DERMASKOPIK TASVIRLARDAN SOCHGA OID ARTEFAKTLARNI BARTARAF QILISHNING TRANSFORMER TEXNOLOGIYALARI VA TASVIR QISMLARINI TIKLASH(INPAINTING) GA ASOSLANGAN ALGORITMI

Akbaraliyev B.B[1]., Gulmirzayeva G.A[2]., Zaripov F.M[3].

[1]Andijon davlat universiteti,
[2,3]Toshkent axborot texnologiyalari universiteti

K E Y W O R D S

Dermaskopik tasvir, soch artefaktlari, SegFormer, tasvir qismlarini tiklash, chuqur o'qitish

A B S T R A C T

Dermaskopik tasvirlar teri o'smalarini erta aniqlash va differensial tashxislashda keng qo'llaniladi. Biroq, tasvirlarda uchraydigan soch artefaktlari diagnostika jarayonida jiddiy muammolarga olib keladi. Soch tolalari pigment tarmoqlari, shikastlanish chegaralari va rang gradiyentlarini qoplashi natijasida ham sun'iy intellekt (SI)ga asoslangan modellar, ham shifokorlarning vizual baholashga salbiy ta'sir qiladi. Ushbu tadqiqotda dermaskopik tasvirlardan soch artefaktlarni olib tashlash uchun ikki bosqichli chuqur o'qitishga asoslangan yondashuv taklif qilindi. Birinchi bosqichda soch tolasi va uning soyalari SegFormerWithDropout arxitekturasi yordamida segmentatsiya qilinadi. Bunda dropout mexanizmi modellarning barqarorligini oshiradi, shadow-aware kengaytirilgan kanal esa soyalarni niqoblash imkonini beradi. Ikkinchi bosqichda gibrid Mask-Aware Transformer(MAT)+(Large Mask Inpainting with Fourier Convolutions) LaMa tasvir qismlarini tiklash generatori global va lokal kontekst asosida niqoblangan joylarni tiklash, artefaktlarsiz klinik tuzilmalarni (pigment tarmog'i, rang o'zgarishlari, chegaralar) qayta tiklash uchun qo'llaniladi. Taklif qilingan yondashuv HAM10000 ma'lumotlar to'plamida sinovdan o'tkazildi va Dice (0.967), IoU (0.935) va SSIM (0.915) kabi yuqori ko'rsatkichlariga erishildi. Olingan natijalar shuni ko'rsatdiki, taklif qilingan usul dermaskopik tasvirlar sifatini oshirish orqali diagnostika tizimlarining umumiy samaradorligini oshirishi mumkin.

I. Kirish. Dermaskopik tasvirlar tibbiy diagnostikada, ayniqsa teri o'smalarini erta aniqlash va differensial tashxislashda muhim rol o'ynaydi. Melanoma va boshqa teri kasalliklarining global miqyosda ko'payishi ushbu jarayonning dolzarbligini ko'rsatadi [1][2]. Dermaskopiya usuli shifokorlarga oddiy ko'z bilan ko'rinmaydigan rang, tekstura va tuzilishdagi farqlarni aniqlash imkonini beradi. Biroq, tasvir sifatini soch artefaktlari, soyalari, jarrohlik izlari va o'lchov chiziqlari kabi turli xil artefaktlar sezilarli darajada pasaytirishi mumkin [3]. Soch artefakti dermaskopik tasvirlardagi eng keng tarqalgan muammolardan biri bo'lib, ular shikastlanish chegaralarini, pigment tarmoqlarini yoki rang o'zgarishlarini yopib qo'yadi. Bu holat esa nafaqat tibbiy ko'riklar paytida, balki avtomatlashtirilgan segmentatsiya va diagnostika tizimlaridagi aniqlikning pasayishiga ham olib keladi. So'nggi tadqiqotlar shuni ko'rsatdiki, dermaskopik tasvirlarda soch tolalarining mavjudligi SI modellarining aniqligini sezilarli darajada pasaytiradi [4]. Shuningdek, ba'zi hollarda siyrak soch tolalari modelni yanada barqaror qilishga yordam beradigan bo'lsa, zich tolali sochlar esa diagnostikada jiddiy xatolarini keltirib chiqaradi. Shu sababli, dermaskopik tasvirlarda soch artefaktlarni samarali olib tashlash bugungi kunda dolzarb vazifa hisoblanadi.

Mavjud muammolarning yechimi sifatida so'nggi o'n yillikda turli yondashuvlar taklif qilingan. Klassik usullarga morfologik operatorlar, filtrlash, interpolatsiya va PDE (qisman differensial tenglama)ga asoslangan tasvir qismlarini tiklash texnikalari kiradi [5]. Bu usullar sodda va tezkor bo'lishi bilan birga turli rang va qalinlikdagi soch tolalarini hisobga olmaydi [6]. U-Net va uning modifikatsiyalari kabi chuqur o'rganishga asoslangan CNN yondashuvlari esa so'nggi yillarda dermaskopik tasvirlarda sochga oid artefaktlarni bartaraf qilishda keng qo'llanilmoqda [7]. Masalan, DullRazor va undan keyingi algoritmlarda segmentatsiya va tasvir qismlarini tiklash amalga oshiriladi, ammo murakkab soyalar

(cc) BY

va chegara tuzilmalarini saqlab qolishda qiyinchiliklarga duch keladi. So‘ngi tadqiqotlarda SegFormer arxitekturasiga asoslangan Transformer yondashuvlari uzoq masofali bog‘lanishlarni hisobga olib, kichik ma’lumotlar to‘plamlaridagi tajribalarda ham yuqori aniqlikga erishishi bilan ajralib turadi [8]. Biroq, bu yondashuv faqat segmentlangan niqobini taqdim etadi va soch tolasi ostidagi shikastlanishning tuzilishi va rangini qayta tiklay olmaydi. Ushbu tadqiqotda dermaskopik tasvirlarda soch artefaktlarini olib tashlash uchun yangi ikki bosqichli chuqur o‘qitish algoritmini ishlab chiqilgan. Taklif qilingan usul quyidagi xususiyatlar bilan ajralib turadi:

1. Transformer asosidagi segmentatsiya qilish (SegFormer + diqqat mexanizmlari) orqali sochga oid artefaktlarini va uning soyalarni aniq niqoblash.

2. Diffusion yoki GAN asosidagi tasvir qismlarini tiklash yordamida soch tolasi ostidagi klinik belgilarni kontekstdan kelib chiqib, artefaktsiz qayta tiklash.

3. *Shadow-aware* kengaytirilgan masklash, ya’ni faqat soch tolasini emas, balki uning soyasini ham hisobga olish.

Natijada, taklif etilayotgan algoritm nafaqat sochga oid artefaktlarni samarali olib tashlaydi, balki shikastlanish chegaralarning diagnostik belgilarini pigment tarmog‘i, chegara, tekstura va rang gradientlarini saqlab qoladi. Bu esa SI yordamida teri o‘smalarini aniqlash tizimlarining aniqligi va ishonchliligini sezilarli darajada oshiradi.

II. Asosiy qism. So‘nggi yillarda dermaskopik tasvirlarda sochga oid artefaktlarini bartaraf etishda uchta asosiy yondashuvlar qo‘llanilib kelmoqda: (I) chuqur o‘rganishga asoslangan segmentatsiya va tasvir qismlarini tiklash usullari, (II) soch tolalari mavjudligining SI natijalariga bevosita ta’sirini o‘lchashga qaratilgan tadqiqotlar va (III) CNNlardan transformerlarga, xususan, SegFormer oilasiga va transformer-tasvir qismlarini tiklashga oid usullar. Masalan, U-Net asosidagi soch tolasini segmentatsiya qilish va erkin niqoblarda tasvir qismlarini tiklash usuli kombinatsiyalanganda, shikastlanish chegarasi segmentatsiyasi natijalarining yaxshilanganligini ko‘rsatadi. Ushbu yondashuvlar haqiqiy dermaskopiya uchun mos keladi, ammo teksturaning izchilligi har doim ham yupqa chegara tuzilmalarida to‘liq darajada saqlanib qolmasligi mumkin [7]. Bundan tashqari, kodlovchi-dekoder CNN soch tolasi niqobini ajratish va L1+TV+SSIM ning birlashgan yo‘qotish funksiyasidan foydalanish orqali tasvir qismlarini tiklash bosqichining aniqligi oshiradi. Lekin umumiy holatda keng soya diapazonlari va turli soch tolasi morfologiyalari (oq/ingichka) uchun cheklanganligini ko‘rish mumkin [9]. [10] tadqiqotda, keng ko‘lamli annotatsiya zaruratini kamaytiradigan, juftlashtirilmagan VAE dekoderi yordamida “artefaktsiz” qayta tiklash amalga oshiriladi. Biroq, VAE dekoderi ba’zan haddan tashqari tekislashga olib kelib, bu esa nozik tuzilmalarni o‘chirib tashlashi mumkin. Shu bilan birga, klassik va chuqur o‘qitish usullarini birlashtirgan gibrid yondashuvlar ham paydo bo‘lmoqda. Ular sirt va chuqur modellarni birlashtiradi, segmentatsiyadan keyin morfologik dastlabki ishlov berish orqali tozalashni yaxshilaydi. Bu yondashuvda chuqur o‘qitishga asoslangan segmentatsiya va tasvir qismlarini tiklash usullariga integratsiya qilingan bo‘lsada, soyani hisobga olish masalasi hal qilinmagan [11]. Artefaktni murakkab shaklda, hatto markerlar bilan ham ko‘taradigan oq va qora soch tolalari aniqlanadi va bo‘yaladi, shuningdek ko‘plab usullar bilan solishtirganda yuqori ko‘rsatkichlar qayd etiladi. Ammo ba’zi amaliyotlarda murakkab tekstura chegaralarida ortiqcha bo‘yash muammosi hali ham duch kelish mumkin [12].

So‘nggi yillarda dermaskopik tasvirlardagi soch artefaktlarining SI asosidagi diagnostika tizimlariga ta’sirini aniqroq o‘lchash dolzarb masalalardan biriga aylandi. Tadqiqotlar natijasi 10 000 dan ortiq dermaskopik tasvirlarda soch tolalarning mavjudligi tasniflash va segmentatsiya qilish aniqligining pasayishini ko‘rsatadi va inf1/inf2 kabi baholash ko‘rsatkichlarni taklif qiladi [4]. Bu faqat “Dice/IoU” bilan cheklanmasdan, downstream vazifalar bo‘yicha ham baholash zarurligini ifodalaydi. Klinik sharoitda, Mpox lezyonlari uchun taklif qilingan usulda [13], U-Net arxitekturasining soch tolalarini tozalash bosqichi bilan kuchaytirilgan usuli diagnostik barqarorligining oshirganligi ko‘rsatiladi. Ushbu integrativ yondashuv soch artefaktlariga shunchaki oldindan ishlov berish sifatida emas, balki task-driven komponent sifatida qarash zarurligini ta’kidlaydi.

(cc) BY

Shuningdek, zamonaviy model arxitekturalarida CNNlardan transformerlarga sezilarli o‘tish kuzatilmoqda. Ierarxik MiT kodlovchisi + yengil MLP dekoder dizayni bilan SegFormer segmentatsiya jarayonida samaradorlik va aniqlik o‘rtasida muvozanatga erishilganligini ko‘rish mumkun. Katta receptive field va positional encoding talablarining yo‘qligi modelning turli xil o‘lchamlarga moslashuvchanlikni yaxshilaydi [14]. Tibbiy tasvirlarni segmentlashda SegFormer usulining turli xil usullar bo‘yicha U-Net arxitekturasiga nisbatan baholanishi transformer usulining haqiqatan ham yuqori ekanligini ko‘rsatadi va uni dermaskopiyada qo‘llash uchun yechim sifatida taqdim etadi [8]. Transformerga xos *edge/chegara* muammosini hal qilishdagi NA-SegFormer yondashuvida *neighborhood attention* va *patch-merging* yordamida chekka segmentatsiyasi yaxshi natijaga ko‘rsatgan. Ushbu tamoyillar soch tolasi segmentatsiyasi niqoblariga ham qo‘llanilishi mumkin [15].

Tozalash jarayonining ikkinchi yarmi tasvir qismlarini tiklashdan iborat. CNNga asoslangan yondashuvlar bilan bir qatorda, receptive field ega LaMa [16] va transformerga asoslangan tasvirlarni qayta tiklash kabi ikkita asosiy yondashuvlar keng qo‘llanilmoqda. LaMa FFC (Fast Fourier Convolutions) foydalanilganda global kontekstga asoslangan holda katta niqoblar yuqori aniqlikda to‘ldiriladi. Dermaskopiyada bu usullar keng soch tolasi soyalari yoki shikastlanish chetlariga biriktirilgan soch tolalari uchun ideal hisoblanadi, chunki global spektral fokus strukturaviy muvofiqlikni saqlab qoladi. Transformerlar orasida MAT [17] metodologiyasi yuqori aniqlikdagi niqobga sezgir transformerga asoslangan tasvir qismlarini tiklash tizimi sifatida tan olingan. Uning stilistik izchillikni saqlab qolish bilan birga katta piksellarda realistik, xilma-xil tarkib yaratish qobiliyati dermaskopik teksturalarni tiklashda afzallik beradi. Bundan tashqari, 2023 va 2025 yillar oralig‘ida transformerga asoslangan tasvir qismlarini tiklash usullarining turli xil versiyalari paydo bo‘ldi, bu ko‘p o‘lchovli strukturani saqlash va mayda detallarni tiklash muammosini bartaraf qilishni ko‘rsatadi. Bu dermaskopiyadagi *shadow-aware* turidagi bo‘yash dizayn tendentsiyasiga mos keladi.

Mavjud usullardan farqli ravishda sintetik soch tolasi benchmarklaridan foydanish ham yuqori natijalar ko‘tsatadi. Xususan, [18] da sun’iy soch tolali dermaskopik ma’lumotlar to‘plami va chuqur o‘qitish modeli taklif qilingan bo‘lib, ular asosiy *ground truth*larni ko‘paytirish orqali baholashni barqarorlashtirishga xizmat qiladi. Biroq, bu ham soch artefaktni to‘liq olib tashlash bosqichini o‘z ichiga olmaydi, ya’ni “mask-only” cheklovi saqlanib qoladi. Aynan shu muammoni bartaraf etishda integratsiyalashgan diffusion transformerga asoslangan tasvir qismlarini tiklash usullariga ehtiyoj paydo bo‘ladi.

III. Metodologiya

Ushbu tadqiqotda dermaskopik tasvirlarda soch artefaktlarni olib tashlash uchun ikki bosqichli algoritmni taklif qilinadi. Yondashuv quyidagi asosiy komponentlardan iborat: (1) soch tolalari va ularning soyalarini aniqlash uchun transformerga asoslangan segmentatsiya moduli, (2) niqoblangan joylarni artefaktsiz kontekstual ravishda tasvir qismlarini tiklash generatori.

Ma’lumotlar to‘plami.

Tajribalar HAM10000 ma’lumotlar to‘plamida sinovdan o‘tkazildi. Ushbu to‘plam melanotsitik nevus (NV), melanoma (MEL), benign keratozga o‘xshash lezyonlar (BKL), bazal hujayrali karsinoma (BCC), aktinik keratoz va intraepitelial karsinoma (AKIEC), dermatofibroma (DF) va qon tomir lezyonlari (VASC) kabi 7 xil klinik tashxis bo‘yicha tasniflangan 10 015 ta dermaskopik tasvirlardan iborat.

Ma’lumotlar to‘plamida turli o‘lcham va sifatdagi sochga oid artefaktlar mavjud bo‘lib 1-jadvalda soch tolalarining mavjud yoki mavjud emasligi bo‘yicha HAM10000 ma’lumotlar to‘plamining taqsimoti ko‘rsatilgan. Statistik tahlil shuni ko‘rsatadiki, soch artefaktlari barcha sinflarda mavjud bo‘lib, nevus (NV) sinfidagi tasvirlarning aksariyati (≈80%) soch tolasi bilan qoplangan. Bu diagnostika jarayonida soch artefaktlarni olib tashlash zarurligini ko‘rsatadi.

1-jadval

HAM10000 ma’lumotlar to‘plamining sochga oid artefaktlari bo‘yicha taqsimlanishi

sinf	***O‘qitish (n=8008)***	***Testlash (n=1998)***
	Soch tolalari	**Soch tolalari**

(cc) BY

	yo‘q (n=4916)	kam sonli (n=1437)	ko‘p sonli (n=1655)	yo‘q (n=1311)	kam sonli (n=416)	ko‘p sonli (n=271)
AKIEC	173 (3.5%)	26 (1.8%)	53 (3.2%)	53 (4.0%)	14 (3.3%)	8 (3.0%)
BCC	300 (6.1%)	31 (2.2%)	85 (5.2%)	69 (5.3%)	15 (3.6%)	14 (5.2%)
BKL	657 (13.4%)	66 (4.6%)	146 (8.8%)	163 (12.4%)	34 (8.2%)	31 (11.4%)
DF	54 (1.1%)	18 (1.3%)	20 (1.2%)	14 (1.1%)	5 (1.2%)	4 (1.5%)
MEL	641 (13.0%)	133 (9.2%)	166 (10.0%)	133 (10.1%)	29 (7.0%)	10 (3.7%)
NV	2998 (61.0%)	1158 (80.6%)	1173 (70.9%)	853 (65.1%)	317 (76.2%)	200 (73.8%)
VASC	93 (1.9%)	30 (2.0%)	50 (3.0%)	26 (2.0%)	20 (5.0%)	4 (1.4%)

3.2. Segmentatsiya usuli

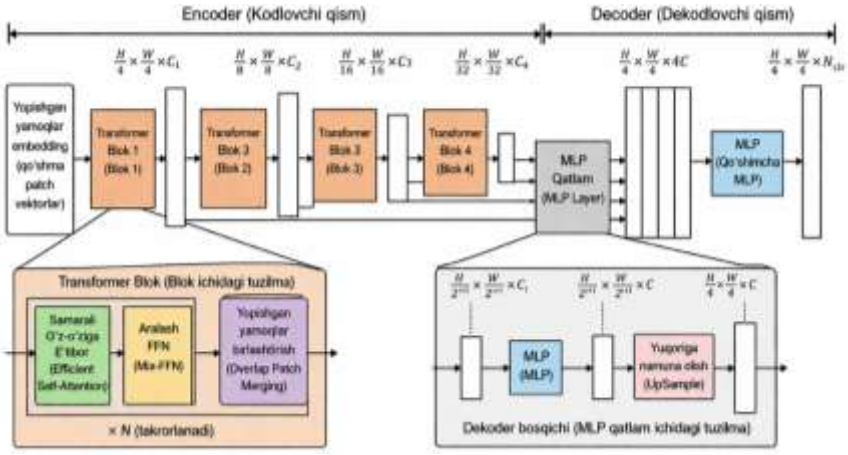
Soch tolasi va uning soyalarini aniqlash uchun SegFormerWithDropout arxitekturasi qo‘llanildi. Ushbu model Mix Transformer (MiT) kodlovchi va ko‘p qatlamli perseptron (MLP) dekoderini o‘z ichiga oladi, bu esa dermaskopik tasvirlarda lokal va global xususiyatlarni bir vaqtning o‘zida o‘rganish imkonini beradi. Kirish tasviri avval klassik konvolyutsion filtrlarga o‘xshash lokal kontekstni saqlashga yordam beradigan, bir-birining ustiga chiqadigan yamoqlarni joylashtirish orqali kichik, qisman ustma-ust joylashgan patchlarga bo‘linadi. Keyin har bir patch to‘rtta ketma-ket transformator bloklaridan o‘tadi, ularning har biri *efficient self-attention* mexanizmi va *Mix-Feed Forward Network (Mix-FFN)* kombinatsiyasidan iborat. Diqqat mexanizmi uzoq masofali ulanishlarni hisobga olish orqali dermaskopik tasvirdagi global tuzilmalarni samarali ravishda ushlaydi, Mix-FFN esa chiziqli bo‘lmagan transformatsiyalar orqali chuqurroq xususiyatlarni ifodalaydi. Har bir bosqichdan so‘ng, fazoviy o‘lchamlar kamayadi va ustma-ust tushadigan patchlarni birlashtirish yordamida kanallar soni oshiriladi, bu esa modelga tasvirning turli darajalarda tasvirlarini yaratish imkonini beradi. Enkoder chiqishida turli o‘lchamdagi xususiyatlar xaritalari olinadi va dekoder bo‘limiga uzatiladi.

Dekoder juda yengil arxitekturaga ega bo‘lib, kodlovchining barcha bosqichlaridan xususiyat xaritalarini MLP orqali bitta o‘lchovga birlashtiradi. Ushbu xaritalar keyinchalik *upsample* jarayoni yordamida asl spatial rezolyutsiyaga qaytariladi va birlashtiriladi. Natijada segmentatsiya xaritasi yaratiladi, unda soch tolalari va uning soyalari aniq niqoblar sifatida ifodalanadi. Bundan tashqari, kichik ma’lumotlar to‘plamida ortiqcha moslashishning oldini olish uchun *dropout (p=0.3)* qo‘llanildi. Shadow-aware kengaytirilgan kanalni kiritish nafaqat soch tolalarining o‘zini, balki uning soyalarini ham niqoblashga olib keldi va shu bilan haqiqiy klinik sharoitlarda aniqlikni oshirdi.

SegFormer arxitekturasining asosiy afzalligi shundaki, klassik U-Net modellaridan farqli ravishda, “U’ pozitsion kodlashni talab qilmaydi va shuning uchun turli o‘lchamdagi tasvirlarda barqaror ishlashi mumkin. Enkoderning samarali dizayni global kontekstni to‘liq hisobga olgan holda xususiyatlarni ajratib olish imkonini beradi, dekoder esa sodda va hisoblash jihatidan sodda bo‘lgani uchun deyarli real vaqt rejimida ishlash imkonini beradi. Bu jihatlar SegFormerWithDropout arxitekturasining dermaskopik tasvirlardagi soch tolasi segmentatsiyasi uchun natijali ekanligini ko‘rsatadi.

(cc) BY

ISSN: 3030-3346



1-rasm: SegformerWithDropout arxitekturasining blok-sxemasi. MiT-B2 enkoderi, dekoder va segmentlashning asosiy qismiga qo'shilgan dropout qatlami.

Taklif etilgan usul.

Soch tolalarini segmentatsiya qilish orqali dermaskopik tasvir niqoblagandan so'ng, klinik tuzilmalarni buzmasdan niqoblangan joylarni qayta tiklash masalasi kelib chiqadi. Ushbu vazifa uchun MAT bloklari va LaMa asosida tasvir qismlarini tiklash gibrid generatori qo'llanildi. MAT bloklari tasvirdagi global va lokal kontekstni hisobga olgan holda niqoblangan joylarda self-attention mexanizmini moslashtiradi. Bu qayta tiklangan maydonni atrofdagi rang, tekstura va chegara xususiyatlari bilan uyg'unlashtirishga imkon beradi. LaMa moduli hatto keng niqoblangan joylarda ham Furye konvolyutsiyalari yordamida yuqori aniqlikdagi tiklash imkonini beradi, bu esa dermaskopik tasvirlarda pigment tarmog'i va shikastlanish chegaralarini saqlab qolish uchun muhim ahamiyatga ega.

Rasmiy ravishda, kirish tasviri $I \in R^{H\times W\times 3}$ bilan, segmentatsiya bosqichida olingan niqob esa $M \in \{0,1\}^{H\times W}$ bilan belgilanadi. Niqoblangan tasvir quyidagicha hosil qilinadi:

$$I_M = I \odot (1 - M),$$

bu yerda $\odot$ -elementlar bo'yicha ko'paytirishni bildiradi.

Tasvir qismlarini tiklash generatori G_θ parametrlar to'plami θ bilan masklangan tasvir va maskani kirish sifatida qabul qilib, tiklangan tasvirni hosil qiladi:

$$\hat{I} = G_\theta(I_M, M).$$

Generator chiqishi D_ϕ diskriminator bilan baholanadi, u haqiqiy tasvir I va tiklangan tasvir $\hat{I}$ orasidagi farqni aniqlash uchun ishlatiladi.

Umumiy yo'qotish funksiyasi bir nechta komponentlarning kombinatsiyasidan iborat:

1. Rekonstruksiya yo'qotishi (L1):

$$\mathcal{L}_{rec} = ||M \odot (\hat{I} - I)||_1,$$

u masklangan hududlarda piksel darajasidagi xatolikni minimallashtiradi.

2. Perceptual loss (VGG asosida):

$$\mathcal{L}_{perc} = \sum_l || \phi_l(\hat{I}) - \phi_l(I)||_2^2,$$

bu yerda ϕ_l – VGG19 ning l-qatlamidagi xususiyat xaritalarini bildiradi.

3. Style loss (Gram-matritsa asosida):

$$\mathcal{L}_{style} = \sum_l | G_l(\hat{I}) - G_l(I)|_F^2,$$

bu yerda $G_l(\cdot)$ – Gram matritsa, $||\cdot||_F$ esa Frobenius normadir.

4. Adversarial loss (PatchGAN diskriminatori bilan):

$$\mathcal{L}_{adv} = E\left[log\, D_\phi\,(I)\right] + E\left[log\left(1 - D_\phi(\hat{I})\right)\right].$$

5. Umumiy yo'qotish:

(cc) BY

$$\mathcal{L} = \lambda_1 \mathcal{L}_{rec} + \lambda_2 \mathcal{L}_{perc} + \lambda_3 \mathcal{L}_{style} + \lambda_4 \mathcal{L}_{adv}.$$

Bu kombinatsiya artefaktlarni minimallashtirish bilan birga tekstura va ranglarning izchilligini yaxshilaydi. Natijada, dermaskopik tasvirlardan tuklar va soyalarni olib tashlaganidan so‘ng, inpainting generatori asosiy klinik tuzilmalarni keng qamrovli va diagnostik jihatdan ahamiyatli tarzda qayta tiklaydi.

Shuningdek, taklif etilgan algoritm samaradorligini baholash uchun bir nechta turli toifadagi metrikalardan foydalangan. Ular segmentatsiyaning aniqligini, bo‘yash sifatini va keyingi klinik vazifalardagi natijalarni baholashga qaratilgan. Niqobning to‘g‘ri ajratilgan darajasini o‘lchash uchun Dice, IoU, BF, PSNR, SSIM segmentatsiya metrikalari ishlatilgan.

IV. Natijalar.

Taklif qilingan ikki bosqichli algoritmning samaradorligi HAM10000 ma’lumotlar to‘plamida o‘tkazilgan tajribalar asosida baholanadi. Tajribalar davomida modelning segmentatsiya aniqligi, bo‘yash sifati ko‘rsatkichlari va downstream vazifalarga ta’siri tahlil qilindi. Tajribalar NVIDIA RTX 3060 GPU (24GB VRAM) hisoblash muhitida PyTorch 2.0 freymvorki yordamida amalga oshirildi. O‘qitish jarayoni uchun AdamW optimizatori ($lr = 1 \times 10^{-4}$) ishlatildi, batch hajmi 32 va o‘qitish 50 davr davomida amalga oshirildi. Modelning otriqcha moslashuvchanligining oldini olish uchun early stopping va learning rate scheduler qo‘llanildi. Dataset 80% o‘quv (o‘qitish va validatsiya) va 20% test to‘plamlariga ajratildi. O‘qitish to‘plamida yorqinlik va kontrastni o‘zgartirish, Gauss shovqinini qo‘shish va sintetik soch tolasi qoplamasi orqali qo‘shimcha soch artefaktlarini kiritish kabi turli xil augmentatsiya usullari qo‘llanildi.

Ushbu yondashuv modelning real klinik sharoitlarda turli artefaktlarga nisbatan barqaror ishlashiga xizmat qiladi. Baholash uchun bir nechta ko‘rsatkichlar qo‘llanildi. Segmentatsiya bosqichida Dice koeffitsienti, IoU va Boundary F-score hisoblab chiqildi. Bo‘yash sifatini baholash uchun PSNR, SSIM, LPIPS va FID mezonlari qo‘llanildi. Bundan tashqari, soch artefaktlarini yo‘qotishning klinik jarayonlarga ta’sirini o‘lchash uchun lezyon segmentatsiyasi (Dice, IoU) va tasniflash (AUC, Accuracy) natijalari ham taqqoslandi. Taklif qilingan yondashuvning samaradorligi DullRazor, U-Net+Inpainting, DeepLabV3+, SegFormerWithDropout (faqat niqob uchun) kabi mavjud usullar bilan ham taqqoslandi. Ushbu taqqoslashlar yordamida taklif qilingan algoritmning afzalliklari baholandi.

Soch tolasi segmentatsiyasi natijalari.

Taklif etilgan SegFormerWithDropout (shadow-aware) modeli HAM10000 ma’lumotlar to‘plamida soch tolalari va soyalarni segmentlashda yuqori aniqlikka erishdi. Baholash Dice koeffitsienti, IoU va Boundary F-ball kabi mezonlar asosida amalga oshirildi. Taqqoslash uchun bir nechta asosiy yondashuvlar tanlandi: klassik DullRazor algoritmi, U-Net+Inpainting, DeepLabV3+ va SegFormer (faqat niqob uchun). Ushbu usullar orasida eng yuqori natija ushbu taklif etilayotgan modelda kuzatildi.

2-jadval

Soch tolasi segmentatsiyasi natijalarining taqqoslanishi (HAM10000 datasetida)

Model	*Dice*	*IoU*	*Boundary F-score*
DullRazor (klassik)	0.781	0.652	0.610
U-Net + Inpainting	0.871	0.794	0.763
DeepLabV3+	0.884	0.808	0.779
SegFormer (mask-only)	0.932	0.891	0.853
Taklif etilgan model	**0.967**	**0.925**	**0.908**

Natijalardan ko‘rinib turibdiki, DullRazor kabi klassik algoritmlar turli xil soch tolalari va soyalarning ta’siriga nisbatan barqaror emas. CNN asosidagi U-Net va DeepLabV3+ sezilarli yaxshilanishlarni taqdim etgan bo‘lsa-da, ular global kontekstni yetarlicha hisobga olmaydi.

(cc) BY

Transformer arxitekturasiga asoslangan SegFormer modelida aniq yaxshilanish kuzatildi, ammo bu vaziyatda mask-level segmentatsiyasi bilan cheklanganligini ko‘rish mumkin. Taklif qilingan SegFormerWithDropout model qo‘shimcha soya kanali va barqarorlashtirilgan dropot mexanizmi orqali eng yuqori natijalarga erishdi.

Tasvir qismlarini tiklash natijalari.

Segmentatsiya bosqichida soch tolalari va soyalarni niqoblagandan so‘ng, tasvir qismlarini tiklash generatori kontekstga asoslanib niqoblangan joylarni qayta tiklash vazifasini bajaradi. Taklif qilingan MAT+LaMa gibrid inpainting generatorining natijalari PSNR (Peak Signal-to-Noise Ratio), SSIM (Structural Similarity Index), LPIPS (Learned Perceptual Image Patch Similarity) va FID (Fréchet Inception Distance) mezonlariga muvofiq baholandi:

3-jadval

Tasvir qismlarini tiklash natijalarining taqqoslanishi (HAM10000 datasetida)

Model	***PSNR***	***SSIM***	***LPIPS***	***FID***
DullRazor (klassik interpol.)	24.12	0.811	0.321	89.4
U-Net + PDE inpainting	26.54	0.843	0.280	73.1
DeepLabV3+ + CNN inpainting	27.02	0.857	0.251	66.7
SegFormer (mask-only) + LaMa	28.93	0.889	0.212	51.6
Taklif etilgan model (MAT+LaMa)	**30.41**	**0.912**	**0.184**	**42.3**

Natijalardan ko‘rinib turibdiki, klassik interpolatsiyaga asoslangan usullar soch artefaktlarini yo‘qotishda asosiy tuzilmalarni tiklay olmaydi, bu esa SSIM va PSNR qiymatlarining past bo‘lishiga olib keladi. CNN asosidagi tasvir qismlarini tiklash usullari (U-Net, DeepLabV3+) yaxshiroq natijalarni bersa-da, ular tekstura uyg‘unligini to‘liq saqlab qolmaydi. SegFormer segmentatsiyasi va LaMa tasvir qismlarini tiklash kombinatsiyasi kuchli natijalar berdi, ammo faqat global tuzilmalarga qaratilgan edi. Taklif qilingan MAT+LaMa gibrid yondashuvi nafaqat global, balki lokal tekstura uyg‘unligini ham tiklash imkonini berdi, PSNR va SSIM ko‘rsatkichlarini sezilarli darajada oshirdi va LPIPS va FID qiymatlarini kamaytirdi. Shu bilan birga taklif etilayotgan yondashuvning ba’zi cheklovlari ham mavjud. Masalan, juda zich va qalin soch tolalarga ega tasvirlarda, bo‘yash bosqichida ba’zi teksturalarning biroz tekislanishiga olib kelishi mumkin. Bundan tashqari, modelni o‘qitishda eng soda HAM10000 ma’lumotlar to‘plamidan foydalanganligi sababli, kengroq klinik sharoitlarda qo‘llash uchun kengroq ma’lumotlar bazasida qo‘shimcha sinovlar o‘tkazish talab etiladi. Shu nuqtai nazardan, kelajakdagi ish rejalari ko‘proq multimodal ma’lumotlardan foydalanishni, turli yorug‘lik sharoitlarida olingan tasvirlar asosida modelni yanada barqarorlashtirishni va diffuziya modellariga asoslangan yanada kuchliroq bo‘yash mexanizmlarini qo‘llashni o‘z ichiga oladi.

V. Xulosalar.

Ushbu tadqiqot dermaskopik tasvirlardagi soch artefaktlarini olib tashlash uchun yangi ikki bosqichli chuqur o‘rganishga asoslangan algoritmni taklif qiladi. Yondashuvning birinchi bosqichida soch tolalari va ularning soyalari SegFormerWithDropout arxitekturasidan foydalangan holda yuqori aniqlik bilan segmentlangan. Dropout mexanizmi modelning barqarorligini oshirib, soyaga sezgir kanal esa haqiqiy klinik sharoitlarda uchraydigan soyalarni to‘g‘ri niqoblash imkonini berdi. Ikkinchi bosqichda niqoblangan joylar MAT+LaMa gibrid bo‘yash generatori yordamida global va lokal kontekst asosida qayta tiklandi, pigment tarmog‘ini, shikastlanish chegaralarini va rang gradientlarini artefaktsiz tikladi. Shu bilan birga, usulning ma’lum cheklovlari mavjud. Juda zich soch tolalariga ega tasvirlarda, bo‘yash bosqichi ba’zan klinik tuzilmalarning biroz tekislanishiga olib kelishi mumkin. Kelajakdagi tadqiqotlar diffuziya modeliga asoslangan yanada murakkab bo‘yash mexanizmlarini qo‘llashga, multimodal ma’lumotlardan foydalanishga va modelni turli yorug‘lik sharoitlarida sinab ko‘rishga qaratilishi mumkin.

Umuman olganda, taklif qilingan yondashuv dermaskopik tasvirlarda soch artefaktlarini

(cc) BY

yo‘qotishning ilgari mavjud bo‘lgan usullarini sezilarli darajada yaxshilaydi va klinik diagnostika uchun yuqori sifatli vizual ma’lumotlarni taqdim etadi. Ushbu tadqiqot natijalari nafaqat ilmiy, balki amaliy jihatdan ham katta ahamiyatga ega va kelajakda teri kasalliklarini erta aniqlash uchun sun’iy intellekt yordamida tashxislash tizimlarini ishlab chiqishga xizmat qiladi.

Adabiyotlar

[1] S. Mocellin and C. R. Rossi, ‘The Melanoma Molecular Map Project’, *Melanoma Research*, vol. 18, no. 3, pp. 163–165, Jun. 2008, doi: 10.1097/CMR.0b013e328300c50b.

[2] G. Randi *et al.*, ‘The European Cancer Information System: exploring linkages between indoor radon concentrations and data on cancer burden’, *radon*, Mar. 2022, doi: 10.35815/radon.v3.7607.

[3] J. K. Winkler *et al.*, ‘Association between different scale bars in dermoscopic images and diagnostic performance of a market-approved deep learning convolutional neural network for melanoma recognition’, *European Journal of Cancer*, vol. 145, pp. 146–154, Mar. 2021, doi: 10.1016/j.ejca.2020.12.010.

[4] Z. Wang *et al.*, ‘Influence of hair presence on dermoscopic image analysis by AI in skin lesion diagnosis’, *Computers in Biology and Medicine*, vol. 183, p. 109335, Dec. 2024, doi: 10.1016/j.compbiomed.2024.109335.

[5] J. A. A. Salido and C. Ruiz, ‘Using morphological operators and inpainting for hair removal in dermoscopic images’, in *Proceedings of the Computer Graphics International Conference*, Yokohama Japan: ACM, Jun. 2017, pp. 1–6. doi: 10.1145/3095140.3095142.

[6] Somnathe, Prathamesh A., and P. P. Gumaste., ‘A review of existing hair removal methods in dermoscopic images’, *IOSR Journal of Electronics and Communication Engineering (IOSRJECE)*, vol. 1, pp. 73–76, 2015.

[7] W. Li, A. N. Joseph Raj, T. Tjahjadi, and Z. Zhuang, ‘Digital hair removal by deep learning for skin lesion segmentation’, *Pattern Recognition*, vol. 117, p. 107994, Sep. 2021, doi: 10.1016/j.patcog.2021.107994.

[8] T. Sourget, S. N. Hasany, F. Mériaudeau, and C. Petitjean, ‘Can SegFormer be a True Competitor to U-Net for Medical Image Segmentation?’, in *Medical Image Understanding and Analysis*, vol. 14122, G. Waiter, T. Lambrou, G. Leontidis, N. Oren, T. Morris, and S. Gordon, Eds, in Lecture Notes in Computer Science, vol. 14122. , Cham: Springer Nature Switzerland, 2024, pp. 111–118. doi: 10.1007/978-3-031-48593-0_8.

[9] L. Talavera-Martínez, P. Bibiloni, and M. González-Hidalgo, ‘Hair Segmentation and Removal in Dermoscopic Images Using Deep Learning’, *IEEE Access*, vol. 9, pp. 2694–2704, Dec. 2020, doi: 10.1109/access.2020.3047258.

[10] D. Bardou, H. Bouaziz, L. Lv, and T. Zhang, ‘Hair removal in dermoscopy images using variational autoencoders’, *Skin Research and Technology*, vol. 28, no. 3, pp. 445–454, May 2022, doi: 10.1111/srt.13145.

[11] K. Delibasis, K. Moutselos, E. Vorgiazidou, and I. Maglogiannis, ‘Automated hair removal in dermoscopy images using shallow and deep learning neural architectures’, *Computer Methods and Programs in Biomedicine Update*, vol. 4, p. 100109, 2023, doi: 10.1016/j.cmpbup.2023.100109.

[12] R. Kasmi *et al.*, ‘SharpRazor: Automatic removal of hair and ruler marks from dermoscopy images’, *Skin Research and Technology*, vol. 29, no. 4, Mar. 2023, doi: 10.1111/srt.13203.

[13] E. M. Onyema *et al.*, ‘Deep learning model for hair artifact removal and Mpox skin lesion analysis and detection’, *Sci Rep*, vol. 15, no. 1, p. 21212, Jul. 2025, doi: 10.1038/s41598-025-05324-2.

[14] E. Xie, W. Wang, Z. Yu, A. Anandkumar, J. M. Alvarez, and P. Luo, ‘SegFormer: Simple and Efficient Design for Semantic Segmentation with Transformers’, 2021, *arXiv*. doi: 10.48550/ARXIV.2105.15203.

[15] D. Liu, C. Lu, H. Sun, and S. Gao, ‘NA-segformer: A multi-level transformer model

(cc) BY

based on neighborhood attention for colonoscopic polyp segmentation', *Sci Rep*, vol. 14, no. 1, p. 22527, Sep. 2024, doi: 10.1038/s41598-024-74123-y.

[16] R. Suvorov *et al.*, 'Resolution-robust Large Mask Inpainting with Fourier Convolutions', in *2022 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV)*, Waikoloa, HI, USA: IEEE, Jan. 2022, pp. 3172–3182. doi: 10.1109/WACV51458.2022.00323.

[17] W. Li, Z. Lin, K. Zhou, L. Qi, Y. Wang, and J. Jia, 'MAT: Mask-Aware Transformer for Large Hole Image Inpainting', in *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, New Orleans, LA, USA: IEEE, Jun. 2022, pp. 10748–10758. doi: 10.1109/CVPR52688.2022.01049.

[18] L. Jütte, H. Patel, and B. Roth, 'Advancing dermoscopy through a synthetic hair benchmark dataset and deep learning-based hair removal', *Journal of Biomedical Optics*, vol. 29, no. 11, pp. 116003–116003, Nov. 2024, doi: 10.1117/1.jbo.29.11.116003.

(cc) BY