



СУНЪИЙ ИНТЕЛЛЕКТДАН ФОЙДАЛАНИБ СИНТЕТИК РАҚАМЛИ ТИББИЙ ТАСВИРЛАРНИ ҲОСИЛ ҚИЛИШ ВА БАҲОЛАШ

Мўминов Баходир Болтаевич

Муҳаммад ал Хоразмий номиндаги Тошкент ахборот технологиялари университети кафедра мудури, т.ф.д. Тошкент, Ўзбекистон.
mbbahodir@gmail.com

Насимова Нигорахон Мизробовна

Муҳаммад ал Хоразмий номиндаги Тошкент ахборот технологиялари университети докторанти. Тошкент, Ўзбекистон.
nigora.nasimova@gmail.com

Насимов Рашид Ҳамид ўғли

Тошкент давлат иқтисодиёт университети “Рақамли иқтисодиёт ва ахборот технологиялари” кафедраси доценти (PhD). Тошкент, Ўзбекистон. rashid.nasimov@gmail.com

DOI: https://doi.org/10.55439/EIT/vol10_iss3/a35

Аннотация

Сўнги йилларда тиббиёт соҳасида қарор қабул қилишга кўмаклашувчи интеллектуал дастурларни ишлаб чиқишга бўлган қизиқишлар ортиб бормоқда. Касалликларга ташхис қўйиш, таснифлаш, тавсиялар бериш жараёнларининг аниқлигини юқори бўлиши катта ҳажмдаги маълумотлар тўпламини ҳосил қилиш билан чамбарчас боғлиқдир. Ушбу мақолада FID қийматини тезкор ҳисоблашда фойдаланилган усуллардан фарқли тиббий тасвирларни баҳолашда аниқлиги FID қийматидан юқори бўлган FMD қийматини киритишни таклиф этдилди.

Калит сўзлар: эхокардиограмма, сунъий интеллект, GAN тармоғи, FID қиймати, синтетик тиббий тасвир, кўрсаткичлар бўйича баҳолаш.

Кириш

Сўнги йилларда тасвир, видео, матн, овоз ва бошқа турдаги тиббий маълумотларга интеллектуал ишлов бериш, уларни автоматик шарҳлаш ва сигментация қилиш жараёнларида сунъий интеллект (СИ) алгоритмларидан фойдаланиш ҳамда касалликларнинг белгиларини аниқлаш, таснифлаш, ташхис қўйиш, қарор қабул қилишга кўмаклашиш ва тавсия беришга йўналтирилган дастурларни ишлаб чиқишга бўлган қизиқишлар тобора ортиб бормоқда. Хусусан, дунёда ўлим кўрсаткичи бўйича энг юқори бўлган юрак қон-томир касалликларини ташхислаш, даволаш, барвақт аниқлаш, жарроҳлик амалиётлари ва бошқа жараёнларда сунъий интеллект алгоритмлари кенг жорий этиб борилмоқда.

Юрак қон-томир касалликлари соҳасида, хусусан юрак тасвирларига интеллектуал ишлов бериш йўналишида олиб борилаётган тадқиқотлар натижалари

машинали ўқитиш, чуқур ўқитиш ва когнитив ҳисоблаш кардиология амалиётлари учун истиқболли эканлигини кўрсатмоқда. Маълумки, тиббиётда СИ алгоритмларига асосланган дастурларни ишлаб чиқишда қон таҳлиллари, рентген тасвирлари, компьютер томография (КТ), магнит резонансли томография (МРТ), электрокардиограмма (ЭКГ), эхокардиограмма (Эхо) каби маълумотлар асосланган маълумотлар базаси талаб этилади. Шу билан бирга ҳар бир юрак касалликлари учун мос маълумотлар базасини ишлаб чиқиш зарур. Дастурнинг ишлаш аниқлиги юқори бўлиши бу катта ҳажмдаги маълумотлар базасини қуриш ва мос СИ алгоритмларини танлашга боғлиқ бўлади.

Маълумотлар базасини ишлаб чиқишда талаб этиладиган тиббий маълумотлар турли манбалар (рақамли қурилмалар)дан олинганлиги сабабли, маълумотлардаги шовқинлар интеллектуал ишлов бериш жараёнига бевосита таъсир қилади. МРТ ва КТ тасвирларидан фарқли Эхо тасвирларида шовқинлар даражаси юқори, тасвир анча мавҳум ва хира бўлади. Ҳатто шовқинлар даражаси пасайтирилгандан кейин ҳам Эхо тасвирларини таснифлаш, улар асосида текшириладиган юрак соҳасини ва ундаги патологияларни аниқлаш текширувчи мутахассисдан етарлича катта малакани талаб этади.

Кардиология амалиётларида СИ алгоритмларига асосланган дастурлардан фойдаланиш, кардиолог мутахассисларга қарор қабул қилишда кўмаклашувчи восита сифатида хизмат қилиши мумкин. Аммо, СИ алгоритмларининг аксарияти ўқитувчи (supervised) бўлганлигини инобатга олса, ўқитишдан қутилган натижани олиш учун синфланган ва номланмаган жуда катта маълумотлар базаси талаб этилади. Бу эса ўз навбатида жуда катта ресурс (вақт, пул, ишчи кучи ва ҳ.к.) деганидир. Бугунги кунда тадқиқот ва изланишлар натижасида ишлаб чиқилган тиббий маълумотлар базалари орасида таснифланган маълумотлар базаларининг сони кам ва аксарияти очиқ фойдаланиш учун ишлаб чиқилмаган. Шунинг учун тиббий маълумотлар базасини синтетик тасвирлар асосида ишлаб чиқишга эҳтиёжлар юзага келмоқда.

Охири йилларда синтетик тасвирлар асосида маълумотлар базасини қуриш бўйича қатор йўналишларда илмий изланишлар олиб борилмоқда [1]. Ушбу йўналишдаги аксарият тадқиқот ишларида синтетик тасвирларни ҳосил қилишда юқори самарадорликка эга бўлган GAN (Generative Adversarial Network), AE (Autoencoder), U-net ҳамда уларнинг гибрид архитектураларидан кенг фойдаланиб келинмоқда. Хусусан, ультратовушли тасвир (УТТ)ларга интеллектуал ишлов беришда GAN архитектурасидан фойдаланиб 4 турдаги тадқиқотлар олиб борилган:

Биринчи: Бунда DGAN (Deep generative adversarial network) ва CycleGAN (Cycle generative adversarial network) архитектураларидан фойдаланган ҳолда тасвирларнинг сифатини яхшилаш, юқори резолуцияли тасвирларни ҳосил қилиш ва тасвирдаги турли шовқинларни пасайтириш бўйича илмий тадқиқотлар амалга оширилган [2, 3].

Иккинчиси: Бу йўналишдаги тадқиқотларда, УТТ тасвирларини шархлашда муҳим босқич ҳисобланувчи - тасвирларни автоматик сегментация қилиш, юракнинг муайян қисмлари ажратиш кўрсатиш ва синтетик УТТ тасвирларни ишлаб чиқиш амалга оширилган [4,5].

Учинчиси: Ушбу мақсадга қаратилган тадқиқотларда тасвирдан тасвирга ўтказиш жараёни тадқиқ қилинган бўлиб, асосан CycleGAN архитектураси ёрдамида УТТ тасвирлари МРТ тасвирларига ўзгартириш, УТТ тасвирларини назарий эскиз тасвирларига айлантириш, УТТ тасвирларини эластография тасвирларига айлантириш каби муҳим тадқиқотлар олиб борилган [6, 7, 8].

Тўртинчиси: *Охири йўналишда* ҳақиқий тасвирлар каби синтетик тасвирларни юқори аниқликда ҳосил қилиш қаратилган тадқиқотлар олиб борилган. Бундай синтетик тасвирларни ҳосил қилишнинг бошқа вазифалардан мураккаблиги

шундаки, синтетик тасвирлар ўқув танланмаларидан фарқли бўлиши, аммо айна пайтда мақсад қилинган касалликнинг белгиларини намоён этиши лозим. Одатда инсонларнинг физиологик ҳолати бир биридан фарқ қилганлиги сабабли, ҳар бир кишида бир турдаги патология ҳолати турлича кузатилиши мумкин. Синтетик тасвирларни ҳосил қилишда, энг аҳамиятли жиҳати шундаки, белгиланган патология чегарасини аниқ белгилаш ва ўша чегарага қатъий амал қилиш муҳимдир, акс ҳолда бошқа патологияни ифодаловчи тасвирлар ҳосил қилиниши мумкин.

Синтетик тасвирларни ҳосил қилишда яратилган алгоритмнинг тўғри ишлашини баҳолаш муҳим ҳисобланади. Юқоридаги тўртда йўналиш доирасида амалга оширилган изланишларда ишлаб чиқилган алгоритмларни баҳолашда махсус математик аппаратлардан фойдаланилади. 2 йўналишдаги тадқиқотларда вазифаларни бажариш аниқлигини баҳолаш учун (а) ҳамжга асосланган кўрсаткичлар; (b) сирт масофасига асосланган кўрсаткичлар; (c) клиник самарадорлик кўрсаткичлари каби ёндашувлардан фойдаланиш мумкин. 4 йўналишдаги тадқиқотлар доирасида ҳосил қилинган синтетик тасвирларни баҳолашда FID ва IS коэффициентларидан фойдаланиш мумкин. Аммо тадқиқот натижаларини FID ва IS коэффициентлари орқали ҳисоблаш мураккаб ва тиббий тасвирлар учун мослаштирилмаган. Шу сабабли, таклиф этилаётган илмий ишимизда баҳолашнинг янгича ёндашуви ишлаб чиқилди. Ушбу мақолада шунингдек GAN архитектураси янгича архитектураси таклиф этилди, ҳамда ҳосил қилинган синтетик тасвирлар янгича ёндашув асосида баҳоланди ва олинган натижалар FID қийматининг натижалари билан таққосланди.

Ушбу мақола қуйидаги боблардан ташкил топди. Биринчи бобда ушбу соҳада ҳозирги кунга қадар амалга оширилган асосий тадқиқотлар ва уларнинг таҳлиллари келтирилган. Иккинчи бобда таклиф этилаётган GAN архитектураси ҳақида маълумотлар келтирилган. Учинчи бобда таклиф этилаётган тармоқ архитектураси ва математик аппарат ва олинган натижалар ҳақида маълумотлар келтирилган. Бешинчи бобда янги таклиф этилган синтетик тасвирларни баҳолаш усули муҳокама қилинган.

II. GAN архитектураси

GAN архитектураси биринчи марта 2014 йилда олим Гудфеллоу томонидан таништирилган ва тармоқ чуқур ўқитишга асосланган генератив модел ҳисобланган. GAN архитектураси бир-бирининг йўқотишларини камайтириш орқали рақобатлашувчи иккита тармоқдан ташкил топади. Биринчи тармоқ генератор вазифасини бажаради ва синтетик тасвирларни ҳосил қилади. Иккинчи тармоқ эса дискриминатор вазифасини бажариб, ҳосил қилинган тасвирнинг синтетик ёки ҳақиқий эканлигини аниқлайди. Ушбу тармоқнинг умумий ёқотишлар функцияси (minmax loss функцияси) қуйидагича:

$$\min_G \max_D V(G, D)$$

$$V(D, G) = E_{x \sim p_{data}(x)} [\log D(x)] + E_{z \sim p_z(z)} [\log(1 - D(G(z)))]$$

Бу ерда:

- $D(x)$ - x берилган маълумотларни ҳақиқий бўлиши эҳтимоллигининг дискриминатор томонидан баҳоланиши;
- E_x - барча ҳақиқий маълумотлар тўплами учун кутилган қиймат.
- $G(z)$ - z шовқин берилганда генераторнинг чиқишида ҳосил қилинган тасвир;

- $D(G(z))$ - дискриминаторнинг синтетик тасвирнинг ҳақиқий бўлиши эҳтимоллигини баҳолаш;
- E_z - генераторга кирган барча тасодикий шовқинларнинг натижаси бўйича кутилган қиймат (аслида барча ҳосил қилинган синтетик тасвирлар бўйича кутилган қиймат $G(z)$).

Формуладан маълум бўладики, генераторнинг йўқотишлари тўғридан тўғри тармоқ ёқотишларига таъсир қилмайди, аммо генератор йўқотишларининг ортиб бориши умумий йўқотишларнинг камайишига олиб келади. Ушбу тармоқнинг камчилиги градиент қийматининг кичрайиб кетиши билан боғлиқ. Агар дискриминаторнинг ажратиш (баҳолаш) қобилияти ортса, генераторга узатадиган қиймати жуда кичрайиб градиент Лосс функцияси нолга яқинлашади: $1 - \log DGz \approx 0$. Натижада, генератор тасвирни ҳосил қилиши учун зарур бўлган градиент қиймати нолга тенг бўлса, генератор ҳеч қандай маълумот ололмайди ва ўрганиш жараёни тўхтайдди. Одатда бундай муаммо кузатилганида, Вассерштейн йўқотиши функцияси орқали бартараф этилиши мумкин.

Тиббий тасвирларни ҳосил қилиш жараёнида минимал йўқотишлар функциясига қўшимча $L_{\text{adversarial}}$, L_{image} , L_{sharp} , L_{shape} каби турли хил Лосс функцияларини киритиш мумкин ва бу орқали градиентнинг қийматини йўқолиб кетишини олдини олиш мумкин [10]. Шунингдек FID қийматини Лосс функция сифатида ҳам киритиш мумкин. Аммо бу қийматни ҳисоблашда матрицаларнинг ўртача квадратик қиймати ва изларини ҳисоблаш талаб этилиши боис, ҳисоблаш учун кўп вақт талаб этилади ва бу тармоқни ўқитиш жараёнини секинлаштиради. Хусусан GAN архитектурали тармоқларда синтетик тасвирларни юқори аниқликда ҳосил қилиш жараёни катта маълумотлар базасини ва жуда кўп давр давомида ўқитишни талаб қилишини инобатга олсак, FID қийматини қўшимча Лосс сифатида киритиш тармоқни ўқитишни янада мураккаблаштиради. 4-бобда ушбу масала бўйича янада аниқроқ танишиб чиқамиз.

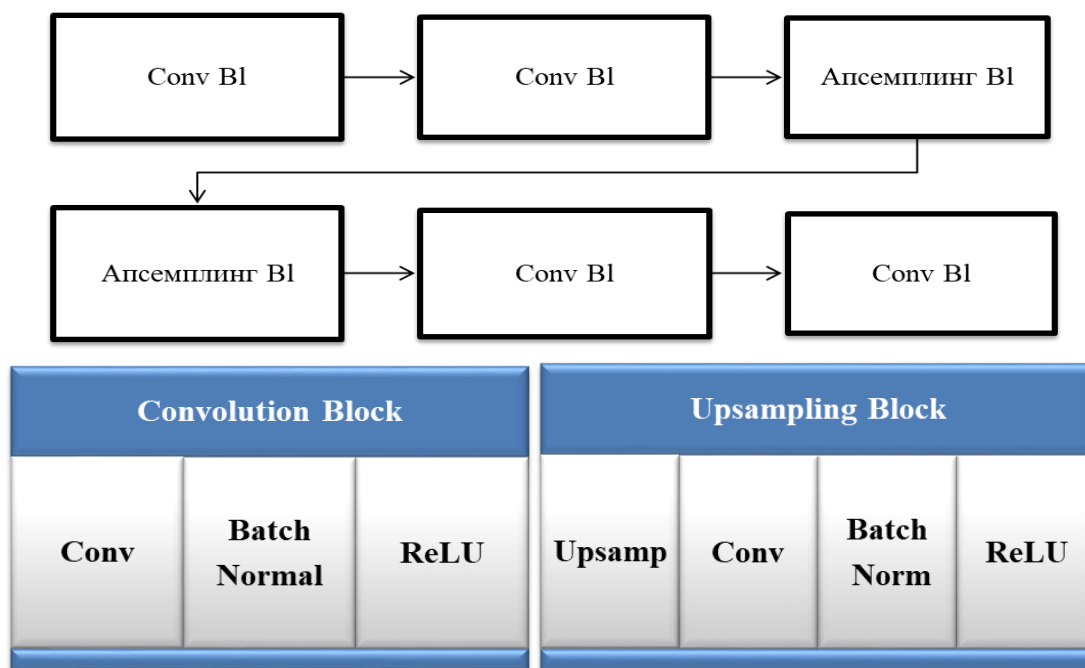
Генераторда синтетик тасвирни ҳосил қилиш билан боғлиқ ҳолат GAN архитектурасида яна бир мураккаб жараён ҳисобланиб, синтетик тасвирни ҳосил бўлиши кириш қатлами маълумоти билан боғлиқ бўлмайди. Шу сабабли GAN архитектурасига кирувчи маълумот сифатида шовқинлардан фойдаланилади. Кирувчи шовқин кичик ўлчамда бўлиб, GAN архитектурасининг кейинги қатламларида ушбу кирувчи шовқиннинг ўлчами катталаштирилади. Аммо катталаштириш жараёнида хира ва оқ-қора шовқинлари пайдо бўлади.

Хира ва оқ-қора шовқинларни камайтириш учун апсемплинг қатламининг энг яқин ва билайнер (икки чизиқли) усуллари таклиф этилган, ушбу усуллардан кўпгина тадқиқотларда фойдаланилган ва уларнинг иш бажариш қобилияти (performance) баҳоланган [11]. Баҳолашларда билайнер усули юқори натижаларни тақдим этган [12]. Апсемплинг қатламидаги амал бирлаштириш (Pooling) амалига тескари амал ҳисобланади ва ушбу қатламда ўқитиладиган параметрлар мавжуд бўлмайди. Шу сабабли тармоқни ўқитишда апсемплинг билан Conv қатламлари биргаликда фойдаланилган ва яхши натижа кўрсатган. Аммо тармоқни ўқитишда апсемплинг ва Conv қатламларидан кетма-кет фойдаланиш ҳисобландиган параметрлар сонининг ортишига ҳамда тармоқни ўқитиш жараёнини мураккаблашишига олиб келади. Ушбу муаммони олдини олиш учун, охириги йилларда амалга оширилган тадқиқотларда ConvTranspose усулидан кенг фойдаланилганлигини кўриш мумкин. ConvTranspose усулидан фойдаланганда тармоқнинг ўқитиш тезлиги ортади, аммо филтрларининг устма-уст тушуши натижасида оқ-қора шовқинлар пайдо бўлади.

III. Тадқиқот методологияси

3.1. Генератор тармоғи архитектураси

Ушбу мақолада синтетик Эхо тасвирларини ҳосил қилувчи GAN архитектурасининг ўзига хос бўлган кўриниши таклиф этилди. УТТ тасвирларини GAN архитектураси орқали ҳосил қилишда одатда хира шовқинлари пайдо бўлади. Бу шовқинлар даражасини пасайтириш учун GAN архитектурасининг генератор тармоғида ConvTranspose қатлами орасида хира шовқин қатламини қўшиш таклиф этилган [13]. Одатда ҳақиқий УТТ тасвирларида хира шовқинлари мавжуд бўлади. Хира шовқини қатлами ҳосил қилинаётган синтетик тасвирларга ушбу хира шовқинларини қўшади. Натижада синтетик тасвирлар айнан ҳақиқий УТТ тасвирлари каби шовқинли кўринишда ҳосил бўлади. Аммо тармоқда хира шовқин қатламини қўшиш натижасида тармоқни ўқитиш тезлиги сезиларли даражада пасаяди. Юқорида муҳокама қилинган ишлар [9-13]да мавжуд камчиликларни бартараф этиш учун махсус GAN архитектураси таклиф этилди. Ушбу архитектуранинг генератор тармоғи кетма-кет келувчи апсемплинг, Conv ва ConvTranspose қатламлидан ташкил топган ўзига хос архитектурадан ташкил топди. Архитектуранинг генератор тармоғи қуйидаги 1-расмда келтирилган.



1-расм. Архитектуранинг генератор тармоғи

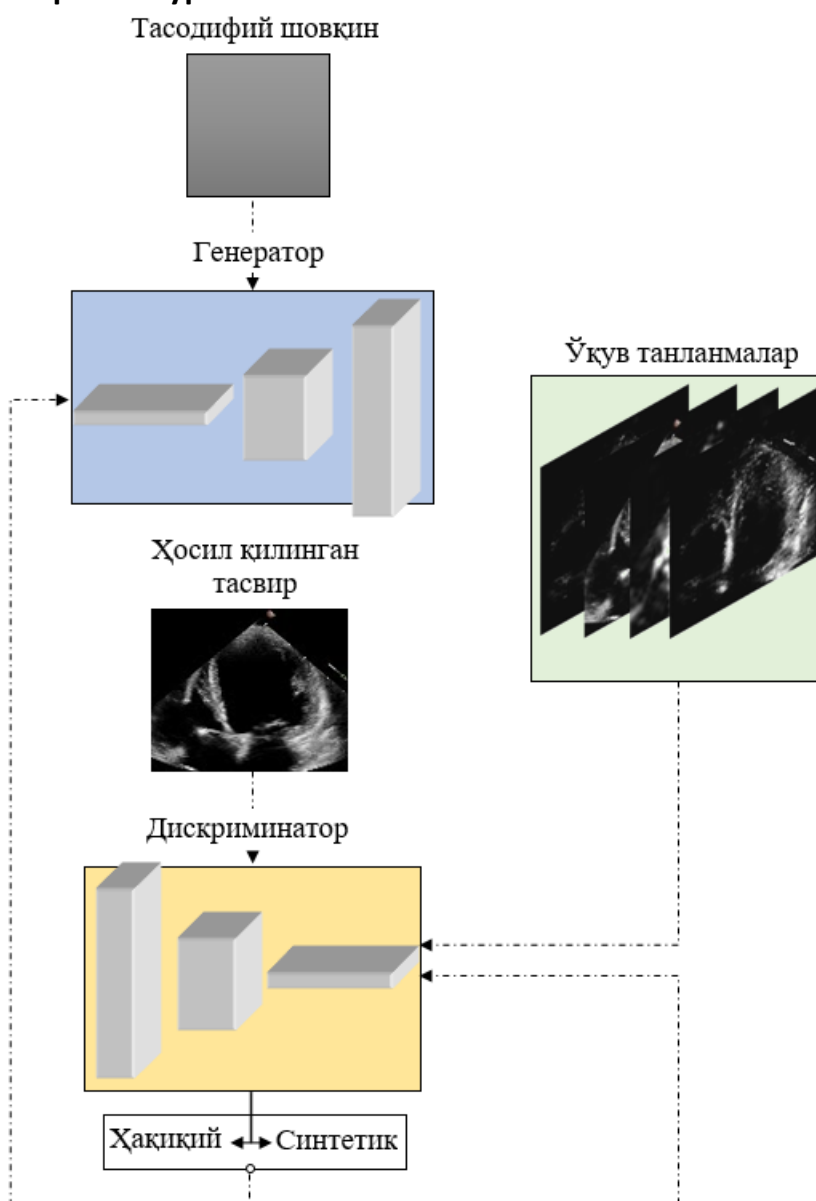
Таклиф этилаётган архитектурадаги апсемплинг қатламида энг яқин интерполяция усулидан ва Conv қатламида 1x1 ўлчамдаги филтрлардан фойдаланилди. 1x1 ўлчамдаги филтрлар тармоққа кирувчи маълумотларнинг ўлчамини ўзгартирмасдан уларга ўқитиладиган вазн коэффициентлари билан таъсир этиш имконини беради. Шунингдек, архитектурада хотира ва тезликни оптимал қийматини таъминлаш учун алмаштириш (transpose) қатлаמידан фойдаланилди. Тармоқда апсемплинг билан Conv қатламли кетма-кет ишлатилганлиги сабабли тармоқни ўқитиш учун сарфланган вақт ConvTranspose қатламини ишлатгандан кўра 4 марта кўпроқ бўлади. Яна бир муҳим жиҳати шундаки, ушбу апсемплингдан кейин ишлатилган Conv қатламининг кернели 1x1 ўлчамда бўлганлиги сабабли транспос (transpose) қатламида содир бўлувчи оқ-қора шовқинлари кузатилмайди. Аслида 1x1 ўлчамли филтрлардан фойдаланиш Conv амалларини қўллашни ифодаламасада, кирувчи маълумот ўлчамини ўзгартирмаган ҳолда белги хариталари сонини ўзгартириш имконини беради. Бундай ҳолатда қўшни нейронлар билан таъсирлашмасдан, фақатгина ҳар бир нейрон янги вазн коэффициентига

(ўқитиладиган параметр) кўпайтирилади. Апсемплинг қатлами ўқитиш параметрларига эга эмас, шу сабабли бу қатламни 1x1 филтрли Conv қатлами билан бирга фойдаланилганида, ўқитиш параметрларига эгадек кўринишга келади. Бироқ, 1x1 ўлчамдан катта филтрли Conv қатлами бундай натижани таъминламайди.

ConvTrans қатламида пикселларни нол билан тўлдирилиши ва филтрларни силжитилганда устма-уст тушиши оқибатида турли шовқинлар юзага келади. Шу сабабли биз таклиф этган архитектуранинг чиқишида ҳам хира ва оқ-қора шовқинлари пайдо бўлди, аммо тармоқда ConvTrans қатлаидан ташқари апсемплинг ва Conv қатламларининг ҳам мавжудлиги сабабли бу шовқинлар жуда кам бўлди. Хусусан, фақат ConvTrans қатлаидан иборат тармоққа қараганда шовқинлар қиймати жуда паст бўлди.

Генератор тармоғининг охириги чиқувчи Conv блогида Batch Normalization ва ReLU қатламлари ўрнига Tanh активация қатлаидан фойдаланилди.

3.2. Умумий GAN архитектураси

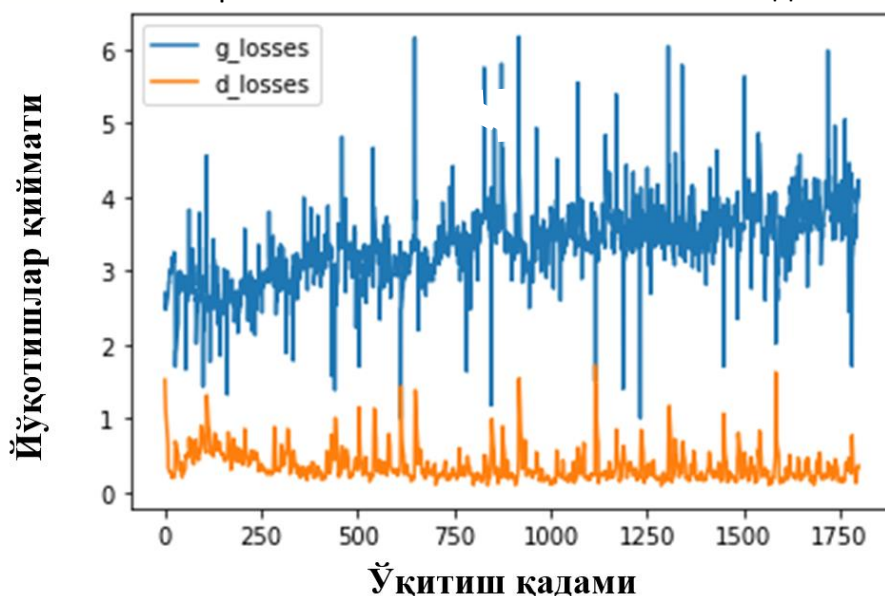


2-расм. GAN архитектураси

Таклиф этилаётган умумий GAN архитектураси қуйидаги 2-расмда келтирилган. GAN архитектураси одатдаги генератор ва дискриминатор тармоқларидан ташкил топган.


GAN архитектура-сида декодер тармоғи 4 та блокдан иборат бўлиб, уларнинг ҳар бири кетма-кет келувчи Conv, Batch Normalization, Relu қатламларидан ташкил топган. Кодердан фарқли равишда декодерда оддий Relu қатламиндан фойдаланилди. Декодернинг энг сўнги блокидаги Batch Normalization ва LeakyReLU қатламлари ўрнига Sigmoid активация ва Flatten қатламларидан фойдаланилди. Ушбу таклиф этилаётган GAN архитектурасининг декодер қисмида Conv қатламининг филтрлари 4x4 ўлчамли қилиб танланди ва улар бир-биридан фақат филтрлар сони ва филтрларнинг силжиш билан фарқланди. Ушбу тармоқни ўқитишда RMSprop оптимизеридан фойдаланилди.

Дискриминатор йўқотишларининг камайиб кетишини олдини олиш мақсадида, генератор ва дискриминатор тармоқларининг ўқиш тезлиги учун фарқли қийматлар танланди: Генератор тармоғи учун $l=0.00005$ ва дискриминатор тармоғи учун $l=0.00001$. Ундан ташқари ҳақиқий ва синтетик тасвирларни номлашда қатъий 1 ва 0 сонларидан эмас, балки Label Smoothingдан фойдаландик. Бунда ҳақиқий лабел учун 0.95 ва синтетик лабел учун 0.05 қийматлар танланди. Бу эса дискриминаторга ҳақиқий ва синтетик тасвирларни тўғри фарқлашга ёрдам беради, ҳамда юзага келадиган кичик хатоликларни инобатга олмасликни таъминлайди.



3-расм. Ҳақиқий ва синтетик тасвирларни ўқитиш давомида йўқотишлар қиймати


Таклиф этилаётган GAN архитектурасини ўқитиш ва белгиланган мақсадга эришиш учун жами 2000 қадам талаб этилди. Ҳақиқий ва синтетик тасвирларни ўқитиш давомида йўқотишлар қиймати юқоридаги 3-расмда график кўринишда келтирилган.



4-расм. Таклиф этилаётган GAN архитектурасида ҳосил қилинган юракнинг А4С кўринишидаги синтетик Эхо тасвирлари

Тадқиқот амалга ошириш учун тўпланган Эхо тасвирлари сонини чекланганлиги сабабли баъзи ҳосил қилинган синтетик тасвирлар айнан маълумотлар базасидаги каби кўринишда ҳосил қилинди. Аммо олиб борилган тадқиқотдан кўзланган асосий мақсад GAN архитектурасидан фойдаланган ҳолда сифатли синтетик Эхо тасвирларини ҳосил қилиш эмас, балки ҳосил қилинган синтетик тасвирларнинг сифатини баҳолаш усулини ишлаб чиқишдан иборат эди. GAN архитектурасида ҳосил қилинган юракнинг А4С кўринишидаги синтетик Эхо тасвирлари 4-расмда келтирилган.

Таклиф этилаётган ва одатдаги GAN архитектураларидан олинган натижалар қиёсий таққосланди ва баҳоланди, 5-расм. Тасвирларни визуал баҳолаш орқали оддий GAN архитектурасида ҳосил қилинган синтетик тасвирларда хира шовқинларининг мавжудлиги, оддий тасвирдан кўра хирароқ эканлигини ва таклиф этилаётган архитектурада ҳосил қилинган синтетик тасвирларда хира шовқинлар сезиларли пасайтирилганлигини кўришимиз мумкин. Демак, хира шовқин қатлаמידан фойдаланмасдан туриб хира шовқинлари паст бўлган синтетик тасвирларни ҳосил қилиш мумкин экан. Фақат биргина камчилиги, SpeckleGAN тармоғи билан ишлагандагидек кам сонли тасвирлар билан юқори натижа олиш имконияти мавжуд эмас.



5-расм. а) Ҳосил қилинган синтетик Эхо тасвири, б) ҳақиқий Эхо тасвири, с) оддий GAN архитектурали тармоқда ҳосил қилинган Эхо тасвир

3.3. Маълумотлар базаси

GAN архитектурали тармоқни қуриш ва синтетик Эхо тасвирларини ҳосил қилиш учун мавжуд маълумотлар базасидан фойдаланилди [13]. Ушбу маълумотлар базаси гипертрофик (ГКМ) ва кенгайган кардиомиопатия (ККМ) нинг А4С соҳасидаги Эхо тасвирларини ўз ичига олган. А4С соҳасидаги Эхо тасвирлари Эхо видео-кадрлар

асосида ҳосил қилинган. Маълумотлар базасидаги барча тасвирлар махсус кардиологлар томонидан таснифланган ҳамда улар 112x112 ўлчамга айлантирилган ва оқ-қора форматда сақланган. Маълумотлар базасидан жами 3530 та тасвир ажратиб олинган. Тасвирларнинг синфлар кесимидаги тақсимоти 1-жадвалда келтирилган.

1-жадвал

Маълумотлар базасидаги ўқув танланмаларининг синфлар кесимда тақсимланиши

#	Эхо тасвири тури	Ўқитиш учун танланмалар сони	Тестлаш учун танланмалар сони	Жами танланмалар сони
2	ГКМ	944	96	1040
3	ККМ	2350	140	2490
	Жами	3294	236	3530

IV. Баҳолаш.

GAN архитектурасидан фойдаланилганда тармоқ самарадорлигини баҳолаш ва натижаларини таққослаш мураккаб вазифалардан бири ҳисобланади.

Одатда тармоқнинг иш бажариш қобилиятини баҳолаш учун MAE, шовқин даражасини пасайтириш учун ишлатилган GAN тармоқларини баҳолаш учун SNR, сигментация масаласини ечиш учун ишлатилган архитектурани баҳолаш учун Дицетрикс ва Жуакард метрик усулларида фойдаланилади. Ҳосил қилинган синтетик тасвирларни ҳақиқий тасвирлар билан ўхшашлик даражасини баҳолашда одатда IS ва FID score усулларида фойдаланилади.

Биринчи марта ҳосил қилинган синтетик тасвирларнинг сифатини ва хилма-хиллигини (diversity) баҳолашда pre-trained InceptionV3 модели ёрдамида ҳисобланадиган IS усули таклиф этилган [15]. InceptionV3 моделини ўқитишда 1 млн дан ортиқ тасвирларни ўз ичига олган ImageNet маълумотлар базасидан фойдаланилган. InceptionV3 модели 78.8% аниқлик билан тасвирларни 1000 та синфга ажратиш хусусиятига эга бўлган. Бироқ IS фақатгина ҳосил қилинган тасвирларнинг синфлар кесимида тақсимланишини баҳолаган, шу сабабли ҳам тасвирларнинг сифатини баҳолашда янги FID (Frechet Inception distance) усули таклиф этилган [16]. FID усули ҳосил қилинган синтетик тасвирларнинг тақсимланишини генераторни ўқитиш учун ишлатилган ҳақиқий тасвирларнинг тақсимланиши билан таққослайди. Бунинг учун InceptionV3 тармоғининг охири avg-pool қатламидаги белги харитасидан фойдаланилади. Бу қатлам жами 2048 та нейрондан иборат. Синтетик ва ҳақиқий тасвирлар тармоққа киритилганида ушбу охири қатламда ҳосил бўлган белги харитаслари тўпламларидан фойдаланиб, FID score қуйидагича аниқланади.

$$d^2(F, G) = |\mu_x - \mu_y|^2 + tr[\Sigma_x + \Sigma_y - 2(\Sigma_x \Sigma_y)^{1/2}]$$

Бу ерда, μ_x ва μ_y - (x_i, y_i) ҳақиқий ва синтетик тасвирлар InceptionV3 тармоғига киритилганда охири avg-pooling қатламида ҳосил бўладиган активациялари - $A(x_i)$ ва $A(y_i)$ ларнинг ўртача қийматларидир. Σ_x ва Σ_y – эса ушбу активацияларнинг намуна ковариант матрицаларидир. Ушбу матрицанинг изи қуйидаги формула ёрдамида аниқланади.

$$tr(\sqrt{\Sigma_1 \Sigma_2}) = \sum_{i=1}^{m-1} \left| \sqrt{\lambda_i(C_1^T C_2 C_2^T C_1)} \right|$$

[17] ishda $(C_1^T C_2 C_2^T C_1)$ va uning xususiy qiymatini hisoblash uchun vaqt murakkabligi $O(mdn + m^2n + m^3)$ kўrinishda, agar kўp sonдаги namunalар mavjud бўлса, ваqt murakkabligi $O(d^2m + m^3)$ kўrinishда келтирилган. Бу ерда, m , n - ҳақиқий ва синтетик намуналар сони, d - охириги қатламдаги нейронлар сони. $m \ll d$ бўлганда, яъни кам сондаги синтетик тасвирларни ҳосил қилишда сарфланадиган ваqt нейронлар сонига тўғри, $d \ll m$ кўп сондаги маълумотлар билан ишлаганда эса квадратига боғлиқ функция бўлар экан. [18] ишда ваqt murakkabligini $O(d^3 + d^2m)$ тезкор ҳисоблашнинг FID алгоритми келтирилган. Демак, кўп маълумотлар билан ишлашда биринчи усулга қараганда иккинчи усул қулай, унда ваqt murakkabligi намуналар сонидан кўра кўпроқ d қийматга боғлиқ бўлар экан. Аммо бу боғлиқлик кубик боғлиқлик эканлигини инобатга олса, d қийматини камайтириш назарий жиҳатдан FID қийматини ҳисоблаш вақтини кескин камайтиришга имконини беради. Хусусан, FID қийматидан йўқотиш қиймати сифатида фойдаланиб тармоқни ўқитишда катта аҳамиятга эга бўлиб, у ўқитиш тезлигини кескин оширади.

Шунингдек, FID қиймати RGB тасвирлари билан ишлашга мўлжалланган бўлса, Эхо тасвирлари асосан оқ-қора кўрinishда бўлади. Ҳосил қилинган синтетик тасвирларни FID қийматини ҳисоблаш учун улар RGB кўрinishга ўтказишга керак бўлади. [18] ишда кўрсатилишича, тасвирларни оқ-қора форматдан RGB форматга ўтказилганда тасвирларнинг сифати сезиларли даражада бузилган. Бу оқ-қора кўрinishдаги тасвирларни баҳолашда FID қийматида хатолик вужудга келишига сабаб бўлади.

Шунингдек, InceptionV3 тармоғи фақат инсонларнинг, атрофдаги жисмларнинг тасвирлари билан ишлаш учун мўлжалланган бўлиб, тиббий тасвирлар ва видеолар билан ишлашга мўлжалланмаган. Бундай ҳолларда махсус усулни ишлаб чиқиш билан баҳолаш аниқлигини ошириш мумкин. Масалан, [19] ишда видеолар билан ишлашга мўлжалланган FVD ишлаб чиқилган. Аммо оқ-қора форматдаги УТТ тасвирларини баҳолаш учун махсус баҳолаш усули таклиф этилмаган.

2-жадвал

№	Қатламларнинг номи	Conv қатлами филтрлари сони	Conv қатлами филтри ўлчами	Dropout (%)
1.	Input			
2.	Conv2d+BatchNorm+ReLU+Dropout	64	3	5
3.	Conv2d+BatchNorm+ReLU+Dropout	128	2	20
4.	Conv2d+BatchNorm+ReLU+Dropout	256	3	40
5.	Conv2d+BatchNorm+ReLU+Dropout	64	1	5
6.	Conv2d+BatchNorm+ReLU+Dropout	8	2	0
7.	Output			

Ушбу камчиликларни инобатга олган ҳолда, биз синтетик УТТ тасвирлари сифатини баҳолашнинг янги усулини ишлаб чиқдик. Бунинг учун УТТ тасвирларини юқори аниқликда ажрата олувчи CNN архитектураси қурилди, 2-жадвалда архитектуранинг параметрлари келтирилган. Олдин таъкидлаб ўтилганидек ушбу тармоқни ўқитишда олдин ишлаб чиқилган маълумотлар базасидан фойдаланилди

[13]. Фақатгина тармоқни баҳолашда хатоликни олдини олиш учун GAN тармоғини ўқитишда тестлаш учун ажратилган танланмалардан фойдаланилди. Яъни таснифловчи қатлам ўқитиш давомида тестлаш учун ажратилган танланмаларни кўрмайди. Аммо тестлаш учун ажратилган танланмаларнинг сони кам бўлганлиги боис тест танланмалари сунъий кўпайтирилди (data augmentation). Ундан ташқари тармоқ ҳаддан ташқари мослашиб қолмаслигини (overfitting) олдини олиш учун ҳар сафар Conv блокдан кейин Dropout қатлами жойлаштирилди.

Ушбу CNN тармоғи 30 давр мобайнида ўқитилди. Оптималлаштирувчи алгоритм сифатида Адам оптимизаторидан фойдаланилди ва ундаги beta1 ва beta2 қийматлар мос ҳолда 0,95 ва 0,99 қилиб белгиланди. Тармоқнинг тест аниқлиги 96,34% га етди. Ушбу тармоқнинг InceptionV3 ва бошқа таклиф этилган тармоқлардан афзаллик жиҳати шундаки, тармоқ RGB форматдаги тасвирлар билан эмас, оқ-қора форматдаги тасвирлар билан ишлашга мослашган. Бу эса баҳолаш жараёнида тасвирлар сифатини сақлаб қолиш ва баҳолаш аниқлигини юқори бўлишини таъминлайди. Шунингдек, УТТ тасвирларидаги белгиларини ажратиб олишга мослашганлиги тармоқнинг яна бир афзаллиги ҳисобланади. Бу тармоқ MedicalNet деб номланди ва ушбу тармоқ ёрдамида тасвирларнинг реалликка яқинлигини баҳоловчи қийматни Frechet MedicalNet Distance (FMD) қиймати деб аталди.

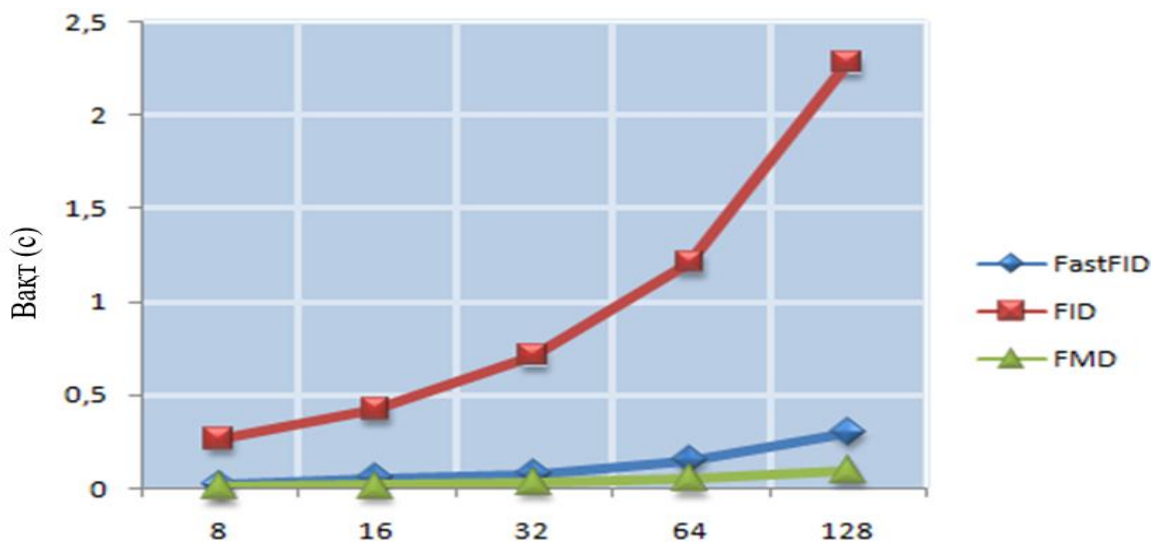
Таклиф этилаётган ёндашувнинг энг муҳим афзаллик томони шундаки, FMD қийматини аниқлашда фойдаланилган MedicalNet тармоғининг махсус қатлами InceptionV3 моделининг FID қийматини ҳисоблаш учун ишлатиладиган қатламидан кўра 4 марта кам нейронларга эга. Бу ҳисобланадиган активация функцияси элементлари 4 марта камлигини кўрсатади. Шу сабабли FMD қийматини ҳисоблаш тезлиги FID қийматини ҳисоблаш тезлигидан сезиларли юқорироқ бўлади. Буни текшириб кўриш учун қуйидаги тажрибани амалга оширдик. FID қийматини ҳисоблаш учун сарфланадиган вақтни аниқлаш учун турли хил сондаги синтетик тасвирлардан иборат тўпламлар ҳосил қилинди. Кейин одатдаги FID ва таклиф этилаётган MedicalNet тармоғи FMD қийматлари ҳисоблаб чиқилди. Тармоқни ўқитишда Google Colabдан фойдаланилди. Тажрибада олинган FID ва FMD қийматларини ҳисоблаш учун сарфланган вақт қуйидаги 3-жадвалда келтирилган.

3-жадвал

FID ва FMD қийматлари ва уларни ҳисоблаш учун сарфланган вақтлар

Синтетик тасвирлар сони	FID қийматини ҳисоблаш вақти	FMD қийматини ҳисоблаш вақти
8	262.49мс	9.335мс
16	420.12мс	15.57мс
32	705.52мс	31.35мс
64	1.21с	51.26мс
128	2.28с	96.86мс

2-жадвалда келтирилганидек, таклиф этилаётган усулимизда ҳисоблаш учун одатдаги мавжуд хатоликни баҳолаш усулларига қараганда 29 мартагача кам вақт сарфланди. Маълумки, FID қийматини ҳисоблаш вақтини камайтириш учун бир қанча тезкор алгоритмлар таклиф этилган [17]. Таклиф этаётган ёндашувимиз асосида олинган натижаларни тезкор алгоритмлар асосида олинган натижалар билан қиёсий таққосладик. Қуйидаги 6-расмда одатдаги яъни [17] ишдаги ва биз таклиф этган усулларда FID, fastFID ва FMD қийматларни ҳисоблаш учун сарфланган вақт келтирилган.



Синтетик намуналар сони

6-расм. FID, FastFID ва FMD қийматларни ҳисоблаш учун сарфлан вақт

Биз томондан таклиф этилаётган алгоритмнинг тезкорлиги бошқаларникига қараганда юқори натижага эришган. Олим Т.Ю.Лин ва С.Маджилар FastFID усули орқали 8 та маълумотни баҳолаш оддий FID усулидан кўра 13 мартагача тезкор эканлигини таъкидлашган. Бизнинг ёндашув FID усулидан кўра 28,9 марта кам вақт сарфланган. Шунингдек, биз таклиф этаётган алгоритм FastFID усулидан кўра 2,2 марта тезроқ ҳисоблаш имконини берган. Баҳоланадиган тасвирлар сонининг ошиши билан барча алгоритмларда сарфланадиган вақт ҳам кескин ошганлигини кўришимиз мумкин, аммо алгоритмлар тезлиги орасидаги фарқ деярли ўзгармас қолган. Мисол учун 128 та тасвирни баҳолаш учун FID алгоритмини анъанавий SCIPY.LINALG.SQRT функцияси ёрдамида ҳисоблаш вақтига қараганда FastFID усулида 2,8 марта кам вақт сарфлаган бўлса, бизнинг алгоритм орқали бу жараёнда 23,7 марта кам вақт сарфланганини кўриш мумкин.

Энди ана шу FID коэффицентини дискриминаторга қўшимча йўқотиш қилиб киритилса, унинг функцияси қўйидаги кўринишга эга бўлади.


$$G^*, D^* = \arg \min_G \max_D L_{CGAN}(G, D) + \lambda L_{L1}(G)$$

Тармоқни ўқитиш давомида, ушбу FID йўқотиш ҳар бир итерацияда ҳисобланиб борилади. Агар маълумотлар базасидаги тасвирлар сони – n ва $batch_size$ – b бўлган ҳолатда, ҳар бир даврдаги итерациялар сони n/b кўринишда ҳамда m та даврда $T_i = m * n/b$ орқали ифодаланилади. FID қийматини ҳисоблашда сарфланадиган қўшимча вақт қўйидагича топилади:

$$t = N_i * t_0$$

Бу ерда t_0 – бир $batch$ даврдаги FID қийматини ҳисоблаш учун сарфланган вақтдир.

Юқоридаги 2-жадвалдан ва формулалардан фойдаланиб, 32 ўлчамли ва 64 ўлчамли кичик даврга тенг бўлгандаги турли даврлар учун сарфланадиган ортиқча вақтнинг қиёсий қиймати 7-расмда келтирилган. Бунда ҳисоблаш вақти FastFID учун [17] ишдаги график асосида олинган. [17] ишда FastFID усулида ҳисоблаш учун сарфланган аниқ сон қийматлари келтирилмаганлиги, қийматлар фақатгина график кўринишда берилганлиги сабабли, графикдаги FastFID ва FID қийматларини ҳисоблаш учун сарфланган вақт чизигини 3% хатолик билан олдик.



7-расм. 32 ва 64 ўлчамли даврларда қўшимча йўқотиш қийматини ҳисоблаш учун сарфланадиган вақт

7-расмда синтетик УТТ тасвирларини ҳосил қилувчи 64 ўлчамли кичик даврда GAN архитектурасини ўқитишда қўшимча йўқотишлар сифатида FMD қийматидан фойдаланиш FID қийматдан фойдаланишдан кўра ҳар 1000 та даврда 115000 секунд кам вақтни сарфлаш мумкин экан, яъни тахминан 32 соат вақтни тежаш мумкин. Бундан ташқари, FastFID усулида FID қийматини ҳисоблаш вақти FMD қийматни ҳисоблаш вақти билан деярли бир хил эканлигини кўриш мумкин. Аммо, биз таклиф этаётган ёндашувда FMD қийматини ҳисоблаш учун SCIPY.LINALG.SQRT функциясидан фойдаландик. Агар SCIPY.LINALG.SQRT функциясининг ўрнига матрица изини ҳисобласак, FMD қийматни ҳисоблаш вақти яна 100 баробаргача камайиши мумкин. Бу эса Т.Ю.Лин ва С.Маджилар томонидан таклиф этилган ёндашувга қараганда 250 мартагача тезроқ деганидир.


Шунингдек, оддий GAN архитектурасида ҳосил қилинган инсон юзи тасвирларининг FMD ва FID қийматлари билан таклиф этаётган усулимиз асосида ҳосил қилинган ҳақиқий тасвирларни баҳолаш жараёнлари таққосланди. Бунинг учун Kaggle сайтидан тайёр синтетик ва ҳақиқий юз тасвирларидан иборат маълумотлар базаси юклуб олинди, 4-жадвалда келтирилган.

4-жадвал

Турли тўпламлар учун ҳисобланган FID ва FMD қийматлари

Тўплам номи	FID	FMD	Фарқи
Юз тасвирлари	109,451	109,475	0,024
Эхо тасвирлари	84,929	80,285	4,644

Қуйидаги 8-расм ва 4-жадвалда келтирилган натижалардан кўриниб турибдики FID қиймати каби FMD қиймати ҳақиқий тасвирларни 0,034 фарқ билан баҳолаган. Аммо тиббий тасвирларни баҳолашда FID қиймати FMD қийматидан 4,644 мартага кўп бўлган. Бу эса тасвирларни оқ-қора форматдан RGB форматга ўтказиш ва тасвирлар ўлчамини ўзгартириш жараёни билан боғлиқ экан (Чунки тиббий маълумотлар ҳажми 112x112 px бўлиб, InceptionV3 моделининг кириши 299x299 px ўлчамли тасвирларни қабул қилади). УТТ тасвирларини баҳолашда айнан FMD қиймати FID қийматига қараганда аниқроқ эканлигини кўриш мумкин.



8-расм. Kaggle.com сайтидан олинган FaceDatabase маълумотлар базасидаги ҳақиқий (а) ва синтетик (б) тасвирлар

V. Келажакда қилиниши мумкин бўлган ишлар

Синтетик тасвирларни баҳолашда тиббий ва одатдаги тасвирлар орасидаги фарқни ажратиш олиш зарур. Одатдаги тасвирларда ҳар қандай ўзгариш агар у тиниқ ва инсон (ёки бирор жисм) хусусиятлари тўғри ифодаланган бўлса (кўзи, қоши, бурни) бу ҳақиқий тасвир сифатида қабул қилинади. Аммо тиббий тасвирларда, бирор бир параметрни ўзгариши, масалан юрак чап бўлмасининг бироз катталаниши ёки деворчаларининг йўғонлашиши бошқа патологияни намоён этади. Яъни тиббий тасвирларни ҳосил қилаётганда тасвир ҳақиқий тасвирга яқинлигидан ташқари унинг муайян бир патологияни ифода этишини баҳолаш ҳам муҳим ҳисобланади. Шу сабабли келажакда жуда кўп сонли юрак касалликларини аниқлашда УТТ тасвирларини юқори аниқликда таснифловчи нейрон архитектураларини қуриш ва уларнинг FMD қийматиини ҳисоблаш учун ишлатиладиган охириги қатламининг ўлчамларини имкон қадар кичик бўлиши ва шу орқали ҳақиқий тиббий тасвирларга яқин тасвирларни ҳосил қилувчи GAN тармоқларини ўқитиш ҳамда баҳолаш имкониятини тақдим этиш мумкин.

VI. Хулоса

Ушбу мақолада Эхо тасвирларининг A4C қисмини синтетик ҳосил қилишнинг махсус GAN архитектураси ишлаб чиқилди ва унда ҳосил қилинган синтетик тиббий тасвирларни баҳолашнинг янги мезони таклиф этилди. Ушбу мезон - FMD ва FID қийматларининг тиббий тасвирларни баҳолаш сифати ва коэффицентни тезкор ҳисолаш жараёни қиёсий таққосланди. Натижалардан маълум бўлдики, FMD қиймати синтетик тасвирларни баҳолашда хусусан тармоқни ўқитишда қўшимча йўқотиш қиймати сифатида фойдаланганда жуда кўп вақтни тежаб қолиш имконини тақдим этди ҳамда тиббий тасвирларни баҳолаш аниқлиги FID қийматнинг аниқлигига қараганда юқорироқ эканлигини кўрсатди.

Фойдаланилган адабиётлар рўйхати

1. Xiuxiu He, Yang Lei, Yingzi Liu, Zhen Tian, Tonghe Wang, Walter J. Curran, Tian Liu, Xiaofeng Yang, "Deep attentional GAN-based high-resolution ultrasound imaging," Proc. SPIE 11319, Medical Imaging 2020: Ultrasonic Imaging and Tomography, 113190B (16 March 2020);
2. Onur Karaog'lu, Hasan Yeñakir Bilge, Ihsan Uluer, "Removal of speckle noises from ultrasound images using five different deep learning networks", Yengineering Science

and Technology, an International Journal, Volume 29, 2022, 101030, ISSN 2215-0986, <https://doi.org/10.1016/j.jestch.2021.06.010>.

3. Liu, R., Zhou, S., Guo, Y. et al. U2F-GAN: Weakly Supervised Super-pixel Sgmentation in Thyroid Ultrasound Images. *Cogn Comput* **13**, 1099–1113 (2021).

4. Negi, Anuja & Joseph Raj, Alex Noel & Nersisson, Ruban & Zhuang, Zhemin & M, Murugappan. RDA-UNET-WGAN: An Accurate Breast Ultrasound Lesion Sgmentation Using Wasserstein Generative Adversarial Networks. *Arabian Journal for Science and Yengineering*. (2020). 45.

5. Peng, B., Huang, X., Wang, S., & Jiang, J. (2019). A Real-Time Medical Ultrasound Simulator Based on a Generative Adversarial Network Model. *Proceedings. International Conference on Image Processing, 2019*, 4629–4633.

6. Teng, Long & Fu, ZhongLiang & Yao, Yu. (2020). Interactive Translation in Yechocardiography Training System With Yenhanced Cycle-GAN. *IEEE Access*. PP. 1-1.

7. Zhang, Qingjie & Zhao, Junjuan & Long, Xiangmeng & Luo, Quanyong & Wang, Ren & Ding, Xuehai & Shen, Chentian. (2022). AUE-Net: Automated Generation of Ultrasound Yelastography Using Generative Adversarial Network. *Diagnostics*. 12. 253. [10.3390/diagnostics12020253](https://doi.org/10.3390/diagnostics12020253).

8. Abdi, A.H., Tsang, T.S., & Abolmaesumi, P. (2019). GAN-yenhanced Conditional Yechocardiogram Generation. *ArXiv, abs/1911.02121*.

9. Singh N.K., Raza K. (2021) Medical Image Generation Using Generative Adversarial Networks: A Review. In: Patgiri R., Biswas A., Roy P. (eds) *Health Informatics: A Computational Perspective in Healthcare*. *Studies in Computational Intelligence*, vol 932. Springer, Singapore.

10. Sugawara, Yusuke & Shiota, Sayaka & Kiya, Hitoshi. (2019). Checkerboard artifacts free convolutional neural networks. *APSIPA Transactions on Signal and Information Processing*. 8. [10.1017/ATSIP.2019.2](https://doi.org/10.1017/ATSIP.2019.2).

11. Wojna, Z., Ferrari, V., Guadarrama, S., Silberman, N., Chen, L. C., Fathi, A., & Uijlings, J. (2019). The devil is in the decoder: Classification, regression and gans. *International Journal of Computer Vision*, 127(11), 1694-1706.

12. Bargsten, Lennart & Schlaefer, Alexander. (2020). SpeckleGAN: a generative adversarial network with an adaptive speckle layer to augment limited training data for ultrasound image processing. *International Journal of Computer Assisted Radiology and Surgery*. 15. [10.1007/s11548-020-02203-1](https://doi.org/10.1007/s11548-020-02203-1).

13. N. Nasimova, B. Muminov, R. Nasimov, K. Abdurashidova and M. Abdullaev, "Comparative Analysis of the Results of Algorithms for Dilated Cardiomyopathy and Hypertrophic Cardiomyopathy Using Deep Learning," *2021 International Conference on Information Science and Communications Technologies (ICISCT)*, 2021, pp. 1-5.

14. Salimans, T., Goodfellow, I., Zaremba, W., Cheung, V., Radford, A., & Chen, X. (2016). Improved techniques for training gans. *Advances in neural information processing systems*, 29.

15. Martin Heusel, Hubert Ramsauer, Thomas Unterthiner, Bernhard Nessler, and Sepp Hochreiter. 2017. GANs trained by a two time-scale update rule converge to a local nash equilibrium. In *Proceedings of the 31st International Conference on Neural Information Processing Systems*. Curran Associates Inc., Red Hook, NY, USA, 6629–6640.

16. Alexander Mathiasen, Frederik Hvilshoj, "Backpropagating through Fréchet Inception Distance", [arXiv:2009.14075v2](https://arxiv.org/abs/2009.14075v2) [cs.LG] 14 Apr 2021

17. Lin, T.-Y. and Maji, S. Improved Bilinear Pooling with CNNs. In *British Machine Vision Conference (BMVC)*, 2017.

18. FVD: A NEW METRIC FOR VIDEO GENERATION