DERMASKOPIK TASVIRLARDAGI O‘ZGARUVCHAN QALINLIKDAGI SOCH VA SOYA ARTEFAKTLARINI BARTARAF ETISHNING KO‘P MIQYOSLI TRANSFORMER HAMDA QIRRALARNI SAQLOVCHI QAYTA TIKLASH ALGORITMI

Gulmirzayeva Go'zal Alisher qizi

Toshkent axborot texnologiyalari universiteti
E-mail: Guzal.Gulmirzaeva@tuit.uz

K E Y W O R D S

Dermaskopik tasvirlar, axborot modellari, soch artefaktlari, Swin Transformer, ko‘p miqyosli segmentatsiya, chekka-sezgir inpainting, Furye konvolyutsiyasi, tasvirni qayta tiklash

A B S T R A C T

Dermaskopik tasvirlar yordamida teri o‘smalari, jumladan, melanomaga xos o‘zgarishlarni avtomatlashtirilgan tahlil qilishda soch tolalari va ularning mikro-soyalari pigmentlangan soha chegaralarining aniqligini pasaytiruvchi, to‘qima relyefini yashiruvchi hamda neyron tarmoqlarida soxta gradientlarni yuzaga keltiruvchi asosiy omillardan hisoblanadi. Mazkur tadqiqotda axborot modellarini yaratish, tasvirlarni tahlil qilish algoritmlari va timsollarni tanib olish metodologiyasi doirasida yangi ikki bosqichli qayta ishlash algoritmi ishlab chiqildi. Birinchi bosqichda ko‘p miqyosli Swin Transformer V2 asosida soch tolalari va ularning yorug‘lik yo‘nalishiga bog‘liq holda hosil bo‘ladigan soyalarini yuqori aniqlikda segmentatsiya qiladigan dinamik niqoblash modeli taklif qilingan. Ikkinchi bosqich lezyonning chekka belgilarini saqlovchi chekka-sezgir Furye-Gibrid inpainting (Edge-Preserving Frequency Inpainting) operatori taklif qilingan. Algoritm xalqaro ochiq HAM10000 va PH2 benchmark ma’lumotlar to‘plamlarida har tomonlama eksperimental sinovdan o‘tkazildi. Eksperimentlar natijasida taklif etilgan algoritm soch va soya segmentatsiyasida Dice koeffitsiyenti 0,958 ni, IoU ko‘rsatkichi esa 0,919 ni tashkil etdi. Qayta tiklangan tasvirlar sifatini baholash natijasida PSNR 32.45 dB, SSIM 0.931 va LPIPS 0.162 ga yetdi. Mazkur qiymatlar taqqoslangan an’anaviy morfologik va konvolyutsion neyron tarmoq usullarining maqolada keltirilgan ko‘rsatkichlariga nisbatan yuqoriroq natijalarni ifodalaydi. Shuningdek, dermatologik ABCD mezonlariga xos atipik pigment tarmog‘i va chegaraviy asimmetriya strukturasini saqlab qolishga imkon qadar e’tibor qaratildi.

1. Kirish. Zamonaviy onkodermatologiyada invaziv bo‘lmagan optik usullar, xususan, raqamli dermaskopiya xavfli teri o‘smalarini erta aniqlashning eng ishonchli vositasi sanaladi [1; 163–165-b., 2]. Biroq, dermaskopiya qurilmasining qoplovchi linzasi va immersion suyuqliklar vositasida olinadigan tasvirlarda soch tolalari, ularning yoritish manbasidan hosil bo‘ladigan mikro-soyalari, shuningdek, shox pardaning optik akslanishlari doimiy to‘siq sifatida mavjud bo‘ladi [3; 146–154-b.]. Nazariy informatika nuqtai nazaridan, bunday artefaktlar tasvir matritsasiga yuqori chastotali additiv va multiplikativ shovqinlarni kiritadi. Natijada, klinik tashxisda muhim hisoblangan ABCD (Asymmetry, Border irregularity, Color variegation, Dermoscopic structures) mezonlarini tahlil qilishda hamda sun’iy intellektga asoslangan chuqur o‘qitish modellarida xatoliklar keskin ortadi [4; 109335-b.].

O‘tkazilgan tadqiqotlarga ko‘ra, teri lezyonlarini samarali segmentatsiyalash va klassifikatsiyalash ko‘p jihatdan boshlang‘ich ma’lumotlarning axborot-tuzilmaviy tozaligiga va sifatli dastlabki ishlov berish bosqichiga bevosita bog‘liq sanaladi [5; 3071–3076-b., 6; 427-b., 7; 104–110-b.]. Xususan, U-Net yoki tanlangan yadroli U-Net (SK-UNet) kabi arxitekturalar yordamida zararlangan sohani chegaralashda soch tolalari filtrlanmagan bo‘lsa, model lezyon konturini soxta chiziqlar hisobiga noto‘g‘ri baholaydi [8; 533–543-b.]. Shu sababli, artefaktlarni samarali yo‘qotish va shikastlanish belgilari to‘liq saqlangan axborot modelini shakllantirish dolzarb vazifa hisoblanadi.

(cc) BY *dtai.uz*

Adabiyotlar tahlili. Dermaskopik tasvirlardan soch artefaktlarini olib tashlash bo‘yicha mavjud ilmiy yondashuvlarni tahliliy jihatdan uchta paradigmatik guruhga ajratish mumkin:

Klassik morfologik ishlov berish va filtrlash usullari. DullRazor algoritmi [8; 533–543-b.] va uning modifikatsiyalarida qoramtir artefaktlarni ajratishga mo‘ljallangan Black-hat morfologik filtri, bo‘sag‘alash orqali ikkilik maska hosil qilish va chiziqli/mediana interpolatsiyasi qo‘llaniladi. Bir qator tadqiqotchilar ushbu yondashuv kam hisoblash resurslarini talab qilishi va tezkorligi bilan ajralib turishini ta’kidlashadi. Biroq, ushbu metodlar yuqori kontrastli, qalin va qora soch tolalari uchun nisbatan barqaror bo‘lib, oq yoki sarg‘ish tusli sochlar, shuningdek, yarim soyali sohalarda samarasiz sanaladi. Bundan tashqari, oddiy mediana interpolatsiyasi lezyonning ichki pigment tarmog‘ini haddan tashqari silliqlab, ularning aniqligi va teksturaviy tafsilotlarini pasaytiradi [9; e13203-b.].

Qisman differensial tenglamalar (PDE) va an’anaviy inpainting. To‘liq variatsiya va Navye-Stoks tenglamalariga asoslangan qayta tiklash usullari [10; 597–604-b.] chekka gradientlarini uzluksiz uzatishga harakat qiladi. Biroq, ularning global cheklovi shundaki, ular tasvirning faqat lokal qo‘shnichilik statistikalariga tayanadi. Katta maydondagi murakkab bir-birini kesib o‘tadigan zich soch tolalarida bu usullar haqiqiy to‘qimaga mos kelmaydigan tasvir qismlarini hosil qilishi mumkin va natijada hisoblash murakkabligi $O(N^2)$ dan oshib ketadi.

Konvolyutsion (CNN) va generativ modellar. U-Net va Autoencoder arxitekturalari soch segmentatsiyasini sezilarli darajada yaxshilaydi [11; 107994-b.]. Shunga qaramay, konvolyutsion yadrolarning local maydoni cheklanganligi sababli, ular butun tasvir bo‘ylab cho‘zilgan soch tolalarining uzun fazoviy bog‘lanishlarini va uzoq masofali kontekstni to‘liq qamrab ololmaydi. Keyingi yillarda taklif qilingan standart Transformer yondashuvlari (masalan, Attention ViT) esa piksellar soniga nisbatan kvadratik hisoblash murakkabligini talab qiladi, bu yuqori aniqlikdagi tibbiy tasvirlarda operativ xotira tanqisligini keltirib chiqaradi.

Mavjud tadqiqotlarning eng asosiy ilmiy bo‘shlig‘i shundaki, ko‘pchilik usullar faqat soch tanasining o‘zini niqoblaydi va uning atrofidagi mikro-soyalarni e’tiborsiz qoldiradi. Bu esa qayta tiklash bosqichidan so‘ng terida to‘q kulrang “izlar” paydo bo‘lishiga olib keladi. Qolaversa, tiklash jarayonida lezyon chegarasining keskin o‘zgarish gradientlari yo‘qotilib, xavfli o‘smalarning klinik asimmetriya ko‘rsatkichlari buziladi.

Ushbu tadqiqotning asosiy maqsadi dermaskopik tasvirlardagi turli qalinlikdagi soch tolalari va ularning soyalarini aniqlash hamda klinik to‘qimalarni to‘liq saqlagan holda tiklash imkonini beruvchi ko‘p miqyosli transformer va chekka-sezgir chastotaviy usulga asoslangan qayta tiklash algoritmini ishlab chiqishdan iborat.

Tadqiqotda ierarxik Swin transformer mexanizmi asosida soch tolalari va ularning mikro-soyalarini qamrab oluvchi ko‘p miqyosli segmentatsiya modeli taklif etildi. Shu bilan birga, tasvir sathidagi mavjud nuqsonlarni to‘ldirish uchun fazoviy va spektral sohalarni birlashtiruvchi chekka-sezgir tezkor Furye qayta tiklash operatori ishlab chiqildi. Ushbu operator chekka yo‘qotishi hamda struktura o‘xshashligi funksiyalarini integrallash orqali zararlangan soha chegaralari va nozik teksturaviy xususiyatlarning xiralashishining oldini oladi. Ishlab chiqilgan algoritm xalqaro HAM10000 va PH2 ma’lumotlar to‘plamlarida keng qamrovli sinovdan o‘tkazildi. Tajribalardan olingan natijalar patologik o‘choq chegaralarini aniqlash hamda kasallik xavflilik darajasini baholash kabi keyingi diagnostik bosqichlarning ishonchliligini sezilarli darajada oshirishini isbotladi.

2. Taklif etilayotgan algoritm va metodologiya

Taklif etilayotgan algoritm funksional jihatdan o‘zaro uzviy bog‘langan ikkita asosiy bosqichdan iborat bo‘lib, uning umumiy strukturaviy modeli 1-rasmda ifodalangan konseptual ketma-ketlikka asoslanadi.

Soch tolalari tasvir maydoni bo‘ylab murakkab egri chiziqlar hosil qiladi va ularning qalinligi piksel o‘lchamidan kichik qiymatlardan o‘nlab piksellargacha o‘zgaradi. Standart konvolyutsiyalar global kontekstni yo‘qotsa, to‘liq

(cc) BY

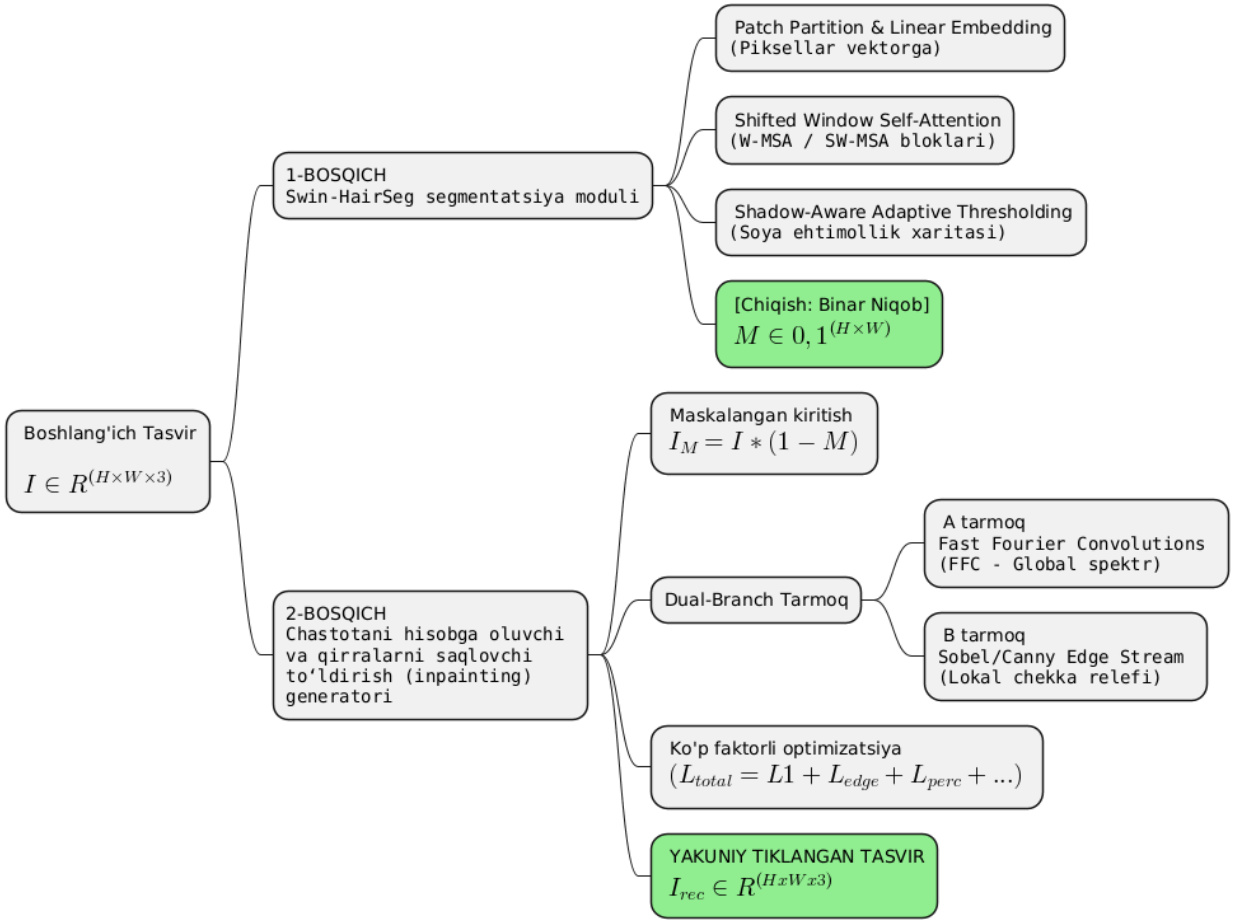
ViT modellari katta hisoblash resurslarini talab qiladi. Shu sababli, tadqiqotda ierarxik tuzilmaga va siljitilgan darchali e'tibor mexanizmi(Shifted Window Self-Attention)ga asoslangan [12] Swin-HairSeg arxitekturasi taklif etiladi.

2.1. 1-bosqich: Soch va ularning mikro-soyalarini segmentatsiyalash (Swin-HairSeg)

Boshlang'ich tasvir $I \in \mathbb{R}^{H\times W\times 3}$ o'lchamli 4×4 bir-birini qoplamaydigan tasvir bo'laklariga bo'linadi. Har bir tasvir bo'lagining xususiyat vektori o'lchami $4 \times 4 \times 3 = 48$ ni tashkil etadi. Bu vektorlar chiziqli proyeksiyalash orqali C o'lchamli fazoga o'tkaziladi.

Modelning ketma-ket transformer bloklarida hisoblash murakkabligini chiziqli $O(M \times N)$ darajada ushlab turish uchun lokal darchalar (darcha o'lchami $M \times M$, odatda $M = 7$) doirasida e'tibor mexanizmidan foydalaniladi:

$$Attention(Q,K,V) = Softmax\left(\frac{QK^T}{\sqrt{d}} + B\right)V$$



1-rasm. Ko'p miqyosli transformer va chekka-sezgir inpainting algoritmining strukturaviy sxemasi

Bu yerda $Q, K, V \in \mathbb{R}^{M^2\times d}$ mos ravishda so'rov, kalit va qiymat matritsalari, d – yashirin qatlam o'lchami, $B \in \mathbb{R}^{M^2\times M^2}$ esa piksellarning nisbiy joylashuvini aks ettiruvchi nisbiy joylashuvga bog'liq qo'shimcha had sanaladi.

Qo'shni darchalar o'rtasidagi bog'liqlikni ta'minlash maqsadida ketma-ket keluvchi bloklarda siljuvchi darcha mexanizmi (SW-MSA) qo'llaniladi:

$$\hat{z}^l = W\text{-}MSA\left(LN(z^{l-1})\right) + z^{l-1}, \quad z^l = MLP\left(LN(\hat{z}^l)\right) + \hat{z}^l$$

$$\hat{z}^{l+1} = SW\text{-}MSA\left(LN(z^l)\right) + z^l, \quad z^{l+1} = MLP\left(LN(\hat{z}^{l+1})\right) + \hat{z}^{l+1}$$

Bu yerda LN – qatlam bo'yicha me'yorlashtirish (Layer Normalization), W-MSA

(cc) BY

va SW-MSA esa mos ravishda standart va siljigan darcha asosida ko‘p boshli o‘z-o‘ziga e’tibor modullari. Ushbu yondashuvda katta o‘lchamli tibbiy tasvirlarda e’tibor qatlamlarida o‘qitish jarayonining barqaror yaqinlashuvini ta’minlash maqsadida masshtablangan kosinusli e’tibor (scaled cosine attention) prinsipi inobatga olingan [12].

Soya-sezgirlik mexanizmi (Shadow-Aware Adaptation). Soch tolasining yonidagi mikro-soyalarni to‘liq qamrab olish maqsadida segmentatsiya chiqishida 2 sinfli emas, balki 3 sinfli ehtimollik taqsimoti shakllantiriladi. Ya’ni, fon (P_{bg}), soch tanasi (P_{hair}) va soch soyasi (P_{shadow})ga ajratiladi. Yakuniy binar niqob $M(x, y)$ quyidagi qaror qoidasi orqali sintezlanadi:

$$M(x,y) = \begin{cases} 1, & agar\ P_{hair}(x,y) \geq \tau_1 \ \vee \ P_{shadow}(x,y) \geq \tau_2 \\ 0, & aks\ holda \end{cases}$$

Bu yerda $\tau_1 = 0.50$ va $\tau_2 = 0.35$ optimal ehtimollik chegaralari bo‘lib, terining ichki atipik pigmentatsiyasi tasodifan o‘chib ketmasligi uchun giperparametr sifatida tajribaviy asoslangan.

Segmentatsiya bosqichi quyidagi birlashgan yo‘qotish funksiyasi orqali optimallashtiriladi:

$$\mathcal{L}_{seg} = \mathcal{L}_{Focal}(P, G) + \alpha \mathcal{L}_{Dice}(P, G)$$

Bu yerda $\mathcal{L}_{\text{Focal}}$ - qalin va ingichka tolalardagi muvozanatsizlikni muvofiqlashtiruvchi fokal yo‘qotish, $\mathcal{L}_{\text{Dice}}$ esa umumiy kontur mosligini ta’minlovchi Dice koeffitsiyenti, $\alpha = 0.5$ qilib tanlangan.

2.2. 2-bosqich: Chegaralarni saqlagan holda chastotaviy tasvirni tiklash (Edge-Preserving Frequency Inpainting)

Niqoblangan tasvir quyidagicha hosil qilinadi:

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

Bu yerda $\odot$ - Adamar (elementlar bo‘yicha) ko‘paytirish amali. Generatorning maqsadi I_M va M ga tayangan holda yo‘qotilgan piksellarni tiklab, haqiqiy etalon tasvirga imkon qadar yaqin bo‘lgan $\hat{I}$ tasvirni hosil qilishdan iborat:

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

Dermaskopik tasvirlarda lezyon sohalari turli fazoviy taqsimotga ega murakkab teksturaviy tuzilmalarga ega. Oddiy konvolyutsiyalar bunday murakkab to‘qimalarni qayta tiklashda ko‘pincha xiralashishlar hosil qiladi. Shu bois generatorning asosiy yadrosi sifatida Fast Fourier Convolution (FFC) qatlami kiritildi. FFC har bir tasvir xususiyat xaritasini ikki parallel oqimga ajratadi:

1. **Lokal oqim (Spatial stream)** – standart konvolyutsiyalar yordamida lokal chekkalarni qayta ishlaydi.
2. **Global chastotaviy oqim (Spectral stream)** – haqiqiy 2D Tezkor Furye Transformatsiyasi (2D-FFT) orqali xususiyatlarni chastota domeniga o‘tkazadi:

$$F(u,v) = \mathcal{F}_2\{f(x,y)\}, \quad f'(x,y) = \mathcal{F}_2^{-1}\{\mathcal{K}(u,v) \cdot F(u,v)\}$$

Bu global chastota domeni orqali butun dermaskopik maydonning umumiy rangi va fon yoritilishi hisobga olinadi.

Chekka va struktura yo‘qotish funksiyalari (Edge & Structural Loss Functions)

To‘qima chegaralari va pigment tarmoqlari buzilmasligini ta’minlash maqsadida generatorni o‘qitishda murakkab optimallashtirish mezonlari ishlab chiqildi:

1. Piksel darajasidagi rekonstruksiya yo‘qotishi ($\mathcal{L}_1$):

$$\mathcal{L}_1 = \frac{1}{N}\left\|M \odot (\hat{I} - I)\right\|_1 + \frac{\gamma}{N}\left\|(1 - M) \odot (\hat{I} - I)\right\|_1$$

Bu yerda $\gamma = 0.1$ fonning o‘zgarmasligini nazorat qiladi.

2. Chekka-sezgirlik yo‘qotishi ($\mathcal{L}_{\text{edge}}$):

Klinik tashxisda eng muhim bo‘lgan lezyon chegaralaridagi intensivlik o‘zgarishlarini saqlash maqsadida Sobel gradient operatorlari (∇_x, ∇_y) asosidagi maxsus chekka yo‘qotishi taklif etildi:

(cc) BY

$$\mathcal{L}_{edge} = \left\|\nabla\hat{I} - \nabla I\right\|_1 = \left\|\sqrt{\left(\nabla_x\hat{I}\right)^2 + \left(\nabla_y\hat{I}\right)^2} - \sqrt{\left(\nabla_x I\right)^2 + \left(\nabla_y I\right)^2}\right\|_1$$

3. Perseptual (VGG-19) yo‘qotish ($\mathcal{L}_{\text{perc}}$):

Chuqur qatlamlardagi semantik o‘xshashlikni ta’minlash uchun oldindan o‘qitilgan VGG-19 tarmog‘ining ϕ_j faollashtirish qatlamlaridan foydalaniladi:

$$\mathcal{L}_{perc} = \sum_j \frac{1}{N_j}\left\|\phi_j(\hat{I}) - \phi_j(I)\right\|_1$$

4. Struktura o‘xshashligi yo‘qotishi ($\mathcal{L}_{\text{SSIM}}$):

$$\mathcal{L}_{SSIM} = 1 - SSIM(\hat{I}, I)$$

To‘liq minimallashtirish funksiyasi:

$$\mathcal{L}_{total} = \lambda_1\mathcal{L}_1 + \lambda_2\mathcal{L}_{edge} + \lambda_3\mathcal{L}_{perc} + \lambda_4\mathcal{L}_{SSIM}$$

Empirik tajribalarda giperparametrlar quyidagicha belgilandi: $\lambda_1 = 10.0, \lambda_2 = 4.0, \lambda_3 = 2.0, \lambda_4 = 5.0$.

3. Eksperimental qism va natijalar

Tadqiqot doirasidagi barcha hisoblash tajribalari yuqori unumdorlikka ega apparat platformasida o‘tkazildi. Mazkur tizim Intel Xeon Silver 4214R markali protsessor, 64 GB hajmdagi tezkor xotira hamda 24 GB GDDR6X xotiraga ega NVIDIA RTX 3090 grafik tezlatkichini o‘z ichiga oladi. Dasturiy ta’minot asosi sifatida Ubuntu 22.04 LTS operatsion tizimi va Python 3.10 dasturlash tili tanlandi. Neyron tarmoqlarni loyihalash, o‘qitish va tasvirlarga shakl berish jarayonlari PyTorch 2.1.2 freymvorki, CUDA 12.1 hisoblash kutubxonasi, shuningdek, torchvision va Albumentations paketlari yordamida amalga oshirildi.

Modellarni optimallashtirish jarayonida AdamW algoritmidan foydalanildi. Bunda birinchi va ikkinchi tartibli moment parametrlarining qiymatlari $\beta_1 = 0.9$ hamda $\beta_2 = 0.999$ ga, vaznning kamayish koeffitsiyenti esa 10^{-4} ga tenglashtirildi. Boshlang‘ich o‘qitish tezligi $\text{lr} = 2 \times 10^{-4}$ miqdorida belgilandi va o‘qitish davomida ushbu ko‘rsatkich kosinusli kamaytirish (Cosine Annealing) usulida bosqichma-bosqich pasaytirildi. Tajribalar paketi o‘lchami (batch size) 16 tadan iborat bo‘lib, modellar jami 80 ta o‘qitish davri (epoch) davomida to‘liq o‘qitildi.

Algoritm samaradorligini baholash uchun ochiq manbali xalqaro ma’lumotlar to‘plamlaridan foydalanildi. Asosiy o‘qitish ma’lumotlari to‘plami sifatida 10 015 ta yuqori aniqlikdagi tasvirni o‘z ichiga olgan HAM10000 to‘plami olindi [13; 180161-b.]. Ushbu to‘plamdagi barcha namunalar mustaqil ravishda 80% o‘qitish, 10% validatsiya hamda 10% test guruhlariga taqsimlandi. Tizimning umumlashtirish qobiliyatini qo‘shimcha tekshirish maqsadida 200 ta klinik tasdiqlangan (80 ta atipik nevus, 80 ta oddiy nevus va 40 ta melanoma) namunadan iborat PH2 to‘plamidan mustaqil sinov to‘plami sifatida foydalanildi [14; 5437–5440-b.].

Qayta tiklash jarayonining sifatini miqdoriy baholash uchun nazorat tajribasi ham tashkil qilindi. Buning uchun dastlab soch artefaktlaridan mutlaqo toza bo‘lgan 500 ta nazorat tasviri tanlab olindi. So‘ngra maxsus metodika [15; 1–17-b.] asosida ushbu tasvirlarga yo‘nalishi, qalinligi va optik zichligi tasodifiy taqsimlangan sintetik soch tolalari hamda ularning mikro-soyalari qatlami sun’iy ravishda kiritildi.

3.1. Soch va soya segmentatsiyasi natijalari

Taklif etilgan **Swin-HairSeg** modelining samaradorligi klassik va zamonaviy neyron tarmoq modellari bilan taqqoslandi. Segmentatsiya aniqligi Dice o‘xshashlik koeffitsiyenti, IoU (Jaccard indeksi) va chegaralar aniqligini ifodalovchi Boundary F-score (BF) ko‘rsatkichlari orqali baholandi.

1-jadval.

Soch va soya artefaktlarini segmentatsiyalash natijalarining qiyosiy tahlili.

Model yoki usul	Dice (DSC) ↑	IoU (Jaccard) ↑	Boundary F-score (BF) ↑	O‘rtacha qayta ishlash vaqti (ms) ↓
DullRazor (Morfologik) [8; 533–543-b.]	0.774 ± 0.015	0.638 ± 0.018	0.598 ± 0.021	**12.4**

U-Net (ResNet-34 bekbon) [11; 107994-b.]	0.862 ± 0.011	0.781 ± 0.014	0.752 ± 0.016	28.5
DeepLabV3+ (ResNet-50)	0.879 ± 0.009	0.801 ± 0.012	0.771 ± 0.013	41.2
SegFormer (MiT-B2) [16]	0.938 ± 0.007	0.895 ± 0.009	0.864 ± 0.010	34.6
Taklif etilayotgan Swin-HairSeg	**0.958 ± 0.005**	**0.919 ± 0.006**	**0.897 ± 0.008**	38.2

Jadvaldan ko‘rinadiki, an’anaviy DullRazor past ko‘rsatkich qayd etgan, chunki u nozik tolalarni e’tibordan chetda qoldiradi. Standart SegFormer yuqori natija ko‘rsatgan bo‘lsa-da, taklif etilgan Swin-HairSeg modeli siljuvchi darcha e’tibori va qo‘shimcha soya ehtimolligi kanali evaziga chekka aniqligida (Boundary F-score) 0.897 natijaga erishdi. Mazkur natija taklif etilgan model artefakt hududlarining chegaralarini aniqlashda taqqoslangan usullarga nisbatan yuqoriroq ko‘rsatkichga erishganini ifodalaydi.

3.2. Tasvirni qayta tiklash (Inpainting) sifati tahlili

Tiklash sifatini o‘lchash uchun PSNR (signal-shovqin nisbati), SSIM (tuzilmaviy o‘xshashlik indeksi) va LPIPS (chuqur perseptual o‘xshashlik, qancha past bo‘lsa shuncha yaxshi) mezonlaridan foydalanildi.

2-jadval.

Qayta tiklangan dermaskopik tasvirlar sifatining qiyosiy ko‘rsatkichlari (PH2 va sintetik HAM10000 nazorat to‘plamida).

Tiklash Usuli (Inpainting Pipeline)	PSNR (dB) ↑	SSIM ↑	LPIPS ↓
DullRazor + Bilinear Interpolation [8; 533–543-b.]	24.85	0.824	0.312
U-Net + Navier-Stokes PDE inpainting	26.90	0.851	0.268
DeepLabV3+ + PatchGAN	28.14	0.872	0.235
Standard LaMa (faqat Fourier) [17; 3172–3182-b.]	30.82	0.904	0.191
Taklif etilgan Ko‘p miqyosli Swin + Chekka-sezgir FFC (Muallif)	**32.45**	**0.931**	**0.162**

Taklif etilayotgan yondashuv PSNR ko‘rsatkichini 32.45 dB ga, SSIM ko‘rsatkichini esa 0.931 ga ko‘tardi. Ushbu o‘sish sababi shundaki, FFC global spektral uyg‘unlikni ta’minlasa, yo‘qotish funksiyasiga kiritilgan Sobel chekka operatori ($\mathcal{L}_{\text{edge}}$) lezyon to‘qimasidagi mayda tomirli va pigmentli chiziqlarning yuvilib ketishiga yo‘l qo‘ymaydi.

3.3. Algoritmning keyingi lezyon segmentatsiyasi aniqligiga ta’siri

Tasvirlarga dastlabki ishlov berish algoritmlarining qiymati yakuniy obrazlarni tanish aniqligi bilan o‘lchanadi. Shu maqsadda tozalangan tasvirlar muallifning avvalgi ishida taklif etilgan takomillashtirilgan SK-UNet [6; 427-b.] segmentatsiya tarmog‘iga kiritildi.

3-jadval.

Sochni tozalash usullarining lezyon segmentatsiyasi aniqligiga ta’siri (PH2 datasetida).

Dastlabki ishlov berish bosqichi	Lezyon Dice koeffitsiyenti ↑	Lezyon IoU (Jaccard) ↑
Dastlabki ishlov berilmagan (Sochli asl tasvir)	0.832	0.724
DullRazor orqali tozalangan [8; 533–543-b.]	0.865	0.771

(cc) BY

Oddiy U-Net inpainting orqali tozalangan	0.891	0.812
Taklif etilgan algoritm orqali tozalangan	**0.944**	**0.896**

Ushbu natijalar shuni ko‘rsatadiki, tolalardan to‘g‘ri tozalash lezyon konturini ajratish aniqligini (Dice) 83.2% dan 94.4% gacha oshiradi.

4. Muhokama va cheklovlar

Olingan eksperimental natijalar soch artefaktlarini bartaraf etish jarayonidagi asosiy murakkabliklarni oydinlashtirdi. Amaliyotda bosh to‘siq soch tanasini aniqlash emas, balki terining tabiiy mikroskopik ajinlarini soxta tolalardan to‘g‘ri ajratish hisoblanadi. Shuningdek, oq, sarg‘ish yoki kulrang sochlar joylashgan sohalarda tasvir kontrasti keskin pasayadi va ularni lokalizatsiya qilish qiyinlashadi. Bundan tashqari, soch tolalari atrofida hosil bo‘ladigan 1-3 piksel qalinlikdagi nozik yarim soyalarni to‘liq niqoblash alohida hisoblash aniqligini talab etadi.

Taklif qilingan Swin-HairSeg modeli siljitilgan darchali e’tibor mexanizmi yordamida nozik tuzilmalarning chegaraviy xususiyatlarini aniqlashga xizmat qiladi. Qirralarni saqlashga yo‘naltirilgan Furye asosidagi qayta tiklash (Furye inpainting) operatori esa an’anaviy neyron tarmoqlariga xos bo‘lgan “haddan tashqari silliqlanish” (over-smoothing) ta’sirini kamaytirishga yo‘naltirilgan bo‘lib, lezyonning tekstura va lezyon chegarasining geometrik notekisliklarini saqlab qoladi. Bu esa melanomani benign (xavfsiz) xollardan ajratishda shifokorlar va neyron tarmoqlar uchun muhim ahamiyatga ega.

Tadqiqot doirasida ishlab chiqilgan algoritm yuqori samaradorlik ko‘rsatishiga qaramay, muayyan chegaraviy shartlarga ega. Xususan, dermaskopik tasvir sathining 65–70% dan ortig‘i qalin soch tolalari bilan zich qoplangan vaziyatlarda inpainting moduli atrof-muhit kontekstining yetishmasligi oqibatida gallyutsinativ to‘qima relyefini generatsiya qilish xavfini yuzaga keltiradi. Bunday ekstremal holatlarda dastlabki mexanik tozalashsiz ishonchli klinik tashxisni shakllantirish axborot-tuzilmaviy jihatdan cheklanadi. Shu bilan birga, transformer arxitekturasining hisoblash resurslariga bo‘lgan talabchanligi klassik filtrlarga nisbatan ancha yuqori bo‘lib, katta hajmdagi video-xotirani talab etadi. Mazkur modelni kelgusida portativ yoki mobil dermatoskopiya tizimlariga integratsiya qilish vazifasi tarmoq parametrlarini INT8 formatida kvantlash hamda hisoblash murakkabligini optimallashtirish zaruratini keltirib chiqaradi.

5. Xulosa

Ushbu tadqiqotda dermaskopik tasvirlardagi murakkab soch va soya artefaktlarini bartaraf qilishning yangi ikki bosqichli algoritmi ishlab chiqildi va tadqiq etildi.

Tadqiqot natijalari ishlab chiqilgan Swin-HairSeg va chekka-sezgir Furye inpainting algoritmining yuqori samaradorligini tasdiqladi. Ushbu algoritm soch tolalari hamda ularning mikro-soyalarini 0.958 Dice aniqligida ajratib, terining tabiiy to‘qimasini 32.45 dB PSNR va 0.931 SSIM ko‘rsatkichlari bilan qayta tiklash imkonini berdi. Chastotaviy Furye sohasi bilan fazoviy chekka yo‘qotishlarining o‘zaro integratsiyasi teridagi patologik pigmentatsiyaning nozik tuzilmalarini saqlagan holda artefaktlar ta’sirini kamaytirish imkoniyatini ko‘rsatdi. Biroq, tasvir maydonining 65% dan ortig‘i zich soch tolalari bilan to‘silgan murakkab holatlarda to‘qima relyefini bashorat qilishda subyektiv noaniqliklar yuzaga kelishi mumkin. Mazkur natijalardan kelib chiqib, ushbu algoritm teri saratonini erta tashxislashga mo‘ljallangan tibbiy axborot tizimlarining tasvirlarga dastlabki ishlov berish modullarida qo‘llanish imkoniyatiga ega. Kelgusidagi ilmiy izlanishlar ushbu yondashuvni yashirin belgilar fazosidagi diffuziya modellari bilan boyitish hamda hisoblash imkoniyatlari cheklangan ko‘chma tibbiy qurilmalar uchun yengillashtirilgan arxitekturalarni yaratishga qaratiladi.

Foydalanilgan adabiyotlar

1. S. Mocellin, C. R. Rossi, “The Melanoma Molecular Map Project,” *Melanoma Research*, vol. 18, no. 3, pp. 163–165, June 2008, doi: 10.1097/CMR.0b013e328300c50b.

(cc) BY

2. G. Randi *et al.*, “The European Cancer Information System: exploring linkages between indoor radon concentrations and data on cancer burden,” *Journal of the European Radon Association*, 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, pp. 109335, Dec. 2024, doi: 10.1016/j.compbiomed.2024.109335.
5. G. A. Gulmirzaeva, “Using semantic indexing and thesauri in processing dermoscopic images,” *Современные инновации, системы и технологии - Modern Innovations, Systems and Technologies*, vol. 5, no. 2, pp. 3071–3076, June 2025, doi: 10.47813/2782-2818-2025-5-2-3071-3076.
6. G. Gulmirzaeva, R. Hudec, B. Akbaraliev, B. Samandarov, “An Optimal Deep Hybrid Framework with Selective Kernel U-Net for Skin Lesion Detection and Classification,” *Bioengineering*, vol. 13, no. 4, pp. 427, Apr. 2026, doi: 10.3390/bioengineering13040427.
7. G. A. qizi Gulmirzayeva, “Automatic segmentation of malignant skin tumors in dermoscopic images using U-Net architecture,” *Raqamli Transformatsiya va Sun’iy Intellekt ilmiy jurnali*, vol. 3, no. 5, pp. 104–110, Oct. 2025.
8. T. Lee, V. Ng, R. Gallagher, A. Coldman, D. McLean, “Dullrazor®: A software approach to hair removal from images,” *Computers in Biology and Medicine*, vol. 27, no. 6, pp. 533–543, Nov. 1997, doi: 10.1016/S0010-4825(97)00020-6.
9. R. Kasmi *et al.*, “SharpRazor: Automatic removal of hair and ruler marks from dermoscopy images,” *Skin Research and Technology*, vol. 29, no. 4, pp. e13203, Apr. 2023, doi: 10.1111/srt.13203.
10. A. H. Khan, D. N. F. A. Iskandar, J. F. Al-Asad, S. El-Nakla, “Classification of Skin Lesion with Hair and Artifacts Removal using Black-hat Morphology and Total Variation,” *International Journal of Computing and Digital Systems*, vol. 10, no. 1, pp. 597–604, May 2021, doi: 10.12785/ijcds/100157.
11. W. Li, A. N. Joseph Raj, T. Tjahjadi, Z. Zhuang, “Digital hair removal by deep learning for skin lesion segmentation,” *Pattern Recognition*, vol. 117, pp. 107994, Sept. 2021, doi: 10.1016/j.patcog.2021.107994.
12. Z. Liu *et al.*, “Swin Transformer V2: Scaling Up Capacity and Resolution,” 2021, doi: 10.48550/ARXIV.2111.09883.
13. P. Tschandl, C. Rosendahl, H. Kittler, “The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions,” *Scientific Data*, vol. 5, no. 1, pp. 180161, Aug. 2018, doi: 10.1038/sdata.2018.161.
14. T. Mendonca, P. M. Ferreira, J. S. Marques, A. R. S. Marcal, J. Rozeira, “PH^2 - A dermoscopic image database for research and benchmarking,” *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Osaka: IEEE, July 2013, pp. 5437–5440. doi: 10.1109/EMBC.2013.6610779.
15. L. Jütte, H. Patel, 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. 1–17, Nov. 2024, doi: 10.1117/1.JBO.29.11.116003.
16. E. Xie, W. Wang, Z. Yu, A. Anandkumar, J. M. Alvarez, P. Luo, “SegFormer: Simple and Efficient Design for Semantic Segmentation with Transformers,” 2021, *arXiv*. doi: 10.48550/ARXIV.2105.15203.
17. R. Suvorov *et al.*, “Resolution-robust Large Mask Inpainting with Fourier Convolutions,” *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.

(cc) BY