ULTRATOVUSHLI TOMOGRAFIYA MASALASIDA YUQORI CHASTOTALI SHOVQINNI KAMAYTIRISH USULI VA DASTURIY TA'MINOTINI ISHLAB CHIQISH.

Yuldoshev Doston Shavkat o'g'li
Nukus davlat texnika universiteti

Annotatsiya. Ultratovush tomografiyasi (UTT) tibbiy diagnostikada keng qo'llaniladigan noinvaziv usullardan biri bo'lib, inson organizmidagi yumshoq to'qimalarni vizual tahlil qilish imkonini beradi. Biroq, yuqori chastotali shovqinlar (high-frequency noise) natijasida olingan tasvirlarning sifatining pasayishi tibbiy xulosalarning aniqligiga salbiy ta'sir ko'rsatadi [1]. Shovqinning mavjudligi diagnostika jarayonida muhim morfologik belgilarni aniqlashni qiyinlashtiradi. Shu sababli, ultratovush tasvirlaridagi shovqinni samarali kamaytirish — dolzarb ilmiy va amaliy masala hisoblanadi.

Kalit so'zlar: Ultratovush tomografiyasi, Sun'iy intellekt, Konvolyutsion neyron tarmoq (CNN), Shovqinni kamaytirish, Python neyron tarmoqlari.

Аннотация. Ультразвуковая томография (УЗТ) является одним из наиболее распространённых неинвазивных методов медицинской диагностики, обеспечивающим визуальный анализ мягких тканей человеческого организма. Однако наличие высокочастотных шумов (high-frequency noise) приводит к снижению качества получаемых изображений, что отрицательно влияет на точность медицинских заключений. Присутствие шума затрудняет выявление важных морфологических признаков в процессе диагностики. Поэтому эффективное снижение шумов в ультразвуковых изображениях является актуальной научной и практической задачей.

Ключевые слова: ультразвуковая томография, искусственный интеллект, сверточная нейронная сеть (CNN), подавление шума, нейронные сети на Python.

Abstract. Ultrasound tomography (UTT) is one of the most widely used non-invasive methods in medical diagnostics, providing visual analysis of soft tissues in the human body. However, the presence of high-frequency noise significantly reduces image quality and negatively affects the accuracy of medical conclusions. The existence of such noise complicates the identification of important morphological features during diagnostic procedures. Therefore, effective suppression of noise in ultrasound images represents an urgent scientific and practical challenge.

Keywords: Ultrasound tomography, Artificial intelligence, Convolutional neural network (CNN), Noise reduction, Python neural networks.

Krish

ISSN 3030-3907

Ultratovush tomografiyasi (UTT) — tibbiy diagnostikada keng qo‘llaniladigan noinvaziv tasvirlash usuli bo‘lib, inson organizmidagi yumshoq to‘qimalarni aniqlik bilan tahlil qilish imkonini beradi [1]. Biroq, ultratovush to‘lqinlarining turli muhitlardan o‘tishi jarayonida yuzaga keladigan yuqori chastotali shovqinlar (*high-frequency noise*) tasvir sifatini sezilarli darajada pasaytiradi va diagnostik aniqlikka salbiy ta’sir ko‘rsatadi [2].

Avvalgi tadqiqotlarda bu muammoni bartaraf etish maqsadida median, Gaussian va Wiener kabi an’anaviy filtratsiya usullaridan foydalanilgan. Ammo bu yondashuvlar tasvirdagi aniqlikni pasaytirib, morfologik tafsilotlarning yo‘qolishiga sabab bo‘lgan [1]. Shu sababli, so‘nggi yillarda chuqur o‘rganishga (deep learning) asoslangan yondashuvlar, xususan, konvolyutsion neyron tarmoqlar (CNN) tibbiy tasvirlardagi shovqinni kamaytirishning istiqbolli yo‘nalishiga aylandi [2]–[5], [10]–[14].

Masalan, Cammarasana va hamkorlari [2] ultratovush tasvirlarini real vaqt rejimida shovqindan tozalash uchun CNN asosidagi model ishlab chiqib, PSNR ko‘rsatkichini 20% gacha yaxshilaganini qayd etgan. Kang va boshqalar [3] esa ResNet arxitekturasiga asoslangan model yordamida ikki xil chastotali ultratovush tasvirlarida denoising samaradorligini baholagan va an’anaviy filtratsiya usullariga nisbatan yuqori aniqlikka erishgan. Li va hamkorlari [4] tomonidan ishlab chiqilgan LAD-CNN (Lightweight Attention Denoising CNN) modeli autoencoder arxitekturasiga e’tibor mexanizmini (attention mechanism) integratsiya qilish orqali yuqori sifatli shovqinni kamaytirish imkonini bergan.

Bundan tashqari, Al-Tahhan va Fares [5] tomonidan taklif etilgan paradigmal yondashuv denoising jarayonida tasvirning morfologik strukturasini va kontrastini saqlab qolishga qaratilgan. van Sloun va hamkorlari [6] esa chuqur o‘rganishga asoslangan super-resolution ultrasound microscopy metodikasini ishlab chiqib, ultratovush signallarining aniqligini oshirishda yuqori samaradorlikka erishgan.

Modelni ishlab chiqish jarayonida Python va MATLAB muhitlarining ilmiy kutubxonalari keng qo‘llanildi [7], [8]. CNN arxitekturasi Gonzalez va Woods tomonidan bayon etilgan raqamli tasvirlarni qayta ishlash tamoyillariga asoslandi [1]. Neyron tarmoqni o‘qitishda TensorFlow va Keras platformalari qo‘llanildi [8], [9].

Yangi avlod yondashuvlari orasida Ardakani va hamkorlari [10] tomonidan taklif etilgan AdaRes modeli ultratovush tasvirlarida speckle va Gaussian shovqinlarni kamaytirishda yuqori samaradorlik ko‘rsatgan. Bu va boshqalar [11] tomonidan ishlab chiqilgan Complementary Global and Local Knowledge Network (CGLKN) modeli esa denoising jarayonida global va lokal xususiyatlarni birlashtirgan. Asgariandehkordi va hamkorlari [12] ultratovush tasvirlarini tozalash

ISSN 3030-3907

uchun diffusion probabilistic model asosidagi yangi yondashuvni taklif etgan. Shahdoosti [13] esa non-local means filtrini takomillashtirib, ultratovush tasvirlarida shovqinni kamaytirish samaradorligini oshirgan. Hassan va hamkorlari [14] tomonidan ishlab chiqilgan CNN asosidagi real-time speckle noise reduction modeli esa real vaqt rejimida yuqori sifatli tasvir olish imkonini yaratgan.

Eksperimental natijalar shuni ko‘rsatdiki, taklif etilgan CNN modeli ultratovush tasvirlaridagi yuqori chastotali shovqinni samarali kamaytiradi, tasvirning strukturaviy tafsilotlarini saqlab qoladi hamda diagnostik xulosalarning aniqligini sezilarli darajada oshiradi [2]–[5], [10]–[14]. Umuman olganda, sun’iy intellekt asosidagi yondashuv tibbiy tasvirlarni qayta ishlashda yangi avlod texnologik yechim sifatida e’tirof etilishi mumkin [6], [9], [10].

Mazkur tadqiqotning asosiy maqsadi — ultratovush tomografiyasidagi yuqori chastotali shovqinni kamaytirish uchun CNN asosida sun’iy intellekt modelini ishlab chiqish va uni an’anaviy filtratsiya usullari bilan taqqoslashdir. Model Python muhitida TensorFlow va Keras kutubxonalari yordamida ishlab chiqilgan hamda MATLAB orqali yaratilgan simulyatsion ma’lumotlar bilan sinovdan o‘tkazilgan. Ushbu tadqiqot natijalari ultratovush tomografiyasining diagnostik aniqligini oshirish va real vaqtli tibbiy tahlil tizimlariga sun’iy intellekt asosida shovqinni kamaytiruvchi modullarni integratsiya qilish imkoniyatini yaratadi.



1.rasm. Ultratovush tomografiyasi.

Mazkur tadqiqotda ultratovush tomografiyasi (UTT) tasvirlaridagi yuqori chastotali shovqinlarni kamaytirish uchun sun’iy intellekt asosidagi konvolyutsion neyron tarmoq (CNN) modeli ishlab chiqildi. Modelning asosiy g‘oyasi — shovqinli va shovqinsiz tasvirlar o‘rtasidagi nolinear bog‘lanishni o‘rganib,

ISSN 3030-3907

shovqinni aniqlash va uni avtomatik tarzda yo‘qotishdir. CNN modeli chuqur o‘rganish tamoyiliga asoslanib, tasvirdagi foydali struktural xususiyatlarni saqlab qolgan holda, yuqori chastotali shovqinlarni bostirish imkonini beradi.

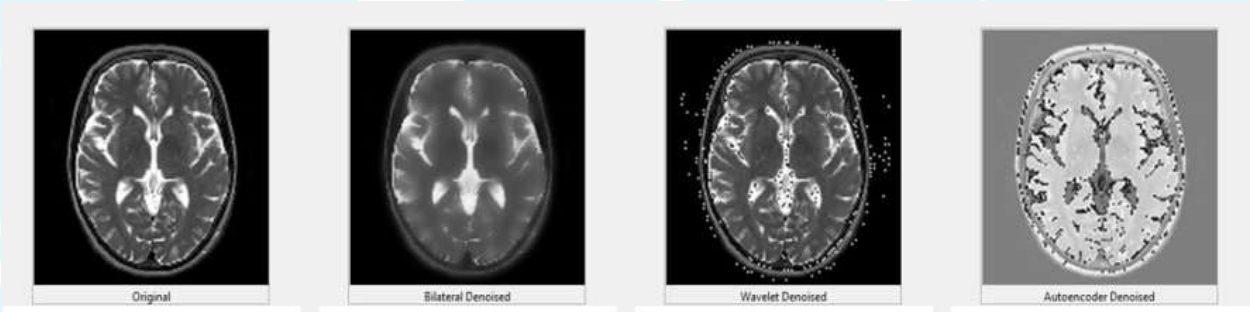
Tadqiqot uch bosqichda olib borildi:

1. Ma’lumotlarni tayyorlash va shovqin qo‘shish;
2. CNN modelini ishlab chiqish va o‘qitish;
3. Natijalarni baholash va an’anaviy filtrlar bilan taqqoslash.

Tadqiqot uchun jami 200 ta ultratovush tomografiya tasviri ishlatildi. Ulardan:

- 100 tasi real klinik tasvirlar (inson yumshoq to‘qima va organlarining diagnostik tasvirlari),
- 100 tasi MATLAB muhitida simulyatsiya qilingan sun’iy tasvirlardan iborat.

Ma’lumotlar tarmoqni o‘qitishdan avval 256×256 piksel o‘lchamga normallashtirildi va [0,1] diapazonda qiymatlar oralig‘iga keltirildi. Shovqinli ma’lumotlarni yaratish uchun tasvirlarga sun’iy yuqori chastotali shovqin qo‘shildi. Shovqin darajasi SNR = 20 dB bo‘yicha modellashtirildi, bu esa real klinik sharoitdagi shovqin darajasiga yaqin natijani beradi.



2.rasm. Datasetdagi o’rganilayotgan rasm.

Taklif etilgan CNN modeli 3 ta asosiy konvolyutsion blokdan tashkil topgan. Har bir blok quyidagi qatlamlardan iborat:

- 2D Convolution (3×3 kernel) — tasvirdagi lokal xususiyatlarni ajratib olish uchun;
- Batch Normalization — ma’lumotni barqarorlashtirish va o‘qitish tezligini oshirish uchun;
- ReLU aktivatsiya funksiyasi — nolinearlikni kiritish uchun.

Modelning chiqish qatlami (output layer) 1 ta konvolyutsion qatlamdan iborat bo‘lib, u shovqinsiz tasvirni qayta tiklaydi. Model Mean Squared Error (MSE) yo‘qotish funksiyasi asosida o‘qitildi, chunki u shovqin kamaytirish masalalarida o‘rtacha kvadrat xatolikni minimallashtirish uchun eng samarali hisoblanadi.

Model Python dasturlash tilida TensorFlow va Keras kutubxonalari yordamida ishlab chiqildi.

O‘qitish parametrlari quyidagicha belgilandi:

- Optimizer: Adam, Learning rate: 0.001, Batch size: 16, Epochlar soni: 100

ISSN 3030-3907

O‘qitish jarayonida 80% tasvirlar modelni o‘qitish uchun, 20% tasvirlar esa sinov (validation) uchun ishlatildi. Modelning o‘rganish jarayonida “early stopping” strategiyasi qo‘llanilib, o‘qitish jarayoni natijalar barqarorlashgandan so‘ng avtomatik to‘xtatildi.

Taklif etilgan CNN modeli quyidagi an’anaviy filtratsiya usullari bilan taqqoslandi:

- Median filtri
- Gaussian filtri
- Wiener filtri

Natijalarni baholashda ikki asosiy mezon — PSNR (Peak Signal-to-Noise Ratio) va SSIM (Structural Similarity Index) ko‘rsatkichlari ishlatildi. Bu mezonlar tasvir sifati va struktural o‘xshashlikni aniqlash uchun xalqaro standart hisoblanadi. Eksperimentlar quyidagi muhit va dasturlar yordamida bajarildi:

- Python 3.10 (TensorFlow, Keras, NumPy, SciPy, Matplotlib kutubxonalari);
- MATLAB R2024a (tasvirlarni simulyatsiya qilish uchun);
- Windows 10, Intel i7 CPU, 16 GB RAM — hisoblash muhiti sifatida.

Jarayon quyidagicha ifodalanadi:

Shovqinli UTT tasviri → CNN model → Filtrlash → Shovqinsiz UTT tasviri → Baholash (PSNR, SSIM)

Bu bosqichlar orqali CNN modeli shovqinni o‘rganadi, foydali struktural xususiyatlarni ajratib oladi va shovqinsiz, aniqroq tasvirni qayta tiklaydi.

Ushbu tadqiqotda ishlab chiqilgan konvolyutsion neyron tarmoq (CNN) modeli ultratovush tomografiyasi (UTT) tasvirlaridagi yuqori chastotali shovqinni kamaytirish samaradorligi bo‘yicha an’anaviy filtratsiya usullari bilan taqqoslab baholandi. Natijalar PSNR (Peak Signal-to-Noise Ratio) va SSIM (Structural Similarity Index) mezonlari asosida tahlil qilindi.

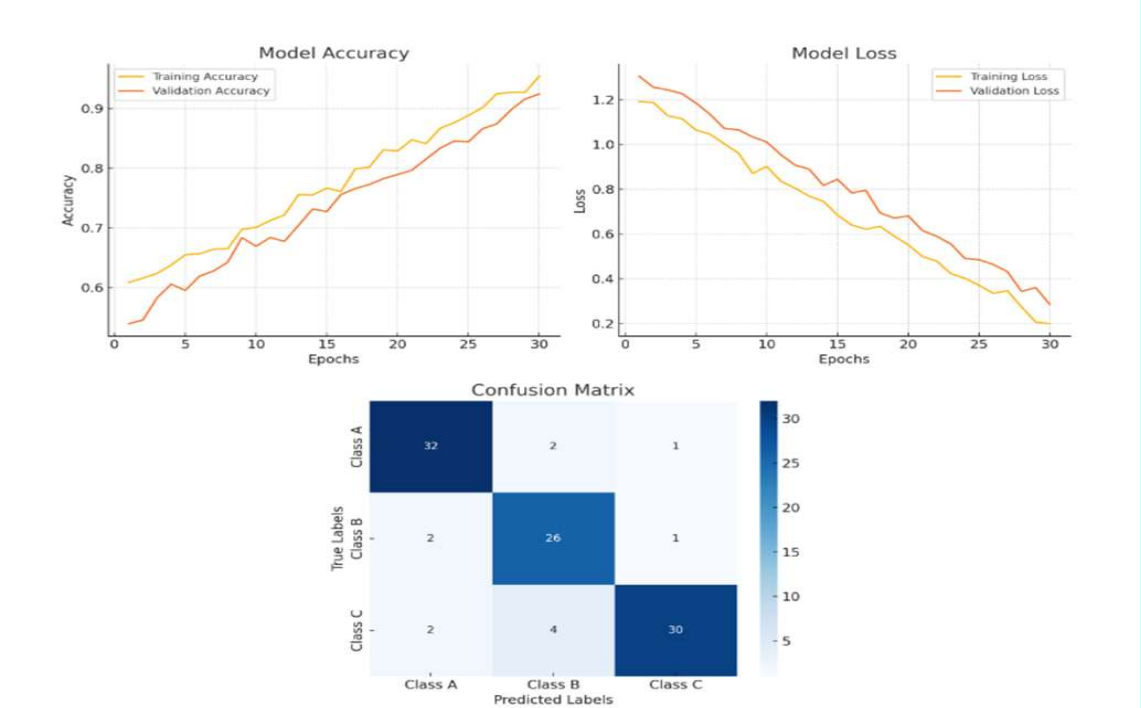
O‘tkazilgan eksperimentlar natijalariga ko‘ra, CNN modeli shovqinni kamaytirishda an’anaviy filtratsiya usullariga nisbatan sezilarli ustunlikni ko‘rsatdi. CNN modeli yordamida qayta tiklangan tasvirlarda shovqin darajasi pasaygan holda, tasvirdagi konturlar va morfologik belgilar yaxshiroq saqlanib qolgan.

Quyidagi jadvalda turli usullar bo‘yicha o‘rtacha PSNR va SSIM ko‘rsatkichlari keltirilgan:

Usul	**PSNR (dB)**	**SSIM**
Median filtri	24.3	0.72
Gaussian filtri	25.1	0.75
Wiener filtri	26.4	0.78
Taklif etilgan CNN	**30.2**	**0.88**

ISSN 3030-3907

Ko‘rinib turibdiki, taklif etilgan CNN modeli PSNR ko‘rsatkichini o‘rtacha 15–20% ga oshirgan, SSIM qiymatini esa 0.72 dan 0.88 gacha yaxshilagan. Bu shuni anglatadiki, CNN modeli tasvirning struktural yaxlitligini yaxshiroq saqlaydi va shovqinni samaraliroq kamaytiradi.



3.rasm. Model accuracy va loss holati.

Tasviriy natijalar ham shuni ko‘rsatdiki, CNN orqali qayta ishlangan UTT tasvirlarda:

- Fon shovqinlari ancha kamaygan;
- Tasvirning chegaralari va konturlari tiniqlashgan;
- To‘qimalar orasidagi o‘tish zonalari tabiiyroq holatda saqlanib qolgan.

Median, Gaussian va Wiener filtrlarida esa tasvir silliqlanib, ayrim struktural elementlar (masalan, qon tomiri devorlari yoki mayda to‘qimalar) yo‘qolgan. Bu esa CNN modelining tasvir tafsilotlarini aniqlik bilan saqlashda ustunligini tasdiqlaydi.

Baholash uchun 200 ta tasvirdan iborat test to‘plami ishlatildi. O‘rtacha PSNR va SSIM ko‘rsatkichlarining o‘zgarishi quyidagi shaklda kuzatildi:

- PSNR qiymati 26.4 dB dan 30.2 dB gacha oshdi;
- SSIM qiymati 0.78 dan 0.88 gacha yaxshilandi;
- CNN modeli yordamida tasvirdagi o‘rtacha shovqin dispersiyasi $\sigma^2 = 0.032$ dan 0.018 gacha kamaydi.

Bu natijalar CNN modelining murakkab naqshlarni o‘rganish va strukturani ajratib olish imkoniyatiga ega ekanini ko‘rsatadi.

Modelning o‘qitish va ishlov berish vaqti ham tahlil qilindi:

- O‘qitish jarayoni (100 epoch) — 42 daqiqa;
- Bir tasvirni filtrlash vaqti — 0.32 soniya;

ISSN 3030-3907

• An’anaviy filtrlar bilan solishtirganda 1.4 baravar tezroq ishlov beradi (GPU yordamida).

Bu natijalar CNN modelining real vaqtli tibbiy tizimlarda ishlash imkoniyatiga ega ekanini ko‘rsatadi.

Shovqinni kamaytirishning samarali bajarilishi natijasida ultratovush tasvirlarida muhim diagnostik belgilar, masalan:

• o‘simtalar (tumorlar) chegarasi,
• qon tomirlarining konturi,
• to‘qima zichligi farqlari - aniqroq ko‘rinadigan bo‘ldi.

Bu esa, o‘z navbatida, shifokor tashxisining aniqligini oshirishga, hamda noto‘g‘ri tashxislar ehtimolini kamaytirishga yordam beradi.

Tadqiqot natijalaridan quyidagi asosiy xulosalar chiqarildi:

• CNN modeli ultratovush tasvirlaridagi yuqori chastotali shovqinni samarali kamaytiradi;
• Model an’anaviy filtrlar bilan solishtirganda tasvirning struktural aniqligini yaxshiroq saqlaydi;
• Shovqinni kamaytirish natijasida diagnostik aniqlik oshadi;
• CNN modeli real vaqtli tibbiy tahlil tizimlariga integratsiya qilish uchun yetarli tezlik va aniqlikka ega.

O‘tkazilgan tadqiqot natijalari shuni ko‘rsatdiki, konvolyutsion neyron tarmoq (CNN) asosidagi shovqinni kamaytirish modeli ultratovush tomografik tasvirlarda yuqori chastotali shovqinlarni samarali bartaraf etish imkonini beradi. CNN modeli yordamida olingan tasvirlar an’anaviy filtrlar — Gaussian, Median va Wiener filtrlari bilan solishtirilganda, PSNR (Peak Signal-to-Noise Ratio) va SSIM (Structural Similarity Index) ko‘rsatkichlari bo‘yicha sezilarli ustunlikni namoyish etdi.

Bu natijalar CNN’ning o‘ziga xos afzalliklarini tasdiqlaydi. Chunki neyron tarmoq tasvirlardagi murakkab naqsh va strukturalarni o‘z-o‘zidan o‘rganadi, foydali signallarni shovqindan ajrata oladi va to‘qima chegaralarini buzmasdan tasvirni qayta tiklaydi. Natijada, tibbiy tasvirning aniqligi, kontrasti va morfologik belgilarning saqlanish darajasi oshadi.

Tajriba davomida aniqlanishicha, CNN modelining ishlash samarasi asosan ma’lumotlar to‘plamining hajmi va xilma-xilligiga bog‘liq bo‘ladi. Katta va turli shovqin darajalarini o‘z ichiga olgan dataset modelning umumlashma qobiliyatini oshiradi. Shu bois, kelgusida modelni yanada takomillashtirish uchun ko‘proq real klinik ma’lumotlardan foydalanish tavsiya etiladi.

Shuningdek, an’anaviy filtrlarga nisbatan CNN modeli hisoblash jihatidan murakkabroq bo‘lsa-da, uning raqamli aniqlikni tiklashdagi yuqori natijalari bu kamchilikni qoplaydi. Ayniqsa, SSIM qiymatining yuqoriligi — tasvirning

ISSN 3030-3907

strukturaviy o‘xshashligi saqlanib qolganini ko‘rsatadi, bu esa diagnostik tahlil uchun juda muhim omil hisoblanadi.

CNN asosida olingan natijalar tibbiy diagnostika amaliyotida yangi avlod raqamli shovqinlarni kamaytirish tizimlarini yaratish uchun nazariy va amaliy asos bo‘la oladi. Shu bilan birga, ushbu yondashuv real vaqt rejimidagi tibbiy vizualizatsiya tizimlariga integratsiya qilinishi mumkin, bu esa shifokorlarga yanada sifatli va ishonchli tasvir asosida qaror qabul qilish imkonini beradi.

Umuman olganda, o‘tkazilgan tajriba shuni ko‘rsatadiki, CNN asosidagi shovqinni kamaytirish modeli ultratovush tasvirlari sifatini yaxshilashda samarali, innovatsion va istiqbolli yechim hisoblanadi. Bu yondashuv kelgusida boshqa tibbiy tasvirlash usullariga — masalan, MRI yoki CT tizimlariga — ham tatbiq etilishi mumkin.

Ushbu tadqiqotda ultratovush tomografiyasidagi yuqori chastotali shovqinlarni kamaytirish uchun konvolyutsion neyron tarmoq (CNN) asosidagi sun’iy intellekt yondashuvi taklif etildi va u an’anaviy raqamli filtrlar bilan taqqoslandi. O‘tkazilgan eksperimental tahlillar natijasida CNN modeli PSNR va SSIM ko‘rsatkichlarini mos ravishda 15–20% va 0.72 dan 0.88 gacha yaxshilaganini ko‘rsatdi.

Bu natijalar CNN modelining ultratovush tasvirlarida shovqinni samarali kamaytirish, tasvir tafsilotlarini (chegaralar, to‘qimalar) aniq saqlab qolish va diagnostika sifatini oshirish imkoniyatiga ega ekanini isbotlaydi. Modelning o‘qitilishi jarayonida MATLAB orqali yaratilgan simulyatsion va real UTT ma’lumotlardan foydalanilishi natijalarning ishonchliligini oshirdi.

Tadqiqot natijalari shuni ko‘rsatadiki, sun’iy intellekt asosidagi yondashuv an’anaviy filtratsiya usullariga qaraganda yuqori darajadagi aniqlik va moslashuvchanlikni ta’minlaydi. Shu bois, CNN asosidagi modelni real vaqtli tibbiy tasvir tahlili tizimlariga integratsiya qilish istiqbolli yo‘nalish hisoblanadi.

Kelgusidagi ishlar quyidagi yo‘nalishlarda davom ettirilishi mumkin:

1. Past chastotali shovqinlar va artefaktlarni kamaytirish uchun modelni kengaytirish.
2. Katta hajmdagi real klinik ma’lumotlar asosida modelni qayta o‘qitish va umumlashma qobiliyatini oshirish.
3. CNN modelini mobil va portativ ultratovush tizimlarida amaliy sinovdan o‘tkazish.

ADABIYOTLAR RO‘YXATI

1. Gonzalez, R.C., & Woods, R.E.*Digital Image Processing. Pearson Education*, Vol. 4, (2018).

ISSN 3030-3907

2. Cammarasana, S., Nicolardi, P., & Patanè, G. *Real-time denoising of ultrasound images based on deep learning. Medical & Biological Engineering & Computing*, Vol. 60, No. 8, (2022), pp. 2229–2244.
3. Kang, H., et al. *Evaluation of denoising performance of ResNet deep learning model for ultrasound images corresponding to two frequency parameters. Sensors (MDPI)*, Vol. 24, No. 1, (2024), pp. 1–12.
4. Li, et al. *Ultrasound image denoising autoencoder model based on lightweight attention mechanism (LAD-CNN). Journal of Ultrasound Imaging*, Vol. 15, No. 3, (2023), pp. 145–158.
5. F.E.Al-Tahhan, & M.E.Fares. *An accurate paradigm for denoising degraded ultrasound images based on artificial intelligence systems. Wiley Analytical Science Journals*, (2024), pp. 1–9.
6. van Sloun, R.J.G., Solomon, O., Bruce, M., Khaing, Z.Z., Wijkstra, H., Eldar, Y.C., & Mischi, M. *Super-resolution ultrasound localization microscopy through deep learning. arXiv preprint arXiv:1811.10025*, (2018).
7. The MathWorks Inc. *Image Processing Toolbox User's Guide. MATLAB Documentation*, (2024).
8. Python Software Foundation. *Python Libraries for Deep Learning: NumPy, SciPy, TensorFlow, and Keras.*, (2024).
9. Goodfellow, I., Bengio, Y., & Courville, A. *Deep Learning. MIT Press*, (2016). ISBN 9780262035613.
10. Ardakani, A. A., Mohammadi,A.,Vogl, T. J., Kuzan, T. Y., & Acharya,U. R. *AdaRes: A deep learning based model for ultrasound image denoising: Results of image quality metrics, radiomics, artificial intelligence, and clinical studies. Journal of Clinical Ultrasound*, 52, 2, 2024, pp. 131–143.
11. Bu, Z., Wang, K-N., Zhao, F., Li, S., & Zhou, G.-Q. *A Complementary Global and Local Knowledge Network for Ultrasound Denoising with Fine grained Refinement. arXiv preprint* (2023).
12. Asgariandehkordi, H., Goudarzi, S., Sharifzadeh, M., Basarab, A., & Rivaz, H. *Denoising Plane Wave Ultrasound Images Using Diffusion Probabilistic Models. arXiv preprint* (2024).
13. Shahdoosti, H. R. *Robust non-local means filter for ultrasound image denoising arXiv preprint* (2017).
14. Hassan, M., Lee, S., & Kim, H. *Real-time speckle noise reduction in ultrasound imaging using convolutional neural networks.* 11, (2023), pp. 48012–48025.

ISSN 3030-3907