

PAPER

KONVOLYUTSION NEYRON TARMOQNING YUZNI ANIQLASHDAGI SAMARADORLIGI

Rustamov Ilhom Azam o'g'li^{1,*} and Jabborov Xayitmurod Ishmo'min o'g'li²

¹Muhammad Al-Xorazmiy nomidagi Toshkent axborot texnologiyalari universiteti 2-kurs magistranti and

²Muhammad Al-Xorazmiy nomidagi Toshkent axborot texnologiyalari universiteti professori

*ilhomsaep0124@gmail.com

Abstract

Ushbu maqolada yangi taklif qilingan Konvolyutsion Neyron Tarmoq (CNN) modelining samaradorligi uchta mashhur tasvirni aniqlash usullari – Asosiy Komponentlar Tahlili (PCA), Mahalliy Ikkilik Naqsh Gistogrammalari (LBPH) va K-Eng Yaqin Qoshni (KNN) bilan solishtirilib sinovdan otkazildi. Tajribalarimizda PCA, LBPH, KNN va taklif etilgan CNN usullarining umumiy aniqlash darajasi korsatib berildi. Barcha tajribalar ORL malumotlar bazasida amalga oshirildi va olingan natijalar taqdim etilib, baholandi. Ushbu yuz malumotlari bazasi 400 ta turli subyektni (40 ta sinf, har bir sinf uchun 10 ta tasvir) o'z ichiga oladi. Tajriba natijalari shuni korsatdiki, LBPH usuli PCA va KNN ga nisbatan ancha yaxshi natijalarni taminlaydi. ORL malumotlar bazasidagi ushbu tajriba natijalari taklif qilingan usulning yuzni aniqlashdagi samaradorligini isbotladi. Taklif etilgan CNN modelida biz 98,3 foizga yetgan eng yuqori aniqlash darajasini qolga kiritdik. CNN ga asoslangan ushbu yangi yondashuv zamonaviy usullardan ustun ekanligini namoyish etdi.

Key words: Yuzni aniqlash tizimi, KNN, LBPH, neyron tarmoqlari, PCA

Kirish

Yuzni aniqlash tuzilmasi [1] deganda, kompyuter tizimiga tasvirlar yoki videolarda inson yuzlarini tez va aniq topish va tanib olish qobiliyatini berish tushuniladi. Yuzni aniqlash samaradorligini oshirish uchun ko'plab algoritmlar va usullar ishlab chiqilgan. Songgi paytlarda chuqur oqitish (Deep Learning) kompyuter vision ilovalari uchun keng qollanilmoqda. Inson miyasi bir vaqtning ozida bir nechta yuzlarni avtomatik va tez aniqlab, tanib olishga qodir. Biroq, kompyuterlar uchun inson miyasining bu darajasida murakkab vazifalarni bajarish juda qiyin. Yuzni aniqlash biometriyaning ajralmas qismidir. Biometriyada insonning asosiy xususiyatlari mavjud malumotlar bilan solishtiriladi. Yuz xususiyatlari ajratib olinadi va algoritmlar orqali qollaniladi. Ushbu algoritmlar samarali bolib, mavjud modellar takomillashtirish uchun bazi o'zgartirishlar kiritiladi. Yuzlarni aniqlovchi va tanib oluvchi kompyuterlar jinoyatchilarni aniqlash, xavfsizlik tizimlari, shaxsni tasdiqlash kabi keng kolamli amaliy sohalarida qollanilishi mumkin. Yuzni aniqlash tizimi [1] odatda ikki bosqichni o'z ichiga oladi: • Yuzni topish – bu yerda kiritilgan tasvirda yuz mavjudligi qidiriladi, songra

tasvirni qayta ishlash orqali yuzni aniqlash jarayoni osonlashtiriladi. • Yuzni tanib olish – aniqlangan va qayta ishlangan yuz malumotlar bazasidagi tanish yuzlar bilan taqqoslanadi va shaxsning kimligi aniqlanadi. Yuzni topish va tanib olish ortasidagi farq shundaki, topishda tasvirda yuz borligini aniqlash kifoya, tanib olishda esa bu yuzning kimga tegishli ekanligini bilish zarur. Yuzdan olingan xususiyatlar qayta ishlanadi va malumotlar bazasidagi shunga oxshash tarzda qayta ishlangan yuzlar bilan solishtiriladi [1] va [2]. Umuman olganda, yuzni aniqlash usullari ikki guruhga bolinadi: • Yuzni tasvirlash usullari – bu usullar yuzning umumiy tekstura xususiyatlaridan foydalanadi va butun yuzga yoki yuzning muayyan qismlariga qollaniladi. • Xususiyatlarga asoslangan usullar – bu usullar yuzning geometrik elementlaridan (ogiz, ko'zlar, qoshlar va hokazo) hamda ular ortasidagi geometrik munosabatlardan foydalanadi. Ushbu maqolaning tuzilishi quyidagicha tartibga solingan: 2-bolimda yuzni aniqlash tizimi muhokama qilinadi. 3-bolimda olingan tajriba natijalari keltiriladi. Nihoyat, 4-bolim xulosa qiladi va kelgusidagi ishlar boyicha takliflar beradi.




Figure 1. Yuzni aniqlash tizimining namunasi.

Yuzni aniqlash tizimi – Zamonaviy holat

Yuzni aniqlash jarayoni ikkita tasvirlar toplami bilan boshlanadi: galereya va mos yozuvlar toplami. Galereya oldindan olingan yuz tasvirlaridan iborat. Maqsad – galereyadagi tasvirlarni berilgan sinov tasviriga (qarang: 1-rasm) oxshashligi bo'yicha tartiblashdir.

Oldindan qayta ishlash jarayonidan song, galereya tasvirlari uchun mos yozuvlarga asoslangan tavsiflovchilar galereya va mos yozuvlar to'plamidagi xususiyat vektorlari ortasidagi oxshashlikni o'lchash orqali hisoblanadi. Yuzni aniqlash algoritmlari galereya va sinov tasvirlari ortasidagi yorug'lik farqlarining katta miqdorini boshqarishi kerak. Sinov tasviri uchun mos yozuvlarga asoslangan tavsiflovchi sinov va mos yozuvlar to'plamidagi tasvirlar ortasidagi oxshashlikni hisoblash yoli bilan yaratiladi. Galereya tasvirlari sinov va galereya tasvirlarining mos yozuvlarga asoslangan tavsiflovchilari ortasidagi oxshashlik ballari asosida tartiblanadi. Galereya va sinov to'plamlari tushunchalari quyidagicha tariflanadi:

- Har bir sinov tasviri galereyadagi tasvirlar bilan moslashtiriladi va tartiblangan mosliklar aniqlash samaradorligini baholash uchun tahlil qilinadi. Bu jarayonda identifikatsiya uchun umumiy moslik bali yoki tasdiqlash ilovalari uchun qabul qiluvchining ishlash xarakteristikasi kabi korsatkichlar ishlab chiqariladi.
- Proyeksiyalar galereya va sinov to'plamidagi barcha namunalardan olinadi.
- Har bir galereya namunasi va sinov ortasidagi ballar ikkala proyeksiya ortasidagi masofa sifatida, moslashtirishdan song aniqlanadi. Qiziqarli jihati shundaki, ananaviy kompyuter vision tasvirlarni tasniflash algoritmlarining kopchiligi ushbu jarayon tartibiga rioya qiladi (qarang: 1-rasm), lekin chuqur oqitishga asoslangan algoritmlar xususiyatlarni ajratib olish bosqichini butunlay otkazib yuboradi [1], [2], [3], [4], [5], [6], [7], [8] va [9]. Bizning barcha tajribalarimizda sinov yuz tasvirlarini bashorat qilish uchun xususiyatlarni ajratib olish (PCA, LBPH) va tasniflash (KNN va taklif qilingan CNN) usullari qollanildi.

Eigenfaces yordamida yuzni aniqlash

Eigenfaces – bu inson yuzini aniqlashning kompyuter vision muammosida ishlatiladigan oziga xos vektorlar to'plamiga berilgan nom [2]. Bu usul piksellarning yorqinlik xususiyatlariga asoslanadi va yuzlar taqsimotidagi Asosiy Komponentlar Tahlili (PCA) yoki oziga xos vektorlardan foydalanadi. Bu vektorlar yuzlarning ozgaruvchanligini tavsiflovchi xususiyatlar to'plami bolib, har bir yuz tasviri har bir oziga xos vektorga malum darajada hissa qoshadi (qarang: 2-rasm). Shunday qilib, oziga xos vektor Eigenface sifatida qaralishi mumkin. Eigenfaces ozlari kovarians matritsasini yaratish uchun ishlatilgan barcha tasvirlarning asosiy to'plamini tashkil qiladi. Bu jarayon asl oquv tasvirlarini ifodalash uchun kichikroq asosiy tasvirlar to'plamidan foydalanish imkonini berib, olchamni qisqartirishni taminlaydi.

Eigenfaces [2] ni amalga oshirishning umumiy bosqichlari quyidagicha: • Avval tasvirlar to'plami ma'lumotlar bazasiga kiritiladi (bu tasvirlar oquv to'plami deb ataladi). • Keyin kiritil-




Figure 2. PCA algoritmining blok diagrammasi.

$$LBP(x, y) = \sum_{n=0}^7 2^n \cdot s(l_n(x, y) - l_c(x, y)), \quad (1)$$

Figure 3

gan yuz tasvirlarining kovarians matritsasi hisoblanadi. • Songra Eigenfaces yaratiladi. Bizning holatda, Eigenfaces tasvir ma'lumotlaridan PCA [3] yordamida ajratib olinadi. • Eigenfaces yaratilgandan song, har bir tasvir ogirlik vektori sifatida ifodalanadi (ma'lumotlar to'plamidagi barcha yuz tasvirlari Eigenfaces ning chiziqli kombinatsiyasi sifatida korsatiladi). • Nihoyat, nomalum tasvirning ogirligi aniqlanadi va tizimdagi mavjud ogirliklar bilan taqqoslanadi. Agar kiritilgan tasvirning ogirligi belgilangan chegaradan yuqori bolsa, u nomalum deb hisoblanadi. Kiritilgan tasvirni identifikatsiya qilish ma'lumotlar bazasidagi tasvirni topish orqali amalga oshiriladi, bunda topilgan tasvirning ogirliklari kiritilgan tasvirning ogirliklariga eng yaqin boladi. Tasniflash esa yuzlarning asosiy to'plam bo'yicha qanday ifodalanishini taqqoslash orqali amalga oshiriladi.

LBP yondashuvi bilan yuzni aniqlash

Gavda yordamida ximoyalanish texnikasining kinematik hususiyatlarini aniqlash; Tadqiqot natijalarini tahlil qilish va kerakli tavsilyalar ishlab chiqish. Mahalliy Ikkilik Naqshlar (LBP) tekstura tavsiflovchisi bolib, yuzlarni ifodalash uchun ham qollanilishi mumkin, chunki yuz tasviri mikro-tekstura naqshlarining birikmasi sifatida qaraladi. Qisqacha aytganda, jarayon yuz tasvirini bir nechta hududlarga bolishdan iborat bolib, unda LBP xususiyatlari ajratib olinadi va keyinchalik yuz tavsiflovchisi sifatida ishlatiladigan xususiyat vektoriga birlashtiriladi [4]. LBP dastlab umumiy tekstura tavsiflovchisi sifatida paydo bolgan. Bu operator har bir pikselga 3×3 atrofidagi qiymatlarni markaziy piksel qiymati bilan chegaralash orqali belgi (label) qoyadi va natijani ikkilik son sifatida qaraydi. Ushbu tadqiqotda ikkilik natija soat yonalishi bo'yicha, yuqori chap qoshnidan boshlab oqish orqali olingan, bu keyingi rasmda korsatilgan.

Boshqacha qilib aytganda, berilgan piksel joylashuvi (x, y) uchun LBP markaziy piksel va uning atrofidagi piksellarning yorqinlik qiymatlarini ikkilik taqqoslashlarning tartibli to'plami sifatida aniqlanadi. Natijada olingan 8-bitli sozning onlik belgi qiymati quyidagicha ifodalanadi [4] va [5]:


Bu yerda l_c markaziy pikselning (x, y) kulrang qiymatiga mos keladi, l_n esa 8 ta atrofidagi piksellarning kulrang qiymatlarini bildiradi, $s(k)$ funksiyasi esa quyidagicha aniqlanadi:

LBP operatori pikselning sakkizta qoshnisi bilan ishlaydi va bu markaziy pikselning qiymatini chegaraviy qiymat sifatida ishlatadi [6]. Agar qoshni pikselning kulrang qiymati markaziy pikselnikidan yuqori bolsa (yoki teng bolsa), u pikselga bir qiymati beriladi, aks holda nol qoyiladi. Keyin markaziy piksel uchun LBP kodi sakkizta bir yoki nolarni birlashtirib, ikkilik kod sifatida hosil qilinadi.

Oquv bosqichida (qarang: 4-rasm), yuzlar va yuz bolmagan

$$s(k) = \begin{cases} 1 & \text{if } k \geq 0, \\ 0 & \text{if else.} \end{cases}$$

Figure 4



Ikkilik: 11100001

O'nlik: 225

Figure 5. LBP hisoblash namunasi (xususiyatlarni ajratib olish).

Figure 6. LBP algoritmining blok diagrammasi.

namunalar xususiyatlar fazosini (LBP fazosi) ifodalovchi yagona oziga xos vektorlar matritsasini hosil qiladi. Keyin har bir sinf (yuzlar va yuz bolmaganlar) uchun bitta vakillik modeli tanlanadi (masalan, har bir sinfning barcha oquv namunalarining ortacha qiymati). Ushbu ikkala model ham LBP fazosiga proyeksiya qilinadi [7].

Sinov bosqichida (qarang: 4-rasm), yangi kiritilgan sinov namunasi uchun xususiyat vektori (agar berilgan bolsa) ortonormal asosga proyeksiya qilinadi. Keyin kiritilgan namunaning proyeksiya qilingan versiyasi ikkita proyeksiya qilingan model (yuzlar va yuz bolmaganlar) bilan taqqoslanadi. Eng kichik masofa kiritilgan vektorning shaklini aniqlaydi [7].

K – Eng yaqin qoshni tasniflagichi

K–Eng yaqin qoshni tasniflagichi hozirgacha mavjud bolgan eng sodda mashinaviy oqitish va tasvirlarni tasniflash algoritmidir. Bu algoritim ichida faqat xususiyat vektorlari orasidagi masofaga tayanadi. Oddiy qilib aytganda, K–NN algoritmi nomalum malumot nuqtalarini K ta eng yaqin namunalar orasidagi eng keng tarqalgan sinfni topish orqali tasniflaydi. K ta eng yaqin namunadagi har bir malumot nuqtasi ovoz beradi va eng kop ovoz toplagan toifa golib chiqadi [8].

5–rasmda korsatilganidek, qizil kvadrat tasniflanishi kerak bolgan namunani ifodalaydi. Uni kok yulduz yoki yashil uchburchak sinfiga tasniflash zarur. K ni 5 ga teng qilib qoyilganda, qizil kvadrat




Figure 7. K-NN tasniflash algoritmining asosiy diagrammasi.

Figure 8




Figure 9. Konvolyutsion neyron tarmoqlar (CNN)

yashil uchburchakka tasniflanadi, chunki uni yashil uchburchakka tasniflash ehtimoli 60 fozi ni tashkil etadi, bu esa kok yulduzga tasniflash ehtimolidan (40foiz) yuqori. K ni 10 ga teng qilib qoyilganda esa, qizil kvadrat kok yulduzga tasniflanadi, chunki bu holda kok yulduzga tasniflash ehtimoli 60 foiz bolib, yashil uchburchakka tasniflash ehtimolidan (40 foiz) yuqori. K–eng yaqin qoshni tasniflashni qollash uchun masofa olchovi yoki oxshashlik funksiyasini aniqlash kerak. Odatda ishlatiladigan variantlar orasida Evklid masofasi mavjud: Konvolyutsion neyron tarmoqlar (CNN) oddiy neyron tarmoqlarga juda oxshaydi. Ular organiladigan ogirliklar va ozgarishlarga ega neyronlardan iborat. Har bir neyron bir nechta kirish qiymatlarini qabul qiladi, nuqta kopaytmasini amalga oshiradi va ixtiyoriy ravishda chiziqsiz (non-linear) funksiyani qollaydi. Butun tarmoq hali ham bitta farqlanadigan baholash funksiyasini ifodalaydi: bir uchida xom tasvir pikselleridan boshlab, boshqa uchida sinf ballarigacha. Ular oxirgi (toliq boglangan) qatlamda yoqotish funksiyasiga (masalan, SVM/Softmax) ega bolib, oddiy neyron tarmoqlarni oqitish uchun ishlab chiqilgan barcha usullar va maslahatlar hali ham qollaniladi [10]. CNN bir nechta qatlamlardan iborat (qarang: 6–rasm va 7–rasm). Har bir qatlam kop olchovli raqamlar massivi kirish sifatida qabul qiladi va boshqa kop olchovli raqamlar massivini chiqish sifatida ishlab chiqaradi (bu keyingi qatlamning kirishiga aylanadi). Tasvirlarni tasniflashda birinchi qatlamning kirishi tasvirning ozi (32 × 32), oxirgi qatlamning chiqishi esa turli toifalarning ehtimolliklar toplami (yani, agar 10 ta toifa bolsa, 1 × 1 × 10 raqamlar) boladi. Oddiy CNN qatlamlar ketma-ketligidan iborat bolib, har bir qatlam farqlanadigan funksiya orqali faollashtirishning bir hajmini boshqasiga aylantiradi. Biz CNN arxitekturasini qurishda uchta asosiy qatlam turidan foydalandik: Konvolyutsiya (CONV) qatlami, Birlashtirish (Pooling) qatlami va Toliq boglangan qatlam (oddiy neyron tarmoqlarda korinadiganidek). Ushbu qatlamlarni bir–biriga ulab, toliq CNN arx–

Figure 10. Namunaviy CNN arxitekturasining faollashtirishlari.

Figure 11. Xususiyat xaritasidagi maksimal birlashtirish (Max Pooling) operatsiyasi (2x2 oynada).

itekturasini shakllantirdik: • INPUT [32 × 32] tasvirning xom piksel qiymatlarini saqlaydi, bu holda kengligi 32 va balandligi 32 bolgan tasvir. • CONV qatlami kirishdagi mahalliy hududlarga ulangan neyronlarning chiqishini hisoblaydi, har biri oz ogirliklari va kirish hajmidagi ulangan kichik hudud ortasida nuqta kopaytmasini amalga oshiradi. Agar 12 ta filtr ishlatishga qaror qilgan bolsak, bu [32 × 32 × 12] hajmga olib kelishi mumkin. • RELU qatlami har bir elementga faollashtirish funksiyasini qollaydi, masalan, $\max(0, x)$ noldan chegaralash funksiyasi. Bu hajm olchamini ozgartirmaydi ([32 × 32 × 12]). • POOL qatlami fazoviy olchamlar (kenglik, balandlik) boyicha pastga namuna olish (down-sampling) amalini bajaradi, natijada [16 × 16 × 12] kabi hajm hosil boladi. • FC (Toliq boglangan) qatlami sinf ballarini hisoblaydi, natijada [1 × 1 × 10] hajmli chiqish olinadi, bunda 10 ta raqamning har biri sinf baliga mos keladi. Oddiy neyron tarmoqlarda bolgani kabi va nomidan korinib turibdiki, bu qatlamdagi har bir neyron oldingi hajmdagi barcha neyronlar bilan boglanadi.

Birlashtirish (Pooling) qatlami (qarang: 8-rasm) kirish hajmining fazoviy olchamlarini mustaqil ravishda har bir chuqurlik qismida pastga namuna olish (downsampling) orqali qisqartiradi. Ushbu misolda [224 × 224 × 64] olchamdagi kirish hajmi 2 olchamli filtr va 2 qadam (stride) bilan birlashtirilib, [112 × 112 × 64] olchamdagi chiqish hajmiga aylantiriladi (qarang: 8-rasm, yuqori qism). Hajm chuqurligining saqlanib qolganiga etibor bering. Eng keng tarqalgan pastga namuna olish amali maksimumni olish bolib, bu maksimal birlashtirish (max pooling) deb ataladi (qarang: 8-rasm, pastki qism). Yani, har bir maksimum 4 ta raqam (kichik 2 × 2 kvadrat) ustidan olinadi [11]. Shu tarzda, CNN asl tasvirni qatlam-qatlam ozgartirib, dastlabki piksel qiymatlaridan oxirgi sinf ballarigacha yetib boradi. Etibor bering, bazi qatlamlar parametrlarni oz ichiga oladi, boshqalari esa yoq. Xususan, CONV/FC qatamlari nafaqat kirish hajmidagi faollashtirishlarga, balki parametrlarga (neyronlarning ogirliklari va ozgarishlariga) bogliq bolgan ozgarishlarni amalga oshiradi. Boshqa tomondan, RELU/POOL qatamlari esa qat'iy belgilangan funksiyani bajaradi [10], [11] va [12].

CONV/FC qatamlaridagi parametrlar gradient tushishi usuli bilan oqitildi, shunda CNN tomonidan hisoblangan sinf ballari har bir tasvir uchun oquv toplanidagi yoriqlar bilan mos keladi [12]. CNN arxitekturasini eng sodda holatda tasvir hajmini chiqish hajmiga (masalan, sinf ballarini saqlovchi) aylantiruvchi qatlamlar royxatidir [12]: • Bir nechta oziga xos qatlam turlari mavjud (masalan, CONV/FC/RELU/POOL eng mashhur hisoblanadi). • Har bir qatlam 3D kirish hajmini qabul qiladi va uni farqlanadigan funksiya orqali 3D chiqish hajmiga ozgartiradi. • Har bir qatlam parametrlarga ega bolishi mumkin (CONV/FC) yoki bolmasligi mumkin (RELU/POOL). • Har bir qatlam qoshimcha giperparametrlarga ega bolishi mumkin (CONV/FC/POOL) yoki bolmasligi mumkin (RELU). Birinchi qatlam asosiy chekkalarni aniqlaydi. Ikkinchi qatlam oldingi qatlamlardan xususiyatlarni aniqlaydi va shuning uchun koz, burun yoki ogiz kabi murakkabroq shakllarni sezishi mumkin. Uchinchi va oxirgi qatlam esa butun yuzlarni aniqlay oladi.

Tajribalar va natijalar

Ushbu bolimda biz taklif qilingan usulning samaradorligini ORL yuz malumotlar bazasida baholaymiz. Barcha tajribalarimizda tasvirlar inson kozlarining joylashuviga asoslangan holda tekislangan va normallashtirilgan. Sinovdan otkazilgan barcha



Figure 12. Xususiyat xaritasidagi maksimal birlashtirish (Max Pooling) operatsiyasi (2x2 oynada).

Qatlam	Turi	Xususiyatlar
Qatlam 1	Kirish	32×32
Qatlam 2	Konvolyutsion	16 xususiyat xaritalari 3×3 yadro o'Ichami
Qatlam 3	Birlashtirish	ehtimollik 0.25
Qatlam 4	Konvolyutsion	16 xususiyat xaritalari 2×2 yadro o'Ichami
Qatlam 5	Birlashtirish	ehtimollik 0.25
Qatlam 6	To'liq bog'langan	3000 neyronlar
Qatlam 7	To'liq bog'langan (Softmax)	40 neyronlar (sinfklar)

Figure 13. XCNN qatlamlari.

usullar (PCA, LBPH, KNN va taklif qilingan CNN) MATLAB hamda C++/Python dasturlash tillarida amalga oshirildi. ORL yuzlar malumotlar bazasi (qarang: 10-rasm) 40 ta turli subyektning har biritdan onta tasvirni oz ichiga oladi (jami 400 ta turli tasvir). Bazi subyektlar uchun tasvirlar turli vaqtlarda va ozgaruvchan yoruglik sharoitida olingan [13]. Ushbu malumotlar bazasida tasvirlarning (yuzlarning) turli kayfiyatlarini, masalan, ochiq va yopiq kozlar, kulgi yoki kulgisiz, soqolli yoki soqolsiz, kozoynakli yoki kozoy-naksiz kabi boshqa tafsilotlar bilan birga taqdim etilgan. Barcha tasvirlar qorong'i bir xil fonda, subyektlar tik, old holatda (bazi yon harakatlarga ruxsat berilgan holda) olingan. Odamlarni peshonasi va sochlari tegishli tasvirlarda korinadi. Yuzning kameraga qarash burchagi yuqoridan pastga va chapdan onga ozgaradi. Barcha rasmlar 112×92 piksel olchamdagi qora-oq tasvirlar bolib, PGM formatida saqlanadi.

Oquv malumotlar bazasidan olingan kirish tasvirlariga misol 10-rasmda korsatilgan. Barcha sinovdan otkazilgan usullar tasvirni aniqlash jarayonining asosiy sxemasiga amal qiladi (1-rasmga qarang). Oquv tasvirlari va sinov tasvirlari vektor shaklida ozgartirilib saqlanadi. Ushbu oquv va sinov malumotlari butun yuzlar bazasini tashkil qiladi (10-rasmga qarang). Yuzni aniqlash algoritmining aniqligini sinov tasvirlari va barcha oquv tasvirlari orasidagi masofani aniqlash uchun Evklid masofasi ishlatilgan.

Taklif etilgan CNN (1-jadval va 11-rasmga qarang) samaradorligini baholash uchun yuzni aniqlash darajasini 3 taniqli algoritm (PCA, LBPH va KNN) bilan solishtirdik. Tizim oquv malumotlari yordamida oqitilgandan song, PCA orqali "Eigenfaces" deb ataladigan xususiyatlar fazosi topiladi. Eigenfacesdan farqli olarak, Mahalliy Ikkilik Naqshlar Gistogrammasi (LBPH) obektning mahalliy xususiyatlarini ajratib oladi va 2D tekstura tahliliga asoslanadi. Yuzni aniqlash modelida fazoviy malumotlarni integratsiya qilish kerak. Keyin, fazoviy jihatdan yaxshilangan xususiyat vektorini gistogrammalarni birlashtirish emas, balki ulash orqali olinadi. Tajribalarimizda KNN klassifikatori ikkita malumot turidan foydalangan.




Figure 14. Taklif etilgan CNNning blok diagrammasi.

Klassifikatsiya modelini yaratish uchun oquv malumotlari ishlatilgan. Oqitilgan modelning aniqligini sinash va baholash uchun esa sinov malumotlaridan foydalanilgan.

Konvolyutsion Neiron Tarmogi (CNN) taklifi 11-rasmda korsatilgan. Kirish tasviri 1024 pikseldan (32×32) iborat. Konvolyutsion qatlamdan keyin Pooling qatlami keladi. Har bir qatlam 3D-kirish hajmini, yani xususiyatlar xaritasini oladi va uni konvolyutsiyalar va no-chiziqlik yordamida boshqa shaklga o'zgartiradi. Qatlamlarni ustma-ust joylashtirish va ularning chiqishlarini pastga olchash orqali CNNlar murakkab va mavhum xususiyatlar xaritalarini ajratib oladi, ular bir vaqtning o'zida buzilishlar va siljishlarga nisbatan ozgaruvchan boladi. CNNning songgi qatlamlari standart toliq ulangan qatlamlardir. Ushbu qatlamlar kirish tasvirlarining yakuniy deskriptorlarini hisoblab chiqadi, ular tasvirlarning global ifodalari sifatida qaralishi mumkin yoki ular kirish tasvirlarini maqsad funksiyasiga qarab sinflarga ajratadi.

CNN kirish tasvirini dastlabki piksel qiymatlaridan yakuniy sinf ballariga qatlam-qatlam uzatish orqali o'zgartiradigan qatlamlardan (1-jadvalga qarang) tashkil topgan feedforward tarmoqdur. Taklif etilgan CNN manba kirish malumotlari qatlamidan tashqari 2 ta konvolyutsion qatlam, toliq ulangan qatlamlar, ReLU qatlamlari va 2 ta ustma-ust tushadigan pooling qatlamlarini oz ichiga oladi. Har bir qatlam koplak xususiyatlar xaritalariga ega. Har bir xususiyatlar xaritasi konvolyutsiya filtri orqali tanlangan bir xususiyatni ajratib olishi mumkin va bir nechta neyronlarni oz ichiga oladi. Malumotlar qatlami oldindan qayta ishlangan tasvirni oz ichiga oladi. Ushbu konvolyutsion tarmoq 8 ta blokka bolingan:

A) Kirish malumotlari sifatida ORL malumotlar toplamidagi yuzlar ishlatilgan. Hisoblash vaqtini yaxshilash uchun har bir yuz tasviri 32×32 piksel olchamiga qayta olchamlangan.

B) Ikkinchi blok 16 ta xususiyatlar xaritasiga ega bolgan 2D CNN qatlami bolib, yadro olchami 3×3 . Kichik malumotlar toplami tufayli L2 regulyarisatsiyasi qollangan. Aktivatsiya funktsiyasi sifatida Togri chiziqli birlik (ReLU) ishlatilgan. Bu butun tarmoqning noyob xususiyatlarini yaxshiladi va neyronlar orasida parametrlarni uzatishga bogliqligini oldini oladi.

C) MaxPooling qatlamlari uchun 2×2 olchamli yadro ishlatilgan va chiqish 0,25 ehtimollik bilan tushirib qoldirilgan (dropout). Pastga olchash qatlami max-pooling usulidan foydalangan, bu foydali malumotlarni saqlab qolgan va yuqori darajada qayta ishlanishi kerak bolgan malumotlar hajmini qisqartirgan.

D) Ikkinchi 2D CNN birinchi qatlam bilan bir xil parametrlar bilan ishlatilgan, ammo xususiyatlar xaritalari soni ikki baravar oshirilib, 32 taga yetkazilgan.

E) Yana MaxPooling qatlami va C blokidagi kabi bir xil qiymatda Dropout qatlami qollangan.

F) Keyingi qatlam sifatida standart zich qatlam (dense layer) ishlatilgan, unda 3000 ta neyron mavjud bolib, aktivatsiya funktsiyasi sifatida yana ReLU qollangan. Ogirliklarni yaxshiroq boshqarish uchun L2 regulyarisatsiyasi yana qollangan.

G) Oxirgi dropout qatlamining chiqishi Softmax yoqotish qatlamiga uzatilgan.

H) Yakuniy chiqish 40 ta turli sinfga nisbatan tasniflangan taqsimot bolib, Softmax aktivatsiya funktsiyasi ishlatilgan. Oquv jaray-

Figure 15. Taklif etilgan CNN orqali oquv jarayoni.

	O'qitish va sinov tasvirlari soni			
	A	B	C	D
PCA (%)	75.2	77.5	82.1	85.6
LBPH (%)	78.1	81.3	86.7	88.9
KNN (%)	71.4	73.8	79.2	81.4
Taklif qilingan CNN (%)	93.9	95.7	97.5	98.3

Figure 16. Turli miqdordagi oquv tasvirlari uchun umumiy yuzni aniqlash darajasi.

onini tekshirish uchun chiqish qatlami sifatida Softmax regres-siyasi qollangan.

Xususiyatlarni ajratish uchun biz oxirgi toliq ulangan qatlam (FC layer) chiqishi sifatida ishlatdik. Tajribalarimizda taklif etilgan CNNning ikkinchi konvolyutsion qatlamlarining aktivatsiya qiymatlarini vizuallashtirdik, ular 12-rasmda korsatilgan. Taklif etilgan CNNda (11-rasmga qarang) pooling operatsiyasi orqali malumotlar siqiladi va muhim xususiyatlar saqlanadi. Ushbu tuzilma orqali CNN yuz tasvirlaridan murakkab xususiyatlarni organadi va ularni aniq sinflarga ajratish imkoniyatiga ega boladi.

Masalan, tasvirni tasniflashda CNN birinchi qatlamda xom piksellardan chetlar (edges) aniqlashni organishi mumkin, ikkinchi qatlamda esa bu chetlardan foydalanib oddiy shakllarni (masalan, chiziqlar yoki burchaklar) aniqlashi mumkin. Keyinchalik, yuqori qatlamlarda bu shakllardan foydalanib yanada murakkab va yuqori darajadagi xususiyatlarni, masalan, yuz shakllari yoki ifodalarni aniqlashi mumkin. Bu jarayon quyidagicha amalga oshiriladi: 1. Birinchi qatlam (Chetlarni aniqlash): o CNN birinchi konvolyutsion qatlamda tasvirdagi chetlar (masalan, yorqinlik o'zgarishi joylari) kabi asosiy xususiyatlarni ajratib oladi. o Bu qatlam tasvirning eng oddiy tuzilmalarini aniqlaydi. 2. Ikkinchi qatlam (Oddiy shakllarni aniqlash): o Birinchi qatlamda aniqlangan chetlar yordamida ikkinchi qatlamda chiziqlar, doiralar, uchburchaklar kabi oddiy shakllar aniqlanadi. o Bu qatlam tasvirning murakkabroq, ammo hali ham nisbatan oddiy tuzilmalarini korsatadi. 3. Yuqori qatlamlar (Murakkab xususiyatlarni aniqlash): o Yuqori qatlamlarda oddiy shakllar yordamida yuz shakllari, ko'zlar, burun kibi murakkab xususiyatlar aniqlanadi. o Bu qatlamlar tasvirning eng muhim va murakkab jihatlarini ifodalaydi. 4. Yakuniy qatlam (Tasniflash): o Oxirgi qatlamlarda yuqori darajadagi xususiyatlar asosida tasvir malum bir sinfga (masalan, yuzning kimga tegishli ekanligi) tasniflanadi. Bu jarayon orqali CNN bosqichma-bosqich murakkab xususiyatlarni organadi va ularni tasniflash uchun ishlatadi. Bu esa tasvirni aniqlash va tushunishda yuqori aniqlik va samaradorlikni taminlaydi.

Ushbu bolimda olingan eksperimental natijalar taqdim etilgan. 3-jadvalning birinchi qatori PCA algoritmi yordamida yuzni aniqlash aniqligini korsatadi. Keyingi qator (3-jadvalga qarang) LBPH algoritmining umumiy aniqligini korsatadi. Uchinchi qator KNN algoritmining umumiy aniqligini tavsiflaydi. 3-jadvalning oxirgi qatori taklif etilgan CNNning eksperimental natijalarini (umumiy aniqligini) korsatadi.

Xulosa

Ushbu ishda taklif etilgan CNNning ishlashini eksperimental baholash taqdim etilgan. Umumiy natijalar turli miqdordagi oquv va sinov tasvirlari yordamida olingan. Konvolyutsion neyron tarmoqlari hozirgacha eng yaxshi natijalarni korsatadi. Murakkab arxitekturalardan foydalangan holda taxminan 98% aniqlik darajasiga erishish mumkin. Shu bilan birga, CNNlar salbiy tasirlarsiz ishlay olmaydi. Juda katta oquv malumotlari toplami yuqori hisoblash

yuki va xotira sarflashga olib keladi, bu esa yuqori qayta ishlash quvvatini talab qiladi. Bizning holatda, sinovdan otkazilgan eng katta yuzlar malumotlar toplami 384×286 piksel olchamidagi 1521 ta kulrang tasvirdan iborat (BioID Yuzlar Malumotlar Bazasi) [14]. Ushbu malumotlar bazasi 23 ta turli sinov tasvirini (shaxslarni) o'z ichiga oladi. Ushbu malumotlar bazasi asosida olingan eksperimental natijalar keyingi ishimizda elon qilinadi. Yaxshiroq va tezroq apparat vositalarining rivojlanishi tufayli katta miqdordagi parametrlar bilan ishlash endi muammo emas. Korinib turibdiki, har bir obekt algoritmi turli afzalliklar va kamchiliklarga ega. Shuning uchun ham toliq va mazmunli reytingni yaratish deyarli mumkin emas, chunki juda kop turli omillar va sharoitlar mavjud.

References

1. MEENA, D. and R. SHARAN. An approach to face detection and recognition. In: International Conference on Recent Advances and Innovations in Engineering (ICRAIE). Jaipur:IEEE, 2016, pp. 1–6. ISBN 978-1-5090-2807-8. DOI:10.1109/ICRAIE.2016.7939462.
2. REKHA, E. and P. RAMAPRASAD. An efficient automated attendance management system based on Eigen Face recognition. In: 7th International Conference on Cloud Computing, Data Science Engineering – Confluence. Noida:IEEE, 2017, pp. 605–608. ISBN 978-1-5090-3519-9. DOI:10.1109/CONFLUENCE.2017.7943223.
3. ABUROMMAN, A. A. and M. B. I. REAZ. Ensemble SVM classifiers based on PCA and LDA for IDS. In: International Conference on Advances in Electrical, Electronic and Systems Engineering (ICAEEES). Putrajaya: IEEE, 2016, pp. 95–99. ISBN 978-1-5090-2889-4. DOI: 10.1109/ICAEEES.2016.7888016.
4. OLIVARES-MERCADO, J., K. TOSCANOMEDINA, G. SANCHEZ-PEREZ, H. PEREZMEANA and M. NAKANO-MIYATAKE. Face recognition system for smartphone based on LBP. In: 5th International Workshop on Biometrics and Forensics (IWBF). Coventry: IEEE, 2017, pp. 1–6. ISBN 978-1-5090-5791-7. DOI: 10.1109/IWBF.2017.7935111.
5. KAMENCAY, P., T. TRNOVSZKY, M. BENCO, R. HUDEC, P. SYKORA and A. SATNIK. Accurate wild animal recognition using PCA, LDA and LBPH. In: ELEKTRO. Strbske Pleso: IEEE, 2016, pp. 62–67. ISBN 978-1-4673-8698-2. DOI: 10.1109/ELEKTRO.2016.7512036.
6. AMEUR, B., S. MASMOUDI, A. G. DERBEL and A. BEN HAMIDA. Fusing Gabor and LBP feature sets for KNN and SRC-based face recognition. In: International Conference on Advanced Technologies for Signal and Image Processing (ATSIP). Monastir: IEEE, 2016, pp. 453–458. ISBN 978-1-4673-8526-8. DOI: 10.1109/ATSIP.2016.7523134.
7. STEKAS, N. and D. HEUVEL. Face Recognition Using Local Binary Patterns Histograms (LBPH) on an FPGA-Based System on Chip (SoC). In: IEEE International Parallel and Distributed Processing Symposium Workshops (IPDPSW). Chicago: IEEE, 2016, pp. 300–304. ISBN 978-1-5090-3682-0. DOI: 10.1109/IPDPSW.2016.67.
8. WANG, Q., K. JIA and P. LIU. Design and Implementation of Remote Facial Expression Recognition Surveillance System Based on PCA and KNN Algorithms. In: International Conference on Intelligent Information Hiding and Multimedia Signal Processing (IIH-MSP). Adelaide: IEEE, 2015, pp. 314–317. ISBN 978-1-5090-0188-0. DOI: 10.1109/IIH-MSP.2015.54.
9. NUGRAHAENI, R. A. and K. MUTIJARSA. Comparative analysis of machine learning KNN, SVM, and random forests algorithm for facial expression classification. In: International Seminar on Application for Technology of Information and Communication (ISEmantic). Semarang: IEEE, 2016, pp. 163–168. ISBN 978-1-5090-2326-4. DOI: 10.1109/ISEMANTIC.2016.7873831.
10. BRITZ, D. Understanding convolutional neural networks. In: WILDML [Online]. 2015. Available at: <http://www.wildml.com/2015/11/understanding-convolutional-neural-networks-for-nlp/>.
11. TOBIAS, L., A. DUCOURNAU, F. ROUSSEAU, G. MERCIER and R. FABLET. Convolutional Neural Networks for object recognition on mobile devices: A case study. In: 23rd International Conference on Pattern Recognition (ICPR). Cancun: IEEE, 2016, pp. 3530–3535. ISBN 978-1-5090-4847-2. DOI: 10.1109/ICPR.2016.7900181.
12. GUO, S., S. CHEN and Y. LI. Face recognition based on convolutional neural network and support vector machine. In: IEEE International Conference on Information and Automation (ICIA). Ningbo: IEEE, 2016, pp. 1787–1792. ISBN 978-1-5090-4102-2. DOI: 10.1109/ICInfA.2016.7832107. Database of Faces (ORL Face Database). In: ATT Laboratories Cambridge [Online]. 2002. Available at: <http://www.cl.cam.ac.uk/research/dtg/attarchive/face-database.html>.