



REAL VAQT REJIMIDA VIDEOMA'LUMOTLARNI TIKLASH VA SIFATINI OSHIRISH UCHUN CHUQUR O'RGANISH METODLARI

R.D.Nortoyeva¹

¹ O'zbekiston jurnalistika va ommaviy kommunikatsiyalar universiteti,

Toshkent, O'zbekiston

E-mail: oripjonovadurdona@gmail.com,

ORCID-0009-0007-2586-6379

Annotatsiya. Ushbu maqolada real vaqt rejimida videoma'lumotlarni tiklash va sifatini oshirish masalalari hamda ularni hal etishda chuqur o'rganish metodlaridan foydalanish imkoniyatlari tahlil qilinadi. Video oqimlarda uchraydigan shovqin, past aniqlik, harakatdagi xiralashuv va siqish artefaktlari kabi muammolarni bartaraf etishda konvolyutsion neyron tarmoqlar (CNN), rekurrent neyron tarmoqlar (RNN), generativ qarama-qarshi tarmoqlar (GAN) va transformer arxitekturalariga asoslangan yondashuvlar ko'rib chiqiladi. Shuningdek, real vaqt talablarini qondirish uchun hisoblash murakkabligini kamaytirish va optimallashtirish masalalariga alohida e'tibor qaratiladi.

Kalit so'zlar: real vaqt video, chuqur o'rganish, CNN, GAN, video tiklash, super-resolution, shovqinni kamaytirish.

Аннотация. В данной статье рассматриваются вопросы восстановления и повышения качества видеоданных в режиме реального времени, а также возможности применения методов глубокого обучения для их решения. Проанализированы подходы, основанные на сверточных нейронных сетях (CNN), рекуррентных нейронных сетях (RNN), генеративно-сопоставительных сетях (GAN) и архитектурах трансформеров, предназначенных для устранения шумов, повышения разрешения, компенсации размытия движения и подавления артефактов сжатия в видеопотоках. Особое внимание уделяется вопросам оптимизации вычислительной сложности и снижению задержек с целью обеспечения требований реального времени.

Ключевые слова. Видео в реальном времени, глубокое обучение, сверточные нейронные сети, генеративно-сопоставительные сети, восстановление видео, повышение качества изображения, супер-разрешение, подавление шума

Abstract. This article examines the problems of real-time video data restoration and quality enhancement, as well as the potential of deep learning methods for addressing these challenges. Approaches based on Convolutional Neural Networks (CNNs), Recurrent Neural Networks (RNNs), Generative Adversarial Networks (GANs), and transformer-based architectures are analyzed for noise reduction, resolution enhancement, motion blur compensation, and compression artifact removal in video streams. Special attention is paid to computational complexity optimization and latency reduction to meet real-time processing requirements.





Keywords. Real-time video, deep learning, convolutional neural networks, generative adversarial networks, video restoration, image quality enhancement, super-resolution, noise reduction

Kirish. So'nggi yillarda raqamli video texnologiyalarining jadal rivojlanishi natijasida video ma'lumotlar hajmi keskin ortdi va ularni real vaqt rejimida qayta ishlash dolzarb masalaga aylandi. Televideniye, video kuzatuv tizimlari, videokonferensiyalar, tibbiy tasvirlash va multimedia ilovalari video sifatining yuqori bo'lishini talab etadi. Biroq real sharoitlarda video oqimlar ko'pincha shovqinli, past aniqlikda yoki siqish natijasida sifat yo'qotilgan holatda bo'ladi. Video tasvir sifatini yaxshilash masalalari chuqur o'rganish metodlari asosida faol tadqiq etilmoqda. Xususan, konvolyutsion neyron tarmoqlar, generativ qarama-qarshi tarmoqlar va vaqtli neyron modellar video shovqinini kamaytirish, aniqlikni oshirish va artefaktlarni bartaraf etishda yuqori samaradorlikni namoyon etmoqda [1–5]. An'anaviy signalni qayta ishlash usullari (filtrlash, interpolatsiya, adaptiv tekislash) murakkab va dinamik sahnalarda yetarli natija bermaydi. Shu sababli, so'nggi yillarda chuqur o'rganishga asoslangan metodlar video ma'lumotlarni tiklash va sifatini oshirishning samarali vositasi sifatida keng qo'llanilmoqda.

Video ma'lumotlarda uchraydigan asosiy muammolar. Real vaqt video oqimlarida quyidagi asosiy muammolar kuzatiladi:

- **Shovqin (noise):** kam yorug'lik yoki past sifatli sensorlar natijasida yuzaga keladi.
- **Past aniqlik (low resolution):** uzatish kanallari cheklanganligi sababli.
- **Harakat xiralashuvi (motion blur):** tez harakatlanuvchi obyektlar mavjud bo'lganda.
- **Siqish artefaktlari:** video kodeklar (H.264, H.265) natijasida paydo bo'ladi.

Mazkur muammolarni real vaqt rejimida bartaraf etish yuqori hisoblash samaradorligini talab qiladi.

Chuqur o'rganish metodlari. Chuqur o'rganish - ko'p qatlamli neyron tarmoqlarga asoslangan mashinaviy o'rganish yo'nalishi bo'lib, murakkab tasviriy va fazoviy- vaqtli bog'lanishlarni avtomatik o'rganish imkonini beradi. Video qayta ishlashda chuqur o'rganishning asosiy afzalligi - qo'lda xususiyat ajratish talab etilmasligi va yuqori aniqlikdagi natijalarga erishishidir. Chuqur o'rganish modellarini real vaqt tizimlarida qo'llashda hisoblash murakkabligini kamaytirish muhim hisoblanadi. Modelni soddalashtirish, kvantlash va apparat tezlatkichlardan foydalanish bo'yicha yondashuvlar adabiyotlarda keng yoritilgan. [1,10,11]

Konvolyutsion neyron tarmoqlar (CNN). Konvolyutsion neyron tarmoqlar (CNN) tasvir va video ma'lumotlarning fazoviy xususiyatlarini samarali aniqlash imkonini beradi. CNN asosidagi modellar video shovqinini kamaytirish va super-resolution masalalarida yuqori natijalarga erishgani ilmiy tadqiqotlarda isbotlangan. [2,4,7]. CNNlar video kadrlaridagi fazoviy xususiyatlarni ajratishda eng keng qo'llaniladigan arxitektura hisoblanadi. Ular quyidagi vazifalarda samarali natija beradi:





- video shovqinini kamaytirish (Video Denoising);
- aniqlikni oshirish (Video Super-Resolution);
- rang va kontrastni yaxshilash.

Real vaqt tizimlarida CNN modellarining soddalashtirilgan variantlari (Lightweight CNN, MobileNet, EfficientNet) qo'llanilib, kechikish (latency) minimal darajaga tushiriladi.

Rekurrent neyron tarmoqlar va vaqt bog'lanishi. Video ketma-ket kadrlar majmuasidan iborat bo'lgani sababli, vaqt bo'yicha bog'lanishni hisobga olish muhimdir. RNN, LSTM va GRU modellaridan foydalanish orqali qo'shni kadrlar orasidagi harakat va o'zgarishlar aniqlanadi. Bu yondashuv ayniqsa video tiklash va barqarorlashtirish jarayonlarida samarali hisoblanadi.

Generativ qarama-qarshi tarmoqlar (GAN). Generativ qarama-qarshi tarmoqlar (GAN) yordamida yuqori vizual sifatga ega video kadrlarni tiklash mumkin. Xususan, SRGAN va unga o'xshash modellar past aniqlikdagi tasvirlardan realistik yuqori aniqlikdagi tasvirlarni hosil qilishda samarali.[3,9]. GAN arxitekturasi generator va diskriminator tarmoqlaridan iborat bo'lib, yuqori vizual sifatga ega video kadrlar yaratish imkonini beradi. GAN asosidagi modellar:

- realistik detallarni tiklash;
- yuqori aniqlikdagi video rekonstruksiya;
- siqish artefaktlarini yo'qotishda samarali.

Biroq GAN modellarining hisoblash murakkabligi yuqori bo'lgani sababli, real vaqt rejimida ularni optimallashtirish muhim masala hisoblanadi.

Real vaqt rejimi uchun optimallashtirish masalalari. Real vaqt rejimida video aniqligini oshirish masalasi spatio-temporal neyron tarmoqlar va harakat kompensatsiyasi asosida hal etilgan bo'lib, ushbu yondashuvlar kechikishni kamaytirgan holda yuqori sifatni ta'minlaydi. [8,9]. Chuqur o'rganish modellarini real vaqt tizimlarida qo'llashda quyidagi yondashuvlar muhim ahamiyatga ega:

- model parametrlarini kamaytirish (model pruning);
- kvantlash (8-bit, 16-bit);
- GPU va maxsus tezlatkichlardan (TPU, NPU) foydalanish;
- parallel hisoblash va kadrlarni bloklar asosida qayta ishlash.

Mazkur usullar yordamida video sifatini sezilarli darajada oshirgan holda, real vaqt talablari qondiriladi.

Xulosa. Xulosa qilib aytganda, chuqur o'rganish metodlari real vaqt rejimida videoma'lumotlarni tiklash va sifatini oshirish masalalarida yuqori samaradorlikni namoyon etmoqda. CNN, RNN va GAN kabi arxitekturalar yordamida shovqinlarni kamaytirish, aniqlikni oshirish va vizual sifatni yaxshilash imkoniyati mavjud. Kelgusida yengil va tezkor neyron tarmoqlarni ishlab chiqish, shuningdek, apparat tezlatkichlar bilan integratsiya qilish orqali real vaqt video tizimlarining samaradorligini yanada oshirish mumkin. O'tkazilgan tahlillar va mavjud ilmiy tadqiqotlar shuni ko'rsatadiki, chuqur o'rganish metodlari real vaqt rejimida videoma'lumotlar sifatini oshirishda eng istiqbolli yo'nalishlardan biri hisoblanadi. [1-12]





Foydalanilgan adabiyotlar

1. Goodfellow I., Bengio Y., Courville A. Deep Learning. - Cambridge: MIT Press, 2016.
2. LeCun Y., Bengio Y., Hinton G. Deep learning // *Nature*. - 2015. - Vol. 521. - P. 436–444.
3. Ledig C. et al. Photo-realistic single image super-resolution using a generative adversarial network // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. - 2017. - P. 4681–4690.
4. Zhang K., Zuo W., Chen Y., Meng D., Zhang L. Beyond a Gaussian denoiser: Residual learning of deep CNN for image denoising // *IEEE Transactions on Image Processing*. - 2017. - Vol. 26(7). - P. 3142–3155.
5. Wang X., Chan K. C. K., Yu K., Dong C., Loy C. C. EDVR: Video restoration with enhanced deformable convolutional networks // *CVPR Workshops*. - 2019.
6. Tao X., Gao H., Shen X., Wang J., Jia J. Scale-recurrent network for deep image deblurring // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. - 2018.
7. Lim B., Son S., Kim H., Nah S., Mu Lee K. Enhanced deep residual networks for single image super-resolution // *CVPR Workshops*. - 2017.
8. Caballero J. et al. Real-time video super-resolution with spatio-temporal networks and motion compensation // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. - 2017.
9. Shi W., Caballero J., Huszár F. et al. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network // *Proceedings of CVPR*. - 2016.
10. Szeliski R. Computer Vision: Algorithms and Applications. - London: Springer, 2022.
11. Gonzalez R. C., Woods R. E. Digital Image Processing. - 4th ed. - Pearson, 2018.
12. 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*. - 2004. - Vol. 13(4). - P. 600–612.

