojo prieširdžio tūrio indeksas; KPP – kairiojo prieširdžio plotas; 2K – viršūninis dviejų kamerų vaizdas; 4K – viršūninis keturių kamerų vaizdas; Dec – ankstyvosios diastolinės pripildymo bangos greičio lėtėjimo laikas; TRMG – didžiausias triburio vožtuvo regurgitacijos gradientas; TRMV – didžiausias triburio vožtuvo regurgitacijos greitis; ŠV – šališkumo vertinimas


4.2.1. Diastolinės disfunkcijos klasifikavimo tikslumas

Klasifikuojant KS diastolinę disfunkciją (KSDD), DI modelis parodė gerus rezultatus nustatant normalią diastolinę funkciją (0 laipsnį), kurio prieiziskumas siekė 90,57 proc. ir tai rodo, kad dauguma atvejų, kuriuos DI pažymėjo kaip normalius, buvo iš tiesų normali diastolinė funkcija. DI modelis taip pat pasiekė 92,13 proc. TNRD, kuris atspindi jo patikimumą teisingai identifikuojant normalios diastolinės funkcijos asmenis. 1 laipsnio diastolinės disfunkcijos atveju DI pasiekė 77,42 proc. atitikties rodiklį, o tai reiškia, kad jis sėkmingai nustatė daugumą tikrųjų 1 laipsnio KSDD atvejų, nors tikslumas buvo mažesnis, o tai rodo dažną kitų laipsnių klaidingą klasifikavimą į šią kategoriją. 2 laipsnio KSDD rezultatai buvo ne tokie tikslūs, tikėtina dėl riboto šios imties dydžio ir sudėtingų diagnostinių ypatybių. 3 laipsnio KSDD nustatymas parodė 75 proc. tikslumą ir 99,65 proc. TNRD. Šie rezultatai rodo, kad dirbtinis intelektas patikimai nustato tiek normalią diastolinę funkciją, tiek sunkius funkcijos sutrikimus (0 ir 3 laipsniai), tačiau susiduria su sunkumais klasifikuojant tarpines kategorijas, kur klinikiniai modeliai linkę sutapti. Klasifikavimo rezultatai detaliau apibendrinti 4.2.1.1 lentelėje, o sumaišymo matrica pateikta 4.2.1.1 pav.

4.2.1.1 lentelė. KS diastolinės disfunkcijos laipsnio klasifikavimo ir nustatymo rezultatai

Laipsnis	Preciziškumas, proc.	AR, proc.	F1 rezultatas, proc.	Tikslumas, proc.	Tikslumas + TN, proc.	TNRD, proc.	Iš viso
0	90,57	56,80	69,82	53,63	71,96	92,13	169
1	48,65	77,42	59,75	42,60	67,23	62,56	93
2	28,95	40,74	33,85	20,37	85,47	89,96	27
3	75,00	42,86	54,55	37,50	98,31	99,65	7

TN – tikrasis neigiamas, TNRD – tikrasis neigiamų rezultatų dažnumas; AR – atitikties rodiklis.



4.2.1.1 pav. DI klasifikuotų KSDD laipsnių rezultatai

4.3. Automatizuoto aortos diametrų vertinimo rezultatai

Vidutiniai aortos šaknies diametrai buvo atitinkamai: aortos žiedas (AoŽ) 22,83 mm ((interkvartilinis diapazonas (IQR), 21,4–24,75)), aortos ančiai (AoS) 33,74 mm (IQR, 30,59–36,8), kylanti aorta (KAo) 33,44 mm (IQR, 30,64–37,02) ir sinotubulinė jungtis (STJ) 28,84 mm (IQR, 26,06–31,73). DI modelis parodė stipriausią koreliaciją su kardiologo vertinimu matuojant AoS ($r = 0,86$), mažiausią koreliaciją su KAo parametru ($r = 0,67$). Detalūs palyginimai tarp automatinių ir rankinių aortos matavimų pateikti 4.3.1 lentelėje.

4.3.1 lentelė. Automatinių ir rankinių echokardiografinių aortos parametrų palyginimas

Matavimas	N	DG, proc.	VKP	ŠV	Apatinė SR	Viršutinė SR	Pirsono r
AoŽ	255	93	1,92	−0,04	−3,82	3,72	0,78
AoS	267	96	2,91	1,12	−4,16	6,41	0,86
STJ	187	84	3,59	1,95	−5,10	8,89	0,69
KAo	224	82	3,85	2,23	−5,35	9,28	0,67

N – tyrimų skaičius; DG – diagnostinė geba; VKP – vidutinė kvadratinė paklaida; ŠV – šališkumo vertinimas; SR – suderinamumo riba; r – koreliacijos koeficientas; AoŽ – aortos žiedas; AoS – aortos ančiai; STJ – sinotubulinė jungtis; KAo – kylančioji aorta.

4.4. Kairiojo skilvelio ir prieširdžio parametrų vertinimo ramybės ir krūvio echokardiografijos metu rezultatai

4.4.1. Tiriamųjų charakteristika

Tyrime dalyvavo 240 pacientų iš penkių skirtingų centrų. 139 (57 proc.) pacientai buvo vyrai, vidutinis amžius buvo 68 metai. Visiems pacientams buvo sinusinis ritmas. Įtariama išeminė širdies liga buvo pagrindinė indikacija atlikti farmakologinį KE tyrimą. Detali tirtų pacientų klinikinė charakteristika pateikta 4.4.1.1 lentelėje.

4.4.1.1 lentelėje. Tyrime dalyvavusių pacientų klinikinė charakteristika

Kintamieji	Vertė
Amžius*, metais	67,5 ± 10,4
Lytis, vyrai, n (proc.)	139 (57)
Ūgis, cm	166 (13)
Svoris, kg	76 (17)
KMI*, kg/cm ²	27,8 ± 4,2
KPP*, m ²	1,89 ± 0,19
Dislipidemija, n (proc.)	159 (65,2)
Cukrinis diabetas, n (proc.)	68 (27,9)
Išeminė širdies liga, n (proc.)	77 (31,6)
Ankstesni MI, n (proc.)	60 (24,6)
Arterinė hipertenzija, n (proc.)	177 (72,5)

Procentai apskaičiuojami remiantis turimais kiekvieno kintamojo duomenimis; Ne visi kintamieji buvo prieinami visiems pacientams; * vidurkis ± SD.

MI – miokardo infarktas; KMI – kūno masės indeksas; KPP – kūno paviršiaus plotas.

4.4.2. Dirbtinio intelekto diagnostinės gebos vertinimas

DI diagnostinė geba buvo pastovi tiek ramybės, tiek krūvio metu. Didžiausia diagnostinė geba stebėta KSGDT keturių ir dviejų kamerų vertinimo atvejais – atitinkamai 98 proc. ir 94 proc. ramybės būsenoje ir 95 proc. streso metu (4.4.2.1 lentelė). Kiti matavimai, įskaitant KS sistolinius tūrius (KSGST keturių ir dviejų kamerų), taip pat parodė didelę diagnostinę gebą – nuo 83 proc. iki 93 proc. Tačiau tokių matavimų kaip keturių ir dviejų kamerų KP tūrių diagnostinė geba buvo mažesnė – nuo 75 proc. iki 83 proc.

4.4.2.1 lentelė. *Kardiologo ir DI matavimų diagnostinės gebos palyginimas KE metu*

Matavimas	Tyrimo fazė	Įvertino kardiologas, n	Įvertino DI, n	DG, proc.
KSGDT 4K	ramybės	235	230	98
	krūvio	226	214	95
KSGST 4K	ramybės	234	209	89
	krūvio	221	206	93
KSGDT 2K	ramybės	230	216	94
	krūvio	225	214	95
KSGST 2K	ramybės	234	199	85
	krūvio	222	185	83
KPT 4K	ramybės	185	146	79
	krūvio	176	142	81
KPT 2K	ramybės	175	145	83
	krūvio	168	126	75

DG – diagnostinė geba; KSGDT – kairiojo skilvelio galinis diastolinis tūris; KSGST – kairiojo skilvelio galinis sistolinis tūris; KPT – kairiojo prieširdžio tūris; 2K – dviejų kamerų vaizde; 4K – keturių kamerų vaizde.

4.4.3. Dirbtinio intelekto ir ekspertų atliktų matavimų ramybės ir krūvio metu palyginimas


Palyginti kardiologų ekspertų ir DI atlikti KS ir KP matavimai. Rezultatai parodė didelį žmogaus ir DI matavimų, vertinant KS tūrius tiek ramybės, tiek krūvio metu, atitikimą. Viršūniniame keturių kamerų (KSGDT ir KSGST) ir dviejų kamerų vaizde (KSGDT ir KSGST) koreliacijos koeficientas svyravo atitinkamai nuo 0,92 iki 0,95 ir nuo 0,89 iki 0,91. Tačiau buvo nedidelių teigiamų paklaidų (4.4.3.1 lentelė), rodančių, kad DI modelis turėjo tendenciją nepakankamai įvertinti kairiojo skilvelio tūrius (išskyrus KSGST 4 kamerų vaizde), lyginant su kardiologais.

KSIF matavimai parodė vidutinį kardiologų ir DI atitikimą tiek ramybės, tiek krūvio fazėse. 9 paveiksle pateikti KSIF (viršūninių keturių ir dviejų kamerų) Blando-Altmano (angl. *Bland-Altman*) pasiskirstymo grafikai ramybės ir krūvio fazėse. VKK svyravo atitinkamai nuo 0,69 iki 0,77 ir nuo 0,6 iki 0,72, o tai rodo vidutinį atitikimą. KP tūrio matavimai (keturių ir dviejų kamerų) parodė dideles VKK vertes ($>0,95$), tai rodo puikų DI ir eksperto matavimų atitikimą. Be to, paklaida buvo nežymi, o VKP vertės svyravo nuo 4 iki 7, o tai reiškia minimalų nuokrypį ar neatitikimą tarp DI ir eksperto matavimų.

4.4.3.1 lentelė. Sutarimas ir šališkumo vertinimas tarp kardiologo ir DI KE metu

Matavimas	Tyrimo fazė	Pirsono r	VKK	ŠV	SR	VAP	VKP
KSGDT 4K	ramybės	0,9	0,89	8,15	$\pm 31,81$	13,48	18,16
	krūvio	0,84	0,83	7,62	$\pm 38,08$	15,4	20,87
KSGST 4K	ramybės	0,86	0,84	-0,10	$\pm 25,62$	9,3	13,07
	krūvio	0,87	0,86	-0,85	$\pm 25,01$	9,25	12,79
KSGDT 2K	ramybės	0,85	0,84	7,97	$\pm 39,70$	15,55	21,76
	krūvio	0,84	0,83	7,29	$\pm 38,70$	16,18	21,04
KSGST 2K	ramybės	0,88	0,87	1,34	$\pm 22,80$	8,04	11,71
	krūvio	0,85	0,83	0,42	$\pm 23,59$	8,56	12,04
KPT 4K	ramybės	0,93	0,93	3,35	$\pm 17,86$	7,11	9,71
	krūvio	0,93	0,93	0,97	$\pm 15,80$	6,07	8,12
KPT 2K	ramybės	0,85	0,83	3,73	$\pm 26,24$	9,52	13,9
	krūvio	0,88	0,88	3,73	$\pm 19,60$	8,09	10,67

r – koreliacijos koeficientas; VKK – vidinis koreliacijos koeficientas; ŠV – šališkumo vertinimas; SR – suderinamumo riba; VAP – vidutinė absoliuti paklaida; VKP – vidutinė kvadratinė paklaida; KSGDT – kairiojo skilvelio galinis diastolinis tūris; KSGST – kairiojo skilvelio galinis sistolinis tūris; KPT – kairiojo prieširdžio tūris; 2K – dviejų kamerų vaizde; 4K – keturių kamerų vaizde.



4.4.3.1 pav. Blando-Altmano (angl. Bland-Altman) KSIF pasiskirstymo grafikai ramybės ir krūvio metu viršūniniuose keturių ir dviejų kamerų vaizduose

SR – suderinamumo ribos, KSIF – kairiojo skilvelio išstūmio frakcija, 2K— dvi kameros, 4K – keturios kameros.

4.4.4. Dirbtinio intelekto ir ekspertų atliktų matavimų atitikimas ir palyginimas tarp skirtingų centrų

Analizė buvo atlikta visai kohortai, o vėliau atskirai analizuoti ir kiekvieno centro duomenys. DI ir kardiologų duomenų atitikimas buvo stebėtas visuose penkiuose centruose, o 3-iasis centras parodė stipriausią atitikimą (4.4.4.1–4.4.4.5 lentelės). Ramybės metu atliktų parametrų atitikimas buvo saikiai didesnis, lyginant su krūvio metu atliktais matavimais.

4.4.4.1 lentelė. DI ir ekspertų atliktų matavimų atitikimas centre nr. 1

Tyrimo fazė	Matavimas	Ivertinti eksperto, n	Ivertinti DI, n	Pirsono r	VKK	ŠV	SR	VAP	VKP
Ramybės	KSGDT 4K	46	43	0,92	0,91	4	±29,55	11,96	15,6
	KSGST 4K	45	37	0,86	0,85	-7,27	±28,61	12,55	16,31
	KSGDT 2K	41	36	0,87	0,86	9,64	±47,39	18,03	26,03
	KSGST 2K	45	41	0,95	0,95	-0,61	±18,95	7,67	9,69
	KPT 4K	42	30	0,94	0,91	8,8	±16,93	9,45	12,33
	KPT 2K	34	25	0,79	0,77	7,85	±23,91	10,7	14,51
Kūrvio	KSGDT 4K	47	43	0,88	0,87	-0,3	±43,19	15,12	22,04
	KSGST 4K	42	36	0,92	0,9	-4,89	±28,83	11,82	15,5
	KSGDT 2K	46	41	0,9	0,87	7,15	±39,7	17,04	21,48
	KSGST 2K	44	33	0,85	0,84	-2,84	±22,1	9,1	11,63
	KPT 4K	34	22	0,94	0,92	0,48	±15,78	5,37	8,07
	KPT 2K	33	22	0,95	0,92	7,22	±17,88	9,28	11,63

DI – dirbtinis intelektas; r – koreliacijos koeficientas; VKK – vidinis koreliacijos koeficientas; ŠV – šališkumo vertinimas; SR – suderinamumo riba; VAP – vidutinė absoliuti paklaida; VKP – vidutinė kvadratinė paklaida; KSGDT – kairiojo skilvelio galinis diastolinis tūris; KSGST – kairiojo skilvelio galinis sistolinis tūris; KPT – kairiojo prieširdžio tūris; 2K – dviejų kamerų vaizde; 4K – keturių kamerų vaizde.

4.4.4.2 lentelė. DI ir ekspertų atliktų matavimų atitikimas centre nr. 2

Tyrimo fazė	Matavimas	Ivertinti eksperto, n	Ivertinti DI, n	Pirsono r	VKK	ŠV	SR	VAP	VKP
Ramybės	KSGDT 4K	43	43	0,91	0,85	18,84	±34,22	20,1	25,69
	KSGST 4K	43	38	0,9	0,85	4,48	±24,66	10,06	13,36
	KSGDT 2K	43	42	0,89	0,78	21,9	±47,65	25,68	32,72
	KSGST 2K	43	29	0,81	0,69	9,99	±36,09	13,14	20,95
	KPT 4K	43	35	0,96	0,95	4,84	±17,21	8,02	10,03
	KPT 2K	41	38	0,93	0,87	10,5	±27,86	11,03	17,67
Krūvio	KSGDT 4K	43	42	0,91	0,88	21,54	±31,17	22,59	26,77
	KSGST 4K	43	41	0,91	0,89	4,92	±21,66	8,86	12,1
	KSGDT 2K	43	42	0,87	0,86	21,05	±42,99	24,89	30,4
	KSGST 2K	43	28	0,94	0,9	10,04	±25,64	11,8	16,49
	KPT 4K	42	33	0,95	0,94	5,02	±14,55	7,05	8,96
	KPT 2K	39	32	0,91	0,91	8,5	±20,65	10,65	13,54

DI – dirbtinis intelektas; r – koreliacijos koeficientas; VKK – vidinis koreliacijos koeficientas; ŠV – šališkumo vertinimas; SR – suderinamumo riba; VAP – vidutinė absoliuti paklaida; VKP – vidutinė kvadratinė paklaida; KSGDT – kairiojo skilvelio galinis diastolinis tūris; KSGST – kairiojo skilvelio galinis sistolinis tūris; KPT – kairiojo prieširdžio tūris; 2K – dviejų kamerų vaizde; 4K – keturių kamerų vaizde.

4.4.4.3 lentelė. DI ir ekspertų atliktų matavimų atitikimas centre nr. 3

Tyrimo fazė	Matavimas	Ivertinti eksperto, n	Ivertinti DI, n	Pirsono r	VKK	ŠV	SR	VAP	VKP
Ramybės	KSGDT 4K	50	50	0,93	0,93	13,42	±21,49	14,05	17,33
	KSGST 4K	50	48	0,91	0,91	3,14	±15,24	6,59	8,39
	KSGDT 2K	50	49	0,89	0,88	9,72	±24,67	13,22	15,9
	KSGST 2K	50	46	0,92	0,91	2,3	±13,58	5,78	7,3
	KPT 4K	50	46	0,96	0,95	4,5	±10,48	5,15	6,99
	KPT 2K	50	37	0,96	0,93	6,53	±16,97	7,66	10,85
Krūvio	KSGDT 4K	50	50	0,93	0,93	10,09	±18,71	11,55	13,89
	KSGST 4K	50	49	0,91	0,91	1,64	±13,21	5,4	6,94
	KSGDT 2K	50	50	0,88	0,88	6,98	±23,22	10,47	13,75
	KSGST 2K	49	45	0,85	0,84	0,73	±14,17	5,51	7,27
	KPT 4K	50	41	0,97	0,96	3	±11,72	4,99	6,69
	KPT 2K	50	39	0,95	0,94	5,54	±11,08	6,19	7,91

DI – dirbtinis intelektas; r – koreliacijos koeficientas; VKK – vidinis koreliacijos koeficientas; ŠV – šališkumo vertinimas; SR – suderinamumo riba; VAP – vidutinė absoliuti paklaida; VKP – vidutinė kvadratinė paklaida; KSGDT – kairiojo skilvelio galinis diastolinis tūris; KSGST – kairiojo skilvelio galinis sistolinis tūris; KPT – kairiojo prieširdžio tūris; 2K – dviejų kamerų vaizdas; 4K – keturių kamerų vaizdas.

4.4.4.4 lentelė. DI ir ekspertų atliktų matavimų atitikimas centre nr. 4

Tyrimo fazė	Matavimas	Ivertinti eksperto, n	Ivertinti DI, n	Pirsono r	VKK	ŠV	SR	VAP	VKP
Ramybės	KSGDT 4K	46	44	0,93	0,91	8,38	±29,9	12,53	17,4
	KSGST 4K	46	42	0,9	0,85	3,52	±29,83	9,77	15,62
	KSGDT 2K	46	42	0,93	0,92	3,26	±28,98	10,98	15,14
	KSGST 2K	46	40	0,91	0,89	3,29	±20,71	8,1	11,07
	KPT 4K	0	0	–	–	–	–	–	–
	KPT 2K	0	0	–	–	–	–	–	–
Krūvio	KSGDT 4K	36	29	0,76	0,75	12,96	±48,05	18,97	27,73
	KSGST 4K	36	33	0,89	0,83	4,03	±31,83	12,39	16,73
	KSGDT 2K	36	34	0,84	0,84	9,11	±36,77	17	20,85
	KSGST 2K	36	34	0,89	0,87	6,6	±23,58	9,45	13,72
	KPT 4K	0	0	–	–	–	–	–	–
	KPT 2K	0	0	–	–	–	–	–	–

DI – dirbtinis intelektas; r – koreliacijos koeficientas; VKK – vidinis koreliacijos koeficientas; ŠV – šališkumo vertinimas; SR – suderinamumo riba; VAP – vidutinė absoliuti paklaida; VKP – vidutinė kvadratinė paklaida; KSGDT – kairiojo skilvelio galinis diastolinis tūris; KSGST – kairiojo skilvelio galinis sistolinis tūris; KPT – kairiojo prieširdžio tūris; 2K – dviejų kamerų vaizde; 4K – keturių kamerų vaizde.

4.4.4.5 lentelė. DI ir ekspertų atliktų matavimų atitikimas centre nr. 5

Tyrimo fazė	Matavimas	Ivertinti eksperto, n	Ivertinti DI, n	Pirsono r	VKK	ŠV	SR	VAP	VKP
Ramybės	KSGDT 4K	50	50	0,92	0,92	-2,95	±25,17	9,35	13,18
	KSGST 4K	50	44	0,82	0,81	-5,01	±19,51	8,42	11,15
	KSGDT 2K	50	47	0,81	0,81	-3,39	±29,13	11,11	15,24
	KSGST 2K	50	43	0,9	0,9	-5,46	±13,65	7,29	8,85
	KPT 4K	50	35	0,96	0,94	-4,33	±17,45	6,76	9,9
	KPT 2K	50	45	0,84	0,84	-6,57	±19,77	9,13	12,04
Kūrvio	KSGDT 4K	50	50	0,88	0,88	-2,82	±27,58	11,39	14,35
	KSGST 4K	50	47	0,9	0,89	-8,82	±17,56	9,45	12,58
	KSGDT 2K	50	47	0,82	0,82	-5,9	±30,21	13,15	16,5
	KSGST 2K	50	45	0,85	0,83	-8,15	±15,97	8,53	11,52
	KPT 4K	50	46	0,91	0,91	-3,52	±15,47	6,65	8,64
	KPT 2K	46	33	0,91	0,9	-5,35	±15,73	7,08	9,64

DI – dirbtinis intelektas; r – koreliacijos koeficientas; VKK – vidinis koreliacijos koeficientas; ŠV – šališkumo vertinimas; SR – suderinamumo riba; VAP – vidutinė absoliuti paklaida; VKP – vidutinė kvadratinė paklaida; KSGDT – kairiojo skilvelio galinis diastolinis tūris; KSGST – kairiojo skilvelio galinis sistolinis tūris; KPT – kairiojo prieširdžio tūris; 2K – dviejų kamerų vaizde; 4K – keturių kamerų vaizde.

4.4.5. Skirtingos kokybės vaizdų vertinimas

Kiekvieno ultragarsinio vaizdo kadro ir širdies kamerų, kuriose buvo atlikti matavimai, vaizdo kokybė įvertinta ir suskirstyta į keturias kokybės kategorijas: optimali, gera, patenkinama arba prasta. Nors krūvio metu vaizdų kokybė turėjo tendenciją mažėti, skirtumai nebuvo statistiškai reikšmingi ($p > 0,05$) (4.4.5.1 lentelė). Kai kuriems pacientams atskirų kamerų matavimų nebuvo galima atlikti dėl nepakankamos vaizdo kokybės pasirinktuose vaizduose, nors pacientai buvo įtraukti į bendrą kohortą.

Tyrimo rezultatai skyrėsi priklausomai nuo vaizdų kokybės. Mažiausia diagnostinė geba stebėta atliekant KS matavimus prastos kokybės vaizduose (45,5–57,7 proc. ramybės metu ir 37,5–80 proc. krūvio metu, 4.4.5.1 lentelė). Esant geresnei vaizdo kokybei, stebėti geresni ir rezultatai, o didžiausia diagnostinė geba gauta optimalios kokybės vaizduose, kur pasiekta didesnė nei 89 proc. visų matavimų diagnostinė geba. Ji pasiekė net 100 proc. tokiuose matavimuose kaip dviejų ir keturių kamerų KSGDT.

4.4.5.1 lentelė. Vaizdo kokybės įtaka tarp eksperto ir DI matavimų diagnostinei gebai krūvio echokardiografijoje

Matavimas	Vaizdo kokybė	Ramybės fazė			Krūvio fazė		
		Įvertino ekspertas, n	Įvertino DI, n	DG, proc.	Įvertino ekspertas, n	Įvertino DI, n	DG, proc.
KSGDT 4K	prastas	1	0	–	4	1	–
	pakankamas	37	35	94,6	47	41	87,2
	geras	96	95	98,9	94	92	97,9
	optimalus	99	99	100	80	79	98,8
KSGST 4K	prastas	6	0	–	12	9	75
	pakankamas	38	27	71,1	49	43	87,8
	geras	91	86	94,5	80	75	93,8
	optimalus	99	96	97	80	79	98,8
KSGDT 2K	prastas	11	5	45,5	15	12	80
	pakankamas	86	78	90,7	82	77	93,9
	geras	82	82	100	77	74	96,1
	optimalus	51	51	100	51	51	100
KSGST 2K	prastas	8	4	50	16	6	37,5
	pakankamas	63	44	69,8	66	51	77,3
	geras	83	76	91,6	76	69	90,8
	optimalus	80	75	93,8	64	59	92,2

4.4.5.1 lentelės tęsinys

Matavimas	Vaizdo kokybė	Ramybės fazė			Krūvio fazė		
		Įvertino ekspertas, n	Įvertino DI, n	DG, proc.	Įvertino ekspertas, n	Įvertino DI, n	DG, proc.
KPT 4K	prastas	4	2	–	7	0	–
	pakankamas	28	15	53,6	28	18	64,3
	geras	64	47	73,4	54	46	85,2
	optimalus	83	81	97,6	80	78	97,5
KPT 2K	prastas	4	2	–	7	1	–
	pakankamas	49	37	75,5	59	36	61
	geras	61	56	91,8	46	42	91,3
	optimalus	54	48	88,9	51	47	92,2

DG – diagnostinė geba; DI – dirbtinis intelektas; KSGDT – kairiojo skilvelio galinis diastolinis tūris; KSGST – kairiojo skilvelio galinis sistolinis tūris; KPT – kairiojo prieširdžio tūris; 2K – dviejų kamerų vaizde; 4K – keturių kamerų vaizde.

4.4.6. Dirbtinio intelekto ir ekspertų atliktų matavimų atitikimas ir palyginimas, esant skirtingos kokybės vaizdams

Palyginti DI ir ekspertų rezultatai ir jų atitikimas vertinant skirtingos kokybės vaizdus (4.4.6.1 lentelė). Analizė parodė, kad geros arba optimalios kokybės vaizdų matavimai buvo tikslesni palyginti su tais, kurie buvo įvertinti kaip prastos arba patenkinamos kokybės. Vertinant kairiosios širdies tūrio matavimus, optimalios ir geros kokybės vaizdų atitikimas tarp DI ir kardiologų buvo puikus, o VKK svyravo nuo 0,91 iki 1,00. Prastos arba patenkinamos kokybės vaizdų matavimai parodė mažesnę atitikimą, palyginti su geros arba optimalios kokybės vaizdais, tačiau vis tiek pateko į pakankamai gero atitikimo diapazoną (VKK svyravo nuo 0,83 iki 0,96).

4.4.6.1 lentelė. DI ir ekspertų atliktų matavimų atitikimas, esant skirtingai vaizdų kokybei

Matavimas	Vaizdo kokybė	Ramybės fazė							Krūvio fazė						
		N	r	VKK	ŠV	SR	VAP	VKP	N	r	VKK	ŠV	SR	VAP	VKP
KSGDT 4K	prasta	0	–	–	–	–	–	–	1	–	–	–	–	–	–
	pakankama	35	0,91	0,91	10,8	±38,1	16,6	22,2	41	0,83	0,82	6,8	±53,6	20,9	28,2
	gera	95	0,91	0,89	6,0	±30,6	12,0	16,7	92	0,85	0,83	6,7	±38,4	15,6	20,7
	optimali	99	0,88	0,86	9,6	±29,6	13,7	17,9	79	0,84	0,84	9,1	±26,5	12,5	16,3
KSGST 4K	prasta	0	–	–	–	–	–	–	9	0,79	0,79	–4,2	±23,3	9,2	12,6
	pakankama	27	0,80	0,78	–5,7	±30,3	11,7	16,6	43	0,92	0,90	0,6	±31,6	11,8	16,1
	gera	86	0,88	0,87	–0,5	±23,6	8,9	12,0	75	0,84	0,83	–2,1	±24,9	9,3	12,9
	optimali	96	0,87	0,83	1,8	±24,0	8,9	12,9	79	0,84	0,84	–0,1	±20,5	7,8	10,5
KSGDT 2K	prasta	5	0,66	0,64	–7,7	±50,0	22,0	26,6	12	0,67	0,67	9,1	±46,2	20,2	25,3
	pakankama	78	0,87	0,85	7,1	±41,8	15,6	22,5	77	0,86	0,85	5,1	±44,3	17,7	23,2
	gera	82	0,85	0,85	6,0	±35,1	14,5	18,9	74	0,84	0,83	8,5	±33,9	15,3	19,3
	optimali	51	0,82	0,82	14,1	±38,8	16,6	24,3	51	0,80	0,78	8,4	±33,3	14,2	19,0
KSGST 2K	prasta	4	0,76	0,65	–12,4	±20,4	13,0	16,2	6	0,65	0,61	–14,1	±24,8	14,4	19,0
	pakankama	44	0,78	0,74	–0,1	±30,8	9,2	15,7	15	0,88	0,85	–1,0	±29,0	11,2	14,8
	gera	76	0,92	0,92	1,0	±20,1	7,9	10,3	69	0,88	0,87	0,7	±18,4	6,9	9,4
	optimali	75	0,92	0,89	3,3	±18,3	7,2	9,9	59	0,81	0,76	2,8	±21,3	7,7	11,2

4.4.6.1 lentelės tęsinys

Matavimas	Vaizdo kokybė	Ramybės fazė						Krūvio fazė							
		N	r	VKK	ŠV	SR	VAP	VKP	N	r	VKK	ŠV	SR	VAP	VKP
KPT 4K	prasta	2	–	–	–	–	–	–	0	–	–	–	–	–	–
	pakankama	15	0,76	0,75	4,6	±22,9	8,9	12,6	18	0,97	0,96	1,1	±11,6	5,1	6,0
	gera	47	0,96	0,96	3,6	±16,0	7,0	8,9	46	0,91	0,91	0,2	±20,8	7,7	10,6
	optimali	81	0,92	0,92	2,4	±16,3	6,4	8,7	78	0,93	0,93	1,4	±12,9	5,3	6,7
KPT 2K	prasta	2	–	–	–	–	–	–	1	–	–	–	–	–	–
	pakankama	37	0,83	0,82	2,7	±28,5	10,6	14,8	36	0,86	0,86	2,2	±23,7	9,4	12,3
	gera	56	0,88	0,86	2,8	±23,0	9,2	12,1	42	0,90	0,89	3,9	±16,3	6,9	9,2
	optimali	48	0,86	0,84	3,8	±17,9	7,5	9,9	47	0,90	0,90	5,1	±18,0	8,1	10,5

N – tyrimų skaičius; r – koreliacijos koeficientas; VKK – vidinis koreliacijos koeficientas; ŠV – šališkumo vertinimas; SR – suderinamumo riba; VAP – vidutinė absoliuti paklaida; VKP – vidutinė kvadratinė paklaida; KSGDT – kairiojo skilvelio galinis diastolinis tūris; KSGST – kairiojo skilvelio galinis sistolinis tūris; KPT – kairiojo prieširdžio tūris; 2K – dviejų kamerų vaizde; 4K – keturių kamerų vaizde.

5. REZULTATŲ APTARIMAS

Šis tyrimas yra vienas pirmųjų pasaulyje, kuriame įvertintas platus DI algoritmų pritaikomumas ir tikslumas analizuojant įvairius echokardiografinius parametrus, svarbius širdies funkcijai nustatyti, atliekant echokardiografijos tyrimą ramybės ir krūvio metu. Nustatytas GNT tikslumas ir koreliacija vertinant KSDF, aortos parametrus bei KPr, KS tūrius ir sistolinę funkciją. Pagrindiniai rezultatai pagrindžia didelį matavimų atitikimą ir stiprią koreliaciją su kardiologų ekspertų vertinimais ir plačias galimybes pritaikyti DI analizuojant įvairius echokardiografinius parametrus bei esant įvairiai ultragarsinio vaizdo kokybei.

Echokardiografinį KSDF įvertinimą turi atlikti patyrę specialistai, galintys interpretuoti daugybę parametrų. KSDF įvertinimas pagal 2016 m. Amerikos echokardiografijos draugijos ir Europos širdies vaizdinių tyrimų asociacijos (ASE/EACVI) gaires gali būti ypač sudėtingas tam tikromis klinikinėmis situacijomis dėl skirtingų doplerio ir struktūrinių, funkcinų matavimų integravimo sudėtingumo. Giliojo mokymosi modeliai gali padėti klinikiškiems specialistams, atliekantiems reikiamus matavimus ir vertinantiems diastolinės disfunkcijos laipsnį. KNT modeliai atpažįsta 2D TTE vaizdus, aptinka reikiamus širdies ciklus, identifikuoja anatominius orientyrus ir pateikia atitinkamus matavimus. Šiame tyrime DI pasiekė puikius visų doplerio parametrų rodiklius ir išlaikė nuosekliai tikslius parametrų rodiklius atliekant daugumą kitų echokardiografinių matavimų. Padedant DI sprendimams, KS funkcijos vertinimas gali tapti veiksmingesnis ir tikslesnis – sumažinti darbo krūvį ir didinti diagnostikos tikslumą.

KSDF įvertinimas taip pat užima daug laiko, o tai lemia, kad reikia priemonių, kurios galėtų padidinti klinikinės praktikos efektyvumą. Šiame tyrime tiesiogiai nematuotos laiko sąnaudos, tačiau Bahrami ir kt. aprašė, kad vidutinis rankinio įvertinimo laikas yra maždaug 6 minutės vienam pacientui, o didelė šio laiko dalis skirta planimetriniams matavimams atlikti [112]. Olaisenetalis ir kt. pademonstravo, kad duomenų gavimo ir apdorojimo laikas sutrumpėjo 77 proc., naudojant tikrojo laiko DI pagrįstus KS tūrių ir išstūmio frakcijos matavimus [74]. Be efektyvumo didinimo, mūsų KNT pagrįstas metodas taip pat gali sumažinti kintamumą ir pagerinti atsikartojamumą. Modelis sukurtas veikti pagal įprastą žmogaus vertinimo ciklo sistemą: jis atlieka automatinį vaizdų klasifikavimą, kadrų pasirinkimą ir matavimų atlikimą, o po jų – preliminarą diastolinės funkcijos klasifikaciją. Šie rezultatai pateikiami vizualiai ir gali būti patikrinti arba pataisyti gydytojo. Šis hibridinis metodas siekia suformuoti labiau standartizuotą atsakymų teikimą ir

pagerinti darbo eigos efektyvumą, nepakeičiant klinikinės praktikos. Reikalingi tolesni tyrimai, siekiant įvertinti tokių sprendimų klinikinį ir ekonominį poveikį platesnėje klinikinėje praktikoje.

Pasiekta didelė gairių standartizavimo pažanga, tačiau vis dar išlieka tam tikri ribotumai vertinant diastolinę funkciją rankiniu būdu. DI pagrįsti modeliai gali padėti spręsti gerai žinomas problemas, tokias kaip vertintojų tarpusavio rezultatų skirtumai. Ankstesni tyrimai parodė, kad net ir nedideli neatitikimai ties ribinėmis vertėmis – ypač vertinant KP tūrį ar KSIF – gali lemti reikšmingus išvadų skirtumus tarp gydytojų. Net ir patyrusių specialistų vertinimai dažnai sutampa tik iš dalies [113, 114]. Nors 2016 m. ASE/EACVI gairės pagerino rezultatų atkuriamumą, palyginti su ankstesniais algoritmais, vertinimų kintamumas vis dar išlieka, ypač esant vidutinio sunkumo laipsniams [112]. Dar svarbiau, kad matavimų netikslumus dažnai labiau lemia vaizdo kokybės skirtumai nei paties vertinimo subjektyvumas [114, 115]. Mūsų tyrime neoptimalių ir blogos kokybės viršūninių projekcijų bei doplerio vaizdų įtraukimas greičiausiai turėjo įtakos sutarimui ribiniais arba neapibrėžtais atvejais. Įdiegus pagrindinius kokybės kontrolės žingsnius į DI darbo eigą, būtų galima atpažinti netinkamos kokybės duomenis ir pažymėti neaiškius rezultatus peržiūrai rankiniu būdu. Rezultatai parodė, kad dauguma Doplerio pagrindu gautų parametrų tarp DI ir rankinių matavimų atskleidė nedidelius sisteminius nuokrypius bei siauras suderinamumo ribas. Tačiau tam tikrais atvejais nustatyti neatitikimai – pavyzdžiui, KP tūrio indeksas šiek tiek pervertintas, tikėtina – dėl sudėtingumo tiksliai nustatyti endokardo ribas. Taip pat buvo didesnių skirtumų vertinant TRMG ir TRMV, kurie jautresni ne visada taisyklingai Doplerio spindulio kryptį bei silpnesnei signalo kokybei. Šios sritys yra svarbios tolesniam DI algoritmų tobulinimui ir platesniam jų taikymo pagrindimui skirtingomis vaizdinimo sąlygomis.

Dauguma šiuolaikinių tyrimų daugiausia dėmesio skiria tam tikrų echokardiografinių parametrų validacijai ir kairiojo skilvelio sistolinės funkcijos vertinimui, tačiau kai kurie darbai nagrinėja giliojo mokymosi metodų galimybes, taikomas KSDD nustatyti pagal echokardiografinius duomenis [116]. Paprastai tiriami neprižiūrimojo dirbtinio intelekto mokymosi modeliai, siekiant identifikuoti naujus KSDD fenotipus ir pateikti aiškias klasifikacijas, kurių tikslumas yra panašus į 2016 m. ASE/EACVI gairių patikimumą. Tačiau reikėtų pažymėti, kad neprižiūrimojo mokymosi modeliai ne visuomet pasiekia norimą tikslumą ir patikimumą dėl KSDD fenotipų kompleksiskumo [117]. Prižiūrimojo mokymosi aplinkoje naudojami mašininio mokymosi modeliai turi dideles galimybes ir atitinka dabartines gaires [6, 7, 84, 118]. Pandey ir bendraautorai sukūrė mašininio mokymosi modelį, kuriuo identifikuoti mažos ir didelės rizikos KSDD fenotipai. Jie nustatė, kad

modelio išskirti rizikos fenotipai gerai koreliavo su kairiojo skilvelio užpildymo slėgiu. Šis modelis buvo patikrintas ir palygintas su aukso standartu – invaziniais hemodinaminiais matavimais, atliktais dešinėsios širdies kateterizacijos metu. Naudojant modelį nustatytas panašus tikslumas kaip ir 2016 m. ASE/EACVI gairės pacientams, kurių diastolinė funkcija buvo klasifikuojama. Tačiau, į analizę įtraukus visą kohortą, įskaitant ir neapibrėžtus diastolinės funkcijos laipsnius turinčius pacientus, jis buvo tikslesnis [115]. Be to, vis daugiau dėmesio skiriama automatizuoto mašininio mokymosi galimybėms vertinant 2D TTE vaizdus ir KSDF pagal galiojančias gaires. Chen ir bendraautoriai sukūrė dirbtiniu intelektu pagrįstą sistemą KSDF vertinti ir laipsniams nustatyti, naudodami tiek daugiavaizdžius, tiek vienaizdžius echokardiografinius duomenis. Naudojant daugiavaizdžių modelį nustatyta, kad jis gerai atitinka ekspertų vertinimus (tikslumas $\geq 0,90$), panašius į mūsų gautus rezultatus. Autoriai taip pat tyrė alternatyvius vienaizdžių metodus, taikydami 2D įtampos analizę ir trimačius KNT, skirtus greitam laipsnių įvertinimui, tačiau mūsų metodika buvo orientuota tik į esamomis gairėmis pagrįstą KSDD vertinimą [118].

Tromp ir bendraautoriai ištyrė 23 skirtingus echokardiografinius parametrus, įskaitant ir tuos, kurie naudojami KSDD vertinti. Mūsų tyrimo metu nustatyti tikslesni visų palyginamų parametrų rezultatai, palyginti su Tromp ir kt. duomenimis, įskaitant dviburio vožtuvo E bangą (MV E), dviburio vožtuvo A bangą (MV A), šoninės ir pertvarinės sienelės e' , E/e' santykį bei didžiausią triburio vožtuvo regurgitacijos greitį (TRMV); visi šie parametrai mūsų modelyje buvo sėkmingai nustatyti 100 proc. atvejų [84]. Be to, Tromp ir kt. sukūrė išsamaus echokardiografinio vertinimo KNT pagrįstą darbo eigą, apimančią klasifikaciją, segmentaciją ir 23 parametrų matavimus, testuotus duomenų rinkiniuose iš Kanados, Taivano ir Jungtinių Amerikos Valstijų. Automatinių ir rankinių matavimų koreliacija tarp centrų skyrėsi, tačiau buvo nustatyta, kad gerai atitiko dviburio vožtuvo E bangos duomenys, šoninis ir pertvarinis e' , E/e' santykis ir KP tūris. Mūsų tyrime nustatyti panašūs rezultatai: koreliacijos koeficientai buvo $r = 0,93$ (E banga), $0,88$ (A banga), $0,87$ (šoninis e'), $0,89$ (pertvarinis e'), $0,87$ (E/e' santykis) ir iki $0,92$ indeksuotam KP tūriui. Šie rodikliai pateko į Tromp ir kt. nurodytus intervalus arba juos viršijo, dar labiau patvirtindami DI gautų matavimų patikimumą ir giliojo mokymosi modelių pritaikomumą diastolinei funkcijai vertinti įvairiose klinikinėse aplinkose [6].

Visai neseniai Park ir kt. pristatė tyrimą, kuriame buvo sukurtas DI pagrįstas programinės įrangos modelis KSDF vertinti. Modelis pasižymėjo dideliu tikslumu identifikuojant reikiamus vaizdus bei stipriomis automatinio ir rankinio diastolinių parametrų matavimų koreliacijomis. Palyginti su Park ir kt. duomenimis, šiuo tyrimu nustatyta didesnė koreliacija su Doplerio

parametrais, įskaitant E bangą ($r = 0,93$ plg. $0,907$) ir E/A santykį ($r = 0,94$ plg. $0,901$). Tačiau šiek tiek mažesnė koreliacija buvo stebėta audinių su Doplerio parametrais ir struktūriniais rodikliais – e' greitis ($r = 0,87$ plg. $0,957$), E/ e' santykis ($r = 0,87$ plg. $0,927$), TRMV ($r = 0,56$ plg. $0,959$) ir KP tūrio indeksas ($r = 0,92$ plg. $0,928$). Park ir kt. e' greičiui apskaičiuoti naudojo tik pertvarinį dviburio žiedo judėjimo greitį, užfiksuotą impulsinės bangos audinių Dopleriu, o mūsų tyrimas apėmė tiek pertvarinį, tiek šoninės KS sienelės matavimus, tai leido atlikti išsamesnį miokardo relaksacijos įvertinimą. Be to, jų tyrimas buvo atliktas nedidelėje, selektyviai atrinktoje imtyje, iš kurios buvo pašalinti pacientai, turintys ne visus parametrus ar prastesnės kokybės vaizdus. Tačiau mūsų tyrime pacientai buvo atrenkami atsitiktinai pagal įtraukimo kriterijus, o vaizdai įtraukti be papildomos kokybės kontrolės, tai galėjo turėti įtakos parametų vertinimo tikslumui [7].

Park ir kt. paskelbė, kad 94 proc. DI nustatytų ir gairėmis pagrįstų KSDF laipsnių nustatymo rezultatai atitiko, tačiau mūsų tyrimo metu nustatytas mažesnis suderinamumas, ypač vidutinių laipsnių atvejais. Tai gali atspindėti papildomų echokardiografinių radinių bei platesnio klinikinio konteksto – tokių kaip gretutinės ligos ar ritmo sutrikimai – įtaką, kurią gydytojai vertina priskirdami laipsnius. Panaši neatitiktis pastebėta ir Park ir kt. tyrime, kur net ir taikant rankinį laipsniavimą suderinamumas tarp DI gautų ir klinikinių vertinimų sumažėjo iki 77,5 proc. [7]. Šie rezultatai pabrėžia griežtai gairėmis pagrįsto laipsnių skyrimo taikymo sudėtingumą realioje klinikinėje praktikoje.

Šiame tyrime naudotas DI modelis buvo sukurtas pagal 2016 m. ASE/EACVI gairėmis pagrįstą algoritmą, kuris tuo metu buvo galiojantis standartas duomenų rinkimo ir analizės metu. Nuo to laiko ASE 2025 m. paskelbė atnaujintas gaires, kuriose įtraukti keli svarbūs pakeitimai, įskaitant amžiui koreguotas normines vertes, didesnę dėmesį plaučių venų Doplerio analizei bei papildomų parametų – BIĮ ir KP deformacijos – įtraukimą kaip pagalbinius kriterijus [83]. Nors mūsų modelis buvo pagrįstas ankstesniais kriterijais, jo rezultatai rodo, kad panašiai struktūrinti taisyklėmis paremti metodai gali būti veiksmingi ir pagal atnaujintas gaires. Ateities tyrimuose reikėtų validuoti modelio veikimą atsižvelgiant į naujas rekomendacijas.

Palygintas rankinių ir automatinių diastolinių parametų vertinimas. Mūsų tyrimas parodė didelę KNT matavimų diagnostinę gebą įvairiems parametrams bei gerą suderinamumą su kardiologų atliktais vertinimais. Svarbiausia, kad buvo įrodyta modelio geba klasifikuoti diastolinės disfunkcijos laipsnius gana tiksliai. Šie rezultatai rodo, kad DI ir giliojo mokymosi modeliai gali labai pagerinti kairiojo skilvelio diastolinės funkcijos vertinimo tikslumą ir efektyvumą.

Visiškai automatizuotas aortos šaknies ir kylančiosios aortos vertinimas, atliekant įprastinę 2D TTE, labai padeda diagnozuoti ir stebėti daugumą aortos ligų. Gydytojai, kurie anksčiau neturėjo pakankamai laiko įvertinti aortą, dabar gali tai atlikti naudodami DI paremtą programinę įrangą. Be to, mūsų rezultatai buvo įvertinti naudojant „nuo pradžios iki pabaigos“ metodą, kai automatizuota sistema turi atlikti echokardiografinio vaizdo atpažinimą, širdies ciklo identifikavimą, segmentaciją, anatominių orientyrų nustatymą ir galiausiai apskaičiuoti aortos matavimus. Priešingai, daugelyje publikacijų apie DI echokardiografijoje dažnai vertinamas tik vienas izoliuotas uždavinys, pavyzdžiui, klasifikacija ar segmentacija, – pateikiami tikslumo rodikliai, kurie nebūtinai gerai pritaikomi klinikinėje praktikoje.

Pastangos automatizuoti aortos matavimus 3D stemplinėje echokardiografijoje, priešingai nei 2D TTE, jau yra išsamiai aprašytos. Pavyzdžiui, Zhang ir bendraautoriai automatiškai įvertino aortos šaknies matavimus 67 pacientams naudodami papildomą vaizdų apdorojimo programinę įrangą ir palygino juos su daugiasluoksne kompiuterine tomografija – nustatė plačią koreliacijos verčių amplitudę ($r = 0,47\text{--}0,88$) [119]. Beneduce ir bendraautoriai palygino pusiau automatizuotą aortos vožtuvo angos ploto apskaičiavimą su kompiuterine tomografija ir nustatė puikią koreliaciją ($r = 0,936$) [120]. 3D echokardiografijos automatizavimo galimybės greitai tobulėja, tačiau dėl brangios įrangos ir sudėtingo vertinimo 3D stemplinė echokardiografija kasdienėje praktikoje tebėra ribotai naudojama [121]. Palyginę automatizuoto metodo pritaikymą, tikslumą ir atkartojamumą su įprastiniais žmogaus matavimais, įrodėme, kad automatizuotas metodas nėra blogesnis už žmogaus atliktą analizę, tačiau turi akivaizdų pranašumą – visiškai automatizuotą ir atkartojamą matavimų pobūdį. Kiek žinoma, šiuo metu yra vos keletas kliniškai prieinamų programinės įrangos sprendimų, skirtų visiškai automatizuotiems aortos matavimams 2D TTE priekrūtinkaulinėje ilgosios ašies projekcijoje.

Šis tyrimas yra vienas pirmųjų daugiacentrių tyrimų, kuriame vertintas DI pagrįstos MM ir GNT sistemos veikimas, atliekant širdies ertmių tūrinį vertinimą farmakologinio KE metu. Įtraukus penkių centrų duomenis, rezultatai parodė, kad DI pagrįstai tūrio analizei būdingas didelis atkartojamumas, palyginti su ekspertų kardiologų atliktais matavimais, ypač vertinant KS ir KP tūrius. Šis tyrimas rodo DI gebėjimą automatizuoti ir standartizuoti ertmių vertinimą atliekant KE – suteikiamas galimas sprendimo būdas dabartiniams tradiciniams KE iššūkiams.

Širdies ertmių tūrio vertinimas, atliekant KE, vis labiau pripažįstamas kaip vertingas diagnostikos algoritmų papildymas. Fiksuojant KS ir KP tūrio pokyčius, KE suteikia detalią informaciją apie bendrą sistolinę ir diastolinę funkcijas [36, 101]. Padidėję KS tūriai krūvio metu gali rodyti sumažėjusį

kontraktilinį rezervą, o padidėjęs KP tūris yra lėtinio padidėjusio užpildymo slėgio žymuo, dažnai susijęs su diastoline disfunkcija ir nepalankiomis prognozėmis [101, 122]. Neatsižvelgiant į galimybes, DI taikymas tūrinei analizei KE metu tebėra ribotas. Ankstesni tyrimai įrodė KNT tinklų galimybes atlikti tūrio analizę naudojant ramybės echokardiografiją. Tromp ir kt. atliko kelis tyrimus, kuriuose nustatytos stiprios koreliacijos ir KS ir KP tūrių matavimų > 87 proc. parametrų rodikliai – panašius rezultatus nustatė ir mūsų tyrimas, apimantis ramybės ir krūvio fazes [6, 84]. Kitame tyrime, atliktame miokardo infarkto, kai S–T segmentas pakilęs, pacientams buvo pristatyta DI pagrįsta sistema KS tūriams, BIĮ ir KP tūriui vertinti; nustatyta stipri koreliacija su rankiniais matavimais ($r = 0,81-0,92$) [123]. Myhre ir kt. nustatė, kad DI gauti KS ir KP tūrių matavimai reikšmingai sumažino kintamumą tarp tyrėjų ir išlaikė panašų tikslumą kaip ir žmogaus atlikti vertinimai ($r = 0,89$ KSGDT, $r = 0,92$ KSGST) [124]. Analogiškai mūsų tyrimas patvirtino didelį suderinamumą su tyrėjų KS ir KP tūrių nustatytais duomenimis – pabrėžiamas DI patikimumas tiek ramybės, tiek krūvio fazėse.

Dauguma ankstesnių tūrinės analizės tyrimų buvo sutelkti į ramybės echokardiografiją, tačiau mūsų rezultatai parodė šių parametrų vertinimo krūvio metu sudėtingumą ir privalumus. Aukštos kokybės vaizdų išlaikymas krūvio metu yra itin svarbus, nes tai užtikrina patikimus ir tikslus tūrio matavimus, prilygstančius ramybės sąlygoms. VKK nustatytas puikus atitikimas, suderinamumo riba (SR) atskleidė, kad kai kuriais atvejais KS tūrio skirtumai tarp DI ir žmogaus vertinimų yra didesni kaip 35 ml. Tokie neatitikimai gali turėti klinikinę reikšmę, ypač kai yra ribinės vertės. Vertinat KS tūrius DI stipriai koreliavo su ekspertais, tačiau KSIF atitikimas buvo tik vidutinis. Ši neatitikimą greičiausiai lėmė paklaidų kaupimasis, nes KSIF yra išvestinis parametras, labai jautrus net mažiausiems KSGDT ir KSGST skirtumams. Tai pabrėžia ekspertinio vertinimo svarbą, ypač neaiškiais atvejais.

KE išsūkia apima priklausomybę nuo tyrėjo, blogas akustines sąlygas, suboptimalią vaizdų kokybę ir ilgai trunkančius procesus. Olaisen ir kt. nustatė, kad realiojo laiko (tikralaikio) DI integracija ramybės echokardiografijoje gali sutrumpinti vaizdų įrašymo ir analizės laiką iki 77 proc., nesumažinant tikslumo [74]. Mor-Avi ir kt. nustatė, kad net pradedantieji tyrėjai, naudodamiesi DI pagalbinėmis sistemomis, gali įrašyti aukštos kokybės vaizdus, prilygstančius ekspertų atliktiems, o tai rodo DI gebą sumažinti priklausomybę nuo didelės specializuotos patirties KE srityje [125]. Bloga vaizdo kokybė siejama su didesniu kintamumu ir mažesniu diagnostiniu tikslumu. Mūsų tyrimas, kaip ir kiti šios srities, pabrėžė suboptimalios kokybės įtaką diagnostikos tikslumui ir suderinamumui su ekspertais [116]. Pastebėta, kad optimalios kokybės vaizdai ne visada padidino tikslumą galbūt dėl to, kad mokymo duomenų bazę daugiausia sudarė geros ar patenkinamos kokybės

vaizdai. Didelė gerų / optimalių KS vaizdų dalis mūsų duomenų rinkinyje iš dalies atspindi ekspertinę kadrų atranką – tai nebūtinai atspindi realią klinikinę praktiką, kur dažnai pasiekama patenkinama kokybė. Ateities tyrimuose DI algoritmai turėtų būti dar labiau optimizuojami darbui su prastos kokybės vaizdais.

DI taikymas IŠL diagnostikai, naudojant KE, suteikė viltingų rezultatų, ypač ligos nustatymo ir rizikos prognozavimo srityse [126]. Upton ir kt. padarė išvadą, kad DI modeliai padidino jautrumą ligai nustatyti 10 proc., palyginti su tradicine KE interpretacija [4]. O'Driscoll ir kt. įrodė, kad DI pagrįsti KSIF ir BIĮ vertinimai reikšmingai pagerino IŠL diagnostiką, jei buvo derinami su tradiciniu sienelių susitraukiamumo (kontrakcijos) vertinimu [127]. PROTEUS tyrimas, nors ir nepasiekta neprastesnio tikslumo, palyginti su ekspertų vertinimu, parodė, kad DI galima naudoti centruose, turinčiuose mažesnę patirtį ir atliekančiuose mažiau tyrimų [127, 128]. Šie rezultatai pabrėžia DI pritaikymo KE galimybes, ypač ribotų išteklių centruose.

Mūsų tyrimo duomenimis, DI pagrįstą tūrio vertinimą farmakologinės KE metu galima naudoti gydymui – užtikrinami patikimi matavimai, artimi ekspertų interpretacijai. Kitas žingsnis turėtų būti šios technologijos pritaikymas fizinio krūvio KE, kuri gairėse rekomenduojama kaip pirmaeilė metodika dėl fiziologinio aspekto ir didesnės prognozinės vertės. Atsižvelgiant į papildomus techninius iššūkius fizinio krūvio metu, tokius kaip judesio artefaktai, būtina validuoti DI veikimą šioje aplinkoje, kad būtų užtikrintas platesnis klinikinis pritaikomumas.

6. TYRIMO RIBOTUMAI

6.1. Diastolinės funkcijos ir aortos parametrų vertinimo ribotumai

Dauguma kohortos pacientų buvo priskirti prie pacientų, kuriems buvo normali diastolinė funkcija arba pirmojo laipsnio diastolinė disfunkcija, todėl nepakankamai reprezentuota pacientų, kuriems buvo sunkesnis diastolinės disfunkcijos laipsnis. Visi pacientai turėjo gerą KSIF (>50 proc.). Šie apribojimai galėjo turėti įtakos DI modelio patikimumui ir platesniam naudojimui. Be to, mūsų tyrime nebuvo atliktas patvirtinimas naudojant auksinio standarto metodus, pvz., invazinę dešinėsios širdies kateterizaciją. Šio lyginamojo patvirtinimo nebuvimas riboja galimybes gauti išsamesnių įžvalgų apie DI galimybes aptikti KSDD ir prognozuoti rezultatus. Kitas apribojimas yra tas, kad tyrimas buvo atliktas viename centre, todėl gali atsirasti su centru susijusių šališkumų ir apriboti rezultatų pritaikymą kituose centruose. Be to, echokardiografinius vertinimus atliko vienas ekspertas, o tai riboja vertintojų tarpusavio kintamumo ir DI bei gydytojų sutarimo patikimumo vertinimą. Vertintojas ekspertas turėjo prieigą prie klinikinės informacijos, kuri galėjo turėti įtakos interpretacijai ribiniuose tyrimuose. Svarbu pažymėti, kad nors gana daug pacientų tyrime turėjo padidėjusias aortos šaknis, tikėtina, kad algoritmų tikslumas sumažėtų esant labai išsiplėtusiai aortai, kurios skersmuo > 60 mm, nes jos nebuvo mokomųjų duomenų rinkinyje.

6.2. Kairiojo skilvelio ir prieširdžio parametrų vertinimo ramybės ir krūvio metu ribotumai

Daugiacentrio tyrimo dizainas leidžia įvertinti platesnį pritaikomumą, tačiau imties dydis išlieka ribotas, todėl norint patvirtinti šiuos rezultatus, reikia atlikti tolimesnius tyrimus su didesnėmis grupėmis. Antra, DI analizė apsiribojo žmonių ekspertų pasirinktais vaizdo kadrais, o tai galėjo įtakoti šališkumą ir pervertinti DI bei žmonių matavimų atitikimą. Kiekvieną tyrimą analizavo vienas vertintojas, ir rezultatai gali skirtis, jei dalyvavo keli vertintojai. Tačiau visi vertintojai buvo patyrę, sertifikuoti ir dalyvavo papildomuose mokymuose, užtikrinant tyrimo nuoseklumą visuose centruose. Daugeliu atvejų naudotas dipiridamolis, todėl vertinimas su kitomis farmakologinėmis medžiagomis arba fiziniu krūviu yra ribotas. Galiausiai, šiame tyrime daugiausia dėmesio skirta tūriniams parametrams, neįtraukiant potencialiai vertingų rodiklių, tokių kaip bendroji išilginė įtampa ir vainikinių arterijų kraujotakos rezervas, kurie turi įrodytą potencialą diagnozuojant vainikinių arterijų ligą. Būsimuose tyrimuose reikėtų ištirti šių parametrų integravimą į DI pagrįstą KE analizę.

IŠVADOS

1. Pilnai automatizuotas GNT modelis dideliu tikslumu įvertino KS diastolinės funkcijos vertinimo parametrus su gera visų parametų diagnostinė geba (73–100 proc.) ir vidutine-stipria koreliacija lyginant su tyrėju ($r = 0,55\text{--}0,94$). DI modelis pakankamai tiksliai klasifikavo ir nustatė KSDD laipsnį, ypač normos atvejus (90,57 proc.) ir sunkiausią disfunkcijos laipsnį (restrikciją) (75,00 proc.).
2. Vertinant aortos parametrus, GNT modelis parodė geriausią tikslumą ir stipriausią koreliaciją matuojant AoŽ ir AoS (atitinkamai $r = 0,78$ ir $0,86$). STJ ir KAo vertinimai turėjo vidutinę koreliaciją su tyrėjais (atitinkamai $r = 0,69$ ir $0,67$).
3. KS ir KP tūrių vertinimas ramybėje ir krūvio metu, naudojant GNT ir MM modelius, parodė aukštą diagnostinę gebą (75–98 proc.) ir stiprią koreliaciją su ekspertais ($r = 0,84\text{--}0,93$). KSIF vertinimas turėjo mažesnę tikslumą, sutapimą ir koreliaciją su ekspertais (VKK svyravo nuo 0,6 iki 0,77).
4. Tyrimas parodė, kad ramybėje ir krūvio metu geros arba optimalios kokybės vaizdų matavimai buvo tikslesni palyginti su tais, kurie buvo įvertinti kaip prastos arba patenkinamos kokybės, tačiau pastarųjų vaizdų matavimai vis tiek pateko į pakankamai gero atitikimo diapazoną (esant gerai arba optimaliai kokybei VKK svyravo nuo 0,91 iki 1,00, prastai arba patenkinamai kokybei – nuo 0,83 iki 0,96). Tai parodo, kad DI modeliai gali būti pritaikomi įvairios kokybės echokardiografijos vaizdų analizei.

PRAKTINĖS REKOMENDACIJOS

1. Pilnai automatizuotų DI algoritmų panaudojimas diastolinės funkcijos parametrų vertinimui leidžia sumažinti rankinio darbo kiekį ir atlikti juos tokiu pačiu kaip kardiologas tikslumu. GNT algoritmai gali reikšmingai padėti kasdieniame klinikiame darbe klasifikuojant KS diastolinės funkcijos laipsnį, ypač pakankamai tiksliai atskiriant normos atvejus ir restrikcinę diastolinę disfunkciją.
2. Automatizuotas aortos parametrų vertinimas leidžia, taip pat, sumažinti rankinį darbą ir skirtingų tyrėjų įtaką matavimų atlikimui. Tai ypač svarbu vertinant aortos parametrus dinamikoje, esant aortos dilatacijai. Įrodytas pakankamai tikslus DI paremtas aortos žiedo matavimas gali reikšmingai prisidėti prie aortos vožtuvo stenozės tikslaus vertinimo ir stebėjimo dinamikoje.
3. Tyrimas parodė, kad automatizuotas KS ir KP tūrių vertinimas gali būti pritaikytas kasdienėje farmakologinio KE taikymo procedūroje. Šis DI pritaikymas leidžia įvertinti ne tik regioninius KS kontrakcijos sutrikimus, bet ir objektyvius tūrinius pokyčius. Tikslingi tolimesni tyrimai leidžiantis DI metodų pritaikomumą su įvairiomis farmakologinėmis medžiagomis bei fiziniu krūviu.
4. DI metodai iki šiol daugiausia naudoti tik su labai geros kokybės ultragarsiniais vaizdais. Šis tyrimas ir naudoti DI modeliai parodė, kad DI gali būti pritaikytas įvairios kokybės ultragarsiniams vaizdams reikšmingai neprarandant vertinimo tikslumo. Tai gali labai padėti sumažinti klaidų riziką, ypač mažiau patyrusiems vertintojams.

SUMMARY

ABBREVIATIONS

AAo	–	ascending aorta
AI	–	artificial intelligence
AoA	–	aortic annulus
AoS	–	aortic sinus
ASE	–	American Society of Echocardiography
CNN	–	convolutional neural network
EACVI	–	European association of cardiovascular imaging
ICC	–	Intraclass Correlation Coefficient
HF	–	heart failure
ML	–	machine learning
LA	–	left atrial
LAVI	–	left atrial volume index
LoA	–	limits of agreement
LV	–	left ventricular
LVDD	–	left ventricular diastolic dysfunction
LVEDV	–	left ventricular end-diastolic volume
LVESV	–	left ventricular end-systolic volume
LVEF	–	left ventricular ejection fraction
DNNs	–	deep neural networks
PACS	–	picture archiving and communication system
RMSE	–	root mean square error
SE	–	stress echocardiography
SE2030	–	Stress Echo 2030
STJ	–	sinotubular junction
TNR	–	true negative rate
2D TTE	–	two-dimensional transthoracic echocardiography

INTRODUCTION

Heart Failure (HF) remains one of the most significant public health challenges, associated with high morbidity, mortality, and substantial health-care costs. The 2021 European Society of Cardiology guidelines recommend echocardiography as the first-line imaging modality in HF diagnostics, as it allows for simultaneous assessment of left ventricular (LV) systolic and diastolic function, valvular status, and hemodynamics [1]. Although HF prevalence has stabilized in some countries, the global number of patients continues to increase due to population aging and improved survival following acute cardiac events (e.g., myocardial infarction). Recent estimates indicate an HF prevalence of approximately 1–3% in the general population, accounting for tens of millions of affected individuals worldwide [2, 3].

Diagnostics are becoming increasingly complex: the large number of

investigations, operator dependence, and interobserver variability drive the need for automated solutions. In recent years, deep learning techniques have been rapidly integrated into this field – from image quality control and view classification to chamber segmentation, volume calculation, left ventricular ejection fraction (LVEF) estimation, wall motion, and valvular flow assessment. Studies and publications in *JACC* in 2023 emphasized that deep neural networks (DNNs) can reduce workload and improve diagnostic accuracy, provided that image quality is high and algorithms are properly validated [4, 5].

LV diastolic function is particularly suitable for automation, as its assessment requires integration of multiple two-dimensional transthoracic echocardiography (2D TTE) and Doppler parameters. Studies from multiple countries published in 2022 demonstrated that DNNs can automatically interpret echocardiographic images and Doppler signals to identify systolic and diastolic dysfunction with accuracy comparable to that of expert readers. Subsequently, studies published in 2024 have already demonstrated semi- or fully automated evaluation of diastolic function in real patient cohorts [6, 7]. The 2025 update of the American Society of Echocardiography (ASE) recommendations for diastolic function assessment emphasizes a standardized, multiparametric, integrative approach, providing a solid foundation for the clinical validation of artificial intelligence (AI) tools [8].

It is well established that HF may coexist with vascular comorbidities. Changes in aortic root and ascending aorta dimensions are common in hypertension and aging, making structural aortic analysis important in the context of HF comorbidity. AI applications in this domain are also expanding. Publications in 2023 demonstrated the potential of deep learning models to automatically assess aortic-related echocardiographic dimensions, such as the LV outflow tract diameter. Meanwhile, 2024 reviews summarized algorithms capable of automatically measuring several aortic diameters [9, 10]. Some of these solutions are still being validated using computed tomography datasets; however, the trend is clear – direct validation in echocardiography, based on guideline-defined standardized measurement principles, is increasingly pursued [9, 10].

AI implementation is also extending beyond resting echocardiography to include stress echocardiography (SE). Early studies indicate that AI models may assist in detecting subtle wall motion abnormalities, accelerate view recognition, and standardize reporting; however, few widely adopted algorithms currently exist [5, 6].

Despite these advances, key gaps remain: most models lack multicenter, prospective, and device-diverse external validation; direct comparisons with expert measurements and analyses of clinical impact are often missing. Reviews published in 2024–2025 emphasize the importance of responsible use of early-stage AI systems involved in decision-making (e.g., CONSORT-AI/

DECIDE-AI) and advocate for integrating AI into clinical workflows in a way that ensures expert verification of measurements and rigorous quality control of input data [4, 9]. This context provides the foundation for the present study, which aims to evaluate the feasibility, applicability, and accuracy of AI-based echocardiographic analysis of HF and aortic parameters in real-world clinical practice.

Aim

To apply DNNs and evaluate their capabilities and accuracy for automated echocardiographic diagnosis of heart failure and aortic changes at rest and during stress.

Objectives

1. To evaluate the accuracy and correlation with experts of DNNs in automated assessment of LV diastolic function parameters and in classifying diastolic dysfunction.
2. To evaluate the accuracy and correlation with experts of DNNs in automated assessment of aortic root and ascending aorta diameters.
3. To evaluate the accuracy and correlation with experts of DNNs in automated assessment of LV and left atrial (LA) volumes and LV systolic function at rest and during stress.
4. To evaluate the accuracy and applicability of DNNs in evaluating echocardiographic images of different quality at rest and during stress.

Scientific novelty of work

This study included a total of over 500 patients, from a total of 6 different centers around the world, analyzed over 5000 two-dimensional echocardiographic images and stood out from other studies with the following features:

- For the first time, the applicability and accuracy of AI has been tested for such a wide range of 2D TTE parameters in standard resting echocardiography and during stress echocardiography:
 - Key parameters for assessing LV diastolic function;
 - Parameters of the aortic root and ascending aorta;
 - Parameters of LV and LA volumes and LV systolic function during rest and stress.
- This is one of the first studies in the world in which AI has been tested in the analysis of pharmacological stress echocardiography.
- One of the first studies in which AI has been applied to the applicability and analysis of echocardiographic images of different quality.
- Until now, there have been very few AI-based 2D TTE studies that used a fully automated workflow, i.e. from image, cycle, frame

selection to measurement performance, their evaluation and presentation of the initial conclusion.

- To maintain a critical and accurate assessment of the AI, its performance was compared with the evaluations of 2D TTE results performed by experts.

MATERIAL AND METHODS

General study stages and criteria

The study was conducted in 3 stages:

1. During the first stage, patients were included in the study and underwent a routine cardiological examination (clinical patient assessment, laboratory tests, imaging studies – 2D TTE examination and, if indicated, stress echocardiography, computed tomography angiography and cardiac magnetic resonance). All patients signed an informed consent.
2. During the second stage, the patients' 2D TTE resting and stress images obtained were analyzed using machine learning (ML) and DNNs (convolutional networks (CNN) and their different architectures (M-RCNN, YOLO, ResNet) and transformer networks (TransFuse) were applied). The number of layers in the neural network architectures varied from 335 to 1054. A duplicate dataset was created for image quality assessment.
3. During the third stage, data analysis was performed. The obtained imaging data were analyzed and the applicability and accuracy of DNNs for calculating aortic, LV and LA volumes, HF parameters and determining echocardiographic diagnosis of HF were assessed. The results of the neural networks were compared with the assessments made by cardiologists.

General criteria for inclusion of subjects in the study:

1. Adults (18 years and older) men and women who are scheduled to undergo transthoracic 2D TTE for various indications. Subject selection period: 2021.09–2024.09.

General criteria for exclusion from the study:

1. Anatomical and functional characteristics of the heart that would interfere with automated analysis of echocardiographic images using DNNs.
2. Hemodynamically significant congenital heart disease or previous surgical correction of a heart defect.
3. Implanted cardiac devices: any type of pacemaker, cardioverter-defibrillator, cardiac resynchronisation device.
4. Atrial fibrillation or flutter during echocardiographic examination.

Methodology for the assessment of aortic and left ventricular diastolic parameters

Study population

This prospective study included 302 participants, comprising a total of 4,120 two-dimensional echocardiographic images. The subjects were examined at the Hospital of the Lithuanian University of Health Sciences Kauno klinikos (Kauno klinikos), where each underwent a 2D TTE between October 1, 2021, and July 10, 2024. The study was approved by the Lithuanian Bioethics Committee (No. L-21-09/1).

Inclusion criteria:

1. Adults (>18 years old) presenting with sinus rhythm during the examination and reporting dyspnea.

Exclusion criteria:

1. Patients with a reduced LVEF (<50%);
2. Patients with atrial fibrillation or atrial flutter;
3. Patients with hemodynamically significant structural heart disease;
4. Patients with implanted cardiac devices.

Two-dimensional echocardiography and automated analysis

Echocardiographic imaging was performed using *GE Vivid E9*, *Philips Affiniti 70*, and *Philips EPIQ 7* ultrasound systems. All studies were anonymized and transferred from the hospital's Picture Archiving and Communication System (PACS) in DICOM format to the *Ligence Heart* server through a secure local network. Each study underwent both manual and automated analysis. Automated measurements were performed using the fully automated *Ligence Heart* software (version 3.32.0; UAB Ligence). The software replicated the sequence of analytical steps typically performed by a cardiologist: identifying appropriate image views, determining cardiac cycles, selecting optimal frames, and performing measurements of aortic structures (aortic annulus in mid-systole; sinuses of Valsalva, sinotubular junction, and ascending aorta at end-diastole) as well as left ventricular diastolic function parameters (Table 1). The cardiac cycle was defined based on LV dimensional changes, and measurements were derived using segmentation algorithms and anatomical landmark detection. During DICOM image processing, convolutional and transformer-based neural networks classified echocardiographic planes, identified the cardiac cycle phase, and selected suitable frames for quantitative assessment. A hybrid neural network ensemble subsequently executed segmentation and landmark localization to generate annotations used for parameter computation. Manual measurements were performed independently by an expert cardiologist.

Table 1. *Echocardiographic measurements in LV diastolic function evaluation*

Measurements	Variable
Blood flow through the mitral valve captured by pulsed wave Doppler	Early diastolic filling wave velocity (E)
	Late diastolic filling wave velocity (A)
	Ratio of early to late diastolic filling wave velocities (E/A)
	Deceleration time of early diastolic filling wave velocity
Blood flow through the tricuspid valve captured by continuous wave Doppler	Maximum tricuspid regurgitation velocity
Movement velocity of the mitral annulus captured by pulsed tissue Doppler:	Maximum early mitral annulus lateral segment movement velocity (Le')
	Maximum early mitral annulus septal segment movement velocity (Se')
	Ratio of early diastolic filling wave to maximum early mitral annulus movement velocities (E/e')
Apical four-chamber view	Left atrial end-systolic volume
	Left atrial end-systolic area
	Left atrial volume index (LAVI)
Apical two-chamber view	Left atrial end-systolic volume
	Left atrial end-systolic area
	Left atrial volume index (LAVI)

Diastolic function assessment followed the algorithmic approach recommended in the 2016 ASE and European Association of Cardiovascular Imaging guidelines, applying the specified combination of diagnostic parameters [8]. The artificial intelligence model operated solely on imaging data and was not linked to manual measurements or any clinical variables. Importantly, AI-based and manual evaluations were conducted independently. Spectral Doppler images consisted of single frames, requiring the AI system to first identify the image type and then perform relevant measurements. In contrast, two-dimensional echocardiographic recordings contained multiple frames, necessitating an additional step to accurately determine the cardiac cycle. Figure 1 illustrates manual and automated measurements of LV diastolic function parameters, while Figure 2 depicts corresponding manual and automated aortic measurements.




Figure 1. Automated (left) and manual (right) measurements of LV diastolic function parameters

(A) Early diastolic filling wave velocity (E) and late diastolic filling wave velocity (A); (B) maximum early mitral annulus lateral segment movement velocity (Le'); (C) left atrial volume (LAV); (D) maximum tricuspid regurgitation velocity.




Figure 2. Automated (left) and manual (right) assessment by expert cardiologist of aortic measurements

(A) aortic annulus (AoA) measurements in mid-systole; (B) aortic sinus (AoS) and sinotubular junction (STJ) measurements in end-diastole; (C) proximal ascending aorta (AAo) measurements in end-diastole.

Statistical analysis

The accuracy of the AI model – built upon a combination of different architectures (YOLO, ResNet, M-RCNN, and TransFuse) – was evaluated by comparing automated and manual echocardiographic measurements used in the assessment of aortic dimensions and LV diastolic function. The **yield** represents the percentage of cases in which the AI system successfully and

correctly reproduced a measurement that was also performed by the cardiologist. The **root mean square error (RMSE)** quantifies the average deviation between AI-generated and manually obtained values, calculated as the square root of the mean of squared differences between predicted and actual measurements. Lower RMSE values indicate a closer agreement between the model's output and the reference data. The **bias** reflects the model's systematic tendency either to overestimate or underestimate the measurements. It was calculated as the mean difference between predicted and observed values. A positive bias denotes overestimation by the AI model, whereas a negative bias indicates underestimation. The **limits of agreement (LoA)** describe the typical range of variability between manual and automated measurements and were determined using the formula: $bias \pm 1.96 \times standard\ deviation$. The **Pearson correlation coefficient (r)** was used to assess the strength of linear agreement between the two measurement methods. Correlations were classified as weak ($r < 0.3$), moderate ($0.3 \leq r \leq 0.7$), or strong ($r > 0.7$). Collectively, these statistical indicators characterize both the accuracy and clinical reliability of the AI model. A p -value < 0.05 was considered statistically significant. All analyses were conducted using *Python* software (version 3.10).

For the classification of LV diastolic dysfunction (LVDD) and the evaluation of AI model performance, several statistical metrics were employed:

- **Precision**, defined as $true\ positives / (true\ positives + false\ positives)$, representing the proportion of correctly identified positive cases among all cases predicted as positive;
- **Accuracy**, defined as $true\ positives / (true\ positives + false\ positives + false\ negatives)$, representing the overall rate of correct predictions;
- **True negative rate (TNR)**, reflecting the model's ability to correctly identify healthy (non-pathological) individuals;
- **Recall**, indicating the proportion of actual positive cases correctly detected by the model;
- **F1-score**, a harmonic mean of precision and recall, used to capture the balance between these two measures.

Methodology for the assessment of left ventricular and atrial parameters during rest and stress echocardiography

Study population

This part of the study was based on a multicenter cohort including five accredited international sites (three in Italy, one in Argentina, and one in

Poland), all of which also participated in the StressEcho 2030 (SE2030) project. The study involved 240 participants who underwent pharmacological stress echocardiography (SE) between November 1, 2023, and June 21, 2024. The overall period reflects the duration of the multicenter investigation, while patient enrollment at each site was restricted to predetermined intervals (up to one month per center). Recruitment was conducted in accordance with the SE2030 inclusion protocol [44].

Eligible participants were adults (aged >18 years) with clinical indications for pharmacological SE to evaluate inducible ischemia in the context of known or suspected ischemic heart disease.

Exclusion criteria:

- Poor resting image quality;
- Clinically significant valvular or congenital heart disease;
- Atrial fibrillation or atrial flutter;
- Implanted cardiac devices;
- Non-cardiac conditions with major prognostic relevance, such as advanced malignancy, end-stage renal disease, or severe obstructive pulmonary disease.

The study protocol was approved by institutional ethics committees as part of the broader SE2030 trial (Ethics approval Nos. 291/294/295, Comitato Etico Lazio-1, March 8, 2021). All participants provided written informed consent prior to inclusion.

Two-dimensional rest and stress echocardiography and automated analysis

Stress echocardiography was performed using ultrasound systems from different manufacturers. In total, 228 patients (95%) underwent dipyridamole SE and 12 patients (5%) received dobutamine SE. No exercise-based protocols were applied. All analyses were performed on non-contrast images, and the examinations were completed in accordance with current guideline criteria [38]. Image data were exported in DICOM format, anonymized, and subsequently analyzed. Each study was reviewed by a cardiologist trained in SE, who selected apical four-chamber and two-chamber views at both rest and stress phases. The cardiologists identified and labeled end-systolic and end-diastolic frames, then delineated the endocardial borders of the LA at end-systole and the LV at both end-systole and end-diastole. The same paired end-systolic and end-diastolic frames were processed and evaluated by AI algorithms trained on an independent image dataset. Each evaluator (the cardiologist and the AI system) performed the measurements independently and

without knowledge of the other's results. Both manual and automated assessments were conducted using the same software (*Ligence Heart*).

The AI model had been trained on a large, independent multicenter dataset consisting of 21,539 patient studies and 24,632 annotated apical four- and two-chamber echocardiographic views from centers in Germany, France, Lithuania, and the United States. None of the subjects from the current cohort were included in the training dataset, ensuring full external validation.

Assessment of two-dimensional echocardiographic image quality

For image quality evaluation, a duplicate dataset was created. Following the guidelines of the EACVI [111], image quality was categorized into four levels: optimal, good, fair, or poor (Figure 3). An expert cardiologist, blinded to all measurement results, assessed the visibility and clarity of all cardiac chambers (left and right ventricles and atria) in the previously selected end-diastolic and end-systolic frames. The cardiologist's sole task was to rate image quality in the preselected frames. Subsequently, another investigator – also blinded to previous evaluations – assessed the specific quality of LV and LA images. Each chamber's image quality in both end-diastolic and end-systolic frames was classified into the same four categories: optimal, good, fair, or poor.




Figure 3. *Quality grades of left ventricle apical four-chamber view*
(A) poor; (B) fair; (C) good; (D) optimal.

Statistical analysis

Descriptive statistics were used to summarize participant characteristics. Paired *t*-tests or Wilcoxon signed-rank tests were applied to compare variables between rest and stress conditions. Statistical significance was defined as $P < 0.05$. Missing data for selected clinical variables were handled by calculating percentages based on available cases. All statistical computations were performed using *Python* software (version 3.10).

Further assessment included calculation of the **Intraclass Correlation Coefficient (ICC)** using a two-way mixed-effects model with fixed raters to quantify the degree of agreement between AI-based and human-derived measurements. The within-patient coefficient of variation was used to evaluate intra-individual measurement variability. In addition, **Bland–Altman analysis** was performed to examine bias and determine the limits of agreement between manual and automated measurements. This method allowed detection of any systematic deviations and provided an overall evaluation of concordance between AI and human assessments, indicating the range within which most differences are expected to occur and offering a comprehensive perspective on AI performance.

RESULTS

Results of aortic and left ventricular diastolic parameter assessment

Study population characteristics

A total of 302 participants were included in this prospective study, all of whom underwent 2D TTE in an outpatient setting. All subjects were of Caucasian ethnicity, and 58.3% ($n = 176$) were female. The mean LVEF was $54.72 \pm 2.5\%$, while the average age of participants was 60.07 years. Most individuals presented with at least one comorbid condition: 76.2% had arterial hypertension, and 43.0% were diagnosed with ischemic heart disease. Among these, 10.6% had a history of myocardial infarction, and 13.9% had previously undergone percutaneous coronary intervention. Paroxysmal atrial fibrillation was present in 9.6% of participants, 7.9% had pulmonary diseases (including asthma and chronic obstructive pulmonary disease), and 13.6% reported a history of malignancy. A detailed overview of the study population characteristics is provided in Table 2.

Table 2. *Study population clinical characteristics*

Clinical characteristics	Value
Age, years	60.07 ± 16.14
Height, cm	169.94 ± 9.63
Weight, kg	79.74 ± 18.06
BMI, kg/cm ²	27.50 ± 5.25
Ejection fraction, %	54.72 ± 2.50
Patients	302
Female	58.3% (176)
Male	41.7% (126)
History of % (n)	
Arterial hypertension	76.2% (230)
Coronary heart disease	43.0% (130)
Myocardial infarction	10.6% (32)
Percutaneous coronary intervention	13.9% (42)
CABG	1.3% (4)
Paroxysmal AF	9.6% (29)
Lung diseases (asthma and COPD)	7.9% (24)
Cancer	13.6% (41)
Aortic root dilatation	16.2% (49)
Ascending aorta dilatation	17.5% (53)

BMI – body mass index, CABG – coronary artery bypass grafting, COPD – chronic obstructive pulmonary disease.

Results of automated diastolic function parameter assessment

The AI model demonstrated excellent accuracy across all spectral Doppler parameters related to diastolic function, including mitral inflow velocities (E, A, and the E/A ratio) as well as mitral annular velocities and their derived ratios (Le', Se', E/e', E/Le', and E/Se'). When evaluating the E-wave velocity and the E/A ratio, strong correlations were observed between AI-derived and manually obtained measurements ($r = 0.93$ and 0.94 , respectively), indicating a high degree of agreement. The A-wave velocity also correlated well ($r = 0.88$), confirming the model's precision in assessing mitral inflow parameters.

Tissue Doppler measurements yielded similarly robust results. The AI-derived Le', Se', and E/e' velocities showed strong linear correlations with manual measurements ($r \geq 0.87$). Ratios such as E/Le' and E/Se' exhibited slightly lower but still substantial correlations ($r = 0.89$ and $r = 0.75$, respectively). No systematic bias was detected in the evaluation of these Doppler-derived parameters, and the LoA between automated and manual measurements were narrow, reflecting clinically acceptable variability (Table 3).

Table 3. Comparison of automated and manual echocardiographic diastolic parameters

Measurement	N	Yield, %	RMSE	Bias	Lower LoA	Upper LoA	Pearson r
LAVi	70	73	12.25	7.11	−12.62	26.85	0.92
LAA2A	91	95	2.91	1.12	−4.16	6.41	0.88
LAV2A	91	95	16.79	5.95	−25.00	36.89	0.84
LAA4A	238	82	2.85	1.11	−4.05	6.27	0.86
LAV4A	238	82	13.47	5.56	−18.54	29.66	0.87
E	218	100	6.97	0.64	−12.99	14.28	0.93
A	221	100	8.94	2.29	−14.68	19.26	0.88
E/A	217	100	0.14	−0.04	−0.30	0.22	0.94
Le'	204	100	1.85	0.11	−3.52	3.74	0.87
Se'	215	100	1.36	0.21	−2.43	2.84	0.89
E/e'	196	100	1.58	−0.11	−3.21	3.00	0.87
E/Le'	196	100	1.33	−0.10	−2.70	−2.50	0.89
E/Se'	196	100	3.15	−0.15	−6.33	6.03	0.75
Dec	175	100	34.92	5.50	−62.28	73.27	0.61
TRPG	243	100	8.12	1.94	−13.54	17.43	0.56
PTRV	259	100	0.43	0.12	−0.69	0.93	0.55

N – number of studies; RMSE – root mean square error; LowerLoA – lower limit of agreement; UpperLoA – upper limit of agreement; LAVi – left atrium volume index; LAA – left atrium area; 2A – apical two-chamber view; 4A – apical four-chamber view; Dec – deceleration time of early diastolic filling wave velocity; TRPG – tricuspid regurgitation peak gradient; PTRV – peak tricuspid regurgitant velocity.

LA area measurements demonstrated high yield (82–95%) and strong agreement with manual quantification ($r = 0.86$ – 0.88). LA volume measurements from apical four- and two-chamber views exhibited slightly lower correlations ($r = 0.87$ and $r = 0.84$, respectively) and somewhat higher variability. The LA volume index showed the lowest yield (73%) despite a strong correlation ($r = 0.92$). However, the AI model displayed a consistent tendency to overestimate this parameter.

Regarding tricuspid valve parameters, both the peak tricuspid regurgitation velocity (TR $V_{\max}$) and the corresponding pressure gradient (TRPG) demonstrated excellent measurement yield but only moderate correlation with manual assessments ($r = 0.55$ and $r = 0.56$, respectively).

Accuracy of diastolic dysfunction classification

When classifying LVDD, the AI model demonstrated strong overall performance. For the identification of normal diastolic function (grade 0), the model achieved a precision of 90.57%, indicating that the vast majority of cases labeled as normal by the AI were indeed correctly classified. The TNR reached 92.13%, reflecting the system's reliability in accurately recognizing individuals with preserved diastolic function. For grade 1 diastolic dysfunction, the model achieved a recall rate of 77.42%, showing that it correctly detected most true cases of mild dysfunction. However, the overall accuracy was lower, suggesting a higher rate of misclassification from adjacent categories. Performance for grade 2 LVDD was less consistent, likely due to the smaller sample size and the greater diagnostic complexity associated with intermediate patterns of diastolic impairment. For grade 3 diastolic dysfunction, the AI achieved 75% accuracy and a TNR of 99.65%, demonstrating a high level of reliability in detecting severe diastolic abnormalities. Overall, these findings indicate that the AI model performs robustly in identifying both normal diastolic function and advanced dysfunction (grades 0 and 3), while showing limitations in distinguishing intermediate stages where clinical and imaging features often overlap. Detailed classification metrics are presented in Table 4, and the corresponding confusion matrix is illustrated in Figure 4.

Table 4. Results of classification and determination of LV diastolic dysfunction degree

Grade	Precision, %	Recall, %	F1 score, %	Accuracy, %	Accuracy + TN, %	TNR, %	Total
0	90.57	56.80	69.82	53.63	71.96	92.13	169
1	48.65	77.42	59.75	42.60	67.23	62.56	93
2	28.95	40.74	33.85	20.37	85.47	89.96	27
3	75.00	42.86	54.55	37.50	98.31	99.65	7

TN – true negative, TNR – true negative ratio.




Figure 4. Results of AI-classified LVDD degrees

Results of automated aortic diameter assessment

The median diameters of the aortic root were as follows: aortic annulus (AoA) – 22.83 mm (interquartile range [IQR], 21.4–24.75), aortic sinuses (AoS) – 33.74 mm (IQR, 30.59–36.8), sinotubular junction (STJ) – 28.84 mm (IQR, 26.06–31.73), and ascending aorta (AAo) – 33.44 mm (IQR, 30.64–37.02). The AI model demonstrated the highest correlation with cardiologist measurements for the aortic sinus diameter ($r = 0.86$), whereas the ascending aorta showed the lowest correlation ($r = 0.67$). A detailed comparison between automated and manual aortic diameter measurements is provided in Table 5.

Table 5. Comparison of automated and manual echocardiographic aortic parameters

Measurement	N	Yield, %	RMSE	Bias	Lower LoA	Upper LoA	Pearson r
AoA	255	93	1.92	−0.04	−3.82	3.72	0.78
AoS	267	96	2.91	1.12	−4.16	6.41	0.86
STJ	187	84	3.59	1.95	−5.10	8.89	0.69
AAo	224	82	3.85	2.23	−5.35	9.28	0.67

N – number of studies; RMSE – root mean square error; LowerLoA – lower limit of agreement; UpperLoA – upper limit of agreement; Aortic annulus (AoA); Aortic sinuses (AoS); Sinotubular junction (STJ); Ascending aorta (AAo).

Results of left ventricular and atrial parameter assessment during rest and stress echocardiography

Participant characteristics

A total of 240 patients from five international centers were included in the study. Among them, 139 (57%) were male, with a mean age of 68 years. All participants were in sinus rhythm at the time of examination. The primary indication for performing the pharmacological stress echocardiography was a suspected ischemic heart disease. Detailed characteristics of the study population are summarized in Table 6.

Table 6. *Clinical characteristics of patients*

Clinical characteristics	Value
Age*, years	67.5 ± 10.4
Sex, male, n (%)	139 (57)
Height, m	166 (13)
Weight, kg	76 (17)
BMI*	27.8 ± 4.2
BSA*, m ²	1.89 ± 0.19
Dyslipidaemia, n (%)	159 (65.2)
Diabetes mellitus, n (%)	68 (27.9)
Ischaemic heart disease, n (%)	77 (31.6)
Previous MI, n (%)	60 (24.6)
Hypertension, n (%)	177 (72.5)

* mean ± SD; Percentages are calculated based on available data for each variable; not all variables were available for all patients. BMI – body mass index; BSA – body surface area; MI – myocardial infarction.

Evaluation of yield

The yield remained consistent under both rest and stress conditions. The highest yield was observed for left ventricular end-diastolic volume (LVEDV) measurements in the four- and two-chamber views – 98% and 94% at rest, and 95% during stress (Table 7). Other measurements, such as left ventricular end-systolic volumes (LVESV) in the four- and two-chamber views, also demonstrated a high yield ranging from 83% to 93%. However, the yield was lower for LA volume measurements in both four- and two-chamber views, varying between 75% and 83%.

Table 7. Comparison of measurement yields between cardiologist and AI in stress echocardiography

Measurement	Stress phase	Cardiologist, n	AI, n	Yield, %
LVEDV4A	rest	235	230	98
	stress	226	214	95
LVESV4A	rest	234	209	89
	stress	221	206	93
LVEDV2A	rest	230	216	94
	stress	225	214	95
LVESV2A	rest	234	199	85
	stress	222	185	83
LAV4A	rest	185	146	79
	stress	176	142	81
LAV2A	rest	175	145	83
	stress	168	126	75

LVEDV – left ventricular end-diastolic volume; LVESV – left ventricular end-systolic volume; LAV – left atrial volume; 4A – apical four chamber; 2A – apical two chamber.

Comparison between artificial intelligence and expert measurements at rest and during stress

LV and LA measurements obtained by cardiology experts were compared with those generated by the AI model. The results demonstrated a high degree of agreement between human and AI-derived LV volume assessments under both resting and stress conditions. In the apical four-chamber (LVEDV and LVESV) and two-chamber views (LVEDV and LVESV), the correlation coefficients ranged from 0.92 to 0.95 and 0.89 to 0.91, respectively. However, slight positive biases were observed (Table 8), suggesting that the AI model tended to underestimate LV volumes compared to expert manual measurements, except for LVESV in the four-chamber view.

Table 8. Agreement and Bland-Altman bias between cardiologist and AI in stress echocardiography

Measurement	Stress phase	Pearson r	ICC	Bias	LOA	MAE	RMSE
LVEDV4A	rest	0.9	0.89	8.15	±31.81	13.48	18.16
	stress	0.84	0.83	7.62	±38.08	15.4	20.87
LVESV4A	rest	0.86	0.84	−0.1	±25.62	9.3	13.07
	stress	0.87	0.86	−0.85	±25.01	9.25	12.79

Table 8. Continued

Measurement	Stress phase	Pearson r	ICC	Bias	LOA	MAE	RMSE
LVEDV2A	rest	0.85	0.84	7.97	±39.7	15.55	21.76
	stress	0.84	0.83	7.29	±38.7	16.18	21.04
LVESV2A	rest	0.88	0.87	1.34	±22.8	8.04	11.71
	stress	0.85	0.83	0.42	±23.59	8.56	12.04
LAV4A	rest	0.93	0.93	3.35	±17.86	7.11	9.71
	stress	0.93	0.93	0.97	±15.8	6.07	8.12
LAV2A	rest	0.85	0.83	3.73	±26.24	9.52	13.9
	stress	0.88	0.88	3.73	±19.6	8.09	10.67

ICC – intraclass correlation coefficient; LOA – limits of agreement; MAE – mean absolute error; RMSE – root mean square error. LVEDV – left ventricular end diastolic volume, LVESV – left ventricular end systolic volume; LAV – left atrial volume, 4A – apical four chamber; 2A – apical two chamber.




Figure 5. Bland-Altman plots of LVEF distribution at rest and during stress in the apical four and two chambers

LVEF – left ventricular ejection fraction; GT – ground truth; PRED – prediction; Lower LOA – lower limit of agreement; Upper LOA – upper limit of agreement.

LVEF measurements showed a moderate level of agreement between AI and cardiologists in both rest and stress phases. Figure 5 presents Bland-Altman plots illustrating the distribution of LVEF differences (from apical four- and two-chamber views) during rest and stress. The ICC ranged from 0.69 to 0.77 at rest and 0.60 to 0.72 during stress, indicating a moderate level of consistency. In contrast, left atrial volume measurements (in both four- and two-chamber views) demonstrated excellent agreement with ICC values exceeding 0.95. The bias was minimal, and RMSE values ranged from 4 to 7, indicating only negligible discrepancies between AI-derived and expert measurements.

Agreement between artificial intelligence and expert measurements and comparison between different centers

The analysis was performed for the entire cohort, and then the data from each center were analyzed separately. Agreement between AI and cardiologist data was observed in all five centers, with center 3 showing the strongest agreement (Table 9). Agreement was moderately higher for parameters measured at rest compared to measurements taken during stress.

Table 9. Comparison of cardiologist and AI agreement in Center 3

Stress Phase	Measurement	Cardiologist, n	AI, n	Pearson r	ICC	Bias	LOA	MAE	RMSE
Rest	LVEDV4A	50	50	0.93	0.93	13.42	±21.49	14.05	17.33
	LVESV4A	50	48	0.91	0.91	3.14	±15.24	6.59	8.39
	LVEDV2A	50	49	0.89	0.88	9.72	±24.67	13.22	15.9
	LVESV2A	50	46	0.92	0.91	2.3	±13.58	5.78	7.3
	LAV4A	50	46	0.96	0.95	4.5	±10.48	5.15	6.99
	LAV2A	50	37	0.96	0.93	6.53	±16.97	7.66	10.85
Stress	LVEDV4A	50	50	0.93	0.93	10.09	±18.71	11.55	13.89
	LVESV4A	50	49	0.91	0.91	1.64	±13.21	5.4	6.94
	LVEDV2A	50	50	0.88	0.88	6.98	±23.22	10.47	13.75
	LVESV2A	49	45	0.85	0.84	0.73	±14.17	5.51	7.27
	LAV4A	50	41	0.97	0.96	3	±11.72	4.99	6.69
	LAV2A	50	39	0.95	0.94	5.54	±11.08	6.19	7.91

ICC – intraclass correlation coefficient; LOA – limits of agreement; MAE – mean absolute error; RMSE – root mean square error. LVEDV – left ventricular end diastolic volume, LVESV – left ventricular end systolic volume; LAV – left atrial volume, 4A – apical four chamber; 2A – apical two chamber.

Assessment of images of varying quality

The image quality of each echocardiographic frame and of the cardiac chambers used for measurements was assessed and classified into four categories: optimal, good, fair, or poor. Although image quality tended to deteriorate during stress, the differences were not statistically significant ($P > 0.05$) (Table 10). In some patients, measurements of specific chambers could not be performed due to insufficient image quality in the selected frames; nevertheless, these patients were included in the overall cohort.

Study outcomes varied depending on image quality. The lowest yield was observed for LV measurements obtained from poor-quality images (45.5–57.7% at rest and 37.5–80% during stress, Table 10). With higher image quality, better measurement yields were achieved, and the highest rates were recorded in optimally acquired images, where more than 89% of all measurements were successfully performed and 100% success was reached for LVEDV assessments in both four- and two-chamber views.

Table 10. Impact of image quality on measurement yields between cardiologist and AI in stress echocardiography

Measurement	Image quality	Rest phase			Stress phase		
		Cardiologist, n	AI, n	Yield	Cardiologist, n	AI, n	Yield
LVEDV4A	poor	1	0	–	4	1	–
	fair	37	35	94.6	47	41	87.2
	good	96	95	98.9	94	92	97.9
	optimal	99	99	100	80	79	98.8
LVESV4A	poor	6	0	–	12	9	75
	fair	38	27	71.1	49	43	87.8
	good	91	86	94.5	80	75	93.8
	optimal	99	96	97	80	79	98.8
LVEDV2A	poor	11	5	45.5	15	12	80
	fair	86	78	90.7	82	77	93.9
	good	82	82	100	77	74	96.1
	optimal	51	51	100	51	51	100
LVESV2A	poor	8	4	50	16	6	37.5
	fair	63	44	69.8	66	51	77.3
	good	83	76	91.6	76	69	90.8
	optimal	80	75	93.8	64	59	92.2

Table 10. Continued

Measurement	Image quality	Rest phase			Stress phase		
		Cardio- logist, n	AI, n	Yield	Cardio- logist, n	AI, n	Yield
LAV4A	poor	4	2	–	7	0	–
	fair	28	15	53.6	28	18	64.3
	good	64	47	73.4	54	46	85.2
	optimal	83	81	97.6	80	78	97.5
LAV2A	poor	4	2	–	7	1	–
	fair	49	37	75.5	59	36	61
	good	61	56	91.8	46	42	91.3
	optimal	54	48	88.9	51	47	92.2

LVEDV – left ventricular end-diastolic volume; LVESV – left ventricular end-systolic volume; LAV – left atrial volume; AI – artificial intelligence.

Agreement and comparison between artificial intelligence and expert measurements across different image qualities

The correspondence between AI-derived and cardiologist-performed measurements was analyzed across varying image quality levels (Table 11). The analysis demonstrated that measurements obtained from good or optimal quality images were more accurate than those derived from fair or poor-quality images. When assessing left heart volume measurements, the agreement between AI and cardiologists was excellent for optimal and good-quality images, with ICC values ranging from 0.91 to 1.00. Measurements obtained from images of fair or poor quality showed lower agreement compared with higher-quality images, yet remained within the range of acceptable concordance (ICC values between 0.83 and 0.96).

Table 11. Agreement between cardiologists and AI within image quality groups

Measurement	Image quality	Rest phase						Stress phase							
		N	r	ICC	Bias	LOA	MAE	RMSE	N	r	ICC	Bias	LOA	MAE	RMSE
LVEDV4A	poor	0	–	–	–	–	–	–	1	–	–	–	–	–	–
	fair	35	0.91	0.91	10.8	±38.1	16.6	22.2	41	0.83	0.82	6.8	±53.6	20.9	28.2
	good	95	0.91	0.89	6.0	±30.6	12.0	16.7	92	0.85	0.83	6.7	±38.4	15.6	20.7
	optimal	99	0.88	0.86	9.6	±29.6	13.7	17.9	79	0.84	0.84	9.1	±26.5	12.5	16.3
LVESV4A	poor	0	–	–	–	–	–	–	9	0.79	0.79	–4.2	±23.3	9.2	12.6
	fair	27	0.80	0.78	–5.7	±30.3	11.7	16.6	43	0.92	0.90	0.6	±31.6	11.8	16.1
	good	86	0.88	0.87	–0.5	±23.6	8.9	12.0	75	0.84	0.83	–2.1	±24.9	9.3	12.9
	optimal	96	0.87	0.83	1.8	±24.0	8.9	12.9	79	0.84	0.84	–0.1	±20.5	7.8	10.5
LVEDV2A	poor	5	0.66	0.64	–7.7	±50.0	22.0	26.6	12	0.67	0.67	9.1	±46.2	20.2	25.3
	fair	78	0.87	0.85	7.1	±41.8	15.6	22.5	77	0.86	0.85	5.1	±44.3	17.7	23.2
	good	82	0.85	0.85	6.0	±35.1	14.5	18.9	74	0.84	0.83	8.5	±33.9	15.3	19.3
	optimal	51	0.82	0.82	14.1	±38.8	16.6	24.3	51	0.80	0.78	8.4	±33.3	14.2	19.0
LVESV2A	poor	4	0.76	0.65	–12.4	±20.4	13.0	16.2	6	0.65	0.61	–14.1	±24.8	14.4	19.0
	fair	44	0.78	0.74	–0.1	±30.8	9.2	15.7	15	0.88	0.85	–1.0	±29.0	11.2	14.8
	good	76	0.92	0.92	1.0	±20.1	7.9	10.3	69	0.88	0.87	0.7	±18.4	6.9	9.4
	optimal	75	0.92	0.89	3.3	±18.3	7.2	9.9	59	0.81	0.76	2.8	±21.3	7.7	11.2

Table 11. Continued

Measurement	Image quality	Rest phase						Stress phase							
		N	r	ICC	Bias	LOA	MAE	RMSE	N	r	ICC	Bias	LOA	MAE	RMSE
LAV4A	poor	2	—	—	—	—	—	—	0	—	—	—	—	—	—
	fair	15	0.76	0.75	4.6	±22.9	8.9	12.6	18	0.97	0.96	1.1	±11.6	5.1	6.0
	good	47	0.96	0.96	3.6	±16.0	7.0	8.9	46	0.91	0.91	0.2	±20.8	7.7	10.6
	optimal	81	0.92	0.92	2.4	±16.3	6.4	8.7	78	0.93	0.93	1.4	±12.9	5.3	6.7
LAV2A	poor	2	—	—	—	—	—	—	1	—	—	—	—	—	—
	fair	37	0.83	0.82	2.7	±28.5	10.6	14.8	36	0.86	0.86	2.2	±23.7	9.4	12.3
	good	56	0.88	0.86	2.8	±23.0	9.2	12.1	42	0.90	0.89	3.9	±16.3	6.9	9.2
	optimal	48	0.86	0.84	3.8	±17.9	7.5	9.9	47	0.90	0.90	5.1	±18.0	8.1	10.5

ICC – intraclass correlation coefficient; LOA – limits of agreement; MAE – mean absolute error; RMSE – root mean square error. LVEDV – left ventricular end diastolic volume, LVESV – left ventricular end systolic volume; LAV – left atrial volume, 4A –apical four chamber; 2A – apical two chamber.

CONCLUSIONS

1. The fully automated AI-based model demonstrated high accuracy in evaluating parameters of LV diastolic function, achieving good measurement yield (73–100%) and moderate to strong correlation with the investigator's results ($r = 0.55$ – 0.94). The AI system also reliably classified the degree of LVDD, showing particularly high accuracy in identifying normal function (90.57%) and the most severe dysfunction grade - restriction (75.00%).
2. When assessing aortic parameters, the model achieved the highest accuracy and strongest correlation for measurements of the AoA and AoS diameters ($r = 0.78$ and 0.86 , respectively). The STJ and AAo measurements demonstrated moderate correlations with investigator-derived values ($r = 0.69$ and 0.67).
3. Evaluation of LV and LA volumes at rest and during stress using both the DNNs and ML models yielded high measurement success rates (75–98%) and strong correlations with expert assessments ($r = 0.84$ – 0.93). In contrast, estimation of the LVEF showed lower accuracy, agreement, and correlation with experts (ICC ranging from 0.60 to 0.77).
4. The study further revealed that measurements derived from good or optimal quality images – both at rest and during stress – were more accurate than those obtained from fair or poor-quality images. Nevertheless, even the latter measurements fell within an acceptable agreement range (ICC 0.91 – 1.00 for good/optimal quality and 0.83 – 0.96 for fair/poor quality). These findings indicate that AI-based models can be effectively applied to echocardiographic image analysis across varying levels of image quality.

PRACTICAL RECOMMENDATIONS

1. The use of fully automated AI algorithms for assessing diastolic function parameters substantially reduces the amount of manual work required and achieves an accuracy comparable to that of an experienced cardiologist. DNNs models can play a valuable role in routine clinical practice by assisting in the classification of LV diastolic function grades, particularly by accurately distinguishing between normal diastolic function and restrictive dysfunction.

2. Automated evaluation of aortic parameters also minimizes manual input and reduces inter-observer variability, which is especially important when monitoring aortic dimensions over time in cases of aortic dilatation. The demonstrated accuracy of AI-assisted measurement of the aortic annulus suggests its potential contribution to the precise assessment and longitudinal monitoring of aortic valve stenosis.
3. The study demonstrated that automated assessment of LV and LA volumes can be successfully integrated into routine pharmacological stress echocardiography. This AI application enables the evaluation not only of regional LV wall motion abnormalities but also of objective volumetric changes. Further research is warranted to explore the applicability of AI-based methods with various pharmacological agents and physical stress protocols.
4. Until recently, AI techniques have predominantly been applied to high-quality echocardiographic images. The present study, however, showed that AI models can be effectively used for image analysis across a wide range of image qualities without a significant loss of accuracy. This capability may help reduce the risk of diagnostic errors, particularly among less experienced operators.

LITERATŪROS SĄRAŠAS

1. McDonagh TA, Metra M, Adamo M, Baumbach A, Böhm M, Burri H, et al. 2021 ESC Guidelines for the diagnosis and treatment of acute and chronic heart failure. *European Heart Journal*. Oxford University Press; 2021;42:3599–726.
2. Savarese G, Becher PM, Lund LH, Seferovic P, Rosano GMC, Coats AJS. Global burden of heart failure: a comprehensive and updated review of epidemiology. *Cardiovascular research* [Internet]. *Cardiovasc Res*; 2023 [cited 2025 Oct 9];118:3272–87. Available from: <https://pubmed.ncbi.nlm.nih.gov/35150240/>
3. Yang C, Jia Y, Zhang C, Jin Z, Ma Y, Bi X, et al. Global, regional, and national burdens of heart failure in adolescents and young adults aged 10–24 years from 1990 to 2021: an analysis of data from the Global Burden of Disease Study 2021. *eClinicalMedicine* [Internet]. Elsevier Ltd; 2025 [cited 2025 Oct 9]; 79:102998. Available from: <https://pubmed.ncbi.nlm.nih.gov/39737218/>
4. Lau ES, Di Achille P, Kopparapu K, Andrews CT, Singh P, Reeder C, et al. Deep learning-enabled assessment of left heart structure and function predicts cardiovascular outcomes. *Journal of the American College of Cardiology* [Internet]. Elsevier Inc.; 2023 [cited 2025 Oct 9];82:1936–48. Available from: <https://pubmed.ncbi.nlm.nih.gov/37940231/>
5. Tokodi M, Kovács A. A new hope for deep learning-based echocardiogram interpretation: The DROIDS you were looking for. *Journal of the American College of Cardiology* [Internet]. Elsevier Inc.; 2023 [cited 2025 Oct 9];82:1949–52. Available from: <https://pubmed.ncbi.nlm.nih.gov/37940232/>
6. Tromp J, Seekings PJ, Hung CL, Iversen MB, Frost MJ, Ouwerkerk W, et al. Automated interpretation of systolic and diastolic function on the echocardiogram: a multicohort study. *The Lancet Digital Health* [Internet]. Elsevier Ltd; 2022 [cited 2025 Oct 9];4:e46–54. Available from: <https://pubmed.ncbi.nlm.nih.gov/34863649/>
7. Park J, Jeon J, Yoon YE, Jang Y, Kim J, Jeong D, et al. Artificial intelligence-enhanced automation of left ventricular diastolic assessment: a pilot study for feasibility, diagnostic validation, and outcome prediction. *Cardiovascular Diagnosis and Therapy* [Internet]. AME Publishing Company; 2024 [cited 2025 Oct 9];14:352–66. Available from: <https://cdt.amegroups.org/article/view/125581/html>
8. Nagueh SF, Smiseth OA, Appleton CP, Byrd BF, Dokainish H, Edvardsen T, et al. Recommendations for the Evaluation of Left Ventricular Diastolic Function by Echocardiography: An Update from the American Society of Echocardiography and the European Association of Cardiovascular Imaging. *Journal of the American Society of Echocardiography* [Internet]. Mosby Inc.; 2016 [cited 2025 Oct 9];29:277–314. Available from: <https://pubmed.ncbi.nlm.nih.gov/27037982/>
9. Lo EMK, Chen S, Ng KHL, Wong RHL. Artificial intelligence-powered solutions for automated aortic diameter measurement in computed tomography: a narrative review. *Annals of translational medicine* [Internet]. *Ann Transl Med*; 2024 [cited 2025 Oct 9];12:116–116. Available from: <https://pubmed.ncbi.nlm.nih.gov/39817238/>
10. Zha SZ, Rogstadkjernet M, Klæboe LG, Skulstad H, Singstad BJ, Gilbert A, et al. Deep learning for automated left ventricular outflow tract diameter measurements in 2D echocardiography. *Cardiovascular ultrasound* [Internet]. *Cardiovasc Ultrasound*; 2023 [cited 2025 Oct 9];21(1):19. Available from: <https://pubmed.ncbi.nlm.nih.gov/37833731/>

11. Schwinger RHG. Pathophysiology of heart failure. Cardiovascular diagnosis and therapy [Internet]. Cardiovasc Diagn Ther; 2021 [cited 2025 Oct 9];11(1):263–76. Available from: <https://pubmed.ncbi.nlm.nih.gov/33708498/>
12. Bozkurt B, Coats AJS, Tsutsui H, Abdelhamid CM, Adamopoulos S, Albert N, et al. Universal definition and classification of heart failure: a report of the Heart Failure Society of America, Heart Failure Association of the European Society of Cardiology, Japanese Heart Failure Society and Writing Committee of the Universal Definition o. European Journal of Heart Failure [Internet]. Eur J Heart Fail; 2021 [cited 2025 Oct 9];23:352–80. Available from: <https://pubmed.ncbi.nlm.nih.gov/33605000/>
13. Roberts E, Ludman AJ, Dworzynski K, Al-Mohammad A, Cowie MR, McMurray JJV, et al. The diagnostic accuracy of the natriuretic peptides in heart failure: Systematic review and diagnostic meta-analysis in the acute care setting. BMJ (Online) [Internet]. BMJ; 2015 [cited 2025 Oct 9];350:h910. Available from: <https://pubmed.ncbi.nlm.nih.gov/25740799/>
14. Harada T, Kagami K, Kato T, Obokata M. Echocardiography in the diagnostic evaluation and phenotyping of heart failure with preserved ejection fraction. Journal of Cardiology [Internet]. Japanese College of Cardiology (Nippon-Sinzobyo-Gakkai); 2022 [cited 2025 Oct 9];79:679–90. Available from: <https://pubmed.ncbi.nlm.nih.gov/34857430/>
15. McDonagh TA, Metra M, Adamo M, Gardner RS, Baumbach A, Böhm M, et al. 2023 Focused Update of the 2021 ESC Guidelines for the diagnosis and treatment of acute and chronic heart failure: Developed by the task force for the diagnosis and treatment of acute and chronic heart failure of the European Society of Cardiology (ESC) With the special contribution of the Heart Failure Association (HFA) of the ESC. European journal of heart failure [Internet]. Eur J Heart Fail; 2024 [cited 2025 Oct 9];26:5–17. Available from: <https://pubmed.ncbi.nlm.nih.gov/38169072/>
16. Murphy SP, Ibrahim NE, Januzzi JL. Heart Failure With Reduced Ejection Fraction: A Review. JAMA [Internet]. JAMA; 2020 [cited 2025 Oct 9];324:488–504. Available from: <https://pubmed.ncbi.nlm.nih.gov/32749493/>
17. Borlaug BA, Sharma K, Shah SJ, Ho JE. Heart failure with preserved ejection fraction: JACC Scientific Statement. Journal of the American College of Cardiology [Internet]. Elsevier Inc.; 2023 [cited 2025 Oct 9];81:1810–34. Available from: <https://pubmed.ncbi.nlm.nih.gov/37137592/>
18. Kapelios CJ, Shahim B, Lund LH, Savarese G. Epidemiology, clinical characteristics and cause-specific outcomes in heart failure with preserved ejection fraction. Cardiac failure review [Internet]. Card Fail Rev; 2023 [cited 2025 Oct 9];9:e14. Available from: <https://pubmed.ncbi.nlm.nih.gov/38020671/>
19. Ashley EA, Niebauer J. Understanding the echocardiogram. Cardiology Explained [Internet]. Remedica; 2004 [cited 2025 Oct 9]. Available from: <https://www.ncbi.nlm.nih.gov/books/NBK2215/>
20. Anavekar NS, Oh JK. Doppler echocardiography: A contemporary review. Journal of Cardiology [Internet]. J Cardiol; 2009 [cited 2025 Oct 9];54:347–58. Available from: <https://pubmed.ncbi.nlm.nih.gov/19944309/>
21. Marwick TH. The role of echocardiography in heart failure [Internet]. Journal of nuclear medicine : official publication, Society of Nuclear Medicine. J Nucl Med; 2015 [cited 2025 Oct 9];56(Suppl 4):31S-38S. Available from: <https://pubmed.ncbi.nlm.nih.gov/26033901/>
22. Lang RM, Badano LP, Victor MA, Afilalo J, Armstrong A, Ernande L, et al. Recommendations for cardiac chamber quantification by echocardiography in adults: An

- update from the American Society of Echocardiography and the European Association of Cardiovascular Imaging. *Journal of the American Society of Echocardiography* [Internet]. Mosby Inc.; 2015 [cited 2025 Oct 9];28:1-39.e14. Available from: <https://pubmed.ncbi.nlm.nih.gov/25559473/>
23. Porter TR, Mulvagh SL, Abdelmoneim SS, Becher H, Belcik JT, Bierig M, et al. Clinical applications of ultrasonic enhancing agents in echocardiography: 2018 American Society of Echocardiography Guidelines Update. *Journal of the American Society of Echocardiography* [Internet]. Mosby Inc.; 2018 [cited 2025 Oct 9];31:241–74. Available from: <https://pubmed.ncbi.nlm.nih.gov/29502588/>
 24. Becher H, Alhumaid W, Windram J, Choy J. Contrast echocardiography in heart failure: update 2023. *Current heart failure reports* [Internet]. *Curr Heart Fail Rep*; 2024 [cited 2025 Oct 9];21:63–72. Available from: <https://pubmed.ncbi.nlm.nih.gov/38305851/>
 25. Dorosz JL, Lezotte DC, Weitzkamp DA, Allen LA, Salcedo EE. Performance of 3-dimensional echocardiography in measuring left ventricular volumes and ejection fraction: a systematic review and meta-analysis. *Journal of the American College of Cardiology* [Internet]. Centre for Reviews and Dissemination (UK); 2012 [cited 2025 Oct 9];59:1799–808. Available from: <https://www.ncbi.nlm.nih.gov/books/NBK116304/>
 26. Rodríguez-Zanella H, Muraru D, Secco E, Boccacini F, Azzolina D, Aruta P, et al. Added value of 3- versus 2-dimensional echocardiography left ventricular ejection fraction to predict arrhythmic risk in patients with left ventricular dysfunction. *JACC: Cardiovascular Imaging* [Internet]. Elsevier Inc.; 2019 [cited 2025 Oct 9];12:1917–26. Available from: <https://pubmed.ncbi.nlm.nih.gov/30219408/>
 27. Baldea SM, Velcea AE, Rimbas RC, Andronic A, Matei L, Calin SI, et al. 3-D Echocardiography is feasible and more reproducible than 2-D echocardiography for in-training echocardiographers in follow-up of patients with heart failure with reduced ejection fraction. *Ultrasound in Medicine and Biology* [Internet]. Elsevier Inc.; 2021 [cited 2025 Oct 9];47:499–510. Available from: <https://pubmed.ncbi.nlm.nih.gov/33267962/>
 28. Smiseth OA, Donal E, Boe E, Ha JW, Fernandes JF, Lamata P. Phenotyping heart failure by echocardiography: imaging of ventricular function and haemodynamics at rest and exercise. *European heart journal Cardiovascular Imaging* [Internet]. *Eur Heart J Cardiovasc Imaging*; 2023 [cited 2025 Oct 9];24:1329–42. Available from: <https://pubmed.ncbi.nlm.nih.gov/37542477/>
 29. Evangelista A, Flachskampf FA, Erbel R, Antonini-Canterin F, Vlachopoulos C, Rocchi G, et al. Echocardiography in aortic diseases: EAE recommendations for clinical practice. *European journal of echocardiography : the journal of the Working Group on Echocardiography of the European Society of Cardiology* [Internet]. *Eur J Echocardiogr*; 2010 [cited 2025 Oct 9];11:645–58. Available from: <https://pubmed.ncbi.nlm.nih.gov/20823280/>
 30. Goldstein SA, Evangelista A, Abbara S, Arai A, Asch FM, Badano LP, et al. Multimodality imaging of diseases of the thoracic aorta in adults: from the American Society of Echocardiography and the European Association of Cardiovascular Imaging: endorsed by the Society of Cardiovascular Computed Tomography and Society for Cardiovascular Magnetic Resonance. *Journal of the American Society of Echocardiography : official publication of the American Society of Echocardiography* [Internet]. *J Am Soc Echocardiogr*; 2015 [cited 2025 Oct 9];28:119–82. Available from: <https://pubmed.ncbi.nlm.nih.gov/25623219/>

31. Rodríguez-Palomares JF, Teixidó-Tura G, Galuppo V, Cuéllar H, Laynez A, Gutiérrez L, et al. Multimodality assessment of ascending aortic diameters: comparison of different measurement methods. *Journal of the American Society of Echocardiography* [Internet]. Mosby Inc.; 2016 [cited 2025 Oct 9];29:819-826.e4. Available from: <https://pubmed.ncbi.nlm.nih.gov/27288090/>
32. Bons LR, Duijnhouwer AL, Boccacini S, van den Hoven AT, van der Vlugt MJ, Chelu RG, et al. Intermodality variation of aortic dimensions: how, where and when to measure the ascending aorta. *International Journal of Cardiology* [Internet]. Elsevier Ireland Ltd; 2019 [cited 2025 Oct 9];276:230–5. Available from: <https://pubmed.ncbi.nlm.nih.gov/30213599/>
33. Madani A, Ong JR, Tibrewal A, Mofrad MRK. Deep echocardiography: data-efficient supervised and semi-supervised deep learning towards automated diagnosis of cardiac disease. *NPJ digital medicine* [Internet]. NPJ Digit Med; 2018 [cited 2025 Oct 9];1:59. Available from: <https://pubmed.ncbi.nlm.nih.gov/31304338/>
34. Bunting KV, Steeds RP, Slater K, Rogers JK, Gkoutos GV, Kotecha D. A practical guide to assess the reproducibility of echocardiographic measurements. *Journal of the American Society of Echocardiography* [Internet]. Elsevier Inc.; 2019 [cited 2025 Oct 9];32:1505–15. Available from: <https://pubmed.ncbi.nlm.nih.gov/31653530/>
35. Steeds RP, Wheeler R, Bhattacharyya S, Reiken J, Nihoyannopoulos P, Senior R, et al. Stress echocardiography in coronary artery disease: A practical guideline from the British Society of Echocardiography [Internet]. *Echo Research and Practice*. Echo Res Pract; 2019 [cited 2025 Oct 9];6(2):G17–G33. Available from: <https://pubmed.ncbi.nlm.nih.gov/30921767/>
36. Pellikka PA, Arruda-Olson A, Chaudhry FA, Chen MH, Marshall JE, Porter TR, et al. Guidelines for performance, interpretation, and application of stress echocardiography in ischemic heart disease: from the American Society of Echocardiography. *Journal of the American Society of Echocardiography* [Internet]. Mosby Inc.; 2020 [cited 2025 Oct 9];33:1-41.e8. Available from: <https://pubmed.ncbi.nlm.nih.gov/31740370/>
37. Sicari R, Nihoyannopoulos P, Evangelista A, Kasprzak J, Lancellotti P, Poldermans D, et al. Stress echocardiography expert consensus statement: European Association of Echocardiography (EAE) (a registered branch of the ESC). *European journal of echocardiography : the journal of the Working Group on Echocardiography of the European Society of Cardiology* [Internet]. *Eur J Echocardiogr*; 2008 [cited 2025 Oct 9];9:415–37. Available from: <https://pubmed.ncbi.nlm.nih.gov/18579481/>
38. Picano E, Pierard L, Peteiro J, Djordjevic-Dikic A, Sade LE, Cortigiani L, et al. The clinical use of stress echocardiography in chronic coronary syndromes and beyond coronary artery disease: A clinical consensus statement from the European Association of Cardiovascular Imaging of the ESC. *European Heart Journal Cardiovascular Imaging* [Internet]. *Eur Heart J Cardiovasc Imaging*; 2024 [cited 2025 Oct 9];25:E65–90. Available from: <https://pubmed.ncbi.nlm.nih.gov/37798126/>
39. Upton R, Mumith A, Beqiri A, Parker A, Hawkes W, Gao S, et al. Automated Echocardiographic Detection of Severe Coronary Artery Disease Using Artificial Intelligence. *JACC: Cardiovascular Imaging* [Internet]. Elsevier Inc.; 2022 [cited 2025 Oct 9];15:715–27. Available from: <https://pubmed.ncbi.nlm.nih.gov/34922865/>
40. Roggel A, Jehn S, Dykun I, Balcer B, Al-Rashid F, Totzeck M, et al. Regional wall motion abnormalities on focused transthoracic echocardiography in patients presenting with acute chest pain: a predefined post hoc analysis of the prospective single-centre observational EPIC-ACS study. *BMJ open* [Internet]. *BMJ Open*; 2024 [cited 2025 Oct 9];14(9):e085677. Available from: <https://pubmed.ncbi.nlm.nih.gov/39260858/>

41. Ihekweba U, Johnson N, Choi JS, Savarese G, Orsini N, Khoo J, et al. Long-term prognostic value of contemporary stress echocardiography in patients with suspected or known coronary artery disease: systematic review and meta-analysis. *Heart (British Cardiac Society)* [Internet]. *Heart*; 2024 [cited 2025 Oct 9];110:1349–56. Available from: <https://pubmed.ncbi.nlm.nih.gov/39179369/>
42. Vrints C, Andreotti F, Koskinas KC, Rossello X, Adamo M, Ainslie J, et al. 2024 ESC Guidelines for the management of chronic coronary syndromes. *European heart journal* [Internet]. *Eur Heart J*; 2024 [cited 2025 Oct 9];45:3415–537. Available from: <https://pubmed.ncbi.nlm.nih.gov/39210710/>
43. Gupta K, Kakar TS, Gupta A, Singh A, Gharpure N, Aryal S, et al. Role of left ventricle deformation analysis in stress echocardiography for significant coronary artery disease detection: A diagnostic study meta-analysis. *Echocardiography (Mount Kisco, NY)* [Internet]. *Echocardiography*; 2019 [cited 2025 Oct 9];36:1084–94. Available from: <https://pubmed.ncbi.nlm.nih.gov/31116467/>
44. Picano E, Ciampi Q, Arbucci R, Cortigiani L, Zagatina A, Celutkienė J, et al. Stress Echo 2030: the new ABCDE protocol defining the future of cardiac imaging. *European heart journal supplements : journal of the European Society of Cardiology* [Internet]. *Eur Heart J Suppl*; 2023 [cited 2025 Oct 9];25:C63–7. Available from: <https://pubmed.ncbi.nlm.nih.gov/37125276/>
45. Ciampi Q, Zagatina A, Cortigiani L, Wierzbowska-Drabik K, Kasprzak JD, Haberka M, et al. Prognostic value of stress echocardiography assessed by the ABCDE protocol. *European heart journal* [Internet]. *Eur Heart J*; 2021 [cited 2025 Oct 9];42:3869–78. Available from: <https://pubmed.ncbi.nlm.nih.gov/34449837/>
46. Lancellotti P, Pellikka PA, Budts W, Chaudhry FA, Donal E, Dulgheru R, et al. The clinical use of stress echocardiography in non-ischaemic heart disease: recommendations from the European Association of Cardiovascular Imaging and the American Society of Echocardiography [Internet]. *Eur Heart J Cardiovasc Imaging*. 2016 [cited 2025 Oct 9];17(11):1191–229. Available from: <https://pubmed.ncbi.nlm.nih.gov/27880640/>
47. Garbi M, Chambers J, Vannan MA, Lancellotti P. Valve stress echocardiography: A practical guide for referral, procedure, reporting, and clinical implementation of results from the HAVEC group [Internet]. *JACC: Cardiovascular Imaging*. Elsevier Inc.; 2015 [cited 2025 Oct 9];8(6):724–36. Available from: <https://pubmed.ncbi.nlm.nih.gov/26068289/>
48. Obokata M, Kane GC, Reddy YNV, Olson TP, Melenovsky V, Borlaug BA. Role of Diastolic Stress Testing in the Evaluation for Heart Failure With Preserved Ejection Fraction: A Simultaneous Invasive-Echocardiographic Study. *Circulation* [Internet]. *Circulation*; 2017 [cited 2025 Oct 9];135:825–38. Available from: <https://pubmed.ncbi.nlm.nih.gov/28039229/>
49. Gibson PH, Riesgo F, Choy JB, Kim DH, Becher H. Dobutamine stress echocardiography after cardiac transplantation: implications of donor–recipient age difference. *Echo Research and Practice* [Internet]. BioScientifica Ltd.; 2015 [cited 2025 Oct 9];2(2):65–71. Available from: <https://pmc.ncbi.nlm.nih.gov/articles/PMC4676477/>
50. Morales MA, Manning WJ, Nezafat R. Present and future innovations in AI and cardiac MRI. *Radiology* [Internet]. *Radiology*; 2024 [cited 2025 Oct 9];310(1):e231269. Available from: <https://pubmed.ncbi.nlm.nih.gov/38193835/>
51. Krittanawong C, Omar AMS, Narula S, Sengupta PP, Glicksberg BS, Narula J, et al. Deep learning for echocardiography: Introduction for clinicians and future vision: State-of-the-Art review. *Life* 2023, Vol 13, Page 1029 [Internet]. Multidisciplinary

- Digital Publishing Institute; 2023 [cited 2025 Oct 9];13(4):1029. Available from: <https://www.mdpi.com/2075-1729/13/4/1029/htm>
52. Nakayama M, Yagi R, Goto S. Deep learning applications in 12-lead electrocardiogram and echocardiogram. *JMA Journal* [Internet]. Japan Medical Association; 2024 [cited 2025 Oct 9];8(1):102–12. Available from: <https://pmc.ncbi.nlm.nih.gov/articles/PMC11799486/>
 53. Ferreira DL, Lau C, Salaymang Z, Arnaout R. Self-supervised learning for label-free segmentation in cardiac ultrasound. *Nature communications* [Internet]. Nat Commun; 2025 [cited 2025 Oct 9];16(1):4070. Available from: <https://pubmed.ncbi.nlm.nih.gov/40307208/>
 54. Motazedian P, Marbach JA, Prosperi-Porta G, Parlow S, Di Santo P, Abdel-Razek O, et al. Diagnostic accuracy of point-of-care ultrasound with artificial intelligence-assisted assessment of left ventricular ejection fraction. *NPJ digital medicine* [Internet]. NPJ Digit Med; 2023 [cited 2025 Oct 9];6(1):201. Available from: <https://pubmed.ncbi.nlm.nih.gov/37898711/>
 55. Akerman AP, Porumb M, Scott CG, Beqiri A, Chartsias A, Ryu AJ, et al. Automated echocardiographic detection of heart failure with preserved ejection fraction using Artificial Intelligence. *JACC: Advances* [Internet]. Elsevier B.V.; 2023 [cited 2025 Oct 9];2(6):100452. Available from: <https://pubmed.ncbi.nlm.nih.gov/38939447/>
 56. Ueda D, Matsumoto T, Ehara S, Yamamoto A, Walston SL, Ito A, et al. Artificial intelligence-based model to classify cardiac functions from chest radiographs: a multi-institutional, retrospective model development and validation study. *The Lancet Digital Health* [Internet]. Elsevier Ltd; 2023 [cited 2025 Oct 9];5:e525–33. Available from: <https://pubmed.ncbi.nlm.nih.gov/37422342/>
 57. Delgado V, Ajmone Marsan N, De Waha S, Bonaros N, Brida M, Burri H, et al. 2023 ESC Guidelines for the management of endocarditis. *European heart journal* [Internet]. Eur Heart J; 2023 [cited 2025 Oct 9];44:3948–4042. Available from: <https://pubmed.ncbi.nlm.nih.gov/37622656/>
 58. Faletta FF, Agricola E, Flachskampf FA, Hahn R, Pepi M, Ajmone Marsan N, et al. Three-dimensional transoesophageal echocardiography: how to use and when to use – a clinical consensus statement from the European Association of Cardiovascular Imaging of the European Society of Cardiology. *European Heart Journal Cardiovascular Imaging* [Internet]. Eur Heart J Cardiovasc Imaging; 2023 [cited 2025 Oct 9];24:E119–97. Available from: <https://pubmed.ncbi.nlm.nih.gov/37259019/>
 59. Steffner KR, Christensen M, Gill G, Bowdish M, Rhee J, Kumaresan A, et al. Deep learning for transesophageal echocardiography view classification. *Scientific reports* [Internet]. Sci Rep; 2024 [cited 2025 Oct 9];14(1):11. Available from: <https://pubmed.ncbi.nlm.nih.gov/38167849/>
 60. Zhang Q, Fotaki A, Ghadimi S, Wang Y, Doneva M, Wetzl J, et al. Improving the efficiency and accuracy of cardiovascular magnetic resonance with artificial intelligence – review of evidence and proposition of a roadmap to clinical translation. *Journal of Cardiovascular Magnetic Resonance* [Internet]. Elsevier B.V.; 2024 [cited 2025 Oct 9];26(2):101051. Available from: <https://pubmed.ncbi.nlm.nih.gov/38909656/>
 61. Jiménez-Jara C, Salas R, Díaz-Navarro R, Chabert S, Andia ME, Vega J, et al. AI applied to cardiac magnetic resonance for precision medicine in coronary artery disease: A systematic review. *Journal of cardiovascular development and disease* [Internet]. J Cardiovasc Dev Dis; 2025 [cited 2025 Oct 9];12(9):345. Available from: <https://pubmed.ncbi.nlm.nih.gov/41002624/>

62. Ihdayhid AR, Tzimas G, Peterson K, Ng N, Mirza S, Maehara A, et al. Diagnostic performance of AI-enabled plaque quantification from coronary CT angiography compared with intravascular ultrasound. *Radiology Cardiothoracic imaging* [Internet]. *Radiol Cardiothorac Imaging*; 2024 [cited 2025 Oct 9];6(6):e230312. Available from: <https://pubmed.ncbi.nlm.nih.gov/39540820/>
63. Narula J, Stuckey TD, Nakazawa G, Ahmadi A, Matsumura M, Petersen K, et al. Prospective deep learning-based quantitative assessment of coronary plaque by computed tomography angiography compared with intravascular ultrasound: the REVEALPLAQUE study. *European heart journal Cardiovascular Imaging* [Internet]. *Eur Heart J Cardiovasc Imaging*; 2024 [cited 2025 Oct 9];25:1287–95. Available from: <https://pubmed.ncbi.nlm.nih.gov/38700097/>
64. Nurmohamed NS, Danad I, Jukema RA, de Winter RW, de Groot RJ, Driessen RS, et al. Development and validation of a quantitative coronary CT angiography model for diagnosis of vessel-specific coronary ischemia. *JACC: Cardiovascular Imaging* [Internet]. Elsevier Inc.; 2024 [cited 2025 Oct 9];17:894–906. Available from: <https://pubmed.ncbi.nlm.nih.gov/38483420/>
65. Miller RJH, Slomka PJ. Artificial Intelligence in nuclear cardiology: An update and future trends. *Seminars in Nuclear medicine* [Internet]. W.B. Saunders; 2024 [cited 2025 Oct 9];54:648–57. Available from: <https://pubmed.ncbi.nlm.nih.gov/38521708/>
66. Golub IS, Thummala A, Morad T, Dhaliwal J, Elisarraras F, Karlsberg RP, et al. Artificial Intelligence in nuclear cardiac imaging: Novel advances, emerging techniques, and recent clinical trials. *Journal of clinical medicine* [Internet]. *J Clin Med*; 2025 [cited 2025 Oct 9];14(6):2095. Available from: <https://pubmed.ncbi.nlm.nih.gov/40142902/>
67. Marcinkiewicz AM, Zhang W, Shanbhag A, Miller RJH, Lemley M, Ramirez G, et al. Holistic AI analysis of hybrid cardiac perfusion images for mortality prediction. *npj Digital Medicine* [Internet]. *Nature Research*; 2025 [cited 2025 Oct 9];8:1–9. Available from: <https://www.nature.com/articles/s41746-025-01526-0>
68. Santoro C, Donal E, Magne J, Sade LE, Penicka M, Katbeh A, et al. Inter-center reproducibility of standard and advanced echocardiographic parameters in the EACVI-AFib echo registry. *Echocardiography (Mount Kisco, NY)* [Internet]. *Echocardiography*; 2023 [cited 2025 Oct 9];40:775–83. Available from: <https://pubmed.ncbi.nlm.nih.gov/37351556/>
69. Taub CC, Stainback RF, Abraham T, Forsha D, Garcia-Sayan E, Hill JC, et al. Guidelines for the standardization of adult echocardiography reporting: Recommendations from the American Society of Echocardiography. *Journal of the American Society of Echocardiography : official publication of the American Society of Echocardiography* [Internet]. *J Am Soc Echocardiogr*; 2025 [cited 2025 Oct 9];38:735–74. Available from: <https://pubmed.ncbi.nlm.nih.gov/40912865/>
70. Cardiology now has more than 100 FDA cleared AI algorithms [Internet]. [cited 2025 Oct 9]. Available from: <https://cardiovascularbusiness.com/topics/artificial-intelligence/cardiology-now-has-more-100-fda-cleared-ai-algorithms>
71. Plana D, Shung DL, Grimshaw AA, Saraf A, Sung JJY, Kann BH. Randomized clinical trials of machine learning interventions in health care: A systematic review. *JAMA network open* [Internet]. *JAMA Netw Open*; 2022 [cited 2025 Oct 9];5:E2233946. Available from: <https://pubmed.ncbi.nlm.nih.gov/36173632/>
72. Al-Zaiti SS, Alghwiri AA, Hu X, Clermont G, Peace A, Macfarlane P, et al. A clinician’s guide to understanding and critically appraising machine learning studies: a checklist for Ruling Out Bias Using Standard Tools in Machine Learning (ROBUST-

- ML). European Heart Journal Digital Health [Internet]. Oxford University Press; 2022 [cited 2025 Oct 9];3(2):125–40. Available from: <https://pmc.ncbi.nlm.nih.gov/articles/PMC9708024/>
73. Meskó B, Görög M. A short guide for medical professionals in the era of artificial intelligence. NPJ digital medicine [Internet]. NPJ Digit Med; 2020 [cited 2025 Oct 9]; 3:126. Available from: <https://pubmed.ncbi.nlm.nih.gov/33043150/>
 74. Olaisen S, Smistad E, Espeland T, Hu J, Padeloup D, Østvik A, et al. Automatic measurements of left ventricular volumes and ejection fraction by artificial intelligence: clinical validation in real time and large databases. European Heart Journal – Cardiovascular Imaging [Internet]. Oxford Academic; 2024 [cited 2025 Oct 9];25:383–95. Available from: <https://dx.doi.org/10.1093/ehjci/jead280>
 75. Akan T, Alp S, Bhuiyan MS, Helmy T, Orr AW, Bhuiyan MMR, et al. ViViEchoformer: deep video regressor predicting ejection fraction. J Imaging Inform Med. [Internet]. medRxiv; 2025 [cited 2025 Oct 9];38(4):2041–52. Available from: <https://pubmed.ncbi.nlm.nih.gov/38947006/>
 76. He B, Kwan AC, Cho JH, Yuan N, Pollick C, Shiota T, et al. Blinded, randomized trial of sonographer versus AI cardiac function assessment. Nature [Internet]. Nature Research; 2023 [cited 2025 Oct 9];616:520–4. Available from: <https://www.nature.com/articles/s41586-023-05947-3>
 77. Neskovic AN, Skinner H, Price S, Via G, De Hert S, Stankovic I, et al. Focus cardiac ultrasound core curriculum and core syllabus of the European Association of Cardiovascular Imaging. European heart journal Cardiovascular Imaging [Internet]. Eur Heart J Cardiovasc Imaging; 2018 [cited 2025 Oct 9];19:475–81. Available from: <https://pubmed.ncbi.nlm.nih.gov/29529170/>
 78. Kagiya N, Abe Y, Kusunose K, Kato N, Kaneko T, Murata A, et al. Multicenter validation study for automated left ventricular ejection fraction assessment using a handheld ultrasound with artificial intelligence. Scientific Reports [Internet]. Nature Research; 2024 [cited 2025 Oct 9];14:1–8. Available from: <https://www.nature.com/articles/s41598-024-65557-5>
 79. Maani F, Ukaye A, Saadi N, Saeed N, Yaqub M. SimLVSeg: simplifying left ventricular segmentation in 2-D+time echocardiograms with self- and weakly supervised learning. Ultrasound in Medicine and Biology [Internet]. Elsevier Inc.; 2024 [cited 2025 Oct 9];50:1945–54. Available from: <https://pubmed.ncbi.nlm.nih.gov/39343627/>
 80. Salte IM, Østvik A, Olaisen SH, Karlsen S, Dahlslett T, Smistad E, et al. Deep learning for improved precision and reproducibility of left ventricular strain in echocardiography: A test-retest study. Journal of the American Society of Echocardiography [Internet]. Elsevier Inc.; 2023 [cited 2025 Oct 9];36:788–99. Available from: <https://pubmed.ncbi.nlm.nih.gov/36933849/>
 81. Kwan AC, Chang EW, Jain I, Theurer J, Tang X, Francisco N, et al. Deep learning-derived myocardial strain. JACC: Cardiovascular Imaging [Internet]. Elsevier Inc.; 2024 [cited 2025 Oct 9];17:715–25. Available from: <https://pubmed.ncbi.nlm.nih.gov/38551533/>
 82. Myhre PL, Hung CL, Frost MJ, Jiang Z, Ouwerkerk W, Teramoto K, et al. External validation of a deep learning algorithm for automated echocardiographic strain measurements. European heart journal Digital health [Internet]. Eur Heart J Digit Health; 2023 [cited 2025 Oct 9];5:60–8. Available from: <https://pubmed.ncbi.nlm.nih.gov/38264705/>
 83. Nagueh SF, Sanborn DY, Oh JK, Anderson B, Billick K, Derumeaux G, et al. Recommendations for the evaluation of left ventricular diastolic function by echocardiography

- and for heart failure with preserved ejection fraction diagnosis: An update from the American Society of Echocardiography. *Journal of the American Society of Echocardiography* [Internet]. Elsevier Inc.; 2025 [cited 2025 Oct 9];38:537–69. Available from: <https://onlinejase.com/action/showFullText?pii=S0894731725001579>
84. Tromp J, Bauer D, Claggett BL, Frost M, Iversen MB, Prasad N, et al. A formal validation of a deep learning-based automated workflow for the interpretation of the echocardiogram. *Nature communications* [Internet]. Nat Commun; 2022 [cited 2025 Oct 9];13. Available from: <https://pubmed.ncbi.nlm.nih.gov/36351912/>
 85. Gruca MM, Slivnick JA, Singh A, Cotella JJ, Subashchandran V, Prabhu D, et al. Noninvasive assessment of left ventricular end-diastolic pressure using machine learning-derived phasic left atrial strain. *European heart journal Cardiovascular Imaging* [Internet]. Eur Heart J Cardiovasc Imaging; 2023 [cited 2025 Oct 9];25:18–26. Available from: <https://pubmed.ncbi.nlm.nih.gov/37708373/>
 86. Karužas A, Miščikas L, Kiziela A, Šablauskas K, Kažukauskienė I, Verikas D, et al. Deep learning-driven automated assessment of left ventricular diastolic function in echocardiography. *Echocardiography (Mount Kisco, NY)* [Internet]. Echocardiography; 2025 [cited 2025 Oct 9];42(9):e70290. Available from: <https://pubmed.ncbi.nlm.nih.gov/40892533/>
 87. Remme EW, Inoue K, Smiseth OA. Machine learning in diastolic dysfunction: Left atrial strain trace superior to single points for estimation of filling pressure†. *European heart journal Cardiovascular Imaging* [Internet]. Eur Heart J Cardiovasc Imaging; 2023 [cited 2025 Oct 9];25:27–8. Available from: <https://pubmed.ncbi.nlm.nih.gov/37818845/>
 88. Lee E, Ito S, Miranda WR, Lopez-Jimenez F, Kane GC, Asirvatham SJ, et al. Artificial intelligence-enabled ECG for left ventricular diastolic function and filling pressure. *NPJ Digital Medicine* [Internet]. Nature Research; 2024 [cited 2025 Oct 9];7(1):4. Available from: <https://pmc.ncbi.nlm.nih.gov/articles/PMC10770308/>
 89. Akerman AP, Al-Roub N, Angell-James C, Cassidy MA, Thompson R, Bosque L, et al. External validation of artificial intelligence for detection of heart failure with preserved ejection fraction. *Nature Communications* [Internet]. Nature Research; 2025 [cited 2025 Oct 9];16:1–12. Available from: <https://www.nature.com/articles/s41467-025-58283-7>
 90. Sveric KM, Botan R, Winkler A, Dindane Z, Allothman G, Cansiz B, et al. The role of artificial intelligence in standardizing global longitudinal strain measurements in echocardiography. *European Heart Journal – Imaging Methods and Practice* [Internet]. Eur Heart J Imaging Methods Pract; 2024 [cited 2025 Oct 9];2(4):qyae130. Available from: <https://pubmed.ncbi.nlm.nih.gov/39712903/>
 91. Averbuch T, Sullivan K, Sauer A, Mamas MA, Voors AA, Gale CP, et al. Applications of artificial intelligence and machine learning in heart failure. *European heart journal Digital health* [Internet]. Eur Heart J Digit Health; 2022 [cited 2025 Oct 9];3:311–22. Available from: <https://pubmed.ncbi.nlm.nih.gov/36713018/>
 92. Khan MS, Arshad MS, Greene SJ, Van Spall HGC, Pandey A, Vemulapalli S, et al. Artificial intelligence and heart failure: A state-of-the-art review. *European journal of heart failure* [Internet]. Eur J Heart Fail; 2023 [cited 2025 Oct 9];25:1507–25. Available from: <https://pubmed.ncbi.nlm.nih.gov/37560778/>
 93. Mazzolai L, Teixeira-Tura G, Lanzi S, Boc V, Bossone E, Brodmann M, et al. 2024 ESC Guidelines for the management of peripheral arterial and aortic diseases. *European heart journal* [Internet]. Eur Heart J; 2024 [cited 2025 Oct 9];45:3538–700. Available from: <https://pubmed.ncbi.nlm.nih.gov/39210722/>

94. Isselbacher EM, Preventza O, Black JH, Augoustides JG, Beck AW, Bolen MA, et al. 2022 ACC/AHA guideline for the diagnosis and management of aortic disease: A report of the American Heart Association/American College of Cardiology Joint Committee on Clinical Practice Guidelines. *Circulation* [Internet]. *Circulation*; 2022 [cited 2025 Oct 9];146:E334–482. Available from: <https://pubmed.ncbi.nlm.nih.gov/36322642/>
95. Sahashi Y, Ieki H, Yuan V, Christensen M, Vukadinovic M, Binder-Rodriguez C, et al. Artificial Intelligence automation of echocardiographic measurements. *Journal of the American College of Cardiology* [Internet]. *J Am Coll Cardiol*; 2025 [cited 2025 Oct 9];86:964–78. Available from: <https://pubmed.ncbi.nlm.nih.gov/40914895/>
96. Holste G, Oikonomou EK, Tokodi M, Kovács A, Wang Z, Khera R. Complete AI-enabled echocardiography interpretation with multitask deep learning. *JAMA* [Internet]. *JAMA*; 2025 [cited 2025 Oct 9];334(4):306–18. Available from: <https://pubmed.ncbi.nlm.nih.gov/40549400/>
97. Karužas A, Balčiūnas J, Fukson M, Verikas D, Matuliuskas D, Platūkis T, et al. Artificial intelligence for automated evaluation of aortic measurements in 2D echocardiography: Feasibility, accuracy, and reproducibility. *Echocardiography (Mount Kisco, NY)* [Internet]. *Echocardiography*; 2022 [cited 2025 Oct 9];39:1439–45. Available from: <https://pubmed.ncbi.nlm.nih.gov/36266744/>
98. Krishna H, Dohse C, Smith D, Frost M, Equilbec C, Chin G, et al. Application of machine learning technology to automate thoracic aorta dimensions by echocardiography. *Journal of the American Society of Echocardiography* [Internet]. Elsevier Inc.; 2025 [cited 2025 Oct 9];38:127–9. Available from: <https://pubmed.ncbi.nlm.nih.gov/39515397/>
99. Krishna H, Desai K, Slostad B, Bhayani S, Arnold JH, Ouwerkerk W, et al. Fully automated Artificial Intelligence assessment of aortic stenosis by echocardiography. *Journal of the American Society of Echocardiography* [Internet]. Elsevier Inc.; 2023 [cited 2025 Oct 13];36:769–77. Available from: <https://pubmed.ncbi.nlm.nih.gov/36958708/>
100. Bartolacelli Y, Barbieri A, Antonini-Canterin F, Pepi M, Monte IP, Trocino G, et al. Imaging quality control, methodology harmonization and clinical data management in Stress Echo 2030. *Journal of clinical medicine* [Internet]. *J Clin Med*; 2021 [cited 2025 Oct 9];10(14):3020. Available from: <https://pubmed.ncbi.nlm.nih.gov/34300186/>
101. Prota C, Cortigiani L, Campagnano E, Wierzbowska-Drabik K, Kasprzak J, Colonna P, et al. Left atrium stress echocardiography: correlation between left atrial volume, function, and B-lines at rest and during stress. *Open Exploration* 2019 2:1 [Internet]. *Open Exploration*; 2024 [cited 2025 Oct 9];2:19–30. Available from: <https://www.explorationpub.com/Journals/ec/Article/101218>
102. Cortigiani L, Gaibazzi N, Ciampi Q, Rigo F, Rodríguez-Zanella H, Wierzbowska-Drabik K, et al. High resting coronary flow velocity by echocardiography is associated with worse survival in patients with chronic coronary syndromes. *Journal of the American Heart Association* [Internet]. *J Am Heart Assoc*; 2024 [cited 2025 Oct 9];13(4):e031270. Available from: <https://pubmed.ncbi.nlm.nih.gov/38362899/>
103. Baggiano A, Mushtaq S, Fusini L, Muratori M, Pontone G, Pepi M. Artificial Intelligence in Cardiovascular Imaging: Current Applications and New Horizons. *Journal of cardiovascular echography* [Internet]. *J Cardiovasc Echogr*; 2025 [cited 2025 Oct 13];35:97–107. Available from: <https://pubmed.ncbi.nlm.nih.gov/40950368/>
104. Raissi-Dehkordi N, Raissi-Dehkordi N, Xu B. Contemporary applications of artificial intelligence and machine learning in echocardiography. *npj Cardiovascular Health*

- 2025 2:1 [Internet]. Nature Publishing Group; 2025 [cited 2025 Oct 9];2:1–10. Available from: <https://www.nature.com/articles/s44325-025-00064-8>
105. Woodward G, Bajre M, Bhattacharyya S, Breen M, Chiocchia V, Dawes H, et al. PROTEUS study: A prospective randomized controlled trial evaluating the use of Artificial Intelligence in stress echocardiography. *American Heart Journal* [Internet]. Elsevier Inc.; 2023 [cited 2025 Oct 9];263:123–32. Available from: <https://pubmed.ncbi.nlm.nih.gov/37192698/>
 106. Mahdavi M, Thomas N, Flood C, Stewart-Lord A, Baillie L, Grisan E, et al. Evaluating artificial intelligence-driven stress echocardiography analysis system (EASE study): A mixed method study. *BMJ open* [Internet]. BMJ Open; 2024 [cited 2025 Oct 9];14(10):e079617. Available from: <https://pubmed.ncbi.nlm.nih.gov/39357985/>
 107. Slivnick JA, Gessert NT, Cotella JI, Oliveira L, Pezzotti N, Eslami P, et al. Echocardiographic detection of regional wall motion abnormalities using Artificial Intelligence compared to human readers. *Journal of the American Society of Echocardiography : official publication of the American Society of Echocardiography* [Internet]. J Am Soc Echocardiogr; 2024 [cited 2025 Oct 9];37:655–63. Available from: <https://pubmed.ncbi.nlm.nih.gov/38556038/>
 108. Johnson CL, Leeson P. Are we ready to let AI replace the human “Eye” when looking for wall motion abnormalities? *Journal of the American Society of Echocardiography* [Internet]. Elsevier Inc.; 2024 [cited 2025 Oct 9];37:664–5. Available from: <https://pubmed.ncbi.nlm.nih.gov/38761986/>
 109. Picano E, Ciampi Q, Arbucci R, Zagatina A, Kalinina E, Padang R, et al. Stress Echo 2030 study: A flagship project of the Italian Society of Echocardiography and Cardiovascular Imaging. *Journal of cardiovascular echography* [Internet]. J Cardiovasc Echogr; 2025 [cited 2025 Oct 9];35:1–7. Available from: <https://pubmed.ncbi.nlm.nih.gov/40463758/>
 110. Okafor J, Almajali M, Cervantes J, Li W, Vamvakidou A, Senior R, et al. Use of ultrasound contrast agents in stress echocardiography: three for the price of one. *CASE* [Internet]. Elsevier BV; 2025 [cited 2025 Oct 9];9:194–9. Available from: <https://pubmed.ncbi.nlm.nih.gov/40583874/>
 111. Galderisi M, Cosyns B, Edvardsen T, Cardim N, Delgado V, Di Salvo G, et al. Standardization of adult transthoracic echocardiography reporting in agreement with recent chamber quantification, diastolic function, and heart valve disease recommendations: an expert consensus document of the European Association of Cardiovascular Imaging. *European heart journal Cardiovascular Imaging* [Internet]. Eur Heart J Cardiovasc Imaging; 2017 [cited 2025 Oct 9];18:1301–10. Available from: <https://pubmed.ncbi.nlm.nih.gov/29045589/>
 112. Bahrami HSZ, Pedersen FHG, Myhr KA, Møgelvang R, Hassager C. Feasibility, repeatability, and reproducibility of contemporary diastolic parameters and classification. *The international journal of cardiovascular imaging* [Internet]. Int J Cardiovasc Imaging; 2021 [cited 2025 Oct 9];37:931–44. Available from: <https://pubmed.ncbi.nlm.nih.gov/33394217/>
 113. Wong JM, Abouzeid CM, Nguyen TD, Fang Q, Bibby D, Schiller NB. Interrater reproducibility of the 2016 American society of echocardiography left ventricular diastolic function guidelines. *Echocardiography (Mount Kisco, NY)* [Internet]. Echocardiography; 2022 [cited 2025 Oct 9];39:678–84. Available from: <https://pubmed.ncbi.nlm.nih.gov/35342988/>
 114. Letnes JM, Eriksen-Volnes T, Nes B, Wisløff U, Salvesen Ø, Dalen H. Variability of echocardiographic measures of left ventricular diastolic function. *The HUNT study*.

- Echocardiography [Internet]. Echocardiography; 2021 [cited 2025 Oct 9];38:901–8. Available from: <https://pubmed.ncbi.nlm.nih.gov/33960012/>
115. Pandey A, Kagiya N, Yanamala N, Segar MW, Cho JS, Tokodi M, et al. Deep-learning models for the echocardiographic assessment of diastolic dysfunction. *JACC: Cardiovascular Imaging* [Internet]. Elsevier Inc.; 2021 [cited 2025 Oct 9];14:1887–900. Available from: <https://pubmed.ncbi.nlm.nih.gov/34023263/>
 116. Kim S, Park HB, Jeon J, Arsanjani R, Heo R, Lee SE, et al. Fully automated quantification of cardiac chamber and function assessment in 2-D echocardiography: clinical feasibility of deep learning-based algorithms. *The international journal of cardiovascular imaging* [Internet]. *Int J Cardiovasc Imaging*; 2022 [cited 2025 Oct 13];38:1047–59. Available from: <https://pubmed.ncbi.nlm.nih.gov/35152371/>
 117. Fletcher AJ, Lapidaire W, Leeson P. Machine learning augmented echocardiography for diastolic function assessment. *Frontiers in cardiovascular medicine* [Internet]. *Front Cardiovasc Med*; 2021 [cited 2025 Oct 9];8:711611. Available from: <https://pubmed.ncbi.nlm.nih.gov/34422935/>
 118. Chen X, Yang F, Zhang P, Lin X, Wang W, Pu H, et al. Artificial Intelligence–Assisted Left Ventricular Diastolic Function Assessment and Grading: Multiview Versus Single View. *Journal of the American Society of Echocardiography* [Internet]. Elsevier Inc.; 2023 [cited 2025 Oct 9];36:1064–78. Available from: <https://pubmed.ncbi.nlm.nih.gov/37437669/>
 119. Zhang M, Wan L, Liu K, Wu W, Li H, Wang Y, et al. Aortic roots assessment by an automated three-dimensional transesophageal echocardiography: an intra-individual comparison. *The international journal of cardiovascular imaging* [Internet]. *Int J Cardiovasc Imaging*; 2019 [cited 2025 Oct 9];35:2029–36. Available from: <https://pubmed.ncbi.nlm.nih.gov/31297671/>
 120. Beneduce A, Capogrosso C, Moroni F, Ancona F, Falasconi G, Pannone L, et al. Aortic valve area calculation using 3D transesophageal echocardiography: Implications for aortic stenosis severity grading. *Echocardiography (Mount Kisco, NY)* [Internet]. Echocardiography; 2020 [cited 2025 Oct 9];37:2071–81. Available from: <https://pubmed.ncbi.nlm.nih.gov/33026122/>
 121. Furiase N, Thomas JD. Automated algorithmic software in echocardiography Artificial Intelligence? *Journal of the American College of Cardiology* [Internet]. Elsevier USA; 2015 [cited 2025 Oct 9];66:1467–9. Available from: <https://pubmed.ncbi.nlm.nih.gov/26403343/>
 122. Wang Y, Yin L. Noninvasive identification and therapeutic implications of supernormal left ventricular contractile phenotype. *Open Exploration* 2019 2:3 [Internet]. *Open Exploration*; 2024 [cited 2025 Oct 9];2:97–113. Available from: <https://www.explorationpub.com/Journals/ec/Article/101225>
 123. Jang Y, Choi H, Yoon YE, Jeon J, Kim H, Kim J, et al. An Artificial Intelligence-based automated echocardiographic analysis: enhancing efficiency and prognostic evaluation in patients with revascularized STEMI. *Korean circulation journal* [Internet]. *Korean Circ J*; 2024 [cited 2025 Oct 13];54:743–56. Available from: <https://pubmed.ncbi.nlm.nih.gov/39434367/>
 124. Myhre PL, Gaibazzi N, Tuttolomondo D, Sartorio D, Ugolotti PT, Covani M, et al. Concordance of left ventricular volumes and function measurements between two human readers, a fully automated AI algorithm, and the 3D heart model. *Frontiers in cardiovascular medicine* [Internet]. *Front Cardiovasc Med*; 2024 [cited 2025 Oct 13];11:1400333. Available from: <https://pubmed.ncbi.nlm.nih.gov/39081366/>

125. Mor-Avi V, Khandheria B, Klempfner R, Cotella JI, Moreno M, Ignatowski D, et al. Real-time Artificial Intelligence-based guidance of echocardiographic imaging by novices: image quality and suitability for diagnostic interpretation and quantitative analysis. *Circulation Cardiovascular imaging* [Internet]. *Circ Cardiovasc Imaging*; 2023 [cited 2025 Oct 13];16:E015569. Available from: <https://pubmed.ncbi.nlm.nih.gov/37955139/>
126. Barzilai DH, Cohen-Shelly M, Sorin V, Zimlichman E, Massalha E, Allison TG, et al. Machine learning in cardiac stress test interpretation: a systematic review. *European heart journal Digital health* [Internet]. *Eur Heart J Digit Health*; 2024 [cited 2025 Oct 13];5:401–8. Available from: <https://pubmed.ncbi.nlm.nih.gov/39081945/>
127. O'Driscoll JM, Hawkes W, Beqiri A, Mumith A, Parker A, Upton R, et al. Left ventricular assessment with artificial intelligence increases the diagnostic accuracy of stress echocardiography. *European heart journal open* [Internet]. *Eur Heart J Open*; 2022 [cited 2025 Oct 13];2(5):oeac059. Available from: <https://pubmed.ncbi.nlm.nih.gov/36284642/>
128. Upton R, Akerman AP, Marwick TH, Johnson CL, Piotrowska H, Bajre M, et al. PROTEUS: A prospective RCT evaluating use of AI in stress echocardiography. *NEJM AI*. Massachusetts Medical Society; 2024;1.

DOKTORANTO INDĖLIS

- Bioetikos leidimui gauti reikiamų dokumentų rengimas ir pateikimas;
- Tiriamųjų grupių įtraukimas ir surinkimas;
- Prisidėjimas kuriant, mokant ir pritaikant DI modelius
- Ramybės echokardiografinis ištyrimas ir gautų duomenų analizė (KS diastolinių ir aortos parametrų dalis);
- Krūvio echokardiografijos duomenų surinkimas, susisteminimas ir DI pritaikymo metodologijos kūrimas kartu su bendraautoriais, dalyvaujant StressEcho2030 tyrime;
- Duomenų bazės sudarymas, susisteminant klinikinius, demografinius, echokardiografinius ir DI gautus duomenis;
- Bendradarbiavimas su UAB Ligence, panaudojant šios įmonės programinę įrangą;
- Statistinė duomenų analizė;
- Mokslinių publikacijų ruošimas su bendraautoriais ir pateikimas;
- Mokslinių tezių rengimas su bendraautoriais ir pristatymas tarptautinėse Europos kardiologų draugijos konferencijose.

PASKELBTOS PUBLIKACIJOS

Mokslo straipsniai, kuriuose skelbti disertacijos tyrimų rezultatai

1. **Karužas A**, Balčiūnas J, Fukson M, Verikas D, Matuliauskas D, Platūkis T, Vaičiulienė D, Jurgaitytė J, Kupstytė-Krištaponė N, Dirsienė R, Jaruševičius G, Šakalytė G, Plisienė J, Lesauskaitė V. Artificial intelligence for automated evaluation of aortic measurements in 2D echocardiography: Feasibility, accuracy, and reproducibility. *Echocardiography*. 2022;1-7. <https://doi.org/10.1111/echo.15475>
2. **Karužas A**, Miščikas L, Kiziela A, Šablauskas K, Kažukauskienė I, Verikas D, Naskauskas K, Šakalytė G, Jaruševičius G, Plisienė J, Lesauskaitė V. Deep learning-driven automated assessment of left ventricular diastolic function in echocardiography. *Echocardiography*. 2025;1-8. <https://doi.org/10.1111/echo.70290>
3. **Karužas A**, Ciampi Q, Kažukauskienė I, Miščikas L, Šablauskas K, Kiziela A, Verikas D, Plisienė J, Lesauskaitė V, Cortigiani L, Wierzbowska-Drabik K, Kasprzak JD, Lowenstein J, Prota C, Gaibazzi N, Tuttolomondo D, Lepone A, Marconi S, Arbucci R, Picano E, Stress Echo 2030 Study Group. Artificial intelligence implementation in automated heart chambers quantification during pharmacological stress echocardiography. *European Heart Journal – Digital Health*, 2025, 1–10, <https://doi.org/10.1093/ehjdh/ztaf121>

Tarptautinėse mokslinėse konferencijose skelbti disertacijos tyrimų rezultatai

1. Moderuojamas žodinis pranešimas Europos kardiologų draugijos kongrese (ESC Congress 2022).
Karužas A, Sablauskas K, Wierzbowska-Drabik K, Dirsienė R, Fukson M, Kiziela A, Matuliauskas D, Balciunas J, Verikas D, Strioga M, Kasprzak J, Lesauskaite V, Ciampi Q, Picano E. “Deep learning for evaluating left atrium stress echocardiography: a proof of principle study”.
2. Moderuojamas žodinis pranešimas Europos širdies vaizdinių tyrimų asociacijos metiniame kongrese (EACVI 2023).
Karužas A, Kažukauskiene I, Kiziela A, Naskauskas K, Wierzbowska-Drabik K, Ciampi Q, Cortigiani L, Kasprzak JD, Prota C, Lepone A, Gaibazzi N, Lowenstein J, Marconi S, Arbucci R, Picano E. “Automated evaluation of the left-sided heart volumes using machine learning during stress echocardiography: a multicenter Stress Echo 2030 study”.

3. Moderuojamas žodinis pranešimas Europos širdies vaizdinių tyrimų asociacijos metiniame kongrese (EuroEcho 2024)
Karuzas A, Miscikas L, Sablauskas K, Kazukauskienė I, Verikas D, Naskauskas K, Sakalytė G, Jarusevicius G, Plisienė J, Lesauskaitė V. “Deep learning-driven automated assessment of left ventricular diastolic function in echocardiography”.

CURRICULUM VITAE

Name, Surname: Arnas Karužas
Address: Sukilėlių str. 15, Kaunas, Lithuania
Phone number +370 679 26921
E-mail: arnas.karuzas@lsmu.lt

Education

2011–2017 Lithuanian University of Health Sciences, Medical Academy, Faculty of Medicine, master degree in medicine, medicine doctor, honors degree

2017–2021 Lithuanian University of Health Sciences, Medical Academy, Faculty of Medicine, cardiology residency, cardiologist

2021 European Society of Cardiology Board certified cardiologist

2021 KTH Royal Institute of Technology, Artificial intelligence in healthcare

2021–2025 PhD student, Lithuanian University of Health Sciences, Automation of Cardiovascular Investigation Laboratory, Institute of Cardiology, Kaunas, Lithuania

2014–2025 Participation in more than 100 different Lithuanian and international conferences of cardiology, project management and leadership, digital health and artificial intelligence

Employment history

2021–until now Hospital of Lithuanian University of Health Sciences Kauno klinikos, Cardiology Department, Cardiologist

2021–until now Lithuanian University of Health Sciences Institute of Cardiology, Laboratory for Automation of Cardiovascular Investigation, Junior researcher

2017–2021 Hospital of Lithuanian University of Health Sciences Kauno klinikos, Cardiology Department, cardiology resident, MD

2018–2020	Lithuanian University of Health Sciences Institute of Physiology and Pharmacology, teaching assistant
2019–2020	Lithuanian University of Health Sciences Development Department, project coordinator

Professional memberships

2015–until now	Professional member of European society of cardiology
2015–until now	Member of European association of cardiovascular imaging (EACVI Associate)
2023–until now	Member of the Working Group on e-Cardiology (European society of cardiology)
2024–until now	Board member of Lithuanian Society of Cardiology, Head of digital transformation and innovation committee
2023–until now	Board member of Kaunas region society of Cardiology

Personal awards

- prof. Kazys Oželis fellowship for master students 2015
- European Commissioner Vytenis Povilas Andriukaitis fellowship 2016.
- Best poster award in European Society of Cardiology congress 2016 in Rome in imaging section;
- Lithuanian Presidential fellowship for master students 2016/2017

Languages

English (C1 level), French (A2 level), German (A1 level),
Lithuanian (native)

PRIEDAS

Kairiojo skilvelio ir prieširdžio tūrių matavimų metodika

Kairiojo skilvelio galinis diastolinis tūris (KSGDT).

KSGDT matavimai atlikti iš viršūninių keturių ir dviejų kamerų projekcijų, galinės diastolės metu, kuri apibrėžiama kaip didžiausias matomas skilvelio plotas kiekviename vaizde. Speniniai raumenys ir trabekulės nebuvo įtraukti į kontūro žymėjimą ir buvo laikomi ertmės dalimi. Kontūras buvo užbaigiamas nubrėžiant horizontalią liniją per kairįjį skilvelį mitralinio vožtuvo žiedo lygyje. Iš šios linijos centro buvo nubrėžta vertikali linija iki toliausio viršūnės taško, kad būtų apskaičiuotas disko aukštis.

Kairiojo skilvelio galinis sistolinis tūris (KSGST).

Kairiojo skilvelio galinio sistolinio tūrio matavimai atlikti iš keturių ir dviejų kamerų projekcijų, galinės sistolės metu, kuri apibrėžiama kaip mažiausias matomas skilvelio plotas kiekviename vaizde. Speniniai raumenys ir trabekulės nebuvo įtraukti į kontūro žymėjimą ir buvo laikomi ertmės dalimi. Kontūras buvo užbaigiamas nubrėžus horizontalią liniją per kairįjį skilvelį mitralinio vožtuvo žiedo lygyje. Iš šios linijos centro buvo nubrėžta vertikali linija iki toliausio viršūnės taško, siekiant apskaičiuoti disko aukštį.

Kairiojo skilvelio išstūmio frakcija (KSIF).

KSGDT ir KSGST reikšmės buvo naudojamos KSIF apskaičiuoti pagal formulę: $KSIF = (KSGST - KSGDT) / KSGST \times 100$.

Kairiojo prieširdžio galinis sistolinis tūris

Kairiojo prieširdžio galinis sistolinis tūris matuotas vertinant prieširdžio endokardo ribas keturių ir dviejų kamerų projekcijose. Kairiojo prieširdžio kontūras buvo užbaigiamas nubrėžiant liniją nuo vienos mitralinio žiedo pusės iki priešingos. Prieširdžio ausytė ir plaučių venos nebuvo įtrauktos į kontūrą. Kairiojo prieširdžio ilgis buvo matuojamas tiek keturių, tiek dviejų kamerų projekcijose – nuo mitralinio žiedo centro iki vidinio, toliausiai esančio nustatyto viršutinės prieširdžio sienelės taško, maždaug vidurinėje jos dalyje.