



RAQAMLI SIGNALLARGA VAQT SOHASIDA ISHLOV BERISH

Nabiyeva D.T.

Muhammad al-Xorazmiy nomidagi Toshkent axborot
texnologiyalari universiteti

diloromtemurovna55@gmail.com

<https://doi.org/10.5281/zenodo.17855191>

Annotatsiya: Ushbu maqolada raqamli signallarga vaqt sohasida ishlov berishning asosiy nazariy va amaliy tamoyillari yoritiladi. Vaqt va chastota sohasidagi tahlil usullari, Zero-Crossing Rate (ZCR), Fourier transformatsiyasi, avtoregressiya tahlili, konvolyutsiya, filtrlash hamda korrelyatsiya kabi fundamental DSP (Digital Signal Processing) operatsiyalarining qo'llanilishi ko'rib chiqiladi.

Kalit so'zlar: Zero-Crossing Rate, raqamli signal, chastota sohasi, vaqt sohasi, Fourier transformatsiyasi.

Bugungi kunda zamonaviy texnologiyalar va raqamli tizimlarning jadal rivojlanishi axborotlarni qayta ishlash, uzatish va saqlashning raqamli shaklini tobora keng qo'llashni talab etmoqda. Shu jumladan, tovush signallarini qayta ishlash texnologiyalari sohasida ham raqamlashtirish jarayonlari alohida ahamiyatga ega. Chunki inson nutqi, musiqa yoki boshqa ovozli axborotlarni analog ko'rinishda emas, balki raqamli ko'rinishda qayta ishlash, uzatish va saqlashda ko'p afzalliklar mavjud bo'lib, ular ichida axborot sifatining barqarorligi, uzoq muddatli saqlash imkoniyatlari va shovqinga bardoshli uzatish texnikalari asosiy o'rin tutadi.

Tovushlardan muhim belgilarni ajratib olishni vaqt, chastota, chastota vaqt sohalarida, statistik va psixoakustik ishlov berish orqali amalga oshirish mumkin. Vaqt sohasida ishlov berish bu signalning vaqt davomidagi amplituda xarakteristikalaridan kelib chiqib, uning belgilarini ajratish tushuniladi. Bunday usullarga Root Mean Square (RMS) Energy ya'ni vaqt o'tishi bilan ovozli signalning intensivligini o'lchaydi. Yuqori energiya ko'pincha balandroq, potensial ko'proq hissiy tovushlar bilan bog'liq, Zero-Crossing Rate (ZCR) bu signalning nol amplituda chizig'ini qanchalik tez-tez kesib o'tishini hisoblaydi. Yuqori ZCR ko'pincha qichqiriy yoki ogohlantirish signali kabi shovqinli yoki hayajonli hissiy tovushlarni bildiradi. Temporal Envelope qiymati signalning ekstremal tomonlarini belgilovchi silliq egri chiziqni ifodalaydi. Bu tovushdagi dinamik o'zgarishlarni ushlab yordam beradi, ko'pincha hissiy intensivlikni aks ettiradi. Signal duration qiymati ovoz signalining uzunligini o'lchaydi. Ba'zi hissiy yoki favqulodda tovushlar xarakterli davomiylikka ega bo'lishi mumkin. (masalan, qisqa portlashlar va doimiy signallar).





ZCR (Zero-Crossing Rate)

$$ZCR = \frac{1}{N-1} \sum_{n=1}^{N-1} \mathbf{1}_{\{x[n] \cdot x[n-1] < 0\}}$$

• ZCR – signalning nol amplituda chizig'ini kesib o'tish tezligini o'lchaydi.

• $x[n]$ va $x[n-1]$ – signalning ketma-ket namunalaridagi amplitudalar.

•

• Agar $x[n] \cdot x[n-1] < 0$, ya'ni amplituda belgisi o'zgarishi bo'lsa, bu holat hisoblanadi.

• $\mathbf{1}_{\{\cdot\}}$ – indikator funksiyasi, shart bajarilsa 1, aks holda 0.

• Bo'linuvchi $N-1$ – signal davomiyligiga nisbatan normalizatsiya qiladi.

ZCR yuqori bo'lsa, signal tez-tez keskin o'zgaradi (masalan, qichqiriq yoki ogohlantirish tovushi).

Chastota sohasidagi tovush belgilariga asosan hozirgi vaqtda chuqur o'rganish modellari (CNN, RNN) yaxshi moslashuvchi Mel-spectrogram, spektral kontrast va Tonnetz (Tonal Centroid Features) usullarini misol qilib keltirishimiz mumkin. Chastota sohasida ishlov berishning afzalligi shundan iboratki, signal amplitudasining o'zgarishiga ta'sirchan bo'lmaganligi sababli, stasionar bo'lmagan shovqinlar mavjudligida ham barqaror tasniflashni ta'minlaydi [1]. Bundan tashqari statistik identifikatorlar va o'lchamlarni kamaytirish usullarini qo'llash klassifikator modellari yaxshiroq ishlash uchun optimallashtirilgan belgilar to'plamini olishini ta'minlaydi.

Tovushlardan muhim belgilar to'plamini hosil qilgandan so'ng ularni tasniflash uchun ko'plab algoritmlar mavjud. Dastlabki yillarda Support Vector Machine (SVM) [2], Gaussian Mixture Model (GMM) [3], Extreme learning machine (ELM) [4] va boshqa mashinali o'qitish algoritmlari tovushdan ajratib olingan belgilarni tasniflashda ishlatib kelingan. Biroq, bu an'anaviy klassifikatorlar kichik o'zgarishlarni simulyatsiya qilish uchun mo'ljallangan, bu esa vaqt va chastotada invariants yetishmasligiga olib keldi.

So'nggi yillarda chuqur neyron tarmoqqa (DNN) asoslangan usul murakkab tasniflash muammolarini hal qilishda samaraliroq ekanligi isbotlandi va asta-sekin an'anaviy mashinali o'qitish algoritmini almashtirmoqda. Konvolyutsion neyron tarmog'i (Convolution Neural Networks - CNN) chuqur o'rganishda eng ko'p qo'llaniladigan arxitekturalardan biri sifatida an'anaviy mashinali o'qitish algoritmining cheklovlarini hal qiladigan konvolyutsiya operatsiyasi orqali bir





vaqtning o'zida ham vaqt ham chastota xususiyatlarini o'rganishi mumkin. Shu bilan birga, CNN qo'lda yaratilgan xususiyatlar asosida tasniflash uchun yanada chuqurroq abstrakt xususiyatlarni olishi mumkin. Ko'p sonli parametrlar va hisob-kitoblar CNN ning ishlash tezligini sekinlashtiradi, bu esa real vaqt rejimida ishlash talablariga javob berishni va saqlashni hamda hisoblash resurslari yo'q bo'lgan o'rnatilgan qurilmalarga joylashtirishni qiyinlashtiradi. Shu sababli, CNN ning ishlash narxini pasaytirish va tasniflash tezligini yaxshilash uchun Fast Convolution Neural Network (FastCNN) [5], Retrieval-Augmented Convolutional Neural Networks (RACNN) neyron tarmoqlari foydalanish tavsiya etiladi.

RACNN o'zida svertka amallarining tezkor amalga oshiruvchi yangi modullardan tashkil topgan bo'lib, nisbatan oson usulda qo'shimcha belgilar kartasini generatsiya qilishni ta'minlab beradi. An'anaviy svertka amallari bilan solishtirganda, u saqlash va ekspluatatsiya narxi past bo'lgan bir xil miqdordagi kanallarni generatsiya qiladi va ko'proq xususiyatlar haqida ma'lumot oladi.

Avtoregressiya tahlilida signal o'zining oldingi namunalarning chiziqli kombinatsiyasi sifatida ifodalanadi. Ushbu kombinatsiyaning koeffitsiyentlari avtoregressiya koeffitsiyentlari deb ataladi. Ushbu usul Fourier transformatsiyasiga nisbatan yuqori chastota aniqligiga ega va qisqa signallarni qayta ishlay oladi. Prony usuli signal komponentlarining fazalari, amplitudalari, boshlang'ich fazalari va so'nishlarini aniqlash uchun ishlatilishi mumkin. Komponentlar murakkab so'nuvchi eksponentlar deb qabul qilinadi.

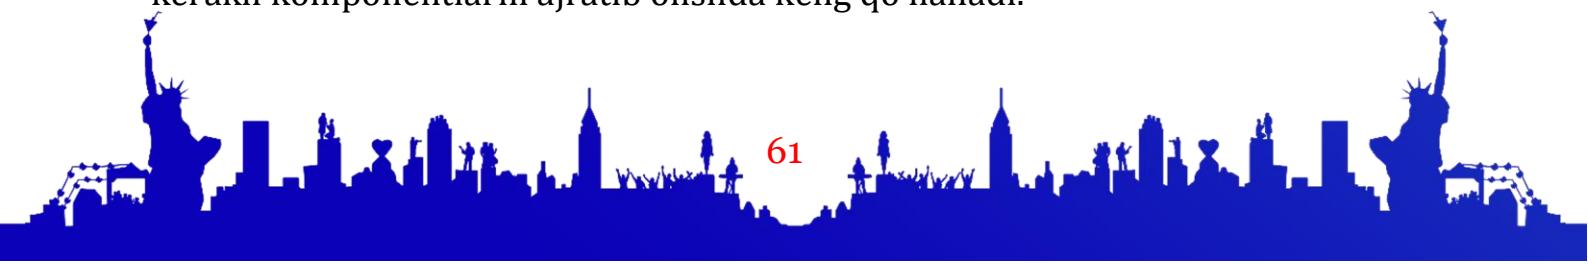
LTI tizimlarda vaqt sohasida ishlov berish. Chiziqli va vaqtga invariant (LTI Linear Time Invariant) tizimlar signalni qayta ishlash nazariyasining eng muhim sinflaridan biridir. Bunday tizimlarning asosiy xususiyati shundaki, tizimning javobi vaqt bo'yicha o'zgarmaydi va kirish signallariga chiziqli ravishda ta'sir qiladi. LTI tizimlarning ishlash qonuniyati superpozitsiya va gomogenlik tamoyillariga asoslanadi. LTI tizimlarda har qanday kirish signaliga beriladigan chiqish signali konvolyutsiya amali orqali aniqlanadi. Bu jarayon quyidagi asosiy tenglama bilan ifodalanadi:

$$y(t) = x(t) * h(t)$$

Bu yerda:

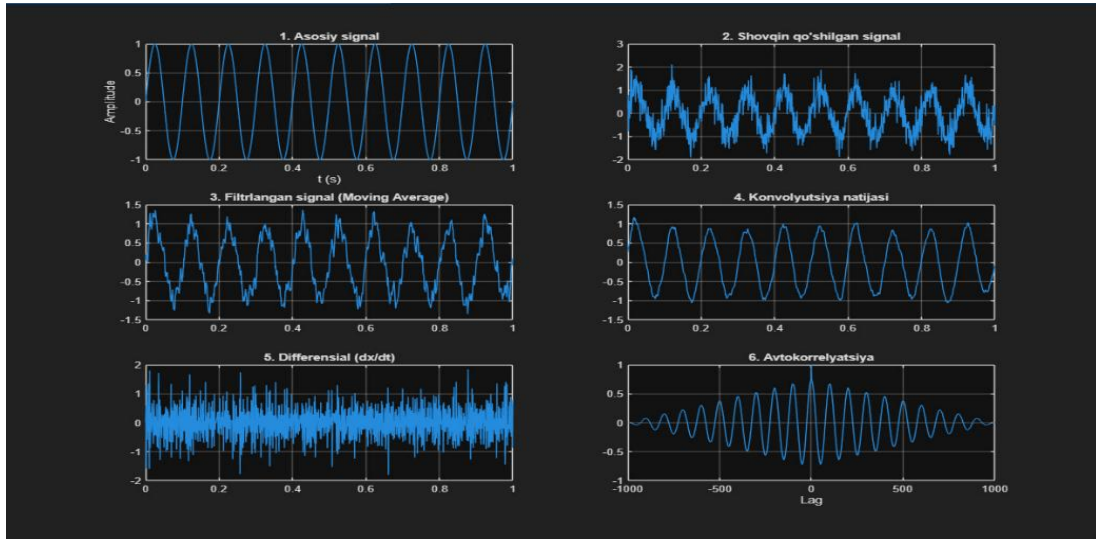
- $x(t)$ — kirish signali,
- $h(t)$ — tizimning impuls javobi,
- $*$ — konvolyutsiya amali.

Konvolyutsiya filtratsiya, shovqinlarni kamaytirish, signalni tekislash va kerakli komponentlarni ajratib olishda keng qo'llanadi.





Quyida keltirilgan (1-rasm) da MATLAB muhitida vaqt sohasidagi signallar ustida bir qator asosiy amallar bajarildi. Jumladan, signalga filtrlash, konvolyutsiya, differensiallash hamda avtokorrelyatsiya kabi muhim jarayonlar qo'llanildi.



1-rasm. Filtratsiya, Konvolyutsiya, Differensiallash, Avtokorrelyatsiya.

Filtrlash jarayoni signal tarkibidagi keraksiz yuqori yoki past chastotali komponentlarni bostirish orqali uni silliqlashga xizmat qiladi. Konvolyutsiya esa tizimning impuls xarakteristikasi bilan signalning o'zaro ta'siri natijasida hosil bo'ladigan javobni aniqlash uchun qo'llaniladi. Signalning o'zgarish tezligini baholash maqsadida differensial amal bajariladi. Avtokorrelyatsiya esa signalning o'ziga nisbatan o'xshashlik darajasini aniqlash orqali uning tarkibiy xususiyatlarini tahlil qilish imkonini beradi. Bu amallar yordamida signalning asosiy parametrlarini baholash, shovqinni kamaytirish va tizim xususiyatlarini chuqurroq o'rganish imkoniyati yaratiladi.

Xulosa o'rnida shuni aytish mumkinki, raqamli signallarga vaqt sohasida ishlov berish usullari signalning boshlang'ich shaklini vaqt bo'yicha tahlil qilishga imkon beradi. Bu jarayonda diskretlashtirish, kvantlash, filtrlar qo'llash, konvolyutsiya, korrelyatsiya va turli transformatsiyalar orqali signalning asosiy xususiyatlari aniqlanadi. Vaqt sohasida ishlov berish real vaqt rejimida ma'lumotlarni qayta ishlash, shovqinni kamaytirish, signalni tekislash, zarur komponentlarni ajratib olish kabi vazifalarni samarali bajarishga yordam beradi. Ushbu yondashuv telekommunikatsiya, audio-video tizimlar, tibbiy diagnostika, avtomatika va raqamli boshqaruv sohalarida keng qo'llaniladi. Umuman olganda, raqamli signallarni vaqt sohasida qayta ishlash texnologiyalari zamonaviy





axborot tizimlarining sifatini oshirish, aniqlik va ishonchlilikni ta'minlashda muhim o'rin egallaydi.

Foydalanilgan adabiyotlar:

1. Arifin, C., & Junaedi, H. (2018). Emotion Sound Classification with Support Vector Machine Algorithm. Kinetik, 3(2). <https://doi.org/10.22219/kinetik.v3i2.610>
2. Z. Hosseini, S. M. Ahadi and N. Faraji, "Speech emotion classification via a modified Gaussian Mixture Model approach," 7'th International Symposium on Telecommunications (IST'2014), Tehran, Iran, 2014, pp. 487-491, doi: 10.1109/ISTEL.2014.7000752.
3. Ainurrochman, I. I. Febriansyah and U. L. Yuhana, "SER: Speech Emotion Recognition Application Based on Extreme Learning Machine," 2021 13th International Conference on Information & Communication Technology and System (ICTS), Surabaya, Indonesia, 2021, pp. 179-183, doi: 10.1109/ICTS52701.2021.9609016.
4. Fei Wang, Shichao Wu, Weiwei Zhang, Zongfeng Xu, Yahui Zhang, Chengdong Wu, Sonya Coleman, Emotion recognition with convolutional neural network and EEG-based EFDMs, *Neuropsychologia*, Volume 146, 2020, 107506, ISSN0028-3932, <https://doi.org/10.1016/j.neuropsychologia.2020.107506>.
5. J. J. Zhao and K. Cho, "Retrieval-Augmented Convolutional Neural Networks Against Adversarial Examples," in 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Long Beach, CA, USA, 2019, pp. 11555-11563, doi: 10.1109/CVPR.2019.01183.

