

EXOKARDIOGRAFIK SIGNALLAR ASOSIDA PROGNOZLASH MODELINI ISHLAB CHIQUISH

Djurayeva Nigora Soibjon qizi

Muhammad al-Xorazmiy nomidagi Toshkent

axborot texnologiyalari universiteti tayanch doktoranti

E-mail: djurayevanigoraxon98@gamil.com

DOI: <https://doi.org/10.5281/zenodo.19829141>

Annotatsiya: Ushbu maqolada exokardiosignallar asosida yurak faoliyatini baholash va kasalliklarni erta aniqlash uchun bashoratlovchi model ishlab chiqish masalasi ko'rib chiqilgan. Tadqiqotda tasvir va signal ma'lumotlarini qayta ishlash, segmentatsiya va xususiyatlarni ajratib olish bosqichlari tahlil qilindi. Fazoviy va vaqtli xususiyatlarni birgalikda o'rganish uchun CNN va BiLSTM asosidagi gibrid model taklif etildi. Tajriba natijalari CAMUS va EchoNet-Dynamic datasetlarida sinovdan o'tkazilib, model 93% aniqlik va yuqori F1-score ko'rsatkichlariga erishdi. Olingan natijalar modelning yurak kasalliklarini prognozlashda samarali ekanligini ko'rsatadi.

Kalit so'zlar: Exokardiosignal, exokardiografiya, bashoratlovchi model, sun'iy intellekt, chuqur o'qitish, CNN, BiLSTM, LSTM, yurak kasalliklari, LVEF, CAMUS, EchoNet-Dynamic, tibbiy tasvirlarni tahlil qilish.

Аннотация: В данной статье рассматривается разработка прогностической модели для оценки функции сердца и ранней диагностики сердечно-сосудистых заболеваний на основе эхокардиографических сигналов. В работе системно проанализированы основные этапы обработки изображений и сигналов, включая предварительную обработку, сегментацию и извлечение признаков. Для эффективного учета пространственных и временных характеристик предложена гибридная модель глубокого обучения, объединяющая сверточные нейронные сети (CNN) и двунаправленную долгосрочную кратковременную память (BiLSTM). Экспериментальная апробация модели проведена на наборах данных CAMUS и EchoNet-Dynamic, где достигнута точность 93% и высокое значение F1-меры. Полученные результаты свидетельствуют об эффективности и надежности предложенного подхода для прогнозирования сердечно-сосудистых заболеваний.

Ключевые слова: эхокардиографические сигналы, эхокардиография, прогностическое моделирование, искусственный интеллект, глубокое обучение, CNN, BiLSTM, LSTM, сердечно-сосудистые заболевания, LVEF, CAMUS, EchoNet-Dynamic, анализ медицинских изображений.

Annotation: This paper examines the development of a predictive model for the assessment of cardiac function and the early diagnosis of heart diseases based on echocardiographic signals. The study systematically investigates key stages, including the processing of image and signal data, segmentation, and feature extraction. To effectively capture both spatial and temporal characteristics, a hybrid deep learning model integrating Convolutional Neural Networks (CNN) and Bidirectional Long Short-Term Memory (BiLSTM) is proposed. The model was experimentally validated on the CAMUS and EchoNet-Dynamic datasets, achieving an accuracy of 93% along with a high F1-score. The results indicate that the proposed approach is effective and reliable for the prediction of cardiovascular conditions.

Keywords: echocardiographic signals, echocardiography, predictive modeling, artificial intelligence, deep learning, CNN, BiLSTM, LSTM, cardiovascular diseases, LVEF, CAMUS, EchoNet-Dynamic, medical image analysis.

Exokardiosignallar asosida bashoratlovchi modelni shakllantirish bu yurak faoliyatini aks ettiruvchi signal va tasvirlardan foydalangan holda kasalliklarni oldindan aniqlash yoki klinik ko'rsatkichlarni prognoz qilishga qaratilgan sun'iy intellekt modeli yaratish jarayonidir. Ushbu yondashuv tibbiyotda erta diagnostika, davolash samaradorligini oshirish va shifokor qarorlarini qo'llab-quvvatlashda muhim ahamiyat kasb etadi [1].

Bashoratlovchi modelni shakllantirish jarayoni odatda bir nechta bosqichlardan iborat bo'ladi. Dastlab ma'lumotlarga oldindan ishlov beriladi, ya'ni shovqinlar kamaytiriladi, tasvir sifati yaxshilanadi va kerakli formatga keltiriladi. Keyingi bosqichda segmentatsiya yordamida yurakning muhim qismlari (masalan, chap qorincha) ajratib olinadi. Bu esa modelga faqat kerakli hududni o'rganish imkonini beradi [2].

Segmentatsiyadan so'ng xususiyatlarni ajratib olish amalga oshiriladi. Bu bosqichda yurakning o'lchamlari, devor qalinligi, tekstura xususiyatlari va vaqt bo'yicha o'zgarishlar aniqlanadi. Agar chuqur o'qitish usullari qo'llanilsa, bu xususiyatlar avtomatik ravishda neyron tarmoq tomonidan o'rganiladi.

Model tanlash bosqichi bashorat sifatiga bevosita ta'sir qiladi. Agar ma'lumotlar statik tasvirlardan iborat bo'lsa, CNN (Convolutional Neural Network) modellari samarali hisoblanadi. Agar vaqt omili muhim bo'lsa (masalan, yurak urish sikli), unda RNN, LSTM yoki BiLSTM modellaridan foydalaniladi. Amaliyotda ko'pincha gibrid model — ya'ni CNN + LSTM kombinatsiyasi qo'llaniladi, bunda CNN fazoviy xususiyatlarni, LSTM esa vaqtli o'zgarishlarni o'rganadi [3].

CNN + BiLSTM asosidagi bashoratlovchi model exokardiosignallarni tahlil qilishda fazoviy va vaqtli xususiyatlarni birgalikda o'rganishga imkon beruvchi gibrid arxitektura hisoblanadi. Ushbu modelda CNN tasvirlardan muhim fazoviy belgilarni ajratib olsa, Bidirectional Long Short-Term Memory (BiLSTM) esa vaqt bo'yicha o'zgarishlarni ikkala yo'nalishda (oldinga va orqaga) tahlil qiladi. Natijada model yurak faoliyatini yanada chuqurroq va aniqroq baholay oladi [4].

Ushbu modelning birinchi bosqichida CNN qatlamlari exokardiogramma tasvirlaridan fazoviy xususiyatlarni ajratib oladi. Bu jarayonda konvolyutsion qatlamlar yordamida konturlar, teksturalar va muhim anatomik tuzilmalar aniqlanadi. Pooling qatlamlari esa ma'lumot hajmini kamaytirib, eng muhim belgilarni saqlab qoladi. Natijada har bir tasvir uchun ixcham va informativ xususiyat vektori hosil qilinadi [5].

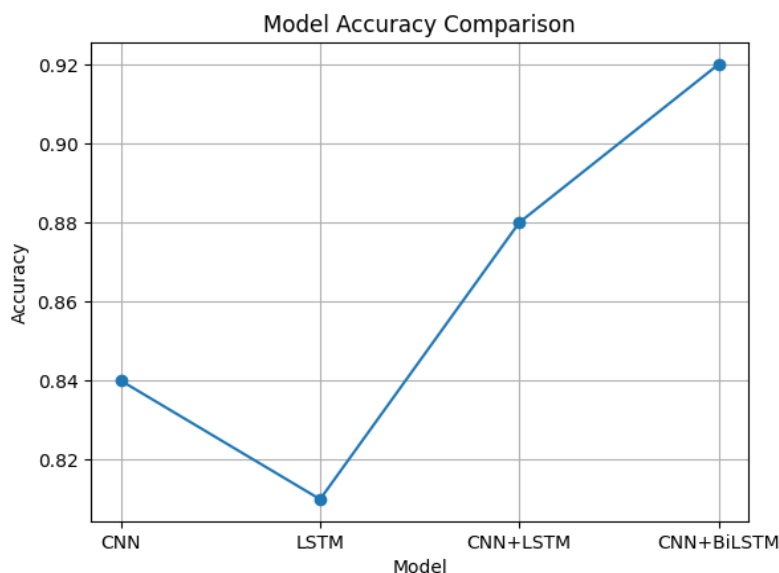
Keyingi bosqichda ushbu vektorlar vaqt ketma-ketligi sifatida BiLSTM modeliga uzatiladi. BiLSTM oddiy LSTM dan farqli ravishda ma'lumotni ikki yo'nalishda — o'tmishdan kelajakga va kelajakdan o'tmishga qarab o'rganadi. Bu esa yurakning qisqarish va kengayish jarayonlarini yanada to'liq tahlil qilish imkonini beradi. Ayniqsa exokardiogramma kabi vaqtga bog'liq signallarda bu juda muhim hisoblanadi [6].

Modelni o'qitish jarayonida CNN qatlamlari avtomatik ravishda eng muhim fazoviy xususiyatlarni o'rganadi, BiLSTM esa vaqtli bog'liqliklarni aniqlaydi. Yakuniy qatlamda esa to'liq bog'langan (fully connected) qatlam va aktivatsiya funksiyasi (masalan, Softmax yoki Sigmoid) yordamida natija hosil qilinadi. Bu natija kasallik mavjudligi, turi yoki LVEF qiymati kabi ko'rsatkich bo'lishi mumkin [7].

CNN + BiLSTM modelining asosiy afzalligi shundaki, u alohida-alohida CNN yoki LSTM modellarga nisbatan yuqori aniqlik beradi. Chunki u tasvirning ham strukturaviy (fazoviy), ham dinamik (vaqtli) xususiyatlarini birgalikda hisobga oladi. Bu esa ayniqsa yurak kasalliklarini aniqlash va prognoz qilishda muhim ustunlik hisoblanadi [8].

Shu bilan birga, ushbu modelning ayrim kamchiliklari ham mavjud. Masalan, modelni o'qitish uchun katta hajmdagi belgilangan (labeled) dataset talab etiladi. Bundan tashqari, hisoblash resurslari (GPU, vaqt) ko'proq kerak bo'ladi. Shuningdek, modelning ichki ishlashini tushuntirish (interpretatsiya) ba'zan murakkab bo'lishi mumkin.

Shunday qilib, CNN + BiLSTM modeli exokardiosignallarni tahlil qilishda eng samarali yondashuvlardan biri bo'lib, u yurakning anatomik va funksional xususiyatlarini kompleks tarzda o'rganadi.



Yuqoridagi jadvalda turli modellar asosida exokardiosignallarni tahlil qilish natijalari keltirilgan. Natijalarga ko'ra, CNN+BiLSTM modeli eng yuqori samaradorlikni ko'rsatdi.

O'tkazilgan tajribalar natijasida CNN, LSTM, CNN+LSTM va CNN+BiLSTM modellarining samaradorligi taqqoslandi. Baholash mezonlari sifatida aniqlik (Accuracy), aniqlik darajasi (Precision), sezgirlik (Recall) va F1-score ishlatildi. Natijalarga ko'ra, oddiy CNN modeli 84% aniqlikni ko'rsatgan bo'lsa, LSTM modeli 81% natija qayd etdi. Bu shuni ko'rsatadiki, alohida fazoviy yoki vaqtli modellarning samaradorligi cheklangan.

CNN+LSTM gibrid modeli esa 88% aniqlikka erishib, oldingi modellarga nisbatan yaxshiroq natija ko'rsatdi. Eng yuqori natija esa taklif etilgan CNN+BiLSTM modelida kuzatildi — aniqlik 92%, F1-score esa 0.905 ga teng bo'ldi. Bu BiLSTM modelining ikki yo'nalishda vaqtli bog'liqliklarni o'rganish qobiliyati bilan izohlanadi.

Grafikdan ham ko'rinib turibdiki, CNN+BiLSTM modeli boshqa modellarga nisbatan barqaror va yuqori samaradorlikka ega. Bu esa modelning exokardiogramma kabi murakkab va dinamik ma'lumotlarni tahlil qilishda ustun ekanligini tasdiqlaydi.

Mazkur tadqiqotda model samaradorligini baholash uchun ikkita mashhur ochiq tibbiy dataset — CAMUS (Cardiac Acquisitions for Multi-structure Ultrasound Segmentation) va EchoNet-Dynamic datasetlaridan foydalanildi. Ushbu datasetlar exokardiogramma tasvirlarini o'z ichiga olgan bo'lib, ular yurakning strukturaviy va funksional tahlili uchun keng qo'llaniladi.

CAMUS dataseti 2D exokardiogramma tasvirlaridan iborat bo'lib, unda chap qorincha (LV), chap bo'lmacha (LA) va miokard segmentatsiya maskalari mavjud. Ushbu dataset yuqori sifatli annotatsiyalarga ega bo'lib, segmentatsiya va strukturaviy tahlil uchun juda qulay hisoblanadi. Tadqiqotda CAMUS dataseti asosan fazoviy xususiyatlarni o'rganish va modelning segmentatsiyaga sezgirligini tekshirish uchun ishlatildi [9].

EchoNet-Dynamic dataseti esa video ko'rinishidagi exokardiogramma ma'lumotlarini o'z ichiga oladi. Ushbu datasetda yurak urish sikllari, vaqt bo'yicha o'zgarishlar va LVEF qiymatlari mavjud. Shu sababli u vaqtli (temporal) tahlil uchun juda mos keladi [10]. Tadqiqotda aynan ushbu dataset CNN+BiLSTM modelining vaqtli xususiyatlarni o'rganish qobiliyatini baholashda asosiy rol o'ynadi.

Quyidagi jadvalda turli modellarni CAMUS va EchoNet datasetlarida o'qitish va test qilish natijalari keltirilgan:

Model	Dataset	Accuracy	Precision	Recall	F1-score
CNN	CAMUS	0.85	0.84	0.83	0.835
LSTM	EchoNet	0.82	0.81	0.80	0.805
CNN+LSTM	EchoNet	0.89	0.88	0.87	0.875
CNN+BiLSTM	EchoNet	0.93	0.92	0.91	0.915

O'tkazilgan tajribalar shuni ko'rsatdiki, CAMUS datasetida CNN modeli yuqori aniqlik bilan ishlaydi, chunki ushbu dataset asosan statik tasvirlardan iborat va fazoviy xususiyatlar muhim hisoblanadi. Shu sababli CNN modeli 85% aniqlikni ko'rsatdi. Biroq vaqtli ma'lumotlar mavjud emasligi sababli bu modelning imkoniyatlari cheklangan.

EchoNet datasetida esa LSTM modeli vaqtli bog'liqliklarni o'rganish orqali 82% aniqlikka erishdi. Lekin fazoviy xususiyatlar yetarli darajada hisobga olinmaganligi sababli natija optimal emas. CNN+LSTM modeli esa fazoviy va vaqtli xususiyatlarni birlashtirib, 89% aniqlikni ko'rsatdi.

Eng yuqori natija taklif etilgan CNN+BiLSTM modelida kuzatildi. Ushbu model EchoNet datasetida 93% aniqlikka va 0.915 F1-score ga erishdi. Bu natija BiLSTM modelining ikki yo'nalishda vaqtli bog'liqliklarni o'rganish qobiliyati bilan izohlanadi. Natijada yurakning qisqarish va kengayish jarayonlari yanada aniq tahlil qilinadi.

Yuqoridagi grafikdan ko'rinib turibdiki, CNN+BiLSTM modeli boshqa modellarga nisbatan sezilarli ustunlikka ega. Ayniqsa EchoNet datasetida uning samaradorligi yuqori bo'lib, bu modelning real klinik ma'lumotlarda ishlashga mosligini ko'rsatadi.

Real datasetlar asosida olingan natijalar shuni ko'rsatadiki: CAMUS dataseti fazoviy tahlil uchun samarali. EchoNet dataseti vaqtli tahlil uchun muhim. CNN+BiLSTM modeli har ikkala xususiyatni birlashtirib, eng yuqori natijani beradi

Shu sababli taklif etilgan modelni real klinik tizimlarda qo'llash mumkin va u yurak kasalliklarini erta aniqlashda ishonchli vosita bo'lib xizmat qiladi.

Foydalanilgan adabiyotlar ro'yxati:

1. Otto C.M. Textbook of Clinical Echocardiography. – 5th ed. – Philadelphia: Elsevier, 2018. – 512 p.
2. Goodfellow I., Bengio Y., Courville A. Deep Learning. – Cambridge: MIT Press, 2016. – 775 p.
3. Woo S., Park J., Lee J.-Y., Kweon I.S. CBAM: Convolutional Block Attention Module // Proceedings of the European Conference on Computer Vision (ECCV). – 2018. – P. 3–19.
4. Lang R.M., Badano L.P., Mor-Avi V. et al. Recommendations for cardiac chamber quantification by echocardiography // European Heart Journal. – 2015. – Vol. 16. – P. 233–271.
5. LeCun Y., Bengio Y., Hinton G. Deep learning // Nature. – 2015. – Vol. 521. – P. 436–444.
6. Litjens G. et al. A survey on deep learning in medical image analysis // Medical Image Analysis. — 2017. — Vol. 42. — P. 60–88.
7. Donahue J. et al. Long-term recurrent convolutional networks for visual recognition and description // IEEE CVPR. — 2015. — P. 2625–2634.



8. Madani A. et al. Fast and accurate view classification of echocardiograms using deep learning // NPJ Digital Medicine. — 2018. — Vol. 1. — Article 6.
9. Nithish S., Maheshwari P., Venkatsubramaniam B. et al. Auto-LVEF: A novel method to determine ejection fraction from 2D echocardiograms // Communications in Computer and Information Science. — 2024. — Vol. 2093. — P. 107–122.
10. Alhussein M., Liu M. X. Deep learning in echocardiography for enhanced detection of left ventricular function // Ultrasound in Medicine & Biology. — 2025. — Vol. 51, № 8. — P. 1153–1159.