IQRO JURNALI , IQRO JOURNAL, ИКРО ЖУРНАЛИ
ISSN:2181-4341| wordlyknowledge.uz/index.php/iqro
Volume 23. Issue 02. Sentabr ,2026

PAST SIFATLI YUZ TASVIRLARINI GFPGAN VA CODEFORMER ALGORITMLARI YORDAMIDA YAXSHILASH: QIYOSIY TAHLIL

Abdulhakimov H.N..
Raqamli texnologiyalar va sun'iy intellektni
rivojlantirish ilmiy-tadqiqot instituti, Toshkent, O'zbekiston
hojiakbar@airi.uz
https://doi.org/10.5281/zenodo.22787789

Annotatsiya. Ushbu ishda GFPGAN v1.4 va CodeFormer algoritmlari past sifatli yuz tasvirini yaxshilash vazifasida amaliy sinab ko'rildi. Bir xil past sifatli tasvir har ikki algoritm yordamida alohida qayta ishlandi. Olingan natijalar asl sifatli tasvir bilan vizual tarzda, shuningdek SSIM va LPIPS ko'rsatkichlari asosida solishtirildi. Tajribadan asosiy maqsad ushbu ikki algoritm yuz tasvirini yaxshilashda amalda qanday natija berishini ko'rib chiqish va ular orasidagi farqlarni tahlil qilishdan iborat. Natijalarda ikkala algoritm ham yuzning ayrim lokal detallarini aniqroq ko'rsatdi. LPIPS qiymati GFPGAN va CodeFormer natijalarida boshlang'ich past sifatli tasvirga nisbatan kamaydi, SSIM qiymatida esa sezilarli o'sish kuzatilmadi. CodeFormer ushbu tajribada biroz pastroq LPIPS qiymatini ko'rsatdi, ammo ikki algoritm orasidagi farq juda kichik bo'ldi. Natijalar yuz tasvirini tiklashni faqat vizual ko'rinish bilan emas, strukturaviy va perceptual ko'rsatkichlar bilan birga baholash foydali ekanini ko'rsatdi.
Kalit so'zlar: yuz tasviri, tasvirni tiklash, tasvir sifatini yaxshilash, GFPGAN, CodeFormer, SSIM, LPIPS.

1. KIRISH

Yuz tasvirining sifati kompyuter ko'rish bilan bog'liq ko'plab amaliy vazifalarda muhim ahamiyatga ega. Tasvir sifati pasayganda yuzdagi mayda detallarni aniq ko'rish qiyinlashadi va bu keyingi qayta ishlash bosqichlariga ham ta'sir qilishi mumkin. Amaliy sharoitda esa yuz tasvirlari har doim ham ideal holatda olinmaydi. Kamera sifati, masofa, yoritilish, fokusning noto'g'ri tanlanishi, harakat yoki tasvirni siqish kabi omillar natijasida yuz tasviri xiralashishi, aniqligi pasayishi yoki ayrim detallar yo'qolishi mumkin.

Ayniqsa past resolution, xiralashish va siqish artefaktlari ko'z, qosh, burun, lab, teri teksturasi hamda yuz konturi kabi lokal elementlarning noaniq ko'rinishiga olib keladi. Bunday tasvirlarni oddiy kattalashtirish orqali sifatli holatga qaytarish har doim ham mumkin emas, chunki ayrim ma'lumotlar tasvir sifati pasayish jarayonida yo'qolgan bo'ladi. Shu sababli past sifatli yuz tasvirlarini yaxshilash va ulardagi muhim vizual detallarni qayta tiklash kompyuter ko'rish sohasidagi dolzarb amaliy masalalardan biri bo'lib qolmoqda.

Tasvir sifatini yaxshilash uchun turli yondashuvlardan foydalaniladi. Klassik usullar odatda filtrlash, shovqinni kamaytirish, kontrastni oshirish yoki tasvirni aniqlashtirish kabi amallarni bajaradi. Bunday usullar mavjud piksel ma'lumotlarini qayta ishlashga asoslanadi va yengil degradatsiyalarda foydali natija berishi mumkin. Biroq yuz tasviri juda xira yoki past aniqlikda bo'lsa, faqat mavjud piksellar asosida yo'qolgan detallarni tiklash qiyinlashadi.

So'nggi yillarda yuz tasvirlarini yaxshilashda generativ modellar keng qo'llanila boshladi. Ushbu modellar ko'plab yuqori sifatli yuz tasvirlaridan o'rganilgan xususiyatlardan foydalanadi va kiruvchi past sifatli tasvirda noaniq yoki yetishmayotgan qismlarni qayta hosil qilishga harakat qiladi. Natijada tasvir vizual jihatdan aniqroq va tozaroq ko'rinishi mumkin. Shu bilan birga, generativ algoritmlar qayta tiklayotgan ayrim mayda detallar original tasvirdagi piksellarning aynan nusxasi bo'lmasligi mumkin. Shuning uchun bunday modellarning

natijalarini faqat vizual ko‘rinish asosida emas, sonli ko‘rsatkichlar yordamida ham baholash muhim.

GFPGAN va CodeFormer yuz tasvirlarini tiklashga mo‘ljallangan zamonaviy algoritmlardan hisoblanadi. GFPGAN Wang va hammualliflar tomonidan generativ facial prior asosida taklif qilingan [1]. Ushbu model oldindan o‘rganilgan yuz xususiyatlaridan foydalanib, past sifatli tasvirdagi yuz detallarini qayta tiklashga harakat qiladi. CodeFormer esa Zhou va hammualliflar tomonidan Transformer hamda diskret codebook yondashuvi asosida ishlab chiqilgan [2]. CodeFormer yuz tasviridagi xususiyatlarni o‘rganilgan kodlar bilan bog‘lab, sifatliroq natija hosil qilishga yo‘naltirilgan. Ikkala algoritm bir xil vazifaga qaratilgan bo‘lsa-da, ularning ishlash prinsipi va tasvirni tiklash yondashuvi bir-biridan farq qiladi.

Shu sababli ushbu ikki algoritmni bir xil sharoitda amaliy sinab ko‘rish va ularning natijalarini solishtirish qiziqish uyg‘otadi. Bunda faqat qayta tiklangan tasvirning tashqi ko‘rinishi emas, balki original sifatli tasvirga qanchalik yaqinligi ham hisobga olinishi kerak. Ushbu ishda bunday baholash uchun strukturaviy o‘xshashlikni ifodalovchi SSIM va perceptual farqni baholovchi LPIPS ko‘rsatkichlaridan foydalanildi.

Ushbu tadqiqotda GFPGAN v1.4 va CodeFormer algoritmlari amaliyotda sinab ko‘rildi. Bir xil past sifatli yuz tasviri har ikki algoritm yordamida alohida qayta ishlandi. Olingan natijalar asl sifatli tasvir bilan vizual tarzda, shuningdek SSIM va LPIPS ko‘rsatkichlari asosida solishtirildi. Asosiy e’tibor ikki algoritm yuz tasvirini yaxshilashda amalda qanday natija berishi, ularning natijalari o‘rtasida qanday farqlar mavjudligi va vizual o‘zgarishlarning sonli ko‘rsatkichlarda qanday aks etishiga qaratildi.

2. ADABIYOTLAR TAHLILI VA NAZARIY ASOSLAR

Past sifatli yuz tasvirlarini yaxshilash masalasi tasvirlarni qayta ishlash va kompyuter ko‘rish sohasida muhim yo‘nalishlardan biri hisoblanadi. Amaliy sharoitda yuz tasviri xiralashishi, past aniqlikda olinishi, siqilishi yoki shovqin ta’siriga uchrashi mumkin. Bunday holatda ko‘z, qosh, burun, lab, yuz konturi va teri teksturasi kabi mayda elementlar aniq ko‘rinmay qoladi. Natijada tasvirni oddiy kattalashtirish yoki keskinlashtirish har doim ham yetarli natija bermaydi.

Klassik tasvirni yaxshilash usullari asosan mavjud piksel ma’lumotlarini qayta ishlashga tayanadi. Interpolatsiya tasvir o‘lchamini kattalashtiradi, filtrlash shovqinni kamaytiradi, sharpening esa konturlarni aniqroq ko‘rsatishga yordam beradi. Bu usullar sodda va tez ishlaydi. Lekin tasvir sifati keskin pasayib, ayrim detallar haqidagi ma’lumot yo‘qolgan bo‘lsa, klassik usullar ularni asl holatida qayta hosil qila olmaydi.

Chuqur o‘rganishga asoslangan modellar bu masalaga boshqacha yondashadi. Ular katta hajmdagi sifatli tasvirlardan yuz tuzilishi, lokal elementlarning joylashuvi va umumiy ko‘rinishi haqida ma’lumot o‘rganadi. Past sifatli tasvir qayta ishlanganda model shu oldindan o‘rganilgan ma’lumotdan foydalanib, noaniq yoki yetishmayotgan qismlarni tiklashga harakat qiladi. Shu sababli zamonaviy yuzni tiklash modellarida faqat kiruvchi tasvir piksellari emas, balki o‘rganilgan yuz priorlari ham muhim rol o‘ynaydi.

Yuzni tiklashda asosiy muammo shundaki, model hosil qilgan aniqroq detal har doim ham original tasvirdagi detalning aynan o‘zi bo‘lmasligi mumkin. Generativ model ko‘rinmay qolgan qismni o‘rgangan yuzlar asosida ehtimolli tarzda qayta hosil qiladi. Shu sababli tiklangan tasvirni baholashda uning faqat chiroyli yoki aniq ko‘rinishiga emas, balki asl sifatli tasvir bilan qanchalik yaqinligiga ham e’tibor berish kerak.

2.1. GFPGAN

GFPGAN — Generative Facial Prior GAN nomining qisqartmasi bo‘lib, real sharoitdagi past sifatli yuz tasvirlarini tiklash uchun taklif qilingan generativ modeldir. Wang va hammualliflar ushbu yondashuvda oldindan o‘rgatilgan yuz generatoridagi ma’lumotlardan

generativ facial prior sifatida foydalanishni taklif qilgan [1]. Modelning asosiy g‘oyasi shundan iboratki, past sifatli tasvirda yetarli bo‘lmagan ma’lumot yuqori sifatli yuzlar haqida oldindan o‘rganilgan xususiyatlar bilan to‘ldiriladi.

GFPGAN kiruvchi tasvirdan yuzning fazoviy xususiyatlarini ajratib oladi va ularni generativ modeldagi yuz xususiyatlari bilan bog‘laydi. Natijada ko‘z, qosh, burun, lab, yuz konturi va teri teksturasi kabi qismlar aniqroq ko‘rinishga keltiriladi. Model ayniqsa xiralashgan, siqilgan yoki past aniqlikdagi yuz tasvirlarini vizual jihatdan tozalashda foydali bo‘lishi mumkin.

GFPGANning afzalligi — u faqat piksel interpolatsiyasiga tayanib qolmay, yuzning umumiy tuzilishi haqida o‘rganilgan ma’lumotdan foydalanadi. Shu sababli oddiy resize yoki sharpening bilan tiklash qiyin bo‘lgan detallarni ham aniqroq ko‘rsatishga harakat qiladi. Biroq generativ prior asosida qayta hosil qilingan ayrim mayda detallar asl tasvirdagi piksel strukturasiga to‘liq mos kelmasligi mumkin. Bu holat keyinchalik SSIM yoki LPIPS kabi ko‘rsatkichlar bilan baholash zarurligini tushuntiradi.

2.2. CodeFormer algoritmi

CodeFormer Zhou va hammualliflar tomonidan past sifatli yuz tasvirlarini tiklash uchun ishlab chiqilgan model bo‘lib, Transformer arxitekturasi va diskret codebook yondashuviga tayangan [2]. GFPGAN generativ yuz prioridan foydalansa, CodeFormer yuqori sifatli yuz tasvirlaridan o‘rganilgan kodlar to‘plami orqali tiklash masalasini hal qiladi.

Model avval kiruvchi tasvirdan xususiyatlarni ajratadi. Keyin Transformer ushbu xususiyatlarning umumiy kontekstini tahlil qilib, codebook ichidan ularga mos yuqori sifatli kodlarni tanlashga yordam beradi. Tanlangan kodlar asosida yuz tasviri qayta quriladi. Ushbu yondashuv yuzning umumiy strukturasi bilan birga lokal detallarni ham tiklashga qaratilgan.

CodeFormerning muhim xususiyatlaridan biri fidelity weight deb ataladigan w parametridir. Ushbu parametr modelning tasvirni qanchalik faol tiklashi va kiruvchi tasvir xususiyatlarini qanchalik saqlashiga ta’sir qiladi. w qiymatini o‘zgartirish orqali tiklash kuchi bilan boshlang‘ich tasvirga sodiqlik orasidagi muvozanatni boshqarish mumkin. Ushbu tadqiqotdagi amaliy sinovda $w = 0.5$ qiymati ishlatildi.

CodeFormer ham generativ tiklash yondashuviga yaqin bo‘lgani sababli, qayta tiklangan tasvirning vizual sifati yuqori bo‘lishi uning reference tasvir bilan barcha piksellarda aynan mos kelishini anglatmaydi. Shu sababli CodeFormer natijasi ham vizual kuzatuv bilan birga sonli ko‘rsatkichlar yordamida baholanishi kerak.

2.3. GFPGAN va CodeFormer yondashuvlarining farqi

GFPGAN va CodeFormer bir xil vazifani — past sifatli yuz tasvirini aniqroq holatga keltirishni — bajarishga yo‘naltirilgan. Lekin ular buning uchun turli usullardan foydalanadi. GFPGAN oldindan o‘rgatilgan generativ yuz prioriga tayansa, CodeFormer diskret codebook va Transformer yordamida mos yuqori sifatli representationni topishga harakat qiladi. Shu farq tufayli bir xil kirish tasvirida ikki model hosil qilgan lokal detallar bir-biridan biroz farq qilishi mumkin.

Xususiyat	GFPGAN	CodeFormer
Asosiy yondashuv	Generativ facial prior	Transformer va diskret codebook
Tiklash g‘oyasi	O‘rganilgan yuz priorlari bilan detallarni qayta hosil qilish	Mos yuqori sifatli kodlarni tanlab tasvirni qayta qurish
Boshqariladigan parametr	Model versiyasi va inference sozlamalari	Fidelity weight (w)
Amaliy maqsad	Past sifatli yuz detallarini aniqroq ko‘rsatish	Past sifatli yuz detallarini aniqroq ko‘rsatish

1-jadval. GFPGAN va CodeFormer yondashuvlarining umumiy taqqoslanishi

2.4. Natijani baholashga yondashuv

Yuz tasvirini tiklash natijasini faqat ko‘z bilan baholash subyektiv bo‘lishi mumkin. Bir tasvir vizual jihatdan aniqroq ko‘rinsa ham, u asl sifatli tasvirning strukturasi bilan to‘liq mos kelmasligi mumkin. Shu sababli amaliy tajribalarda vizual tahlil bilan birga sonli ko‘rsatkichlardan foydalanish maqsadga muvofiq.

Ushbu ishda SSIM va LPIPS ko‘rsatkichlari tanlandi. SSIM tasvirlarning strukturaviy o‘xshashligini baholaydi [3]. U yuqori bo‘lsa, ikki tasvir strukturaviy jihatdan bir-biriga yaqin deb qaraladi. LPIPS esa chuqur neyron tarmoqdan olingan featurelar orqali perceptual farqni baholaydi [4]. LPIPS qiymati qancha kichik bo‘lsa, ikki tasvir perceptual jihatdan shuncha yaqin deb hisoblanadi.

SSIM va LPIPS bir xil narsani o‘lchamaydi. Shu sababli generativ model vizual jihatdan yaxshi natija berganida SSIM albatta oshishi shart emas. Xuddi shuningdek, LPIPSdagi o‘zgarish ham tasvirning barcha strukturaviy xususiyatlari bir xil bo‘lib qolganini anglatmaydi. Ikki ko‘rsatkichni birgalikda ko‘rish tiklash natijasini to‘liqroq tushunishga yordam beradi.

2.5. Adabiyotlar tahlilidan kelib chiqadigan yondashuv

Ko‘rib chiqilgan yondashuvlar shuni ko‘rsatadiki, GFPGAN va CodeFormer yuz tasvirini tiklashda bir-biridan farqli mexanizmlardan foydalanadi. Shu sababli ularni bir xil past sifatli tasvirda amaliy sinovdan o‘tkazish va natijalarini bir xil mezonlar asosida solishtirish mazkur ish uchun mantiqiy yondashuv bo‘ldi. Keyingi bo‘limda aynan shu amaliy tajribaning bajarilish tartibi, ishlatilgan sozlamalar va baholash usullari bayon qilinadi.

3. TADQIQOT USULLARI

Ushbu tadqiqotda past sifatli yuz tasvirlarini yaxshilash uchun GFPGAN v1.4 va CodeFormer algoritmlari amaliy sinovdan o‘tkazildi. Tajribaning asosiy maqsadi bir xil past sifatli yuz tasviriga ikkala algoritmni alohida qo‘llash va hosil bo‘lgan natijalarni bir xil mezonlar asosida solishtirishdan iborat bo‘ldi.

Tajriba uchun sifatli original yuz tasviri va uning past sifatli varianti ishlatildi. Sifatli tasvir keyingi baholashda reference tasvir sifatida qabul qilindi. Past sifatli tasvir esa GFPGAN va CodeFormer algoritmlariga kirish ma’lumoti sifatida berildi.

Har ikkala algoritm bir xil past sifatli tasvirni mustaqil ravishda qayta ishladi. GFPGAN natijasi CodeFormerga yoki CodeFormer natijasi GFPGANga berilmadi. Shu tartib ikki modelning bir xil boshlang‘ich tasvirda qanday natija berishini alohida ko‘rish va keyin to‘g‘ridan-to‘g‘ri solishtirish imkonini berdi.

3.1. Tajriba muhiti

Amaliy tajriba Google Colab muhitida bajarildi. Hisoblash jarayonida NVIDIA Tesla T4 grafik protsessoridan foydalanildi. Tajriba bajarilgan vaqtda muhitda Python 3.13.15, PyTorch 2.11.0+cu128 va CUDA mavjud edi.

Google Colab ushbu tajriba uchun qulay muhit bo‘ldi, chunki GFPGAN va CodeFormer kabi oldindan o‘qitilgan modellarni GPU yordamida ishga tushirish, natijalarni tez ko‘rish va barcha hisoblashlarni bir joyda bajarish imkonini berdi. Ikkala algoritm ham bir xil runtime ichida ishga tushirildi.

Muhit / komponent	Tajriba holati
Platforma	Google Colab
GPU	NVIDIA Tesla T4
Python	3.13.15
PyTorch	2.11.0+cu128
Hisoblash muhiti	CUDA

3.2. Tajriba uchun tasvirlarni tayyorlash

Tajriba uchun yuz tasvirining ikki holati ishlatildi: sifatli original tasvir va past sifatli tasvir. Sifatli original tasvir algoritmlarga berilmadi. U faqat keyinchalik olingan natijalarni solishtirish uchun reference sifatida ishlatildi.

Past sifatli tasvir esa ikkala algoritm uchun bir xil kirish tasviri bo‘ldi. Bu jihat muhim, chunki GFPGAN va CodeFormer natijalarini solishtirishda boshlang‘ich sharoit bir xil bo‘lishi kerak.

Algoritmlardan keyin to‘rtta tasvir birgalikda ko‘rib chiqildi: original reference tasvir, past sifatli tasvir, GFPGAN yordamida tiklangan tasvir va CodeFormer yordamida tiklangan tasvir. Vizual tahlilda yuzning umumiy aniqligi bilan birga ko‘z, qosh, burun, lab, yuz konturi va teri teksturasidagi o‘zgarishlarga e’tibor berildi.

3.3. Tajribaning umumiy tartibi

Bir xil past sifatli yuz tasviri	
GFPGAN v1.4	**CodeFormer (w = 0.5)**
GFPGAN natijasi	CodeFormer natijasi
Reference tasvir bilan vizual, SSIM va LPIPS bo‘yicha taqqoslash	

Avval low-quality tasvir o‘zgartirilmagan holda saqlandi. Keyin aynan shu tasvir GFPGAN va CodeFormer yordamida alohida qayta ishlandi. Har bir modelning chiqish tasviri alohida saqlandi. Keyingi bosqichda reference, low-quality, GFPGAN va CodeFormer natijalari bir xil tartibda solishtirildi.

3.4. GFPGAN algoritmini qo‘llash

Birinchi tajribada GFPGAN v1.4 modeli ishlatildi. Modelga tayyorlangan past sifatli yuz tasviri berildi va GFPGAN uni qayta ishlab, tiklangan tasvirni alohida natija sifatida saqladi.

Tajribada GFPGAN uchun upscale qiymati 1× qilib belgilandi. Bu holatda asosiy e’tibor tasvir o‘lchamini kattalashtirishga emas, yuzning o‘zida hosil bo‘lgan sifat o‘zgarishini kuzatishga qaratildi. Natija PNG formatida saqlandi.

3.5. CodeFormer algoritmini qo‘llash

Ikkinchi tajribada CodeFormer modeli ishlatildi. U ham xuddi GFPGAN kabi bir xil past sifatli yuz tasvirini kirish ma’lumoti sifatida qabul qildi va natijani alohida saqladi.

CodeFormerda muhim parametrlardan biri fidelity weight, ya’ni w qiymatidir. Ushbu parametr tasvirni tiklash darajasi bilan boshlang‘ich tasvirga sodiqlik o‘rtasidagi muvozanatga ta’sir qiladi. Ushbu tajribada $w = 0.5$ qiymati ishlatildi. Bu qiymat amaliy sinov uchun o‘rta holat sifatida tanlandi.

CodeFormer uchun ham upscale qiymati 1× qilib belgilandi. Hosil bo‘lgan tiklangan tasvir keyinchalik GFPGAN natijasi va reference tasvir bilan bir xil baholash tartibida solishtirildi.

Algoritm	Sozlama	Qiymat
GFPGAN	Model versiyasi	v1.4
GFPGAN	Upscale	1×
CodeFormer	Fidelity weight	w = 0.5
CodeFormer	Upscale	1×

3.6. Vizual taqqoslash

Algoritmlarning natijalarini baholashning birinchi bosqichi vizual taqqoslash bo‘ldi. Buning uchun tasvirlar Reference | Low-quality | GFPGAN | CodeFormer tartibida yonma-yon joylashtirildi.

Vizual tahlilda yuzning umumiy tiniqligi, ko‘z va qoshlarning aniqligi, lab va burun konturlarining ko‘rinishi, yuz konturining saqlanishi hamda teri yuzasidagi lokal detallar kuzatildi. Vizual baholash ma’lum darajada subyektiv bo‘lishi mumkinligi sababli, uning yonida SSIM va LPIPS ko‘rsatkichlari ham hisoblandi.

3.7. SSIM orqali baholash

SSIM — Structural Similarity Index Measure — reference tasvir va baholanayotgan tasvir o‘rtasidagi strukturaviy o‘xshashlikni baholash uchun ishlatildi. U tasvirlarning yorqinligi, kontrasti va lokal strukturasi haqidagi ma’lumotlarni birgalikda hisobga oladi.

$$SSIM(x,y) = ((2\mu x\mu y + C1)(2\sigma xy + C2)) / ((\mu x^2 + \mu y^2 + C1)(\sigma x^2 + \sigma y^2 + C2))$$

Bu yerda μx va μy — tasvirlarning o‘rtacha qiymatlari, σx² va σy² — dispersiya, σxy — tasvirlar orasidagi kovariatsiya, C1 va C2 esa hisoblashni barqarorlashtiruvchi konstantalardir. Amaliy talqinda SSIM qiymati qancha yuqori bo‘lsa, ikki tasvir strukturaviy jihatdan shuncha yaqin hisoblanadi.

3.8. LPIPS orqali baholash

Ikkinchi baholash mezoni sifatida LPIPS — Learned Perceptual Image Patch Similarity — ishlatildi. LPIPS tasvirlar orasidagi perceptual farqni chuqur neyron tarmoqdan olingan featurelar asosida baholaydi.

$$LPIPS(x,y) = \Sigma_l\, d_l(f_l(x), f_l(y))$$

Bu soddalashtirilgan ifodada $f_l(x)$ va $f_l(y)$ — ikki tasvirdan neyron tarmoqning ma’lum qatlamida olingan xususiyatlar, d_l esa ular orasidagi farqni bildiradi. LPIPS qiymati qancha kichik bo‘lsa, baholanayotgan tasvir reference tasvirga perceptual jihatdan shuncha yaqin hisoblanadi.

3.9. Ishlash vaqtini o‘lchash

GFPGAN va CodeFormerning ishlash davomiyligi ham alohida qayd etildi. Vaqt modelni ishga tushirishdan boshlab natija tasviri hosil bo‘lgunga qadar hisoblandi. Shu sababli olingan qiymat faqat neyron tarmoqning sof inference vaqtini emas, balki modelni ishga tushirish, tasvirni qayta ishlash va natijani saqlash kabi amaliy bosqichlarni ham qamrab oladi.

Processing time algoritmlarning asosiy sifat ko‘rsatkichi sifatida olinmadi. U faqat bir xil Google Colab muhitida ikki algoritmning ishlash davomiyligini qo‘shimcha ravishda solishtirish uchun ishlatildi.

3.10. Natijalarni umumlashtirish

Tajriba yakunida GFPGAN va CodeFormer uchun olingan natijalar bir joyga yig‘ildi. Baholashda vizual sifat, SSIM, LPIPS va ishlash vaqti birgalikda ko‘rib chiqildi. Vizual tahlil yuz tasviridagi ko‘rinadigan o‘zgarishni, SSIM strukturaviy o‘xshashlikni, LPIPS perceptual yaqinlikni, ishlash vaqti esa algoritmlarning amaliy bajarilish davomiyligini ko‘rsatdi.

4. NATIJALAR VA MUHOKAMA

Tajriba yakunida bir xil past sifatli yuz tasviri GFPGAN v1.4 va CodeFormer algoritmlari yordamida alohida qayta ishlandi. Har ikkala modeldan olingan natijalar sifatli original tasvir bilan vizual tarzda va SSIM hamda LPIPS ko‘rsatkichlari asosida solishtirildi. Bundan tashqari, algoritmlarning Google Colab muhitidagi umumiy ishlash vaqti qayd etildi. Natijalarni tahlil qilishda birgina sonli ko‘rsatkichga tayanmasdan, vizual o‘zgarishlar, strukturaviy o‘xshashlik, perceptual yaqinlik va hisoblash davomiyligi birgalikda ko‘rib chiqildi.



1-rasm. Reference, low-quality, GFPGAN v1.4 va CodeFormer natijalarining vizual taqqoslanishi

4.1. Vizual natijalar

Vizual taqqoslashda past sifatli tasvirda yuzning ayrim lokal qismlari xiralashgani, konturlar yumshagani va mayda detallar kamaygani ko‘rindi. GFPGAN va CodeFormer qo‘llangandan keyin esa yuzning umumiy ko‘rinishi tozaroq va aniqroq tus oldi. Ayniqsa ko‘z, qosh, lab va yuz konturi kabi qismlarda boshlang‘ich low-quality tasvirga nisbatan aniqroq ko‘rinish kuzatildi.

GFPGAN natijasida yuzning ayrim lokal elementlari keskinroq va vizual jihatdan ravshanroq ko‘rindi. CodeFormer ham o‘xshash tarzda yuz tasvirini tozaladi va noaniq qismlarni qayta tiklashga harakat qildi. Ushbu namunada ikkala model orasidagi vizual farq juda katta emas. Shunga qaramay, low-quality tasvir bilan taqqoslaganda ikkala algoritm natijasida ham yuzning ko‘rinishi yaxshilangani sezildi.

Bu kuzatuv generativ tiklash algoritmlarining asosiy xususiyatini ko‘rsatadi: model kiruvchi tasvirda yetarlicha aniq bo‘lmagan yuz detallarini oldindan o‘rganilgan ma’lumotlar asosida qayta hosil qiladi. Natijada tasvir ko‘zga aniqroq ko‘rinishi mumkin. Biroq bunday vizual yaxshilanish har doim ham reference tasvir bilan piksel yoki strukturaviy darajada kuchliroq moslikni anglatmaydi. Shu sababli keyingi bosqichda SSIM va LPIPS qiymatlari alohida tahlil qilindi.

4.2. Asosiy sonli natijalar

Usul	SSIM ↑	LPIPS ↓	Umumiy vaqt, s
Low-quality	0.615798	0.613639	—
GFPGAN v1.4	0.614958	0.608958	13.984
CodeFormer w=0.5	0.615080	0.608636	15.886

1-jadval. Tajribada olingan SSIM, LPIPS va umumiy ishlash vaqti

Jadvaldagi qiymatlar shuni ko‘rsatadiki, SSIM natijalari barcha holatlarda bir-biriga juda yaqin bo‘ldi. LPIPS bo‘yicha esa GFPGAN va CodeFormer natijalari boshlang‘ich low-quality tasvirga nisbatan biroz past qiymat berdi. Vaqt ko‘rsatkichida GFPGAN ushbu tajribada CodeFormerga nisbatan tezroq ishladi.

4.3. SSIM natijalarining tahlili

Low-quality tasvirning reference tasvirga nisbatan SSIM qiymati 0.615798 bo‘ldi. GFPGAN v1.4 qo‘llangandan keyin $SSIM$=0.614958, CodeFormer natijasida esa 0.615080 qiymatni ko‘rsatdi. Ushbu uch qiymat o‘rtasidagi tafovut juda kichik.

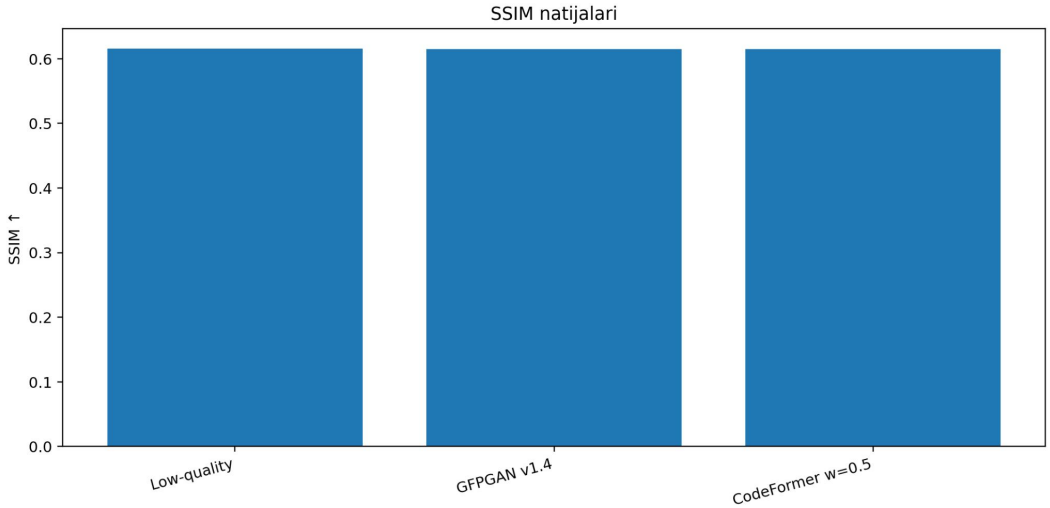
$$\Delta SSIM = SSIMrestored - SSIMLQ$$

$$\Delta SSIMGFPGAN = 0.614958 - 0.615798 = -0.000840$$

$$\Delta SSIMCodeFormer = 0.615080 - 0.615798 = -0.000718$$

GFPGAN uchun SSIM o‘zgarishi -0.000840, CodeFormer uchun esa -0.000718 bo‘ldi. Har ikkala qiymat juda kichik manfiy son bo‘lgani sababli, ushbu namunada tiklashdan keyin SSIM bo‘yicha sezilarli o‘sish kuzatilmadi. CodeFormerning SSIM qiymati GFPGANnikidan juda oz yuqori bo‘lsa-da, bu farq amaliy jihatdan juda kichik.

SSIMning oshmaganini tasvir tiklanmadi, deb talqin qilish to‘g‘ri bo‘lmaydi. SSIM reference va tiklangan tasvirlarning lokal strukturasi qanchalik mos ekaniga sezgir. Generativ model yuzning xira qismlarini aniqroq ko‘rsatish uchun yangi lokal detallarni qayta hosil qilganda, bu detallar vizual jihatdan tabiiy ko‘rinsa ham, reference tasvirdagi struktura bilan aynan bir xil bo‘lmasligi mumkin. Natijada inson ko‘zi uchun aniqroq ko‘ringan tasvirda SSIM qiymati o‘zgarishsiz qolishi yoki juda oz pasayishi mumkin.



2-rasm. Low-quality, GFPGAN va CodeFormer uchun SSIM natijalari

4.4. LPIPS natijalarining tahlili

LPIPS bo‘yicha boshlang‘ich low-quality tasvirning qiymati 0.613639 bo‘ldi. GFPGAN natijasida LPIPS 0.608958 gacha, CodeFormer natijasida esa 0.608636 gacha kamaydi. LPIPS uchun kichik qiymat reference tasvirga perceptual jihatdan yaqinroq natijani bildirgani sababli, bu kamayish ijobiy o‘zgarish sifatida talqin qilindi.

$$\Delta LPIPS = LPIPSLQ - LPIPSrestored$$

$$\Delta LPIPSGFPGAN = 0.613639 - 0.608958 = 0.004681$$

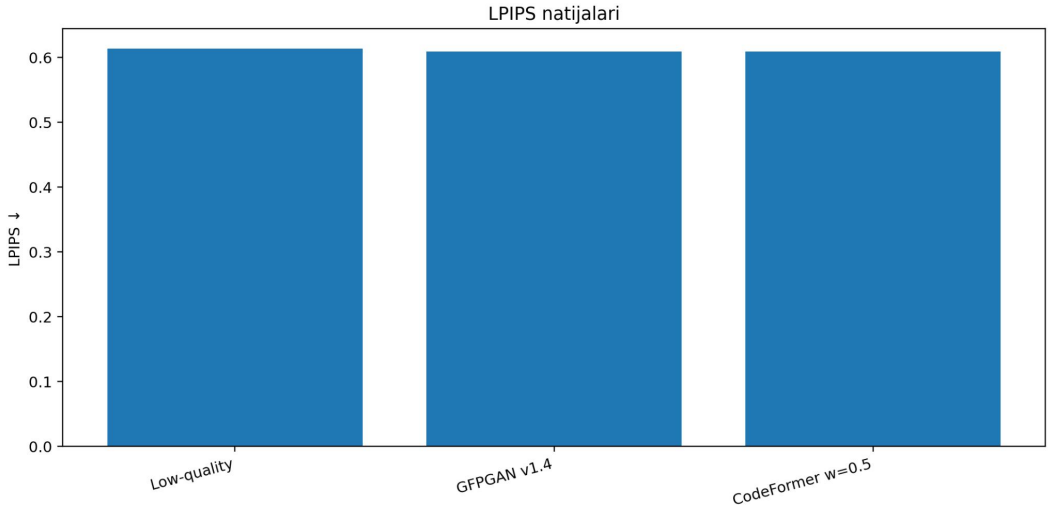
$$\Delta LPIPSCodeFormer = 0.613639 - 0.608636 = 0.005003$$

GFPGAN uchun LPIPS yaxshilanishi 0.004681, CodeFormer uchun esa 0.005003 ni tashkil etdi. Boshlang‘ich LPIPS qiymatiga nisbatan hisoblanganda bu mos ravishda taxminan 0.763% va 0.815% yaxshilanishdir.

$$LPIPS\ yaxshilanishi\ (\%) = (\Delta LPIPS\ /\ LPIPSLQ) \times 100$$

CodeFormerning LPIPS qiymati GFPGANnikidan 0.000322 ga past chiqdi. Bu CodeFormer ushbu tajribada perceptual ko‘rsatkich bo‘yicha biroz yaxshiroq natija berganini ko‘rsatadi. Biroq ikki algoritm orasidagi farq juda kichik bo‘lgani sababli, faqat shu natijaga asoslanib CodeFormerni mutlaq ustun deb baholash maqsadga muvofiq emas.

LPIPSning ikkala algoritmda ham kamaygani vizual kuzatuv bilan bir yo‘nalishda bo‘ldi. Ya’ni yuz tasviri ko‘zga aniqroq ko‘ringanidan tashqari, chuqur neyron tarmoq featurelari asosida hisoblangan perceptual farq ham oz miqdorda kamaydi. Bu natija tiklashdan keyingi o‘zgarishni SSIM yolg‘iz o‘zi to‘liq ifodalamaganini ko‘rsatadi.



3-rasm. Low-quality, GFPGAN va CodeFormer uchun LPIPS natijalari

4.5. Ishlash vaqtining tahlili

GFPGAN v1.4 uchun umumiy ishlash vaqti 13.984 soniya, CodeFormer uchun esa 15.886 soniya bo‘ldi. Ikki algoritm orasidagi vaqt farqi quyidagicha hisoblandi:

$$\Delta T = 15.886 - 13.984 = 1.902\ s$$

Shunday qilib, ushbu Google Colab sinovida GFPGAN CodeFormerga nisbatan taxminan 1.902 soniya tezroq ishladi. CodeFormerning umumiy vaqtiga nisbatan hisoblanganda GFPGAN taxminan 12.0% kam vaqt sarfladi.

Bu yerda qayd etilgan vaqtni faqat neyron tarmoqning sof inference tezligi deb qabul qilish kerak emas. O‘lchov modelni ishga tushirish, yuzni qayta ishlash va natijani saqlash kabi umumiy amaliy jarayonlarni ham o‘z ichiga oladi. Shu sababli vaqt ko‘rsatkichi ushbu ishda asosiy sifat mezoni emas, balki algoritmlarning bir xil tajriba muhitidagi amaliy ishlash davomiyligini ko‘rsatuvchi yordamchi natija sifatida ishlatildi.

4.6. GFPGAN va CodeFormer natijalarini qiyosiy muhokama qilish

Olingan natijalar GFPGAN va CodeFormerning bir xil past sifatli yuz tasviriga turlicha, lekin bir-biriga yaqin natija berganini ko‘rsatdi. Vizual jihatdan ikkala model ham yuzning ayrim lokal detallarini aniqroq ko‘rsatdi. SSIM natijalari deyarli o‘zgarmadi, LPIPS qiymatlari esa har ikkala modelda oz miqdorda yaxshilandi.

GFPGAN ushbu tajribada ishlash tezligi bo‘yicha afzallik ko‘rsatdi. CodeFormer esa LPIPS bo‘yicha biroz pastroq, ya’ni yaxshiroq qiymat berdi. SSIM bo‘yicha CodeFormerning qiymati GFPGANnikidan juda oz yuqori bo‘lsa-da, ikki model o‘rtasidagi farq juda kichik bo‘lib qoldi. Shu sababli natijalarni “bir algoritm yaxshi, ikkinchisi yomon” tarzida soddalashtirish o‘rniga, har bir ko‘rsatkich nimani o‘lchayotganini alohida hisobga olish muhim.

Ayniqsa SSIM va LPIPS orasidagi farqli xulq e’tiborga loyiq. SSIM strukturaviy moslikka sezgir bo‘lsa, LPIPS perceptual featurelar orasidagi farqni baholaydi. Generativ tiklash natijasida yuzdagi lokal detal vizual jihatdan yaxshilanishi mumkin, lekin reference tasvirdagi struktura bilan piksel darajasida aynan mos kelmasligi ehtimoli mavjud. Shu sababli bir metrikaning o‘zgarishi boshqa metrikaning ham aynan shu yo‘nalishda o‘zgarishini talab qilmaydi.

Ushbu tajribada eng muhim natija algoritmlardan birini g‘olib deb e’lon qilish emas, balki ikki zamonaviy yuzni tiklash modelining bir xil tasvirda qanday ishlashini amaliy ko‘rish bo‘ldi. Tajriba natijalari GFPGAN va CodeFormerning yuz tasvirini vizual yaxshilashi mumkinligini, biroq bu yaxshilanishni baholashda faqat bitta metrikadan foydalanish yetarli emasligini ko‘rsatdi.

4.7. Natijalarning amaliy mazmuni

Amaliy nuqtai nazardan GFPGAN va CodeFormer past sifatli yuz tasvirlarini yaxshilash uchun foydali vositalar ekanini ko‘rsatdi. Agar vazifada tezroq qayta ishlash muhim bo‘lsa, ushbu sinovda GFPGAN qulayroq natija berdi. Agar perceptual yaqinlikdagi juda kichik farq ham hisobga olinsa, CodeFormer LPIPS bo‘yicha ozgina ustunlik ko‘rsatdi.

Biroq bunday tanlovni faqat bitta tasvir yoki bitta metrika asosida umumlashtirish to‘g‘ri bo‘lmaydi. Ushbu natijalar aynan bajarilgan amaliy sinov doirasiga tegishli. Keyingi tajribalarda turli xiralashish darajasi, past resolution, siqish artefaktlari va boshqa degradatsiya holatlaridagi ko‘proq yuz tasvirlarini sinab ko‘rish orqali ikki algoritmning xulqini kengroq baholash mumkin.

5. XULOSA

Ushbu tadqiqotda GFPGAN v1.4 va CodeFormer algoritmlarining past sifatli yuz tasvirini yaxshilashdagi amaliy natijalari qiyosiy tarzda o‘rganildi. Bir xil low-quality yuz tasviri har ikki model yordamida alohida qayta ishlandi va hosil bo‘lgan tasvirlar sifatli original reference bilan vizual, SSIM va LPIPS ko‘rsatkichlari asosida taqqoslandi. Algoritmlarning Google Colab muhitidagi umumiy ishlash vaqti ham qo‘shimcha ko‘rsatkich sifatida qayd etildi.

Vizual tahlil GFPGAN va CodeFormerning ikkala holatda ham past sifatli tasvirdagi yuz ko‘rinishini aniqroq qilganini ko‘rsatdi. Ko‘z, qosh, lab, yuz konturi va boshqa lokal qismlar boshlang‘ich low-quality tasvirga nisbatan ravshanroq ko‘rindi. Shu bilan birga, ikki algoritm orasidagi vizual farq katta bo‘lmadi va ikkala model ham o‘ziga xos tarzda yuz detallarini qayta tikladi.

SSIM bo‘yicha low-quality tasvir uchun 0.615798, GFPGAN uchun 0.614958, CodeFormer uchun 0.615080 qiymatlar olindi. Tiklashdan keyingi o‘zgarish GFPGAN uchun -0.000840, CodeFormer uchun -0.000718 ni tashkil etdi. Bu qiymatlar SSIM bo‘yicha sezilarli yaxshilanish kuzatilmaganini ko‘rsatdi. Shu natija generativ tiklashda vizual aniqlik oshishi strukturaviy o‘xshashlikning albatta oshishini anglatmasligini ko‘rsatadigan amaliy holat sifatida qaraldi.

LPIPS natijalari esa boshqa yo‘nalishni ko‘rsatdi. Low-quality tasvirning LPIPS qiymati 0.613639 bo‘lgan bo‘lsa, GFPGAN natijasida 0.608958, CodeFormer natijasida 0.608636 gacha kamaydi. Bu GFPGAN uchun taxminan 0.763%, CodeFormer uchun 0.815% perceptual yaxshilanishga to‘g‘ri keldi. CodeFormerning LPIPS qiymati GFPGANnikidan atigi 0.000322 ga past bo‘ldi. Farq juda kichik bo‘lsa-da, ushbu tajribada CodeFormer perceptual metrika bo‘yicha biroz yaxshi natija ko‘rsatdi.

Hisoblash davomiyligi bo‘yicha GFPGAN 13.984 soniya, CodeFormer 15.886 soniyada ishladi. GFPGANning umumiy bajarilish vaqti 1.902 soniyaga qisqaroq bo‘ldi. Bu ko‘rsatkich sof inference tezligini emas, tajriba davomida kuzatilgan umumiy bajarilish vaqtini ifodalaydi, shuning uchun u asosiy sifat mezoni emas, balki amaliy samaradorlikni ko‘rsatadigan yordamchi natija sifatida baholandi.

Umuman olganda, tajriba GFPGAN va CodeFormer past sifatli yuz tasvirini vizual jihatdan yaxshilash imkoniyatiga ega ekanini ko‘rsatdi. Biroq natijalar shuni ham ko‘rsatdiki, yuzni tiklash sifatini bitta ko‘rsatkich bilan baholash yetarli emas. SSIM strukturaviy o‘xshashlikni, LPIPS perceptual yaqinlikni, vizual kuzatuv esa inson ko‘zi bilan seziladigan o‘zgarishni ifodalaydi. Ushbu uch yondashuvni birgalikda ko‘rib chiqish natijani ancha to‘liq tushunish imkonini berdi.

Mazkur amaliy ish ikki algoritmning ishlash prinsiplarini nazariy jihatdan o‘rganish bilan cheklanmay, ularni real hisoblash muhitida sinab ko‘rish va natijalarini sonli ko‘rsatkichlar orqali tahlil qilish imkonini berdi. Shu jihatdan tajriba keyingi kengroq tadqiqotlar uchun boshlang‘ich asos bo‘lib xizmat qilishi mumkin. Kelgusida ko‘proq yuz tasvirlari, turli degradatsiya turlari va turli og‘irlik darajalarini qo‘llash orqali GFPGAN va CodeFormerning natijalarini kengroq statistik tahlil qilish maqsadga muvofiq.

FOYDALANILGAN ADABIYOTLAR

1. Wang X., Li Y., Zhang H., Shan Y. Towards Real-World Blind Face Restoration with Generative Facial Prior. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2021, pp. 9168–9178.
2. Zhou S., Chan K. C. K., Li C., Loy C. C. Towards Robust Blind Face Restoration with Codebook Lookup Transformer. Advances in Neural Information Processing Systems (NeurIPS), Vol. 35, 2022, pp. 30599–30611.
3. Wang Z., Bovik A. C., Sheikh H. R., Simoncelli E. P. Image Quality Assessment: From Error Visibility to Structural Similarity. IEEE Transactions on Image Processing, Vol. 13, No. 4, 2004, pp. 600–612.
4. Zhang R., Isola P., Efros A. A., Shechtman E., Wang O. The Unreasonable Effectiveness of Deep Features as a Perceptual Metric. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2018, pp. 586–595.
5. Li X., Chen C., Zhou S., Lin X., Zuo W., Zhang L. Blind Face Restoration via Deep Multi-Scale Component Dictionaries. Proceedings of the European Conference on Computer Vision (ECCV), 2020. DOI: 10.1007/978-3-030-58545-7_23.
6. Yang L., Liu C., Wang P., Wang S., Ren P., Ma S., Gao W. HiFaceGAN: Face Renovation via Collaborative Suppression and Replenishment. Proceedings of the 28th ACM International Conference on Multimedia (ACM MM), 2020, pp. 1551–1560.
7. Yang T., Ren P., Xie X., Zhang L. GAN Prior Embedded Network for Blind Face Restoration in the Wild. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2021, pp. 672–681.
8. Wang Z., Zhang J., Chen R., Wang W., Luo P. RestoreFormer: High-Quality Blind Face Restoration from Undegraded Key-Value Pairs. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2022, pp. 17512–17521.
9. Gu Y., Wang X., Xie L., Dong C., Li G., Shan Y., Cheng M.-M. VQFR: Blind Face Restoration with Vector-Quantized Dictionary and Parallel Decoder. Proceedings of the European Conference on Computer Vision (ECCV), 2022, pp. 126–143.
10. Menon S., Damian A., Hu S., Ravi N., Rudin C. PULSE: Self-Supervised Photo Upsampling via Latent Space Exploration of Generative Models. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020, pp. 2437–2445.