

# Klasifikacija vremenskih serija primenom hibridnog CNN-LSTM modela

Katarina Vujić  
Katedra za signale i sisteme  
Elektrotehnički fakultet, Univerzitet u  
Beogradu  
Beograd, Srbija  
vk233018m@student.etf.bg.ac.rs

Marija Novičić  
Katedra za signale i sisteme  
Elektrotehnički fakultet, Univerzitet u  
Beogradu  
Beograd, Srbija  
novicic@etf.bg.ac.rs  
0000-0001-9713-810X

Goran Kvašček  
Katedra za signale i sisteme  
Elektrotehnički fakultet, Univerzitet u  
Beogradu  
Beograd, Srbija  
kvascev@etf.bg.ac.rs  
0000-0001-8642-0361

**Abstract**— Ovaj rad istražuje primenu dubokog učenja za klasifikaciju srčanih aritmija, fokusirajući se na kombinaciju konvolucione neuralne mreže i duge kratkoročne memorije, omogućavajući bolje razumevanje vremenskih i prostornih karakteristika elektrokardiogramskih signala iz MIT-BIH baze podataka. Kroz sistematično treniranje i evaluaciju modela, dobijena je tačnost od 97,59% na test skupu. Ovi rezultati ukazuju na obećavajuće performanse modela u klasifikaciji srčanih aritmija, ističući potencijal dubokog učenja u medicinskoj dijagnostici i lečenju srčanih oboljenja. Ovo istraživanje doprinosi razumevanju primene dubokog učenja u medicini, sa primenom za unapređenje rada zdravstvenog osoblja.

**Cljučne reči**— Konvolucione neuralne mreže; Duga kratkoročna memorija; Duboko učenje; Elektrokardiogram.

## I. UVOD

Aritmije predstavljaju značajne izazove u zdravstvenoj dijagnostici i lečenju, a pretpostavlja se da 1,5-5% ukupne populacije boluje od neke vrste aritmije [1]. Precizno otkrivanje i klasifikovanje aritmija je ključno za pravovremene intervencije. Najznačajniji doprinos u polju poboljšanja automatizacije ovog procesa, kao i analizi elektrokardiograma (EKG) bio je u okviru istraživanja u kojima su se primenjivale metode mašinskog [2], [3] i dubokog učenja, naročito osvrćući se na transfer učenje [4], [5].

Nekoliko zapaženih studija doprinelo je napretku u klasifikaciji aritmija koristeći bazu podataka MIT-BIH [6]. Ova baza podataka se pokazala kao izuzetno pogodna za primenu različitih tehnika mašinskog učenja za klasifikaciju normalnih i abnormalnih EKG signala, kao što su Bajesov klasifikator (eng. *Bayesian Classifier*, BC) [3], metod potpornih vektora (eng. *Support Vector Machine*, SVM) [7], neuralne mreže (eng. *Artificial Neural Network*, ANN) sa algoritmom propagacije unazad [8], kao i rekurentne neuralne mreže (eng. *Recurrent Neural Networks*, RNN) [9].

Sa porastom interesovanja za duboko učenje, rađena su brojna istraživanja korišćenjem različitih modela. Studija opisana u radu [10] je pokazala uspešnost korišćenja konvolucione neuralne mreže u identifikaciji pet različitih kategorija otkucaja srca u EKG signalima. U ovom radu je pokazana uspešnost klasifikacije nad originalnim signalima iz baze i nad signalima sa odstranjenim šumom. Pokazano je da su rezultati bolji u slučaju kada se koriste originalni signali.

Značajne rezultate imale su metode transfer učenja, naročito modeli sa Res-Net18 arhitekturom mreže [5].

Ove studije služe kao osnova za dalja istraživanja i ideje za nastavak rada. U ovom radu će se razmotriti primena konvolucionih neuralnih mreža (eng. *Convolutional Neural Networks*, CNN) i duge kratkoročne memorije (eng. *Long Short-term Memory*, LSTM).

Kombinovana upotreba CNN i LSTM slojeva predstavlja hibridni pristup klasifikaciji signala sa primenama u različitim domenima, demonstrirajući svoju prilagodljivost i efikasnost. U medicini, ova tehnika se odlično pokazala za automatsko otkrivanje bolesti kao što je COVID-19 na rendgenskim slikama [11]. Pored toga, ovakva mreža može se primeniti za monitoring životne sredine, gde precizno simulira nivoe vode i kvalitet na osnovu različitih podataka [12]. CNN slojevi su odlični u prepoznavanju lokalnih prostornih obrazaca u podacima, što ih čini pogodnim za analizu oblika i morfologije EKG signala [13], dok su LSTM slojevi specijalizovani za razumevanje vremenskih zavisnosti i sekvencijalnih obrazaca u podacima [14]. Pristup koji kombinuje ove dve vrste neuralnih mreža omogućava modelu da uoči suptilne razlike između različitih tipova aritmija izdvajanjem i prostornih i vremenskih karakteristika iz EKG signala. CNN su se pokazale indiferentnim na prostorne varijacije i šum u podacima, što ih čini efikasnim u obradi EKG signala, koji su veoma podložni različitim artefaktima i varijabilnosti zbog faktora kao što su pomeranje elektroda i kretanje pacijenta [15]. CNN omogućavaju izdvajanje robusnih karakteristika koje su nepromenljive u odnosu na šum i prostorne varijacije. Prethodnom obradom podataka sa CNN slojevima poboljšava se ukupna robusnost modela klasifikacije.

Aritmije se često manifestuju kao složeni vremenski obrasci u EKG signalima [16], koji se teško uočavaju. LSTM mreže, sa svojom sposobnošću da razumeju dugoročne zavisnosti u sekvencijalnim podacima, su veoma pogodne za modeliranje takve vremenske dinamike. Ugrađivanjem LSTM slojeva u arhitekturu modela, model može efikasno da shvati dinamičku prirodu aritmija i nauči da prepozna složene obrasce koji se vremenom razvijaju. Zajednička primena CNN i LSTM slojeva nudi poboljšanu interpretabilnost korišćenjem prednosti obe arhitekture.

Ovaj rad je podeljen u sledeće sekcije: Sekcija 2 daje uvid u bazu podataka i arhitekturu korišćenog modela, Sekcija 3 sadrži rezultate klasifikacije EKG signala iz MIT-BIH baze sa diskusijom, dok je u Sekciji 4 dat zaključak samog rada.

This work was financially supported by the Ministry of Science, Technological Development and Innovation of the Republic of Serbia under contract number: 451-03-65/2024- 03/200103 and Science Fund of the Republic of Serbia, 1375/2023, NOx Reduction Based Thermal Power Plant Optimization - NOXTROT.

## II. METOD

### A. Baza podataka

Za potrebe ovog rada, korišćena je baza podataka MIT-BIH, koja je jedna od široko korišćenih javno dostupnih baza podataka za otkrivanje i klasifikaciju aritmija u EKG signalima. Razvijena je od strane Masačusetskog tehnološkog instituta (MIT) i bolnice Bet Izrael.

Baza sadrži dvokanalni ambulatorni EKG prikupljen na 47 ispitanika sa različitim vrstama aritmija u periodu od nekoliko godina. Trajanje jednog EKG signala je 30 min, a signali su prikupljeni sa učestanošću odabiranja od 360 Hz.

Svaki otkucaj u bazi podataka je ručno obeležen od strane obučanih kardiologa, obezbeđujući beleške za različite tipove aritmija (Sl. 1). Na raspolaganju je bilo 87554 anotiranih otkucaja srca podeljenih u pet klasa. Ovi signali su korišćeni kao trening skup. U Tabeli 1 je dat pregled klasa sa pridruženim brojem odbiraka koji se nalazi u njoj.

### B. Pretprocesiranje podataka


Posmatrajući trening skup podataka, primećena je značajna neuravnoteženost klasa. Izvršeno je balansiranje podataka da bi svaka klasa imala podjednak broj odbiraka tako što je najveća klasa smanjena slučajnim putem, a manjim klasama je povećan broj odbiraka takođe nasumičnim odabirom. Zasad robusnosti rešenja i veće raznolikosti obučavajućeg skupa, uključen je beli Gausov šum nulte srednje vrednosti i standardne devijacije od 0,02 na signale u skupu.

### C. Arhitektura modela

Arhitektura modela se sastoji od kombinacije CNN i LSTM slojeva, dizajniranih da klasifikuju EKG signale u pet različitih klasa aritmija. Arhitektura mreže prikazana je na Sl. 2. Tri konvoluciona bloka se koriste za izdvajanje karakteristika iz ulaznih EKG signala. Jedan blok se sastoji od konvolucionog sloja, ReLu aktivacione funkcije i *MaxPooling* sloja.

Sva tri bloka se međusobno razlikuju po vrednostima prosleđenih parametara, omogućavajući modelu da prepozna različite obrasce unutar ulaznih podataka. Nakon konvolucionih slojeva, izdvojene karakteristike se dovode na dva LSTM sloja, koji su od suštinskog značaja za razumevanje vremenskih zavisnosti u sekvencijalnim podacima. Na kraju se nalaze dva potpuno povezana sloja (eng. *Fully Connected*, FC) sa *ReLU* aktivacionom funkcijom i jedan klasifikacioni sloj sa *softmax* aktivacionom funkcijom.

Kako bi se maksimizovale performanse izvršena je optimizacija hiperparametara modela. Za pronalaženje najboljih hiperparametara korišćena je nasumična pretraga, a optimizovani su parametri konvolucionih slojeva (broj i veličina filtera), parametri *MaxPool* slojeva (veličina filtera i pomeraj), broj neurona LSTM slojeva i broj neurona u FC slojevima. Osim parametara arhitekture modela optimizovana je i konstanta obučavanja. Hiperparametri koji su dobijeni ovom pretragom, prikazani su u Tabeli 2. U borbi protiv preobučavanja korišćena je metoda ranog zaustavljanja.




Sl. 1 Primer obeleženog EKG signala u MIT-BIH bazi podataka. Slika preuzeta iz [6]

TABELA I. OZNAKE KLASA ARITMIJA I NJIHOVO ZNAČENJE

Oznaka klase	Značenje	Broj odbiraka
N	Normalni otkucaji srca	72471
S	Preвременa supraventrikularna kontrakcija	6431
V	Preвременa ventrikularna kontrakcija	5788
F	Otkucaji srca fuzionog porekla	2223
Q	Otkucaji srca nepoznatog porekla	641

TABELA II. OPTIMALNI HIPERPARAMETRI

	Hiperparametar	Vrednost
Prvi CNN blok	Broj filtera	256
	Veličina jezgra	4
	Veličina <i>pool</i> prozora	2
	Pomeraj <i>pool</i> prozora	2
Drugi CNN blok	Broj filtera	64
	Veličina jezgra	3
	Veličina <i>pool</i> prozora	2
	Pomeraj <i>pool</i> prozora	3
Treći CNN blok	Broj filtera	80
	Veličina jezgra	3
	Veličina <i>pool</i> prozora	2
	Pomeraj <i>pool</i> prozora	2
Prvi LSTM sloj	Broj jedinica na izlazu	96
Drugi LSTM sloj	Broj jedinica na izlazu	48
Prvi FC sloj	Broj jedinica na izlazu	80
	Broj jedinica na izlazu	112
	Konstanta učenja	0.001



Sl. 2 Arhitektura mreže

### III. REZULTATI

Obučeni model je evaluiran na skupu za testiranje da bi se procenila njegova sposobnost generalizacije. Metrike performansi kao što su tačnost, F1-skor, preciznost i stopa stvarnih pozitivna su izračunate da bi se kvantifikovao učinak klasifikacije modela u različitim klasama aritmija na test skupu. Performanse modela prikazane su u Tabeli 3. Na Sl. 3 je prikazana matrica konfuzije kako bi se vizualizovala predviđanja modela i identifikovali potencijalni izvori pogrešne klasifikacije.

Dobijeni rezultati pokazuju efikasnost predložene arhitekture modela u preciznoj klasifikaciji EKG signala u pet različitim klasa aritmija. Model je postigao visoku ukupnu tačnost i pokazao robusne performanse u svim klasama na skupu za testiranje, što ukazuje na njegovu efikasnost u razlikovanju između različitih tipova aritmija. Štaviše, sposobnost modela da generalizuje neviđene podatke ukazuje na njegov potencijal za primene u stvarnom svetu u kliničkim okruženjima.

U poređenju sa drugim postojećim metodama, Tabela 4 prikazuje pregled tačnosti predloženog CNN-LSTM modela zajedno sa različitim modelima i pristupima pri klasifikaciji aritmija u pet klasa. Tabela ilustruje superiorne performanse predloženog modela, sa značajno većom tačnošću. Ovi rezultati naglašavaju efikasnost CNN-LSTM arhitekture u klasifikaciji aritmija i njen potencijal da nadmaši tradicionalne metode.

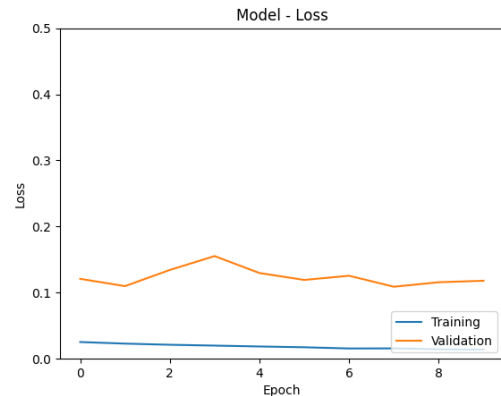
TABELA III. PERFORMANSE MODELA

Metrika	Performanse modela (%)
Tačnost	97,59
F1-skor	97,71
Preciznost	97,92
Stopa stvarnih pozitivna	97,59

Željeni izlaz	Predikcije				
	N	S	V	F	Q
N	0.98	0.01	0.0	0.0	0.0
S	0.12	0.86	0.01	0.01	0.0
V	0.02	0.0	0.95	0.02	0.0
F	0.04	0.0	0.06	0.9	0.0
Q	0.0	0.0	0.0	0.0	0.99

Sl. 3 Matrica konfuzije

Na Sl. 4 prikazan je grafik gubitaka na kome opadajuća kriva ukazuje na smanjenje greške tokom obučavanja. Konvergencija i trend krive sugerise da je model dostigao optimalno stanje i da nije došlo do preobučavanja.



Sl. 4 Gubici na trening i test skupu

TABELA IV. POREĐENJE PERFORMANSI MODELA IZ PRETHODNIH RADOVA I PREDLOŽENOG MODELA

Autori	Metoda klasifikacije	Tačnost (%)
Y. Zhang, et al. [10]	CNN	94,03
V. H. C. De Albuquerque, et al. [3]	BC	90,95
M. Cao, et al. [5]	ResNet-18	90,80
Z. Zhang, et al. [7]	SVM	86,66
S. Singh, et al. [9]	RNN	83.1
Predloženi metod	CNN - LSTM	97,59

### IV. ZAKLJUČAK

Ovaj rad pokazuje efikasnost modela neuralne mreže sa CNN i LSTM slojevima za klasifikaciju EKG signala, što je dovelo do poboljšane tačnosti klasifikacije i performansi u poređenju sa tradicionalnim pristupima mašinskog učenja.

Dobre performanse modela naglašavaju njegovu kliničku relevantnost i potencijal za primene u stvarnim sistemima za automatsku dijagnozu EKG signala.

Iako ovaj rad pruža obećavajuće rezultate, postoje različite mogućnosti za buduća istraživanja. Na primer, sprovođenje eksperimenata nad većim i raznovrsnijim skupovima podataka moglo bi poboljšati generalizaciju i skalabilnost predloženog pristupa.

## REFERENCE/LITERATURA

- [1] D. S. Desai and S. Hajouli, "Arrhythmias," in *StatPearls, Treasure Island (FL): StatPearls Publishing*, 2024. Accessed: Feb. 16, 2024. [Online]. Available: <http://www.ncbi.nlm.nih.gov/books/NBK558923/>
- [2] V. Singh, S. Tewary, V. Sardana, and H. Sardana, "Arrhythmia Detection - A Machine Learning based Comparative Analysis with MIT-BIH ECG Data." 2019, p. 5. doi: 10.1109/I2CT45611.2019.9033665.
- [3] V. H. C. De Albuquerque et al., "Robust automated cardiac arrhythmia detection in ECG beat signals," *Neural Comput. Appl.*, vol. 29, no. 3, pp. 679–693, Feb. 2018, doi: 10.1007/s00521-016-2472-8.
- [4] R. S. Sabeenian and K. K. Sree Janani, "Transfer Learning-Based Electrocardiogram Classification Using Wavelet Scattered Features," *Biomed. Biotechnol. Res. J. BBRJ*, vol. 7, no. 1, p. 52, Mar. 2023, doi: 10.4103/bbrj.bbrj\_341\_22.
- [5] M. Cao, T. Zhao, Y. Li, W. Zhang, P. Benharash, and R. Ramezani, "ECG Heartbeat classification using deep transfer learning with Convolutional Neural Network and STFT technique," *J. Phys. Conf. Ser.*, vol. 2547, no. 1, p. 012031, Jul. 2023, doi: 10.1088/1742-6596/2547/1/012031.
- [6] G. B. Moody and R. G. Mark, "The impact of the MIT-BIH Arrhythmia Database," *IEEE Eng. Med. Biol. Mag.*, vol. 20, no. 3, pp. 45–50, May 2001, doi: 10.1109/51.932724.
- [7] Z. Zhang, J. Dong, X. Luo, K.-S. Choi, and X. Wu, "Heartbeat classification using disease-specific feature selection," *Comput. Biol. Med.*, vol. 46, pp. 79–89, Mar. 2014, doi: 10.1016/j.combiomed.2013.11.019.
- [8] A. Vishwa, M. K. Lal, S. Dixit, and P. Vardwaj, "Clasification Of Arrhythmic ECG Data Using Machine Learning Techniques," *Int. J. Interact. Multimed. Artif. Intell.*, vol. 1, no. 4, p. 67, 2011, doi: 10.9781/ijimai.2011.1411.
- [9] S. Singh, S. Pandey, U. Pawar, and R. Janghel, "Classification of ECG Arrhythmia using Recurrent Neural Networks," *Procedia Comput. Sci.*, vol. 132, pp. 1290–1297, Jan. 2018, doi: 10.1016/j.procs.2018.05.045.
- [10] Y. Zhang, J. Yi, A. Chen, and L. Cheng, "Cardiac arrhythmia classification by time–frequency features inputted to the designed convolutional neural networks," *Biomed. Signal Process. Control*, vol. 79, p. 104224, Jan. 2023, doi: 10.1016/j.bspc.2022.104224.
- [11] Md. Z. Islam, Md. M. Islam, and A. Asraf, "A combined deep CNN-LSTM network for the detection of novel coronavirus (COVID-19) using X-ray images," *Inform. Med. Unlocked*, vol. 20, p. 100412, Jan. 2020, doi: 10.1016/j.imu.2020.100412.
- [12] S.-S. Baek, J. Pyo, and J. A. Chun, "Prediction of Water Level and Water Quality Using a CNN-LSTM Combined Deep Learning Approach," *Water*, vol. 12, no. 12, Art. no. 12, Dec. 2020, doi: 10.3390/w12123399.
- [13] M. Chourasia, A. Thakur, S. Gupta, and A. Singh, "ECG Heartbeat Classification Using CNN," in *2020 IEEE 7th Uttar Pradesh Section International Conference on Electrical, Electronics and Computer Engineering (UPCON)*, Nov. 2020, pp. 1–6. doi: 10.1109/UPCON50219.2020.9376451.
- [14] S. Saadatnejad, M. Oveisi, and M. Hashemi, "LSTM-Based ECG Classification for Continuous Monitoring on Personal Wearable Devices," *IEEE J. Biomed. Health Inform.*, vol. 24, no. 2, pp. 515–523, Feb. 2020, doi: 10.1109/JBHI.2019.2911367.
- [15] S. Chatterjee, R. S. Thakur, R. N. Yadav, L. Gupta, and D. K. Raghuvanshi, "Review of noise removal techniques in ECG signals," *IET Signal Process.*, vol. 14, no. 9, pp. 569–590, 2020, doi: 10.1049/iet-spr.2020.0104.
- [16] L. Sörnmo and P. Laguna, "Electrocardiogram (ECG) Signal Processing," in *Wiley Encyclopedia of Biomedical Engineering*, 1st ed., M. Akay, Ed., Wiley, 2006. doi: 10.1002/9780471740360.ebs1482.

## ABSTRACT

This paper investigates the application of deep learning for the classification of cardiac arrhythmias, focusing on the combination of a convolutional neural network and long short-term memory, allowing a better understanding of the temporal and spatial characteristics of electrocardiogram signals from the MIT-BIH database. Through systematic training and evaluation of the model, an accuracy of 97.59% was obtained on the test set.

These results indicate the promising performance of the model in the classification of cardiac arrhythmias, highlighting the potential of deep learning in the medical diagnosis and treatment of heart diseases. This research contributes to the understanding of the application of deep learning in medicine, with an application for improving the work of healthcare personnel.

Keywords—Convolutional neural networks; Long short-term memory; Deep learning; Electrocardiogram.

### CLASSIFICATION OF TIME SERIES USING THE HYBRID CNN-LSTM MODEL

Katarina Vujić, Marija Novičić, Goran Kvaščev