

CHUQUR O'QITISHNING TASVIRLARNI TAHLIL QILISH VA KOMPYUTERLI KO'RISH SOHASIDAGI SHOVQINDAN TOZALASH MODELI

Topvoldiyeva H. X.

Farg'ona davlat universiteti, Farg'ona, O'zbekiston

Annotatsiya: *Ushbu maqolada chuqur o'qitish (deep learning) texnologiyalarining tasvirlarni tahlil qilish va shovqindan tozalashdagi roli yoritilgan. Asosiy e'tibor Denoising Autoencoder, Denoising konvolyutsion neyron tarmoqlar va diffusion model kabi ilg'or yondashuvlarga qaratilgan. Ushbu modellar yordamida shovqinli tasvirlardan asl tasvirni tiklash, ayniqsa tibbiy diagnostika, sun'iy yo'ldosh tasvirlarini tahlil qilish, biometrik tizimlar va arxiv suratlarini restavratsiya qilishda yuqori samaradorlikka erishish mumkin. Maqolada, shuningdek, modelning ishlash prinsipi, o'qitish jarayoni, yo'qotish funksiyasi va matematik asoslangan teoremlar orqali model samaradorligi nazariy jihatdan isbotlangan. Tadqiqot natijalari chuqur o'qitishning tasvir tiklashdagi keng imkoniyatlarini ochib beradi va amaliy sohalarda qo'llanishini asoslab beradi.*

Kalit so'zlar: *Chuqur o'qitish, tasvirlarni tahlil qilish, shovqindan tozalash, Denoising Autoencoder, konvolyutsion neyron tarmoq, diffusion model, tasvir tiklash, yo'qotish funksiyasi, kompyuterli ko'rish, sun'iy intellekt*

Chuqur o'qitish (Deep Learning) so'nggi yillarda tasvirlarni tahlil qilish va kompyuterli ko'rish sohalarida keng qo'llanilmoqda. Bu sohalarda matematik metodlar va modellar yordamida tasvirlarning o'ziga xos xususiyatlari aniqlanadi, shovqindan tozalanadi, ob'ektlar tanib olinadi, va boshqa ko'plab vazifalar amalga oshiriladi. Chuqur o'qitish esa tasvirlarni tahlil qilishda an'anaviy metodlar bilan solishtirganda yuqori samaradorlikni ta'minlaydi. Biz maqolada chuqur o'qitishning tasvirlarni tahlil qilinadi.

Shovqindan tozalash modeli. Shovqindan tozalash masalasi tasvirdagi kerakmas tasodifiy ma'lumotlarni yo'qotib, foydali tuzilmani saqlab qolishga qaratilgan. Chuqur o'qitish bu jarayonni yanada aniqlik bilan bajarishga imkon beradi. Eng ko'p qo'llaniladigan model bu Denoising Autoencoder hisoblanadi. Bu model shovqinli kirish tasvirini toza chiqishga o'rgatilgan. Neyron tarmoq vaqt o'tishi bilan qaysi elementlar shovqin va qaysilari foydali signal ekanligini farqlashni o'rganadi.

Bundan tashqari Denoising Konvolyutsion neyron tarmoqlar modeli klassik Konvolyutsion neyron tarmoqlar arxitekturasida asosida tuzilgan bo'lib, har xil turdagi shovqinlar bilan ishlashga moslashtirilgan. Ushbu model qatlamlar orqali tasvir

xususiyatlarini chuqur o'rganib chiqib natijada shovqindan tozalangan versiyani hosil qiladi.

Yana bir zamonaviy yondashuv bu diffusion models hisoblanadi. Ushbu modellar tasvirni shovqinli holatdan asta sekinlik bilan toza holatga aylantirish orqali ishlaydi. Bu yondashuvlar orqali eng murakkab shovqin turlarini ham samarali tarzda bartaraf etish mumkin.

Chuqur o'qitish asosidagi tiklash va tozalash texnologiyalari quyidagi sohalarda keng qo'llaniladi:

Tibbiy tasvirlarni aniqlashtirish- masalan MRI yoki rentgen suratlaridagi noaniqliklarni yo'qotish. Sun'iy yo'ldosh tasvirlarini tiklash va tafsilotlarni yaxshilash. Yuzni aniqlash va biometrik xavfsizlik tizimlarida yomon sifatlarga ega suratlarni qayta ishlash. Raqamli restavratsiya ya'ni eski arxiv suratlarini tiklash.

Shovqinli tasvirlardan asl tasvirni tiklash masalasi quyidagicha ifodalanadi. Agar bizda Y shovqinli tasvir bo'lsa, u holda biz bu tasvirni tiklash uchun chuqur o'qitish modelidan foydalanamiz, ya'ni haqiqiy tasvir X ni tiklashga harakat qilamiz. Masalani yechish uchun modelni o'qitish jarayonida yo'qotish funksiyasini hisoblash kerak bo'ladi. Tiklangan tasvirni $X_{decoded}$ deb belgilaymiz. Shovqinli tasvirdan tiklangan tasvirning modeli

$$X_{decoded} = M(Y)$$

ko'rinishda bo'ladi, bu yerda

M - model,

Y - shovqinli tasvir (input),

$X_{decoded}$ - tiklangan tasvir (output).

Ushbu modelning maqsadi Y tasviridan $X_{decoded}$ ni tiklashdir.

O'qitish jarayonida modelni optimallashtirish uchun loss functionni ishlatamiz. Shovqinli tasvirdan tiklangan tasvir va haqiqiy tasvir orasidagi xatolikni minimalizatsiya qilish kerak. Odatda, o'rtacha kvadrat xato funksiyasi ishlatiladi, u quyidagi tarzda ifodalanadi:

$$L = \frac{1}{N} \sum_{i=1}^N (X_i - X_{decoded,i})^2,$$

bu yerda,

N - tasvirdagi piksel soni;

X_i - haqiqiy tasvirning i -chi pikseli;

$X_{decoded,i}$ - tiklangan tasvirning i -chi pikseli.

Modelni o'qitish jarayonida bir nechta optimallashtirish algoritmlaridan foydalanish mumkin bo'ladi. Modelni o'qitishda shovqinli tasvir Y va haqiqiy tasvir X birgalikda modelga taqdim etiladi. Model shovqinli tasvirdan haqiqiy tasvirni tiklashga harakat qiladi. O'qitish jarayonida loss function minimalizatsiya qilinadi va modelning chiqishi $X_{decoded}$ haqiqiy tasvirga yaqinlashadi. O'qitish jarayonida shovqinli Y tasvir va model tomonidan tiklangan $X_{decoded}$ tasvirni taqqoslash orqali modelning samaradorligini baholaymiz.

Natijalar quyidagicha bo'ladi:

Shovqinli tasvir Y - modelga kirish sifatida taqdim etiladi, tiklangan tasvir $X_{decoded}$ - model tomonidan qayta tiklanadi, haqiqiy tasvir X - asl tasvir olinadi.

1-teorema. Agar modelni o'rgatishda Y tasvirini X tasviriga yaqinlashtirishga intilsa, modelda o'rnatilgan parametrlar M orqali $X_{decoded} \approx X$, ya'ni yo'qotish funksiyasini minimallashtirish orqali $X_{decoded}$ tasvirining X tasviriga maksimal darajada yaqinlashishi ta'minlansa, unda model yordamida shovqinli tasvirda asl tasvirni tiklash mumkin.

Isbot: Bizda Y shovqinli tasvir mavjud va uni tiklash uchun model $X_{decoded} = M(Y)$ yordamida X tasvirini tiklaymiz. Shovqinli tasvirdan asl tasvirni tiklash uchun modelni o'rgatish jarayonida yo'qotish funksiyasi minimallashtiriladi. Yo'qotish funksiyasi quyidagicha ifodalanadi:

$$L(Y, X_{decoded}) = \frac{1}{N} \sum_{i=1}^N (X_i - X_{decoded,i})^2$$

Model parametrlarini o'rnatishda yo'qotish funksiyasini minimallashtirib, $X_{decoded}$ tasvirini X tasviriga maksimal darajada yaqinlashtiramiz. Bu jarayonni optimallashtirish algoritmi yordamida amalga oshiramiz. Yo'qotish funksiyasining gradienti:

$$\frac{\partial L}{\partial \theta} = \frac{2}{N} \sum_{i=1}^N (X_{decoded,i} - X_i) \frac{\partial X_{decoded,i}}{\partial \theta}$$

Model parametrlarini optimallashtirgan holda, $X_{decoded} \approx X$ bo'ladi, ya'ni model Y shovqinli tasviridan X asl tasvirni tiklashga erishadi.

2-teorema: Agar M chuqur o'qitish modeli shovqinli tasvirni Y ning tenglama shaklida tiklashni o'rnatgan bo'lsa, ya'ni $X_{decoded} = M(Y)$, va model parametrlarini o'qitishda yo'qotish funksiyasini quyidagicha minimallashtirsa:

$$\min_M L(Y, X_{decoded}) = \frac{1}{N} \sum_{i=1}^N (X_i - X_{decoded,i})^2$$

unda model Y shovqinli tasvirdan X asl tasvirini tiklash uchun optimal parametrlar to'plamini topadi.

Isbot. Shovqinli tasvirdan asl tasvirni tiklash masalasini matematik jihatdan isbotlash uchun biz quyidagi yo'qotish funksiyasi minimallashtirishga asoslanamiz. Agar Y shovqinli tasvir bo'lsa va X asl tasvir bo'lsa, shovqinli tasvirdan asl tasvirni tiklash uchun M chuqur o'qitish modelini ishlatamiz. Model quyidagicha ifodalanadi:

$$X_{decoded} = M(Y)$$

Tiklangan tasvirni $X_{decoded}$ deb belgilaymiz va yo'qotish funksiyasini minimallashtirish uchun Model Conv2D qatlamida ishlashi uchun o'lchamga [28,28,1] (1 kanal – kulrang) formatiga o'tkaziladi.

hun quyidagi ifodadan foydalanamiz:

$$L = \frac{1}{N} \sum_{i=1}^N (X_i - X_{decoded,i})^2$$

ADABIYOTLAR

1. **Shuicheng Yan, Zhiwei Luo, Yingli Tian** "Deep Learning for Computer Vision: A Brief Review"(2016)
2. **Zhang, K., Zuo, W., Zhang, L. (2017).** Learning Deep CNN Denoiser Prior for Image Restoration. IEEE Transactions on Image Processing, 26(7), 3142-3155.
3. **Shuicheng Yan, Shunqing Li, Yingli Tian** "Deep Learning for Image Understanding"(2018)
4. **Chakrabarti, A., Zoran, D. (2016).** A Comparative Study of Image Denoising Methods. ACM Computing Surveys (CSUR), 48(4), 1-24.