EKG BIOSIGNALLARINI SUN’IY INTELLEKT YORDAMIDA TAHLIL QILISH VA ARITMIYA ZARBALARINI KLASSIFIKATSIYA QILISH ARXITEKTURALARINING QIYOSIY TAHLILI

G‘aniyev Alisher Islomovich

Qarshi davlat texnika universitet dotsent v.b.
E-mail: tatuqfalisher91@gmail.com

K E Y W O R D S

biosignallar, elektrokardiogramma (EKG), aritmiya, sun’iy intellekt, chuqur o‘rganish, konvolyutsion neyron tarmoq, BiLSTM, diqqat (attention) mexanizmi, zarbalarni klassifikatsiya qilish, shovqinga chidamlilik

A B S T R A C T

Ushbu maqolada biosignallarni, xususan, elektrokardiogramma (EKG) signallarini sun’iy intellekt usullari yordamida tahlil qilish masalasi ko‘rib chiqilgan. EKG zarbalarini to‘rt sinfga — normal (N), supraventrikulyar (S), qorincha (V) va qo‘shilish (F) zarbalariga — ajratish uchun konvolyutsion neyron tarmoq (CNN), ikki yo‘nalishli uzoq qisqa muddatli xotira (BiLSTM) tarmog‘i va diqqat (attention) mexanizmini turlicha birlashtiruvchi neyron arxitekturalar hamda klassik Random Forest modeli qiyosiy o‘rganildi. Tajribalar 40 ta virtual subyektdan olingan 8 000 ta sintetik EKG zarbasida, subyektlar bo‘yicha ajratilgan o‘qitish, tekshiruv va test to‘plamlarida o‘tkazildi.

Kirish: Biosignallar — tirik organizmning hayotiy faoliyati davomida hosil bo‘ladigan va o‘lchash mumkin bo‘lgan fiziologik signallardir. Ularga yurakning elektr faolligini aks ettiruvchi elektrokardiogramma (EKG), miya biopotensiallari (EEG), mushaklar faolligi (EMG), qon tomirlar hajmining o‘zgarishini qayd etuvchi fotopletizmogramma (PPG), shuningdek nafas va teri qarshiligi signallari kiradi. So‘nggi yillarda kiyiladigan (wearable) qurilmalar va masofaviy monitoring tizimlarining keng tarqalishi natijasida biosignallar uzluksiz qayd etilmoqda, bu esa shifokor qo‘lda tahlil qila oladigan hajmdan ancha ortiq ma’lumot hosil qilmoqda. Masalan, bir sutkalik Holter monitoringi yozuvi taxminan yuz mingga yaqin yurak urishini o‘z ichiga oladi. Jahon sog‘liqni saqlash tashkiloti (JSST) ma’lumotlariga ko‘ra, yurak-qon tomir kasalliklari dunyoda o‘lim sabablari orasida birinchi o‘rinda turadi: 2019-yilda ularning oqibatida taxminan 17,9 million kishi vafot etgan, bu barcha o‘limlarning 32 foizini tashkil etadi [1]. Yurak ritmining buzilishlari (aritmiyalar) bu kasalliklarning muhim belgisi bo‘lib, ayrim hollarda to‘satdan yurak o‘limiga olib kelishi mumkin. Aritmiyalarni erta va ishonchli aniqlash uchun EKG yozuvidagi har bir yurak zarbasini turiga ko‘ra ajratish — zarbalarni klassifikatsiya qilish — zarur. An’anaviy yondashuvda bu ishni mutaxassis bajaradi, biroq katta hajmdagi yozuvlar uchun u ko‘p vaqt talab qiladi va charchoq tufayli xatolarga moyil.

So‘nggi o‘n yillikda sun’iy intellekt va chuqur o‘rganish (deep learning) usullari biosignallarni avtomatik tahlil qilishda an’anaviy usullardan ustun bo‘lib bormoqda. Konvolyutsion neyron tarmoqlar (CNN) signal shaklining mahalliy morfologik belgilarini, rekurrent tarmoqlar (LSTM) vaqt bo‘yicha bog‘liqliklarni avtomatik o‘rganadi, diqqat (attention) mexanizmi esa signalning eng informativ qismlariga ustuvorlik berishga imkon beradi. Biroq amaliy masalada bu tarkibiy qismlarning har biri qancha foyda berishi, ayniqsa ma’lumotlar hajmi cheklangan va shovqinli bo‘lganda, oldindan ma’lum emas. Shu sababli ushbu maqolaning maqsadi — EKG zarbalarini to‘rt sinfga ajratish masalasida CNN, BiLSTM va attention bloklarining turli kombinatsiyalarini yagona sharoitda o‘qitib, ularning aniqligi, shovqinga chidamliligi va hisoblash murakkabligini qiyosiy baholashdan iborat.

Mavzuga oid adabiyotlar tahlili: Biosignallar asosida aritmiyani aniqlash bo‘yicha ishlarni shartli ravishda uch guruhga ajratish mumkin: (1) qo‘lda tanlangan belgilarga asoslangan klassik mashinaviy o‘qitish usullari, (2) chuqur konvolyutsion tarmoqlarga asoslangan

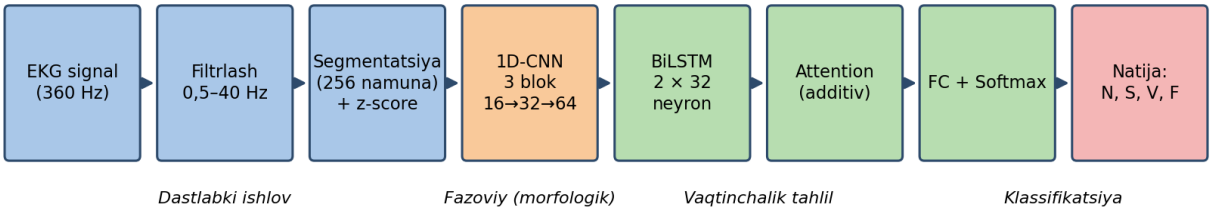
(cc) BY

usullar va (3) rekurrent hamda diqqat mexanizmiga asoslangan ketma-ketlik modellari. Dastlabki tadqiqotlarda avval QRS majmuasi Pan va Tompkins algoritmi kabi usullar bilan aniqlanib [5], so‘ngra RR intervallari, QRS kengligi, to‘lqinchalar (wavelet) koeffitsiyentlari kabi qo‘lda tanlangan belgilar yordamida chiziqli diskriminant, SVM, k-NN va Random Forest klassifikatorlari qo‘llangan [6]. Bunday yondashuvlar hisoblash jihatidan tejamkor va talqin qilish oson bo‘lsa-da, ularning sifati belgilarni tanlash bosqichiga va signal sifatiga kuchli bog‘liq bo‘lib, bir bemorda sozlangan model boshqa bemorda sezilarli yomonlashishi mumkin.

Chuqur o‘rganish davrida belgilarni qo‘lda tanlashdan voz kechib, xom signaldan to‘g‘ridan-to‘g‘ri o‘rganishga o‘tildi. Acharya va hammualliflar yurak zarbalarini AAMI standartidagi sinflarga ajratish uchun chuqur CNN modelini taklif etishgan [7]; Rajpurkar va Hannun boshchiligidagi guruh bir kanalli ambulator EKG yozuvlarida chuqur CNN yordamida ritm turlarini ajratib, natijalarni kardiologlar bahosi bilan solishtirgan [8, 9]. Ushbu ishlar CNN arxitekturalarining EKG morfologiyasini o‘rganishdagi samaradorligini ko‘rsatgan bo‘lsa-da, ularda mutaxassislar tomonidan belgilangan katta hajmli ma’lumotlar to‘plamlaridan foydalanilgan.

Vaqt bo‘yicha bog‘liqliklarni modellashtirish uchun uzoq qisqa muddatli xotira (LSTM) tarmog‘i [10] va uning ikki yo‘nalishli varianti (BiLSTM) [11] keng qo‘llanadi: ikki yo‘nalishli ishlov berish zarbaning P to‘lqinidan T to‘lqinigacha bo‘lgan kontekstni ham oldinga, ham orqaga qarab hisobga olish imkonini beradi. Diqqat mexanizmi dastlab mashina tarjimasi uchun taklif etilgan [12] va keyinchalik transformer arxitekturalarining asosiga aylangan [13]; biosignallar tahlilida u modelga signalning diagnostik jihatdan muhim bo‘laklariga ko‘proq e’tibor qaratish va qarorni talqin qilish imkonini beradi. Shunga qaramay, CNN, BiLSTM va attention bloklarini birlashtirish har doim ham aniqlikni oshiravermaydi — bu ko‘p jihatdan ma’lumotlar xususiyatiga, hajmiga va shovqin darajasiga bog‘liq. Ushbu yo‘nalishdagi tadqiqotlarning aksariyati MIT-BIH aritmiya ma’lumotlar bazasiga [2, 3] tayanadi va zarbalarni AAMI EC57 standartidagi sinflarga ajratadi [4]; mazkur ishda ham sinflar mantig‘i shu standartga mos olingan.

Tadqiqot metodologiyasi: Tadqiqot EKG zarbalarini to‘rt sinfga — normal (N), supraventrikulyar ektopik (S), qorincha ektopik (V) va qo‘shilish (F) zarbalariga — ajratish masalasi sifatida shakllantirildi. Qiyosiy tahlil uchun bir xil dastlabki ishlov berish va o‘qitish tartibida oltita model ko‘rib chiqildi: (1) Random Forest (klassik asos modeli), (2) 1D-CNN, (3) BiLSTM, (4) BiLSTM + Attention, (5) CNN + BiLSTM va (6) CNN + BiLSTM + Attention gibrid modeli. To‘liq gibrid arxitekturaning umumiy tuzilishi 1-rasmda keltirilgan; qolgan neyron modellar undan tegishli bloklarni olib tashlash orqali hosil qilingan (ablation tahlili).



1-rasm. Tadqiq etilgan gibrid arxitekturaning umumiy tuzilishi

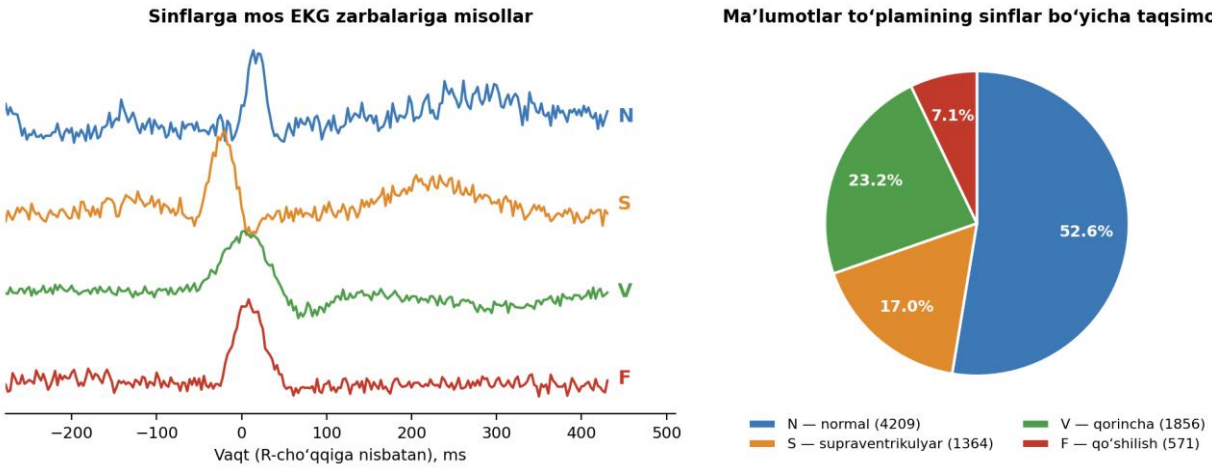
Tadqiqotning ushbu bosqichida real klinik yozuvlar o‘rniga sintetik EKG zarbalari ishlatildi. Zarbalar P, Q, R, S va T to‘lqinlarini Gauss funksiyalari yig‘indisi ko‘rinishida ifodalovchi generator yordamida hosil qilindi [14]; diskretlash chastotasi MIT-BIH bazasiga mos ravishda 360 Hz, zarba oynasi uzunligi 256 namuna (taxminan 711 ms) qilib olindi, R cho‘qqisi oynaning 101-namunasiga joylashtirildi. Sinflar morfologiyasi quyidagicha modellashtirildi: N zarbalarida odatdagi P to‘lqini, tor QRS majmuasi va musbat T to‘lqini mavjud; S zarbalarida P to‘lqini o‘zgargan (PR oralig‘i qisqargan, ayrim hollarda P to‘lqini teskari qutbli), QRS majmuasi tor; V zarbalarida P to‘lqini yo‘q, QRS majmuasi keng va yuqori amplitudali, T to‘lqini teskari qutbli; F

(cc) BY

zarbalari esa N va V zarbalarining oraliq shakli sifatida — qisman P to‘lqini, o‘rtacha kenglikdagi QRS va o‘zgaruvchan T to‘lqini bilan — beriladi.

Real signallarga xos o‘zgaruvchanlikni hisobga olish uchun har bir virtual subyekt uchun to‘lqin amplitudasi (standart og‘ish 12 %), QRS kengligi (10 %), T to‘lqini amplitudasi (18 %) va PR oralig‘i (12 ms) bo‘yicha individual og‘ishlar, shuningdek har bir zarba uchun tasodifiy parametr o‘zgarishlari kiritildi. Signalga uch turdagi xalaqit qo‘shildi: izochiziq dreyfi (chastotasi 0,2–0,5 Hz, amplitudasi R cho‘qqisining 5–25 %), 50 Hz tarmoq xalaqiti va mushak faolligiga xos Gauss shovqini; R cho‘qqisini aniqlashdagi xatoni modellashtirish uchun zarba oynasi ±8 namuna oralig‘ida tasodifiy siljitildi. Har bir zarba alohida z-score usulida normallashtirildi.

Jami 40 ta virtual subyektning har biridan 200 tadan zarba hosil qilindi (jami 8 000 ta); sinflar nisbati MIT-BIH dagi nomutanosiblikni eslatuvchi tarzda (nominal ravishda N — 52,5 %, S — 17,5 %, V — 22,5 %, F — 7,5 %) tanlandi, amalda esa mos ravishda 52,6; 17,0; 23,2 va 7,1 % hosil bo‘ldi. Bir subyektning zarbalari ham o‘qitish, ham test to‘plamiga tushib qolishining (ma’lumotlar sizib o‘tishining) oldini olish uchun to‘plamlarga bo‘lish subyektlar bo‘yicha amalga oshirildi: 28 subyekt o‘qitish, 6 subyekt tekshiruv va 6 subyekt test uchun ajratildi. Ma’lumotlar to‘plamining sinflar bo‘yicha taqsimoti 2-rasmda, asosiy statistik ko‘rsatkichlari 1-jadvalda keltirilgan.



2-rasm. Ma’lumotlar to‘plamining tarkibiy taqsimoti

1-jadval.

Ma’lumotlar to‘plamining asosiy statistik ko‘rsatkichlari

Ko‘rsatkich	Qiymat	Izoh
Umumiy zarbalar soni	8 000	—
Virtual subyektlar soni	40	Har biridan 200 zarba
«N» sinfidagi zarbalar	4 209 (52,6 %)	Normal
«S» sinfidagi zarbalar	1 364 (17,0 %)	Supraventrikulyar
«V» sinfidagi zarbalar	1 856 (23,2 %)	Qorincha
«F» sinfidagi zarbalar	571 (7,1 %)	Qo‘shilish
Diskretlash chastotasi	360 Hz	MIT-BIH ga mos
Zarba oynasi uzunligi	256 namuna	≈ 711 ms
O‘qitish / tekshiruv / test	5 600 / 1 200 / 1 200	Subyektlar bo‘yicha (28/6/6)

(cc) BY

Gibrid modelning birinchi bloki — bir o‘lchamli konvolyutsion tarmoq (1D-CNN). U uchta ketma-ket konvolyutsion qatlamdan (mos ravishda 16, 32 va 64 ta filtr, yadro uzunligi 7, 5 va 3) iborat bo‘lib, har biridan keyin ReLU faollashtirish funksiyasi va 2 ga teng maksimal pulling qo‘llaniladi; natijada 256 namunali zarba 64 kanalli, 32 qadamli xususiyatlar ketma-ketligiga aylanadi. Tarmoqning har bir neyroni quyidagi umumiy ifoda bilan tavsiflanadi:

$$y = \sigma(\sum_{i=1}^{n} w_i x_i + b) \quad (1)$$

bunda x_i — kirish signali, w_i — mos vazn koeffitsiyenti (konvolyutsion qatlamda bu vaznlar signal bo‘yicha siljiganda umumiy bo‘ladi), b — siljish (bias) hadi, σ — faollashtirish funksiyasi (yashirin qatlamlarda ReLU, chiqishda softmax).

Vaqtinchalik bog‘liqliklarni modellashtirish uchun xususiyatlar ketma-ketligi ikki yo‘nalishli LSTM tarmog‘iga (har yo‘nalishda 32 ta yashirin neyron) uzatiladi. LSTM katagi unutish (forget), kirish (input) va chiqish (output) darvozalari orqali xotira holatini boshqaradi:

$$f_t = \sigma\big(W_f \cdot [h_{t-1}, x_t] + b_f\big)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o)$$

$$C'_t = tanh(W_C \cdot [h_{t-1}, x_t] + b_C)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot C'_t$$

$$h_t = o_t \odot tanh(C_t) \quad (2)$$

bunda f_t, i_t, o_t — mos ravishda unutish, kirish va chiqish darvozalari qiymatlari, C_t — xotira holati, C'_t — nomzod xotira holati, h_{t-1} — oldingi qadamdagi yashirin holat, W va b — vazn matritsalari hamda siljish hadlari, $\odot$— elementlar bo‘yicha ko‘paytirish. Ikki yo‘nalishli ishlov berish natijasida har bir t qadam uchun oldinga va orqaga yo‘nalishdagi yashirin holatlar birlashtirilib, 64 o‘lchamli h_t vektor hosil bo‘ladi. Faqat BiLSTM dan iborat modellarda CNN bloki ishlatilmaydi: buning o‘rniga xom signal 8 namunali oyna bo‘yicha o‘rtalashtirilib (32 qadamli ketma-ketlik) tarmoqqa beriladi. Diqqat bloki additiv (Bahdanau) ko‘rinishida amalga oshirilgan: har bir qadam uchun muhimlik bahosi hisoblanadi, u softmax orqali normallashtiriladi va BiLSTM chiqishlarining vaznli yig‘indisi sifatida kontekst vektori shakllantiriladi:

$$e_t = v^T\, tanh(W_a h_t + b_a)$$

$$\alpha_t = \frac{exp(e_t)}{\sum_{j=1}^{T} exp(e_j)}$$

$$c = \sum_{t=1}^{T} \alpha_t h_t \quad (3)$$

bunda e_t — t-qadamning muhimlik bahosi, α_t — diqqat vazni ($\sum\alpha_t$ = 1), v, W_a, b_a — o‘rganiladigan parametrlar, c — kontekst vektori. Attention bo‘lmagan variantlarda kontekst vektori sifatida oldinga yo‘nalishdagi oxirgi va orqaga yo‘nalishdagi birinchi yashirin holatlar birlashmasi olinadi. Kontekst vektori 32 neyronli to‘liq bog‘langan qatlamga (ReLU, dropout 0,2) va to‘rt neyronli softmax chiqishiga uzatiladi.Sinflar nomutanosibligini kamaytirish uchun sinflarga bog‘liq vaznli kross-entropiya yo‘qotish funksiyasi qo‘llanildi:

$$L = -\frac{\sum_{n=1}^{N} w_{y_n}\, log\, p_{n,y_n}}{\sum_{n=1}^{N} w_{y_n}}$$

$$w_k = \sqrt{\frac{N}{K \cdot N_k}} \quad (4)$$

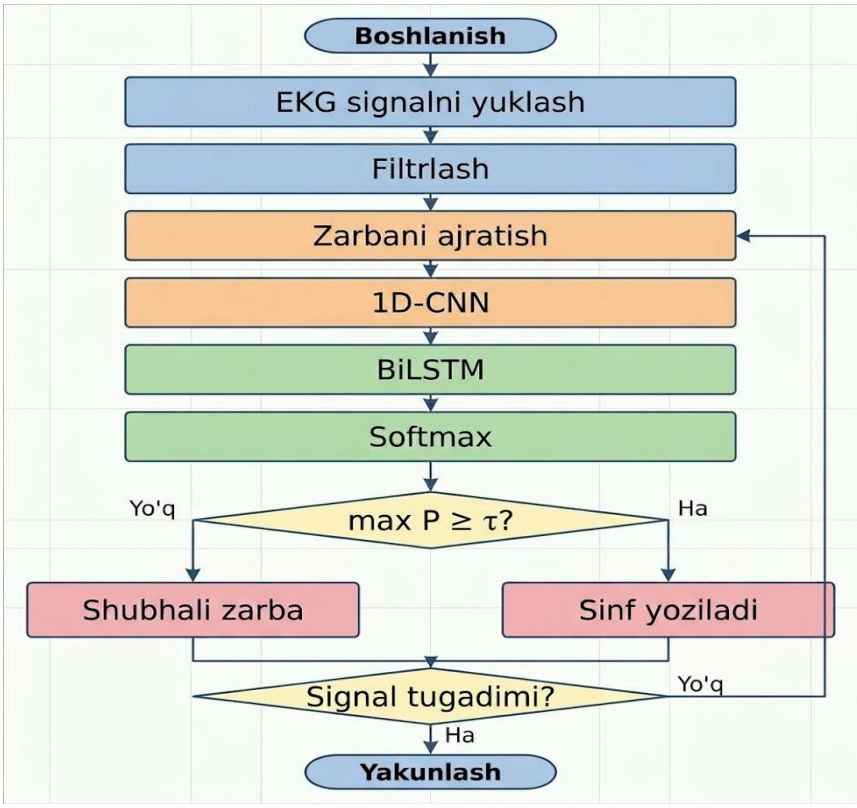
bunda $p_{n,k}$ — n-zarba uchun k-sinf ehtimoli, y_n — haqiqiy sinf, N_k — o‘qitish to‘plamidagi k-sinf zarbalari soni, N — o‘qitish zarbalarining umumiy soni, K = 4. Har bir model uchun tekshiruv to‘plamida yo‘qotish eng kichik bo‘lgan epoxaning og‘irliklari saqlab qolindi. Asos modeli sifatida 200 ta daraxtdan iborat Random Forest [16] olindi; unga 4 marta siyraklashtirilgan signal (64 ta kirish belgisi) berildi. Barcha neyron modellar JAX kutubxonasida [17] amalga oshirilib, bitta CPU yadrosida, bir xil tasodifiy boshlang‘ich holat (seed) bilan o‘qitildi. Modellar test to‘plamida umumiy aniqlik (accuracy), har bir sinf bo‘yicha aniqlik darajasi (precision), qamrov (recall) va F1-ko‘rsatkich hamda ularning sinflar bo‘yicha o‘rtacha (makro) qiymatlari bilan baholandi:

$$P_k = \frac{TP_k}{TP_k + FP_k}, \quad R_k = \frac{TP_k}{TP_k + FN_k}$$

$$F1_k = \frac{2P_k R_k}{P_k + R_k}, \quad F1_{makro} = \frac{1}{K}\sum_{k=1}^{K} F1_k \quad (5)$$

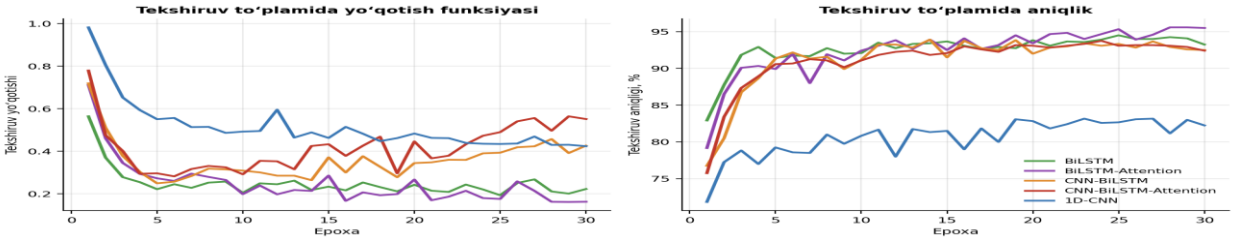
(cc) BY

bunda TP_k, FP_k va FN_k — k-sinf uchun to‘g‘ri musbat, yolg‘on musbat va yolg‘on manfiy natijalar soni. Eng yaxshi modelning amaliy ishlash tartibi 3-rasmda blok-sxema ko‘rinishida berilgan. Algoritm EKG signalini filtrlaydi (0,5–40 Hz), R cho‘qqilarini aniqlaydi, har bir zarbani ajratib normallashtiradi va neyron tarmoq orqali sinflar ehtimolliklarini hisoblaydi. Agar eng yuqori ehtimollik belgilangan ishonchlilik chegarasi τ dan past bo‘lsa, zarba «shubhali» deb belgilanib mutaxassis ko‘rigiga yuboriladi; aks holda sinf yoziladi, V yoki F sinfi aniqlanganda esa ogohlantirish shakllantiriladi.



3-rasm. EKG zarbalarini klassifikatsiya qilish algoritmi

Tahlil va natijalar: Modellarning o‘qitilish dinamikasi 4-rasmda keltirilgan. BiLSTM va BiLSTM + Attention modellarida tekshiruv yo‘qotishi deyarli butun o‘qitish davomida kamayib bordi va eng kichik qiymatlarga (mos ravishda 0,193 va 0,162) 25- va 29-epoxalarda erishildi. CNN bloki mavjud gibrid modellarda esa eng yaxshi tekshiruv natijasi juda erta — CNN + BiLSTM uchun 5-epoxada (yo‘qotish 0,249), CNN + BiLSTM + Attention uchun 6-epoxada (0,282) — qayd etildi, undan keyin tekshiruv yo‘qotishi o‘sa boshlab, 30-epoxada mos ravishda 0,426 va 0,551 ga yetdi; shu bilan birga o‘qitish aniqligi 99,8–99,9 % gacha ko‘tarildi. Bu qayta moslashish (overfitting) belgisidir. Faqat CNN dan iborat model esa o‘qitishda ham, tekshiruvda ham (taxminan 82 %) past aniqlikda qoldi.



4-rasm. Tekshiruv to‘plamida yo‘qotish funksiyasi va aniqlikning epoxalar bo‘yicha dinamikasi

(cc) BY *dtai.uz*

3-jadval.

Modellarning test to‘plamidagi taqqoslama natijalari

Model	Aniqlik, %	Precision, %	Recall, %	F1, %	Parametrlar	ms / zarba
Random Forest	87,5	90,7	77,2	81,4	—	—
1D-CNN	84,1	83,1	77,0	78,3	11 140	0,071
BiLSTM	**96,3**	**95,5**	**95,5**	**95,5**	10 916	0,057
BiLSTM + Attention	94,0	92,8	95,0	93,8	13 028	0,067
CNN + BiLSTM	92,1	90,6	89,5	90,0	35 972	0,105
CNN + BiLSTM + Attention	93,5	93,4	91,1	92,2	38 084	0,098

Eslatma: Precision, Recall va F1 — makro o‘rtacha qiymatlar. «ms / zarba» — bitta CPU yadrosida, 256 ta zarbadan iborat paketda JAX/XLA yordamida o‘lchangan chiqarish vaqti (dastlabki ishlov berishsiz).

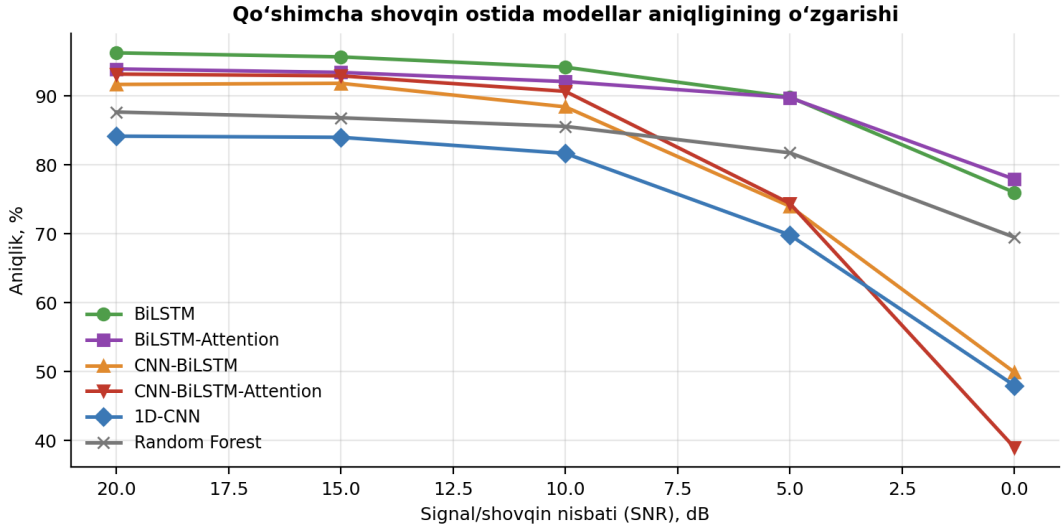
Eng yaxshi model uchun konfuzion matritsa va ROC egri chiziqlari 5-rasmda, sinflar bo‘yicha ko‘rsatkichlar 4-jadvalda berilgan. Test to‘plamidagi 1 200 ta zarbadan 44 tasi noto‘g‘ri sinflangan; ularning 34 tasi (77 %) N va S sinflari o‘rtasidagi chalkashliklardir (19 ta N zarba S deb, 15 ta S zarba N deb aniqlangan). Bu tabiiy holat: ushbu sinflarda QRS majmuasi bir xil bo‘lib, ular asosan amplitudasi kichik P to‘lqini bilan farqlanadi, P to‘lqinini esa shovqin va izochiziq dreyfi eng ko‘p buzadi. V sinfi eng yaxshi ajratildi (F1 = 98,4 %, AUC = 1,000), qo‘shilish zarbalaridan (F) 6 tasi V sinfiga kiritilgan. Barcha sinflar bo‘yicha o‘rtacha AUC 0,996 ni tashkil etdi.

Klinik amaliyotda noaniq zarbalarni mutaxassisga yo‘naltirish xatolar xavfini kamaytiradi. 3-rasmda ko‘rsatilgan ishonchlilik chegarasi $\tau = 0{,}8$ bo‘lganda test zarbalarining 94,6 % i avtomatik sinflangan va ularda aniqlik 97,9 % gacha ko‘tarildi, 5,4 % zarba esa mutaxassis ko‘rigiga yuborildi; $\tau = 0{,}9$ da bu ko‘rsatkichlar mos ravishda 90,6 %, 98,9 % va 9,4 % ni tashkil etdi.

Shovqinga chidamlilik tahlili (6-rasm) neyron modellar o‘rtasida sezilarli farqni ko‘rsatdi. SNR = 20 dB da barcha modellarning aniqligi shovqinsiz holatdagidan deyarli farq qilmadi. SNR = 10 dB da BiLSTM aniqligi 94,2 %, BiLSTM + Attention — 92,1 %, CNN bloki bor gibrid modellar esa 88,4–90,7 % ni tashkil etdi. SNR = 5 dB da BiLSTM va BiLSTM + Attention modellarining aniqligi 89,8 % da saqlanib qolgan bo‘lsa, CNN + BiLSTM va CNN + BiLSTM + Attention modellarida u mos ravishda 74,0 % va 74,4 % gacha pasaydi; 0 dB da esa BiLSTM + Attention (77,9 %) va BiLSTM (76,0 %) eng yuqori natijani saqlab qoldi, CNN + BiLSTM + Attention modeli aniqligi 39,0 % gacha, 1D-CNN aniqligi 48,0 % gacha tushib ketdi. Random Forest shovqinga nisbatan barqarorroq bo‘ldi (0 dB da 69,5 %), biroq toza signalda BiLSTM asosidagi modellardan sezilarli past natija berdi.

Olingan natijalar bir necha xulosa chiqarishga imkon beradi. Birinchidan, bu tajribada eng samarali arxitektura eng murakkabi emas, balki eng sodda ketma-ketlik modeli — BiLSTM bo‘ldi; uning parametrlari soni (10 916) gibrid modelnikidan (38 084) qariyb 3,5 baravar kam. Ehtimol, sintetik zarbalarda diagnostik axborotning asosiy qismi P, QRS va T to‘lqinlarining nisbiy joylashuvi va ketma-ket o‘zgarishida mujassam bo‘lib, uni BiLSTM xom signaldan bevosita samarali o‘zlashtiradi; CNN bloki esa qo‘shimcha parametrlar hisobiga qayta moslashishga moyillikni oshiradi. Bu faraz qo‘shimcha tajribalar (batch-normalizatsiya, ma’lumotlarni kengaytirish, filtrlar sonini kamaytirish) bilan tekshirilishi lozim.

(cc) BY



6-rasm. Qo‘shimcha shovqin ostida modellar aniqligining o‘zgarishi

Ikkinchidan, diqqat mexanizmining ta’siri bir xil emas. Gibrid modelda u test aniqligini 92,1 % dan 93,5 % ga, F1 ni esa 90,0 % dan 92,2 % ga oshirdi; BiLSTM modelida esa tekshiruv to‘plamidagi yo‘qotish va aniqlik biroz yaxshilangan bo‘lsa-da (0,193 dan 0,162 ga va 94,5 % dan 95,6 % ga), test to‘plamida aniqlik 96,3 % dan 94,0 % ga pasaydi. Bunday farqlar (test to‘plamida taxminan 28 ta zarba) bitta tasodifiy boshlang‘ich holat bilan olingan natijalarda statistik jihatdan ishonchli deb hisoblanishi mumkin emas, shu sababli attention foydasi haqida qat’iy xulosa chiqarish uchun bir necha seed bilan takroriy tajribalar zarur. Shu bilan birga, attention mexanizmi eng og‘ir shovqin sharoitida (0 dB) BiLSTM dan biroz yuqori natija berdi va qarorni talqin qilish imkoniyatini yaratadi.

Uchinchidan, eng yaxshi modelning hajmi 10 916 parametrni (32-bitli sonlarda taxminan 44 kB) tashkil etadi, bitta CPU yadrosida bir zarbaga ishlov berish vaqti taxminan 0,06 ms ga teng. Bu ko‘rsatkichlar modelni chekka (edge) hisoblash qurilmalari va kiyiladigan monitorlarda qo‘llash uchun istiqbolli ekanini ko‘rsatadi, biroq ular aynan shu tajriba sharoitida o‘lchangan va mikrokontrollerlarda qayta tekshirilishi kerak.

Tadqiqotning asosiy cheklovlari quyidagilardan iborat: (1) ma’lumotlar sintetik bo‘lib, generator real EKG ning barcha murakkabliklarini (RR oraliqlarining o‘zgarishi, ko‘p kanallilik, bemorlararo morfologik xilma-xillik, harakat artefaktlari) qamrab olmaydi, shuning uchun mutlaq ko‘rsatkichlar (masalan, 96,3 %) real klinik ma’lumotlarga ko‘chirilishi mumkin emas va faqat arxitekturalarni bir xil sharoitda solishtirishga xizmat qiladi; (2) AAMI standartidagi Q sinfi hisobga olinmagan; (3) filtrlash va R cho‘qqilarini aniqlash bosqichlari baholanmagan, zarbalar tayyor segmentlangan holda berilgan; (4) natijalar bitta tasodifiy boshlang‘ich holat bilan olingan; (5) tizim klinik sinovdan o‘tmagan va tibbiy tashxis qo‘yish vositasi sifatida ishlatilishi mumkin emas.

Xulosa va takliflar

Ushbu tadqiqotda biosignallarni, xususan EKG zarbalarini sun’iy intellekt yordamida tahlil qilish masalasi ko‘rib chiqilib, to‘rt sinfli (N, S, V, F) klassifikatsiya uchun CNN, BiLSTM va attention bloklarining turli kombinatsiyalari hamda klassik Random Forest modeli yagona sharoitda qiyoslandi. 40 ta virtual subyektdan olingan 8 000 ta sintetik zarbada, subyektlar bo‘yicha ajratilgan to‘plamlarda o‘tkazilgan tajribalar natijasida eng yuqori natijani BiLSTM modeli ko‘rsatdi — 96,3 % aniqlik, 95,5 % makro F1 va 0,996 o‘rtacha AUC. Shovqinli sharoitda (SNR = 5 dB) BiLSTM va BiLSTM + Attention modellari 89,8 % aniqlikni saqlab qoldi, CNN blokiga ega gibrid modellarda esa bu ko‘rsatkich 74 % atrofiga tushdi. Ishonchlilik chegarasi (τ = 0,8) asosida noaniq zarbalarni mutaxassisga yo‘naltirish aniqlikni 97,9 % gacha oshirdi.

Olingan natijalarga tayanib quyidagi takliflar beriladi: birinchidan, keyingi bosqichda modellarni MIT-BIH kabi real ochiq ma’lumotlar

(cc) BY

to‘plamlarida, bemorlararo (inter-patient) tekshirish tartibida va AAMI ning besh sinfi bo‘yicha sinab ko‘rish; ikkinchidan, har bir arxitektura uchun bir necha tasodifiy boshlang‘ich holat bilan takroriy tajribalar o‘tkazib, farqlarning statistik ahamiyatini baholash; uchinchidan, CNN bloklarida batch-normalizatsiya va ma’lumotlarni kengaytirish usullarini qo‘llab, qayta moslashishni kamaytirish; to‘rtinchidan, ixcham BiLSTM modelini kiyiladigan qurilmalarda (kvantlash orqali) sinab, real vaqt rejimidagi kechikish va energiya sarfini baholash. Taklif etilgan yondashuvni boshqa biosignallar — EEG, EMG va PPG signallarini tahlil qilishda ham qo‘llash mumkin.

Foydalanilgan adabiyotlar ro‘yxati

1. World Health Organization. Cardiovascular diseases (CVDs): Fact sheet. URL: https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds)
2. Moody G.B., Mark R.G. The impact of the MIT-BIH Arrhythmia Database // IEEE Engineering in Medicine and Biology Magazine. 2001. Vol. 20, No. 3. P. 45–50.
3. Goldberger A.L., Amaral L.A.N., Glass L. et al. PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals // Circulation. 2000. Vol. 101, No. 23. P. e215–e220.
4. ANSI/AAMI EC57:2012. Testing and reporting performance results of cardiac rhythm and ST segment measurement algorithms. Association for the Advancement of Medical Instrumentation, 2012.
5. Pan J., Tompkins W.J. A Real-Time QRS Detection Algorithm // IEEE Transactions on Biomedical Engineering. 1985. Vol. BME-32, No. 3. P. 230–236.
6. de Chazal P., O’Dwyer M., Reilly R.B. Automatic Classification of Heartbeats Using ECG Morphology and Heartbeat Interval Features // IEEE Transactions on Biomedical Engineering. 2004. Vol. 51, No. 7. P. 1196–1206.
7. Acharya U.R., Oh S.L., Hagiwara Y. et al. A deep convolutional neural network model to classify heartbeats // Computers in Biology and Medicine. 2017. Vol. 89. P. 389–396.
8. Rajpurkar P., Hannun A.Y., Haghpanahi M., Bourn C., Ng A.Y. Cardiologist-Level Arrhythmia Detection with Convolutional Neural Networks // arXiv preprint arXiv:1707.01836. 2017.
9. Hannun A.Y., Rajpurkar P., Haghpanahi M. et al. Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network // Nature Medicine. 2019. Vol. 25, No. 1. P. 65–69.
10. Hochreiter S., Schmidhuber J. Long Short-Term Memory // Neural Computation. 1997. Vol. 9, No. 8. P. 1735–1780.
11. Schuster M., Paliwal K.K. Bidirectional recurrent neural networks // IEEE Transactions on Signal Processing. 1997. Vol. 45, No. 11. P. 2673–2681.
12. Bahdanau D., Cho K., Bengio Y. Neural Machine Translation by Jointly Learning to Align and Translate // International Conference on Learning Representations (ICLR). 2015. arXiv:1409.0473.
13. Vaswani A., Shazeer N., Parmar N. et al. Attention Is All You Need // Advances in Neural Information Processing Systems (NeurIPS). 2017. Vol. 30. P. 5998–6008.
14. McSharry P.E., Clifford G.D., Tarassenko L., Smith L.A. A dynamical model for generating synthetic electrocardiogram signals // IEEE Transactions on Biomedical Engineering. 2003. Vol. 50, No. 3. P. 289–294.
15. Kingma D.P., Ba J. Adam: A Method for Stochastic Optimization // International Conference on Learning Representations (ICLR). 2015. arXiv:1412.6980.
16. Breiman L. Random Forests // Machine Learning. 2001. Vol. 45, No. 1. P. 5–32.
17. Bradbury J., Frostig R., Hawkins P. et al. JAX: composable transformations of Python+NumPy programs. 2018. URL: https://github.com/jax-ml/jax

(cc) BY *dtai.uz*