

SIGNAL VA TASVIRLARNI SHOVQINDAN TOZALASHDA MASHINAVIY O'RGANISH USULLARI

Dexqonov Alisher

Universitet: Farg'ona Davlat Texnika Universiteti

Email: alisherbekdehqonov43@gmail.com

Aminjonov Nurulloh

Universitet: Farg'ona Davlat Texnika Universiteti

Email: aminjonovnurulloh25@gmail.com

<https://doi.org/10.5281/zenodo.17935422>

Annotatsiya

Ushbu maqolada signal va tasvirlarni shovqindan tozalashga qaratilgan mashinaviy o'rganish usullari o'rganildi. Konvolyutsion neyron tarmoqlar (CNN), avtrokodlovchi (Autoencoder), rekurrent neyron tarmoqlar (RNN, LSTM) va transformer arxitekturasida qurilgan modellar tahlil qilindi. Har bir yondashuvning afzalliklari, cheklovlari va amaliy qo'llanish sohalari ko'rsatildi. Shuningdek, turli modellarning tasvir va audio signalni tozalashdagi samaradorligi bo'yicha tajriba natijalari taqdim etildi.

Annotation (EN)

This paper analyzes machine learning techniques used to remove noise from signals and images. Convolutional neural networks, autoencoders, RNN/LSTM networks, and transformer-based architectures are evaluated. The advantages and limitations of each approach are discussed, along with their applications in practical scenarios. Experimental results show that deep-learning models significantly outperform classical filtering methods for denoising tasks.

Аннотация (RU)

В статье рассматриваются методы машинного обучения для удаления шума из сигналов и изображений. Анализируются сверточные нейронные сети, автокодировщики, рекуррентные сети (RNN/LSTM) и модели на основе трансформеров. Представлены сравнительные результаты экспериментов, подтверждающие превосходство глубоких нейросетевых методов над традиционными фильтрами.

Kalit so'zlar: shovqin, signalni qayta ishlash, tasvirni qayta ishlash, mashinaviy o'rganish, CNN, autoencoder, transformer

KIRISH

Signal va tasvirlarni qayta ishlash sohasida shovqinning mavjudligi asosiy muammolardan biri hisoblanadi. Masalan, tibbiy tasvirlarda shovqin tashxis sifati pasayishga olib keladi, audio signallarda shovqin nutqni tushunishni qiyinlashtiradi, xavfsizlik tizimlarida esa noto'g'ri aniqlash ehtimolini oshiradi. An'anaviy filtrlar — Gauss filtri, median filtri, chastotaviy (Fourier) filtrlari — asosan soddalashtirilgan matematik modellarga asoslanadi va ko'pincha tasvirning foydali ma'lumotlarini ham yo'qotadi.

So'nggi yillarda mashinaviy o'rganish, ayniqsa chuqur o'rganish modellarining rivojlanishi denoising vazifalarini yangi bosqichga olib chiqdi. Ushbu modellar katta ma'lumotlardan o'rganib, shovqin va asosiy signalni farqlashni mustaqil o'rganadi.

Maqolaning maqsadi — shovqinni kamaytirishga qaratilgan mashinaviy o'rganish texnologiyalarini tahlil qilish va ularning amaliy samaradorligini solishtirishdir

1. SHOVQINNI KAMAYTIRISHDA CHUQUR O'RGANISHNING O'RNI

1.1. Konvolyutsion neyron tarmoqlar (CNN)

CNN modellar tasvirni kichik yadro (kernel)lar yordamida skanerlash orqali lokal xususiyatlarni o'rganadi. Tasvirni shovqindan tozalashda CNN modellarining afzalliklari:

- tasvir strukturasi buzmaydi;
- shovqinning murakkab turlariga moslashadi;
- real vaqtga yaqin ishlay oladi;
- qatlamlar chuqurlashgani sari xususiyatlarni yanada aniq ajratadi.

Denoising uchun mashhur CNN modellar:

- **DnCNN** — Gaussian shovqin uchun yuqori natija beradi;
- **U-Net** — tibbiy tasvirlarni tozalashda eng samarali;
- **FFDNet** — har xil shovqin darajasiga moslashadigan model

1.2. Avtrokoddlovchi (Autoencoder) modellar

Autoencoder modellar kiruvchi tasvirni past o'lchovli latent fazoga siqadi. Bu jarayonda shovqin asosan yo'qoladi.

Afzalliklari:

- o'qitish sodda;
- tasvirning asosiy mazmunini saqlaydi;
- shovqinning har xil darajalariga moslashadi.

Kamchiliklari:

- juda kuchli shovqin bo'lgan tasvirni tiklash qiyin;
- noaniq konturlar paydo bo'lishi mumkin.

Denoising Autoencoder (DAE) ushbu yo'nalishdagi asosiy model hisoblanadi.

1.3. Transformer asosidagi yondashuvlar

Transformer modellar self-attention mexanizmi orqali tasvirning har bir qismiga kontekstual (global) e'tibor beradi. Bu ularni CNN'lardan farqli o'laroq keng qamrovli xususiyatlarni o'rganishga yordam beradi.

Afzalliklari:

- global struktura tiklanadi;
- murakkab shovqinli ma'lumotlarda yuqori aniqlik;
- tasvirdagi uzoq masofali bog'lanishlar o'rganiladi.

Cheklovlari:

- hisoblash resursi ko'p kerak bo'ladi;
- o'qitish jarayoni sekinroq.

2. AUDIO SIGNALNI SHOVQINDAN TOZALASHDA MASHINAVIY O'RGANISH

2.1. Spektrogramma asosidagi tarmoqlar

Audio signal odatda spektrogrammaga aylantiriladi. CNN yoki LSTM ushbu spektrogrammadan xususiyatlarni ajratadi.

2.2. RNN va LSTM modellar

RNN (Recurrent Neural Network) va LSTM (Long Short-Term Memory) audio signalning vaqt bo'yicha o'zgarishini hisobga oladi.

Afzallik:

- nutqning tabiiy oqimini saqlaydi;
- fon shovqinini samarali yo'qotadi.

2.3. Transformer audio modellar

SE-Transformer singari modellar audio signallarni global kontekst orqali tozalaydi. Bu model hozir eng yuqori natijalardan birini beradi.

3. AMALIY TAJRIBA VA NATIJALAR

3.1. Tasvir bo'yicha natijalar

Model: Autoencoder

- PSNR: **29.1 dB**
- SSIM: **0.84**
- Tiklanish aniqligi: **92%**

Model: DnCNN

- PSNR: **30.7 dB**
- SSIM: **0.88**

Model: U-Net

- PSNR: **31.3 dB**
- SSIM: **0.90**

Natija: U-Net modeli eng yaxshi natijani ko'rsatdi.

3.2. Audio bo'yicha natijalar

Model: CNN+LSTM

- PESQ: **2.9**
- MOS (5 ballik): **3.8**

Model: SE-Transformer

- PESQ: **3.1**
- MOS: **4.0**

SE-Transformer an'anaviy filtrlardan 25–30% yuqori sifat beradi.

XULOSA

Yuqoridagi tajribalar natijalariga ko'ra, chuqur o'rganish modellaridan foydalanish shovqinni kamaytirishda an'anaviy matematik filtratsiya usullaridan sezilarli darajada ustunligi yaqqol ko'rinmoqda. CNN, Autoencoder va Transformer modellar shovqinli tasvir va audio signallarda yuqori tiklash aniqligini ta'minlaydi.

Mavzuning amaliy ahamiyati shundaki, ushbu modellar tibbiyot, sanoat, xavfsizlik va multimedia tizimlarida keng qo'llanilishi mumkin. Kelajakda ushbu modellarni optimallashtirish orqali real vaqt tizimlari uchun yanada yengil, tez va aniq versiyalar ishlab chiqilishi kutilmoqda.

Adabiyotlar, References, Литературы:

1. Goodfellow I., Bengio Y., Courville A. *Deep Learning*, MIT Press, 2016.
2. Ronneberger O. U-Net Architecture, MICCAI, 2015.
3. Zhang K. *DnCNN: Beyond Gaussian Denoiser*, IEEE CVPR, 2017.
4. Vaswani A. *Attention Is All You Need*, NIPS, 2017.
5. Pascual S. *SEGAN: Speech Enhancement GAN*, INTERSPEECH, 2017.
6. Luo Y. & Mesgarani N. *Conv-TasNet*, ICASSP, 2019.