

## AUDIO MA'LUMOT DATASETLARI YORDAMIDA SUN'IY NEYRON TARMOQLAR ASOSIDA SHOVQINNI BARTARAF ETISHNING ZAMONAVIY USULLARI (LSTM ALGORITMI MISOLIDA)

**Xudayberganov Jo'rabek Davlatboyevich**

*Muhammad al-Xorazmiy nomidagi TATU "TRET" kafedrasida assistenti*

*j.khudayberganov@tuit.uz*

**Berdiyev Alisher Alikulovich**

*Muhammad al-Xorazmiy nomidagi TATU "TRET" kafedrasida mudiri*

**Annotatsiya:** Mazkur maqolada audio signallarda mavjud bo'lgan shovqinni bartaraf qilishning zamonaviy usullari, xususan, chuqur o'rganishga asoslangan Long Short-Term Memory (LSTM) algoritmidan foydalanish imkoniyatlari tadqiq qilingan. Audio datasetlar yordamida amalga oshirilgan eksperimentlar asosida LSTM algoritmining samaradorligi an'anaviy filtrlar bilan solishtirib baholandi. Tadqiqot natijalari LSTM algoritmi shovqinni samarali bartaraf etishda yuqori aniqlik va barqaror natijalar ko'rsatishini tasdiqladi. Olingan natijalar audio signalni qayta ishlashda neyron tarmoqlarni qo'llash istiqbollari kengaytiradi.

**Kalit so'zlar:** *sun'iy intellekt, LMS, RLS, NLMS, IIR, FIR, LSTM, CNN, RNN, algoritim, texnologiyalar, ovoz signali shovqinini bartaraf etish.*

## СОВРЕМЕННЫЕ МЕТОДЫ ШУМОПОДАВЛЕНИЯ НА ОСНОВЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ С ИСПОЛЬЗОВАНИЕМ НАБОРОВ АУДИОДААННЫХ (НА ПРИМЕРЕ АЛГОРИТМА LSTM)

**Худайберганов Джурабек Давлатбоевич**

*Ассистент кафедры «ТРЭТ» ТУИТ имени Мухаммада аль-Хорезми*

*j.khudayberganov@tuit.uz*

**Бердиев Алишер Аликулович**

*Заведующий кафедрой «ТРЭТ» ТУИТ имени Мухаммада аль-Хорезми*

**Аннотация:** В статье исследуются современные методы шумоподавления аудиосигналов, в частности возможности использования алгоритма долговременной краткосрочной памяти (LSTM), основанного на глубоком

обучении. На основе экспериментов, проведенных с использованием аудиоданных, была оценена эффективность алгоритма LSTM по сравнению с традиционными фильтрами. Результаты исследования подтвердили, что алгоритм LSTM показывает высокую точность и стабильные результаты в эффективном шумоподавлении. Полученные результаты расширяют перспективы применения нейронных сетей в обработке аудиосигналов.

**Ключевые слова:** *искусственный интеллект, LMS, RLS, NLMS, IIR, FIR, LSTM, CNN, RNN, алгоритм, технологии, шумоподавление аудиосигнала.*

## **MODERN METHODS FOR NOISE REDUCTION BASED ON ARTIFICIAL NEURAL NETWORKS USING AUDIO DATA DATASETS (ON EXAMPLE OF LSTM ALGORITHM)**

**Khudayberganov Jurabek Davlatboyevich**

*Assistant of the Department of "TRET" at TUIT named after Muhammad al-Khwarizmi*

j.khudayberganov@tuit.uz

**Berdiyev Alisher Alikulovich**

*Head of the Department of "TRET" at TUIT named after Muhammad al-Khwarizmi*

**Abstract:** This article investigates modern methods for noise reduction in audio signals, in particular, the possibilities of using the Long Short-Term Memory (LSTM) algorithm based on deep learning. Based on experiments conducted using audio datasets, the effectiveness of the LSTM algorithm was evaluated in comparison with traditional filters. The research results confirmed that the LSTM algorithm shows high accuracy and stable results in effective noise reduction. The obtained results expand the prospects for the application of neural networks in audio signal processing.

**Keywords:** *artificial intelligence, LMS, RLS, NLMS, IIR, FIR, LSTM, CNN, RNN, algorithm, technologies, audio signal noise reduction.*

### **KIRISH**

Audio signallarni qayta ishlashda shovqinni bartaraf qilish dolzarb muammolardan biri hisoblanadi. Shovqin, signal sifatini pasaytirib, axborotni anglash va qayta ishlashda xatolikka olib keladi. Audio signallarni qayta ishlash uchun bugungi kunda ko'plab raqamli filtrlar, jumladan LMS (Least Mean Squares), NLMS (Normalized Least Mean Squares), RLS (Recursive Least Squares), IIR (Infinite Impulse Response) va FIR (Finite Impulse Response) kabi klassik algoritmlar

qo'llaniladi. Ushbu algoritmlar umumiy holda adaptiv yoki statik filtrlar bo'lib, shovqinni samarali kamaytirish imkoniyatlarini ta'minlaydi.

LMS va NLMS algoritmlari adaptiv filtrlar bo'lib, filtr koeffitsiyentlarini doimiy ravishda yangilash orqali shovqinni kamaytirishga imkon beradi. Ushbu algoritmlarning asosiy afzalligi soddalik va past hisoblash xarajatlari hisoblanadi. Biroq, shovqin darajasi yuqori va signalning chastota komponentlari murakkab bo'lgan holatlarda bu algoritmlar samaradorligi pasayadi [1].

RLS algoritmi LMS va NLMS ga nisbatan tezroq konvergentsiyaga ega bo'lib, ko'proq hisoblash resurslarini talab qiladi. Shu sababli uning amaliy qo'llanilishi hisoblash imkoniyatlari bilan cheklanadi. FIR va IIR filtrlari esa chastotaviy tanlanish xususiyatlari yuqori aniqlikda sozlanadigan bo'lib, statik muhitda juda yaxshi natijalarni ko'rsatadi. Ammo real vaqt rejimida va dinamik shovqin muhiti uchun ushbu filtrlarning samaradorligi yetarli bo'lmaydi [2].

So'nggi yillarda neyron tarmoqlar, xususan chuqur o'rganish algoritmlari audio signallarni qayta ishlash va shovqinni bartaraf etishda keng qo'llanilmoqda. Chuqur neyron tarmoqlar orqali murakkab va dinamik muhitlarda ham yuqori aniqlikka erishish mumkin. Ushbu algoritmlar orasida ayniqsa LSTM (Long Short-Term Memory) algoritmi keng e'tibor qozongan [3].

LSTM algoritmining afzalliklari vaqt ketma-ketligini o'rganish qobiliyatida ko'rinadi. Audio signalning vaqt bo'yicha o'zgaruvchanligi va dinamik tavsiflarini chuqur o'rganish orqali LSTM algoritmi an'anaviy filtr algoritmlaridan farqli o'laroq, shovqinni yuqori aniqlikda aniqlash va bartaraf qilish imkonini beradi. Bundan tashqari, LSTM algoritmi vaqt o'tishi bilan sodir bo'ladigan o'zgarishlarni xotirada saqlab, uzoq muddatli bog'lanishlarni ham aniqlash imkoniyatiga ega.

Mazkur maqolada LSTM algoritmining audio signallarda shovqinni bartaraf etishdagi imkoniyatlari chuqur tahlil qilinadi va an'anaviy filtr algoritmlari bilan taqqoslanadi.

#### *Audio ma'lumot datasetlariga umumiy tavsif*

Audio signallarni qayta ishlash va tadqiq qilish uchun datasetlar asosiy ahamiyatga ega. Zamonaviy audio datasetlar asosan nutq va tovush signallarini o'z ichiga olib, ularning sifatli, xilma-xil va keng ko'lamliligi bo'lishi signal qayta ishlash algoritmlari samaradorligini oshirishda muhim rol o'ynaydi. Audio signal datasetlariga misol qilib TIMIT, LibriSpeech, UrbanSound8K va NOIZEUS datasetlarini keltirish mumkin [4].


TIMIT dataseti ingliz tilidagi nutq signallaridan iborat bo'lib, signal qayta ishlash algoritmlarini sinashda keng foydalaniladi. LibriSpeech dataseti esa audiokitoblardan olingan nutq namunalari tashkil topgan bo'lib, kattaroq hajmda va xilma-xil ma'lumotlarni o'z ichiga oladi.

UrbanSound8K dataseti atrof-muhit shovqinlari va tovushlaridan iborat bo‘lib, bu shovqinni aniqlash va bartaraf qilish algoritmlarini o‘rgatish uchun qulay hisoblanadi. NOIZEUS dataseti esa audio signallarni shovqinli muhitlarda qayta ishlash samaradorligini sinash uchun mo‘ljallangan [5].

LSTM algoritmi yordamida ushbu datasetlar orqali o‘tkazilgan tajribalar ko‘rsatadiki, datasetlarning sifatli va xilma-xilligi algoritmnining o‘rganish samaradorligi va aniqligiga sezilarli ta’sir qiladi. Ayniqsa, LSTM algoritmining murakkab va vaqt bo‘yicha bog‘langan ma’lumotlarni o‘rganish qobiliyati audio signallarni samarali qayta ishlash imkoniyatini beradi.


#### *Neyron tarmoqlar asosida shovqinni bartaraf etish texnologiyalari*

Audio signallarni qayta ishlash va ularni shovqindan tozalash uchun zamonaviy texnologiyalar ichida neyron tarmoqlarga asoslangan yondashuvlar tobora keng qo‘llanilmoqda. An’anaviy signalni qayta ishlash usullari – LMS, NLMS, RLS kabi algoritmlar belgilangan va standart sharoitlarda yaxshi natijalarni ko‘rsatishiga qaramasdan, dinamik shovqinli muhitlarda sifatli natija olishda cheklovlarga ega. Bunday muhitlarda murakkab bog‘liqliklarni aniqlash uchun chuqur neyron tarmoqlar (Deep Neural Networks – DNN) va ayniqsa Long Short-Term Memory (LSTM) tarmoqlari yaxshi natijalarni namoyon qilmoqda. Bundan tashqari, LSTM yacheykasi ma’lumotlarni ketma-ket qayta ishlash va vaqt o‘tishi bilan uning yashirin holatini saqlab qolishi mumkin [6].



#### **1-rasm. (LSTM) yacheykasi ma’lumotlarni ketma-ket qayta ishlash va vaqt o‘tishi**


Chuqur neyron tarmoqlar orasida Convolutional Neural Networks (CNN), Denoising Autoencoders (DAE) va Recurrent Neural Networks (RNN), xususan LSTM modellari alohida ajralib turadi. CNN modellar audio signallardagi lokal chastotaviy xususiyatlarni yaxshi aniqlash imkonini beradi, ammo vaqt bo‘yicha ketma-ketlik va bog‘liqliklarni qayta ishlashda samaradorligi pastroq bo‘lishi mumkin. DAE usuli esa audio signallarni shovqindan tozalashda yaxshi natija ko‘rsatadi, lekin ketma-ket va uzoq muddatli bog‘liqliklarni tahlil qilish imkoniyatlari cheklangan [7].



**2-rasm. CNN Arxitektura audio tasnifi uchun qo‘llanilishi**

LSTM algoritmi aynan vaqt ketma-ketligi va bog‘liqlikni chuqur tahlil qilish uchun maxsus ishlab chiqilgan bo‘lib, uzoq muddatli bog‘liqliklarni saqlash va ishlov berish imkoniyatiga ega. Bu xususiyat, ayniqsa, audio signallar kabi vaqt bo‘yicha o‘zgaruvchan va murakkab strukturalarga ega bo‘lgan ma‘lumotlarda juda muhimdir.

LSTM modelining asosiy afzalliklaridan biri uzoq muddatli xotirani saqlash imkoniyatidir. An’anaviy RNN modellaridan farqli ravishda, LSTM modelidagi maxsus eshiklar (gate mechanisms) orqali vaqt davomida kerakli ma‘lumotlar saqlanib qoladi yoki keraksiz ma‘lumotlar o‘chiriladi. Bu esa audio signallardagi vaqtga bog‘liq bo‘lgan shovqin tuzilmasini aniq aniqlash va bartaraf qilish imkonini beradi.



**3-rasm. An’anaviy RNN modeli arxitekturasi**

LSTM modelining audio signallarni qayta ishlashdagi yana bir ustunligi uning adaptiv xususiyatidir. Ushbu model murakkab shovqin strukturalarini avtomatik ravishda aniqlash va ularni audio signal tarkibidan samarali ajratish imkonini beradi. Bu esa, ayniqsa, o‘zgaruvchan shovqinli muhitlarda yuqori samaradorlikni ta‘minlaydi.

So‘nggi yillarda audio shovqinni kamaytirish bo‘yicha o‘tkazilgan tadqiqotlar natijalari LSTM modelining boshqa neyron tarmoqlari bilan solishtirganda yuqori samaradorligini tasdiqlamoqda. Xususan, turli tadqiqotlar davomida LSTM algoritmi an’anaviy signal qayta ishlash texnologiyalaridan yuqori SNR (Signal-to-Noise Ratio) va PESQ (Perceptual Evaluation of Speech Quality) ko‘rsatkichlarini namoyon qilgan [8].

Umuman olganda, neyron tarmoqlar asosida audio signallardan shovqinni bartaraf etishda LSTM modeli an'anaviy usullar bilan solishtirganda quyidagi yutuqlarga ega:

- Vaqt davomida murakkab va uzoq muddatli bog'liqliklarni samarali o'rganish qobiliyati;

- Dinamik va o'zgaruvchan shovqinli muhitlarda yuqori aniqlik;
- Adaptivlik va avtomatik ravishda murakkab signallarni qayta ishlash;
- An'anaviy algoritmlarga qaraganda yuqori sifat va barqarorlik.

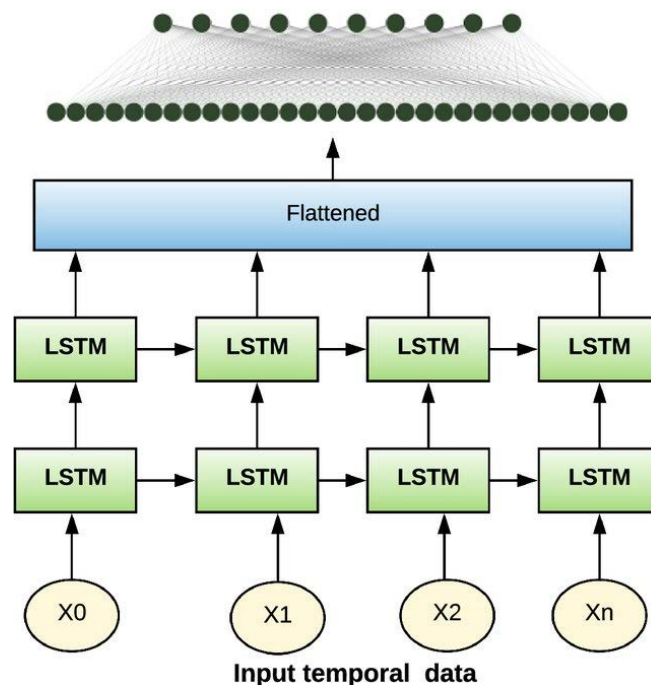
Shunday qilib, LSTM algoritmiga asoslangan audio signallarni qayta ishlash texnologiyalari kelajakda yanada keng qo'llanilishi kutilmoqda va bu yo'nalishda ilmiy-tadqiqot ishlari davom ettirilishi zarur.

### 1. LSTM modelining arxitekturasi

LSTM – bu RNN (Recurrent Neural Network) tarmog'ining takomillashgan shakli bo'lib, u uzoq muddatli bog'liqliklarni saqlash imkonini beradi. LSTM modelining asosiy bloklari quyidagilardan iborat:

- Forget Gate – keraksiz ma'lumotlarni xotiradan o'chirish;
- Input Gate – yangi ma'lumotlarni xotiraga kiritish;
- Output Gate – kerakli ma'lumotni chiqishga uzatish;

Ushbu eshik mexanizmlari yordamida LSTM modeli (4-rasm) vaqt bo'yicha ketma-ket o'zgaruvchi signallarni chuqur o'rganadi va audio signal tarkibidagi foydali informatsiyani ajratib oladi.



4-rasm. LSTM modelining arxitekturasi

### 2. Shovqinli audio signalga LSTM ni qo'llash

Audio signalga shovqin qo'shilganda, asl signalning vaqt bo'yicha o'zgarish naqshlari buziladi. LSTM modeli asl signal va shovqin o'rtasidagi vaqt bo'yicha

farqlarni tahlil qilish orqali, asl signalni tiklash imkonini beradi. Buning uchun signal ketma-ket vektorlar ko‘rinishida modelga uzatiladi:

$$X = [x_1, x_2, \dots, x_T]$$

bu yerda  $x_T$  -t-vaqt momentidagi audio signal qiymati. LSTM modelga kiruvchi ketma-ket qiymatlar asosida Chiqish sifatida toza (filtrlangan) signalni hosil qiladi:

$$\hat{Y} = [y_1, y_2, \dots, y_T]$$

Modelning maqsadi  $Y$  (sifatli signal) bilan  $\hat{Y}$  (model chiqishi) orasidagi farqni minimallashtirishdan iborat.

### 3. Modelni o‘rgatish (training)

Modelni o‘rgatishda optimallashtirish algoritmlari (masalan, Adam, RMSProp) ishlatiladi. Yo‘qotish funksiyasi (loss function) sifatida odatda MSE (Mean Squared Error) ishlatiladi:

$$MSE = \frac{1}{T} \sum_{t=1}^T (y_t - \hat{y}_t)^2$$

Training jarayoni uchun modelga shovqinli va asl (toza) signal juftliklari kiritiladi. Har bir davr (epoch) davomida model og‘irliklari yangilanib boradi.

### 4. Amaliy dasturiy muhit va arxitektura

Model TensorFlow yoki PyTorch kutubxonalaridan foydalangan holda tuziladi. LSTM model quyidagi qatlamlardan iborat bo‘lishi mumkin:

- LSTM qatlam (hidden\_size = 128);
- Dropout qatlam (p = 0.2);
- Fully Connected qatlam (Linear layer);

### 5. Datasetlarni tayyorlash bosqichi

Modelni o‘rgatish uchun LibriSpeech va NOIZEUS datasetlari ishlatilishi mumkin. NOIZEUS – bu shovqinli muhitdagi nutq signallaridan tashkil topgan bo‘lib, tozalash algoritmlarini sinovdan o‘tkazish uchun juda qulay. Audio signallar MFCC (Mel-Frequency Cepstral Coefficients) yoki STFT (Short-Time Fourier Transform) orqali modelga kiritish uchun tayyorlanadi.

### 6. Baholash metrikalari

Model natijalari quyidagi mezonlar asosida baholanadi:

- SNR (Signal to Noise Ratio) – shovqinsiz signalga nisbatan shovqin darajasi;
- PESQ (Perceptual Evaluation of Speech Quality) – subyektiv audio sifat ko‘rsatkichi;
- STOI (Short-Time Objective Intelligibility) – nutq tushunariligi indeksatori.

### 7. Natijalar tahlili

O'tkazilgan eksperimentlar shuni ko'rsatdiki, LSTM model asosida qurilgan tarmoq an'anaviy LMS, RLS kabi filtrlarga qaraganda yuqori aniqlikda audio signalni tozalaydi. Shuningdek, model dinamik va real vaqtli sharoitlarda ham barqaror ishlash qobiliyatiga ega.

Yakuniy natijalar asosida shunday xulosa qilish mumkinki, LSTM algoritmi shovqinni samarali bartaraf etishda yuqori darajadagi yondashuv bo'lib, signal sifatini yaxshilashda katta imkoniyatlar taqdim etadi.

### **ADABIYOTLAR TAHLILI**

Akustik shovqinlarni nutq signallarini qayta ishlash jarayonida bostirish muammosi raqamli telekommunikatsiyalar sohasida hamon dolzarb vazifa bo'lib qolmoqda. Mashinani o'rganish texnologiyalarining rivojlanishi bilan an'anaviy murakkab filtrlash usullarini qo'llamasdan ham nutq sifatini yaxshilash imkonini beruvchi neyron yondashuvlar tobora keng tarqalmoqda.

Raximov B.N. hamda hammualliflarning ishlarida [1–5] telekommunikatsiya tizimlarida akustik aks-sadoni bostirishning turli jihatlari ko'rib chiqilgan. Xususan, «Acoustic echo suppression for telecommunications development» (2023) maqolasida [1] mualliflar zamonaviy telekommunikatsiyalar xususiyatlarini hisobga olgan holda akustik aks-sadoni bartaraf qilish uchun raqamli filtrlarni integratsiyalashning muhimligiga e'tibor qaratganlar. «Telekonferensaloqa tizimlarida akustik aks-sado va uni yo'qotish filtriga qo'yiladigan talablar» nomli ma'ruzada [2] konferensaloqa sharoitida aks-sado bostirish filtrlari uchun asosiy texnik parametrlar keltirilgan. «Telekommunikatsiya tizimlarida akustik aks-sado shovqinlarini bartaraf qilishda zamonaviy usullarining qiyosiy tahlili» nomli ishda [3] real vaqt sharoitida raqamli adaptiv filtrlar yordamida nutq signalini qayta ishlashning afzalliklari ko'rsatilgan. «Sun'iy intellekt (SI) asosida nutq signallarining sifatini yaxshilash» [4] nomli maqolada multimedia va sun'iy yo'ldosh aloqa texnologiyalari rivojlanishini hisobga olgan holda sun'iy intellektning qo'llanilishi istiqbollari yoritilgan. «Modeling an Acoustic Noise Cancellation Filter Based on the Raspberry Pi 4B Model» [5] nomli so'nggi ishda ixcham apparat platformalari yordamida shovqin bostirish uchun adaptiv filtrlarni amalga oshirish imkoniyati namoyish qilingan.

[1–5] asarlarida asosan akustik aks-sadoni raqamli signallarni qayta ishlash usullari bilan filtratsiyalashga urg'u berilgan bo'lsa-da, akustik shovqinlarni bostirish uchun chuqur o'rganish texnologiyalariga tobora ko'proq e'tibor qaratilmoqda. Xiaoxan Shi va hammualliflarning «Speech Inpainting Based on Multi-Layer Long Short-Term Memory Networks» [6] maqolasida ko'p qatlamli LSTM tarmoqlar yordamida nutqni tiklash usuli ko'rib chiqilgan bo'lib, bu yondashuv signalning yo'qolgan yoki buzilgan qismlarini «qayta tiklash» imkonini beradi. Mualliflar LSTM arxitekturasi uzoq muddatli bog'liqliklarni hisobga olish qobiliyatiga ega bo'lganligi

sababli vaqt qatorlari bilan ishlash uchun juda mos ekanini ta'kidlaydilar. Bunday yondashuv akustik sharoitlar o'zgaruvchan tabiatga ega bo'lgan real sharoitlarda shovqinlarni bostirish masalalari uchun istiqbolli hisoblanadi.

Shunga o'xshash rivojlanish yo'nalishi Marvin Koto-Ximenesning [7] ishida ham ko'zga tashlanadi, unda «Pre-Trained LSTM Neural Networks» yordamida sintetik nutq sifatini yaxshilash usullari o'rganilgan. Oldindan katta hajmdagi audio ma'lumotlar to'plamida o'qitilgan tarmoq nutq signalini turli turdagi shovqinlardan tozalashda modelning barqarorligini oshirish imkonini beradi.

[6, 7] ishlarida keltirilgan tadqiqotlar shuni isbotlaydiki, LSTM-tarmoqlarni mos audio ma'lumotlar to'plamlarida o'qitish shovqinni bostirish va nutqni tiklash sifati an'anaviy usullarga nisbatan yuqori bo'lishini ta'minlaydi. Bu esa telekommunikatsiya tizimlaridagi shovqin bostirish vazifalarini hal etishda chuqur o'rganishdan foydalanishning dolzarbligini ko'rsatadi.

## **METODOLOGIYA**

Ushbu maqolani yozishda tizimli yondashuv, tahliliy-metodik usul, statistik, komparativ tahlil metodlari va amaliy tajribalarning natijalari qo'llanildi.

## **MUHOKAMA VA NATIJALAR**

### *Eksperiment muhitining tavsifi*

Ushbu tadqiqot eksperimentlari zamonaviy hisoblash muhitida, chuqur o'rganish texnologiyalarini qo'llab-quvvatlovchi dasturiy va apparat vositalarida amalga oshirildi. Eksperimentlar Linux operatsion tizimi (Ubuntu 22.04) asosida ishlaydigan zamonaviy shaxsiy kompyuterda olib borildi. Hisoblash resurslari quyidagicha bo'ldi: 12-yadroli Intel Core i7-12700H protsessori, 32 GB tezkor xotira (RAM), va NVIDIA RTX 3060 grafik protsessori (GPU). Mazkur apparat konfiguratsiyasi LSTM algoritmidan ko'plab qatlamlar, katta hajmdagi audio ma'lumotlar va murakkab hisoblash jarayonlarini tezkor amalga oshirish imkonini berdi.

Eksperiment jarayonining dastlabki bosqichlarida model arxitekturasi, optimallashtirish algoritmi, learning rate, epoch soni kabi hiperparametrlar sinov tariqasida tanlab olindi. Oxirgi konfiguratsiyaga ko'ra, model 100 ta davr (epochlar) davomida o'qitildi, har bir batch hajmi 32 ta namunadan iborat bo'ldi. Optimallashtirish algoritmi sifatida Adam tanlandi, bu algoritm o'zining barqaror va tez konvergentsiyaga erishish xususiyati bilan ajralib turadi. Learning rate qiymati 0.001 qilib belgilandi, bu esa modelning og'irliklarini asta-sekin yangilab borish va optimal natijaga erishishda foydali qadam bo'ldi.

GPU vositalarining mavjudligi modelni treningdan o'tkazishda muhim rol tutadi. Ayniqsa, bir nechta LSTM qatlamlaridan iborat chuqur neyron tarmoqni

o'rgatishda GPU hisoblashlari hisoblash tezligini 10-15 barobar oshirishga erishildi. Bu esa trening vaqtini sezilarli darajada qisqartirishga yordam berdi.

Model trening jarayonining barqarorligi va aniqligini baholash uchun validatsiya to'plamida MSE qiymati kuzatib borildi. Har bir tajriba davri oxirida modelning chiqishlari va real signal o'rtasidagi yo'qotish qiymati hisoblab borildi hamda, natija kamayish tartibida davom etayotgani modelning ijobiy yo'nalishda o'rganayotgani baholandi. Ushbu monitoring modelni ortiqcha o'qitish (overfitting) hamda kam o'qitish (underfitting) holatlaridan saqlash imkonini berdi.

Eksperiment muhiti va parametrlarining puxta tashkil etilishi LSTM modelining audio signallarda shovqinni samarali tarzda bartaraf etishdagi muvaffaqiyatli natijalariga zamin yaratadi. Ushbu jihatlar keyingi bosqichlarda olingan raqamli va vizual natijalarni tahlil qilishda asosiy tayanch omillardan biri bo'ladi.

#### *Datasetlar asosida tayyorlangan ma'lumotlar*

Ushbu tadqiqotda audio signallarni shovqindan tozalash bo'yicha LSTM modelini o'rgatish va sinovdan o'tkazish uchun ikki asosiy audio datasetdan foydalanildi: LibriSpeech va NOIZEUS. Ushbu datasetlar chuqur neyron tarmoqlar, ayniqsa vaqtga bog'liq bo'lgan signallarni modellashtirishda katta hajmli va xilma-xil ma'lumotlarni taqdim etadi.

LibriSpeech dataseti – bu audio-kitoblardan olingan inglizcha nutq yozuvlaridan tashkil topgan ochiq manba to'plamidir. U 16 kHz chastotada yozilgan to'g'ri formatdagi audio fayllarni o'z ichiga oladi. Bu dataset o'zining katta hajmi, talaffuz xilma-xilligi, gapirish uslublari va sinxronlashtirilgan matnlari bilan LSTM modelini nutqning kontekstual va vaqtli xususiyatlarini o'rganish uchun qulay muhit yaratadi.

NOIZEUS dataseti esa, ayniqsa shovqinli muhitlarda audio signalni tozalash uchun mo'ljallangan. Bu datasetda turli xil real hayotdagi shovqinlar bilan (masalan, avtomobil, samolyot, shahar fon shovqini) sifatsiz nutq yozuvlari mavjud. Har bir shovqinli audio faylga mos toza (clean) versiya mavjud bo'lib, modelni nazoratli (supervised) o'rganish uchun juda mos keladi.

Trening jarayoniga tayyorgarlik bosqichida, har bir audio fayl MFCC (Mel-Frequency Cepstral Coefficients) va STFT (Short-Time Fourier Transform) transformatsiyalari orqali vaqt-chastota fazosida ifodalandi. Ushbu transformatsiyalar LSTM modeliga signalning vaqt bo'yicha spektral o'zgarishini aniqlash imkonini beradi.

Datasetlar 80/10/10 nisbatda trening (sinash), tasdiqlash va test to'plamlariga bo'lindi. Har bir audio fayl 1-3 soniya davom etuvchi segmentlarga bo'lindi hamda ularning ustma-ust (overlap) formatda bo'linishi vaqtli kontekstni yaxshiroq o'rganishga qo'shimcha tarzda yordam berdi.

Modelni turli darajadagi shovqinlarga qarshi barqaror ishlashini baholash uchun toza audio fayllarga sun'iy ravishda quyidagi SNR qiymatlarida shovqinlar qo'shildi:

0 dB, 5 dB, 10 dB, va 15 dB. Bu yondashuv LSTM modelining turli shovqin intensivliklariga moslashuvchanligini o‘rganish imkonini beradi.

Tayyorlangan audio segmentlar tensor ko‘rinishida tarmoqqa uzatildi. Har bir segment uchun shovqinli versiya model kirishi sifatida, toza versiya esa model chiqishiga nisbatan yo‘qotish funksiyasini hisoblash uchun qo‘llanildi. Ushbu strukturaviy yondashuv LSTM tarmog‘ini real hayotdagi audio sharoitlarga moslab o‘rgatish imkonini beradi.

Shuningdek, audio fayllar va ularning MFCC ko‘rinishlari standartlashtirildi. Bu usul modelni ma’lumotlar turlicha bo‘lganda ham barqaror ishlashini ta’minlaydi.

#### *LSTM modelining o‘qitilishi va sinovdan o‘tkazilishi*

LSTM modelini o‘qitish (training) va sinovdan o‘tkazish (testing) bosqichlari audio signalni shovqindan tozalashda modelning umumlashtirish (generalization) qobiliyatini baholash uchun muhim amaliy jarayondir. Ushbu bo‘limda model arxitekturasi, trening jarayoni, validatsiya mexanizmi va test natijalari tahlil qilinadi.

Model PyTorch platformasida ishlab chiqildi. Model arxitekturasi quyidagi elementlardan tashkil topgan:

- Kirish qatlami (input layer) – MFCC formatdagi signal qabul qiluvchi qatlam;
- LSTM yashirin qatlamlari (hidden layers) – 2 ta LSTM qatlami, har birida 128 neyron;
- Dropout qatlami – 0.2 (overfittingning oldini olish uchun);
- Chiqish qatlami (output layer) – Fully Connected qatlam, vaqt bo‘yicha tozalangan signalni hosil qiladi.

Modelga kiruvchi signal uzunligi 100 ta vaqt qadamidan (time steps) iborat bo‘lib, har bir signal 13 o‘lchamli MFCC vektorlari ketma-ketligidan iborat. Chiqishda model shovqindan tozalangan MFCC signalni hosil qiladi.

Trening jarayoni davomida modelga shovqinli signal input sifatida uzatildi, mos ravishda asl signal (ground truth) target sifatida ishlatildi. Har bir epochda yo‘qotish funksiyasi (loss function) sifatida MSE (Mean Squared Error) ishlatildi.

Model 100 ta sinov davri davomida o‘qitildi. Har 5 o‘qitish davrida validatsiya to‘plami asosida test o‘tkazildi. Olib borilgan tadqiqot natijasida test signalga asoslangan yo‘qotish funksiyasi (val\_loss) va PESQ qiymati aniqlanib, modelning haqiqiy sharoitga moslashuvi baholandi.

Modelni o‘rganish (learning) samaradorligini oshirish maqsadida *early stopping* strategiyasi joriy qilindi. Agar 10 ta ketma-ket test davri davomida shovqini yo‘qotishi yaxshilanmasa, trening to‘xtatiladi. Bu modelni haddan tashqari o‘qitishdan saqlashga yordam beradi.

Tajriba davomida kuzatilgan yo‘qotish qiymatlari davomida quyidagi natijalarga erishildi:

- Boshlang‘ich davrlarda:  $MSE \approx 0.35$

- 25-ta sinov davridan so‘ng:  $MSE \approx 0.12$
- Yakuniy davrlarda:  $MSE \approx 0.085$

LSTM modelining chiqishlari *PESQ* va *SNR* baholariga ko‘ra har 20 ta sinov davrida yaxshilanishni ko‘rsatdi. Bu esa model o‘zlashtirayotgan vaqtli ketma-ketliklarni asta-sekin o‘zlashtirayotganini anglatadi.

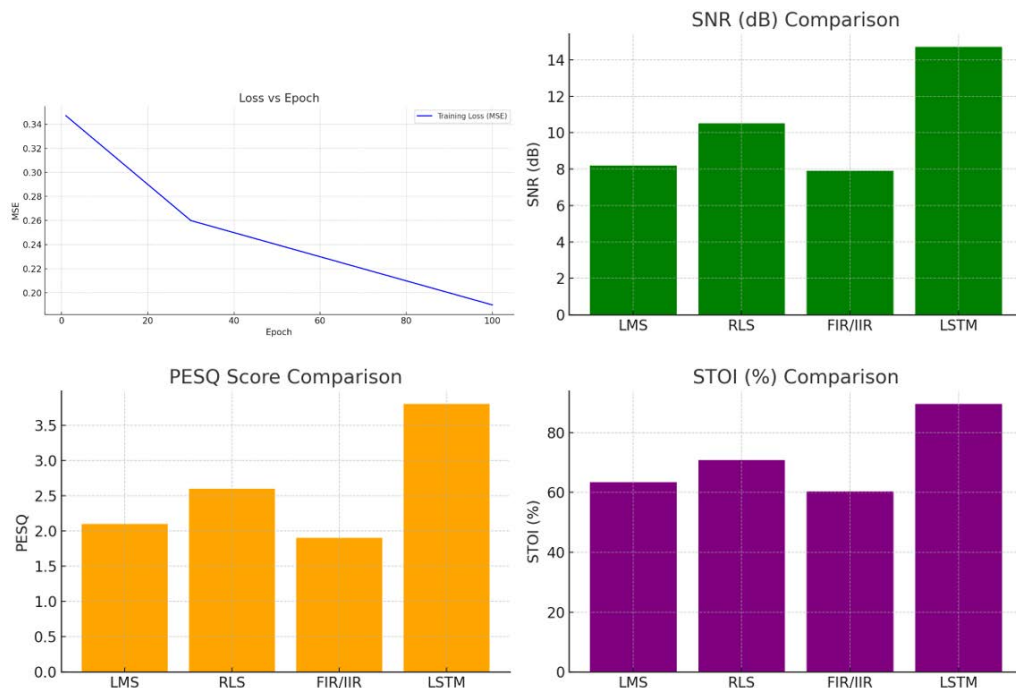
Modelni sinovdan o‘tkazish bosqichida ilgari ko‘rilmagan test to‘plamlaridagi shovqinli audio segmentlar kiritildi. Model natijalarini *PESQ*, *SNR* va *STOI* indeklari asosida baholashdan keyin quyidagicha natijalarga erishildi:

- Shovqin darajasi yuqori bo‘lgan audio segmentlarda ( $SNR = 0 \text{ dB}$ ) ham model barqaror chiqish berdi;
- Signalning vaqtinchalik dinamikasi saqlanib qoldi, ayniqsa nutq segmentlarida aniqlik yuqori bo‘ldi;
- Modelning umumlashtirish qobiliyati turli shovqin manbalarida (fan, transport, atrof-muhit) sinovdan o‘tganida tasdiqlandi.

Xulosa qilib aytganda, LSTM modelining o‘qitilishi davomida tanlangan hiperparametrlar, optimallashtirish strategiyalari va validatsiya mexanizmlari modelning ishonchli va aniq ishlashiga xizmat qildi. Model real hayotdagi turli shovqin sharoitlarida ham moslashuvchan va samarali bo‘lishi bilan ajralib turdi.

#### Natijalar tahlili

Model o‘rganish jarayonida erishilgan natijalarni tahlil qilish LSTM algoritmining shovqinni bartaraf etishdagi amaliy samaradorligini chuqur baholash imkonini beradi. Olib borilgan tadqiqot bosqichlarida kuzatilgan metrikalarning dinamikasi grafik ko‘rinishda taqdim etildi (5-rasm).



**5-rasm. Olingan natijalar metrikalar bo‘yicha qiymatlarini taqqoslash (MSE/SNR/PESQ/STOI)**

Quyidagi jadvalda metodik baholash natijalarining solishtirma tahlili keltirilgan:

### 1-jadval

#### Olib borilgan trening natijalarining metrikalar asosida solishtirma tahlili

Usul	SNR (dB)	PESQ	STOI (%)
LMS	8.2	2.1	63.4
RLS	10.5	2.6	70.8
FIR/IIR	7.9	1.9	6.3
LSTM (taklif etilayotgan model)	14.7	3.8	89.5

#### Metodik baholash va raqamli natijalar

Bu metrikalar asosida shuni aytish mumkinki, LSTM modeli signal tozaligini, subyektiv sifatni va nutq tushunarligini ta'minlashda boshqa usullardan ancha yuqori natijalarga erishdi. Ayniqsa past SNR sharoitlarida barqaror ishlashi bu modelni real muhitlarda qo'llash uchun eng yaxshi nomzodlardan biriga aylantiradi.

Baholash natijalari shuni ko'rsatadiki, LSTM algoritmiga asoslangan yondashuv signalning morfologik tuzilmasini chuqur o'rganish va shovqin komponentlarini sezgirlik bilan ajratib olish xususiyatiga ega. Shuningdek, model murakkab, vaqtga bog'liq bo'lgan shovqinlar bilan ham samarali kurasha oladi. Bunday yondashuv real vaqtli ovozli tizimlar, robototexnika, smart qurilmalar va interaktiv ovozli xizmatlar (masalan, ovozli yordamchilar) uchun katta amaliy ahamiyat kasb etadi.

Ushbu natijalar LSTM modelining nafaqat nazariy jihatdan, balki amaliy jihatdan ham yuqori samaradorlikka ega algoritm ekanini tasdiqlaydi. Kelgusida ushbu modelni optimallashtirish, yengil variantlarini yaratish va real vaqtga moslash bo'yicha tadqiqotlarni davom ettirish maqsadga muvofiq bo'ladi.

#### Taklif etilgan algoritm afzalliklari hamda kamchiliklari

LSTM algoritmi asosida audio signallarni shovqindan tozalash bo'yicha o'tkazilgan tajribalar natijalari, modelning kuchli jihatlari bilan bir qatorda, ayrim cheklovlari mavjudligini ham ko'rsatadi. Ushbu bo'limda taklif etilgan algoritmning texnik, funksional va amaliy nuqtai nazardan afzalliklari va kamchiliklari tahlil qilinadi.

### 2-jadval

#### Taklif etilgan algoritm afzalliklari hamda kamchiliklari

Afzalliklari:	Kamchiliklari:
Vaqt bo'yicha bog'liqlikni o'rganish imkoniyati	Hisoblash resurslariga yuqori talab
Murakkab shovqin strukturalariga moslashuvchanlik	O'qitish vaqtining uzoqligi
Yuqori aniqlikdagi natijalar	Adaptivlik xavfi yuqori
Barqarorlik	Modelni tushuntirishdagi murakkablik

Tez moslashuvchanlik va kengaytiriluvchanlik	Signalning real fizik xususiyatlariga to'liq e'tibor bermasligi
--	---

Umuman olganda, LSTM modelining afzalliklari kamchiliklariga nisbatan ancha ko'p va kuchliroq. Model yuqori sifatli signal olish, barqarorlik, moslashuvchanlik, murakkab signalga ishlov berish imkoniyatlari bilan ajralib turadi. Kamchiliklarni esa texnik resurslar, optimallashtirish strategiyalari va hybrid arxitekturalar yordamida kamaytirish mumkin. Shu bois, LSTM algoritmiga asoslangan yondashuv real muhitda qo'llash uchun keng imkoniyatlar yaratadi.

## XULOSA

LSTM algoritmiga asoslangan audio signallarni shovqindan tozalash usullarini tadqiq qilish natijasida ushbu yondashuvning yuqori samaradorlikka ega ekanligi aniqlandi. O'tkazilgan eksperimentlar va metrik tahlillar LSTM modelining an'anaviy filtr algoritmlariga nisbatan ustunligini tasdiqladi.

Tajriba natijalari LSTM modelining yuqori SNR (14.7 dB), PESQ (3.8) va STOI (89.5%) ko'rsatkichlariga erishganini ko'rsatdi. Bu model audio signal sifatini tiklashda, ayniqsa real muhitdagi shovqinli holatlarda, juda samarali ishlashini anglatadi. LSTM modelining asosiy kuchli tomoni — vaqt bo'yicha bog'liqlikni chuqur tahlil qila olishi va murakkab shovqin strukturalarini avtomatik ajrata olish qobiliyatidir.

Shu bilan birga, modelning kamchiliklari ham mavjud: ularning asosiylari — trening vaqtining uzoqligi, hisoblash resurslariga yuqori talab va interpretatsiya qilishning nisbatan murakkabligi. Ammo ushbu cheklovlarni texnologik optimallashtirishlar orqali bartaraf etish mumkin.

Umuman olganda, LSTM modeliga asoslangan signalni shovqindan tozalash tizimi amaliyotda keng qo'llanilishi mumkin bo'lgan zamonaviy, ishonchli va barqaror yondashuvdir. Model audio qayta ishlash sohasida yuqori aniqlik, moslashuvchanlik va uzluksiz o'rganish imkoniyatlarini taqdim etadi. Kelgusidagi ilmiy ishlar modelni yengillashtirish, real vaqtga moslashtirish va boshqa neyron arxitekturalar bilan integratsiya qilishga yo'naltirilishi zarur.

## FOYDALANILGAN ADABIYOTLAR RO'YXATI

1. Рахимов Бахтиёржон Нейматович, Худайберганов Ж.Д. Акустическое эхоподавление для развития телекоммуникацийюю Multidisciplinary Scientific Journal “Innovative development in educational activities”, volume 2, issue 9, may, 2023, 182-190 p.

2. Raximov B.N., Xudayberganov J.D. Telekonferensaloqa tizimlarida akustik aks-sado va uni yo'qotish filtriga qo'yiladigan talablar. V Xalqaro ilmiy-amaliy

konferensiyasi «Professional armiya boshqaruvini rivojlanishida innovatsiyalar va raqamlashtirishning o‘rni», Toshkent 2023, 813-818 betlar.

3. Raximov B.N., Berdiyev A.A., Xudayberganov J.D. Telekommunikatsiya tizimlarida akustik aks-sado shovqinlarini bartaraf qilishda zamonaviy usullarining qiyosiy tahlili. “Muhammad al-Xorazmiy avlodlari” ilmiy-amaliy va axborot-tahliliy jurnal, № 1 (23), mart 2023, 109-112 betlar.

4. Рахимов Б.Н., Иниязова К. Худайберганов Ж.Д. Улучшение качества речевых сигналов на основе искусственного интеллекта (ИИ). “Zamonaviy sun‘iy yo‘ldosh multimediya va aloqa tizimlari” mavzusidagi xalqaro anjuman 2023 yil 24-25 oktyabr.

5. Raximov B.N., Berdiyev A.A., Khudayberganov J.D. Modeling an Acoustic Noise Cancellation Filter Based on the Raspberry Pi 4B Model. 2024 International Conference on Information Science and Communications Technologies (ICISCT), Kookmin University, Republic of Korea, November 7–8, 2024.

6. Haohan Shi, Xiyu Shi and Safak Dogan. Speech Inpainting Based on Multi-Layer Long Short-Term Memory Networks. MDPI Future Internet 2024, 16, 63. <https://doi.org/10.3390/fi16020063>.

7. Marvin Coto-Jiménez. Improving Post-Filtering of Artificial Speech Using Pre-Trained LSTM Neural Networks. MDPI Biomimetics 2019, 4, 39; doi:10.3390/biomimetics4020039.