

PRIMENA VEŠTAČKIH NEURONSKIH MREŽA U ESTIMACIJI UNUTRAŠNJE TELESNE TEMPERATURE**APPLICATION OF ARTIFICIAL NEURAL NETWORKS IN ESTIMATING CORE BODY TEMPERATURE**Vukašin Pavković, *Fakultet tehničkih nauka, Novi Sad***Oblast – ELEKTROTEHNIKA I RAČUNARSTVO**

Kratak sadržaj – Rad se bavi procenom unutrašnje telesne temperature čoveka na osnovu neinvazivnih fizioloških signala. Primenom različitih arhitektura veštačkih neuronskih mreža razvijeni su modeli za estimaciju unutrašnje temperature. Nakon obrade i normalizacije podataka, modeli su obučeni i testirani, a njihova tačnost procenjena primenom standardnih metrika

Ključne reči: Veštačke neuronske mreže, unutrašnja telesna temperatura, obrada podataka

Abstract – This thesis addresses the estimation of core body temperature using non-invasive physiological signals. Machine-learning models based on different artificial neural-network architectures were developed to estimate temperature. After data preprocessing and normalization, the models were trained and tested, and their accuracy assessed with standard regression metrics.

Keywords: Artificial neural networks, core body temperature, data processing

1. UVOD

Precizno praćenje unutrašnje telesne temperature je od suštinskog značaja u mnogim situacijama od intenzivne nege pacijenata do praćenja stanja sportista i radnika u ekstremnim uslovima [1]. Unutrašnja telesna temperatura pouzdan je indikator zdravstvenog stanja; čak i relativno mala odstupanja mogu ukazivati na ozbiljne probleme (npr. hipertermiju ili hipotermiju). Ipak, direktno merenje temperature jezgra tela obično zahteva invazivne metode (npr. rektalne ili ezofagealne sonde) koje nisu pogodno za kontinuirani nadzor ili terensku primenu [2]. Razvoj neinvazivnih metoda za procenu unutrašnje temperature postao je važan istraživački izazov. Jedan od pristupa je korišćenje veštačkih neuronskih mreža (VNM) koji na osnovu lako merljivih fizioloških signala mogu predvideti unutrašnju temperaturu. Motivi za primenu VNM leže u njihovoj sposobnosti da modeluju složene nelinearne odnose između ulaznih parametara (npr. temperatura kože, puls, spoljašnja temperatura okoline) i telesne temperature. Na taj način, moguće je dizajnirati sistem za kontinuirano praćenje koji je istovremeno neinvazivan i dovoljno precizan.

NAPOMENA:

Ovaj rad proistekao je iz master rada čiji mentor je bio dr Nikola Jorgovanović, red. prof.

U ovom radu istražene su dve strukture neuronskih mreža: klasična feedforward mreža i njena proširena verzija rekurentna feedforward mreža sa ciljem estimacije unutrašnje telesne temperature.


2. METODOLOGIJA**2.1. Prikupljanje i obrada podataka**

U istraživanju su korišćeni preuzeti podaci prikupljeni sa više ispitanika tokom kontrolisanih fizičkih aktivnosti u okviru projekta SixthSense. Merene su spoljašnje fiziološke veličine, uključujući temperaturu na površini grudnog koša, srčana frekvencija i varijabilnost srčanog ritma, dok je referentna unutrašnja temperatura tela merena invazivnom metodom (kapsulama). Eksperimenti su obuhvatili više scenarija, sa variranjem uslova okoline i stanja ispitanika (nivo fizičke aktivnosti, hidracije, aklimatizacije), kako bi model mogao da nauči odnose u različitim okolnostima [3, 4]. Prikupljeni sirovi podaci filtrirani su radi uklanjanja šuma, a zatim normalizovani i podeljeni na skup za obuku i testiranje.

2.2. Razvoj modela

Formirana su dva modela neuronskih mreža za predikciju unutrašnje temperature:

1. *Feedforward neuronska mreža (FFNN)* – klasična višeslojna perceptronska mreža, sa ulaznim čvorovima koji predstavljaju trenutne vrednosti fizioloških parametara: temperatura kože - T_{chest} , srčana frekvencija – HR i varijabilnost srčanog ritma - HRV. Mreža se sastoji od jednog ili više skrivenih slojeva sa nelinearnim aktivacionim funkcijama, i jednim izlaznim čvorom koji estimira unutrašnju telesnu temperaturu – Slika 1.




Slika 1. Struktura feedforward neuronske mreže

Kao najjednostavnija struktura razmatrana je mreža sa samo dva skrivena sloja sa po jednim neuronom i jedan izlazni neuron. Takođe je isprobana arhitektura sa dva skrivena sloja sa po dva neurona radi povećanja kapaciteta

modela, kao i složenija konfiguracija sa tri skrivena sloja. Poređenjem ovih struktura obezbeđeno je da se ispita uticaj kompleksnosti modela na tačnost estimacije. FFNN model nema internu memoriju stanja odnosno svaka predikcija se vrši samo na osnovu trenutnih ulaza, bez eksplicitnog uvažavanja prethodnih vrednosti signala. Veći broj neurona u skrivenom sloju omogućava modelu da nauči složenije nelinearne odnose, dok minimalistička mreža služi kao baseline za upoređivanje. Sve neuronske jedinice u eksperimentima koristile su nelinearnu aktivacionu funkciju (ReLU), osim izlaznog neurona koji je bio linearni regresor, čime se omogućava predviđanje kontinuirane vrednosti temperature.

2. *Rekurentna feedforward neuronska mreža (RFFNN)* ili proširenje FFNN modela dodatkom jednostavne povratne veze. U RFFNN arhitekturi, originalnom skupu ulaza dodat je još jedan ulaz koji nosi informaciju o prethodnoj predikciji unutrašnje temperature. Na taj način, model pri predviđanju sledeće vrednosti uzima u obzir i neposredno prethodnu izlaznu vrednost, omogućavajući mu osnovni vid “pamćenja” dinamike sistema – Slika 2.



Slika 2. *Rekurentna veštačka neuronska mreža*

Tokom treniranja, za ovaj dodatni ulaz koriste se stvarne prethodno izmerene vrednosti temperature (jer su poznate u trening skupu), dok se prilikom testiranja koristi prethodna predikovana vrednost (feedback petlja). Ovakva jednostavna rekurentna povratna sprega omogućava RFFNN modelu da bolje uhvati vremenske zavisnosti u podacima u poređenju sa običnim FFNN [5, 6].

2.3. Obuka modela

Za treniranje obe mreže korišćen je skup označenih podataka (ulazi sa pripadajućom merenom unutrašnjom temperaturom kao izlazom). Modeli su trenirani metodom nadgledanog učenja, minimizacijom funkcije greške između predikcija mreže i stvarne temperature. Isprobano je više konfiguracija hiperparametara (broj slojeva i neurona, parametri učenja) i različitih funkcija greške MAE, MSE, kao i Huber-ova funkcija kako bi se pronašla optimalna arhitektura za dati problem. Korišćena je k-fold unakrsna validacija, pri čemu su podaci jednog ispitanika ostavljani za validaciju (pristup *Leave-One-Subject-Out*) da bi se proverila sposobnost generalizacije modela. Treniranje je ponavljano za svaku arhitekturu (FFNN i RFFNN), a modeli su upoređeni po performansama na nezavisnom test skupu.

2.4. Evaluacija tačnosti

U radu su izvršene dve vrste evaluacije i odabira modela u cilju analize performansi i izbora optimalnog rešenja. Kod obe arhitekture urađena je evaluacija korišćenjem globalno

najboljeg prosečnog modela i evaluacija korišćenjem individualno optimalnog modela za svakog subjekta. U nastavku teksta razmatraće se rezultati dobijeni kod individualno optimalnog modela.

Za kvantitativnu ocenu performansi modela korišćene su standardne metrike regresije: *srednja apsolutna greška* (MAE), *srednja kvadratna greška* (MSE), *koren srednje kvadratne greške* (RMSE) i *koeficijent determinacije* (R^2). MAE i RMSE izražavaju prosečno odstupanje predikcije od stvarne vrednosti (u $^{\circ}\text{C}$), dok R^2 pokazuje udeo varijanse objašnjen modelom (vrednost bliža 1 označava bolju usklađenost predikcije sa realnim podatkom). Nakon treniranja, za svakog ispitanika izračunate su navedene metrike posebno, a zatim je izvršeno poređenje rezultata FFNN i RFFNN modela.


3. REZULTATI I DISKUSIJA

Dobijeni rezultati potvrđuju da model sa povratnom vezom (RFFNN) uspešnije predviđa unutrašnju temperaturu u odnosu na klasičnu neuronsku mrežu. Tabela 1. prikazuje vrednosti evaluacionih metrika za jednog reprezentativnog ispitanika (oznaka *BM13*) pri korišćenju oba tipa modela. RFFNN model ostvaruje znatno manje greške (niže MAE, MSE, RMSE) i viši R^2 u poređenju sa FFNN, što znači da bolje prati stvarne promene temperature.


Tabela 1. *Metrike predikcije unutrašnje temperature za ispitanika BM13 (poređenje arhitektura)*

Model	MAE	MSE	RMSE	R^2
FFNN	0.186	0.042	0.205	0.501
RFFNN	0.071	0.006	0.078	0.928

Na slikama ispod prikazane su krive stvarne temperature tela (*Actual output*, plava linija) i predikcije neuronske mreže (*Predicted output*, narandžasta linija) za ispitanika BM13. Slika 3. prikazuje model FFNN. Vidljivo je da postoje izvesna odstupanja kao i da reaguje sa zakašnjenjem na nagli pad temperature. Suprotno tome, Slika 4. predstavlja RFFNN model koji prati unutrašnju temperaturu kroz vreme. Takođe, može se primetiti da su promene pravilnije predviđene.



Slika 3. *Rezultati predikcije za ispitanika BM13 korišćenjem FFNN modela*



Slika 4. Rezultati predikcije za ispitanika BM13 korišćenjem RFFNN modela

4. ZAKLJUČAK

U ovom radu prikazana je primena veštačkih neuronskih mreža za estimaciju unutrašnje telesne temperature na osnovu spoljašnjih fizioloških merenja. Upoređene su dve arhitekture – feedforward i rekurentna feedforward neuronska mreža – i pokazano je da dodavanje povratne veze (memorije) značajno poboljšava performanse predikcije. RFFNN model se pokazao bolji u odnosu na običnu feedforward neuronsku mrežu, što potvrđuje hipotezu da uvođenje vremenskog konteksta u modele poboljšava preciznost predikcija. Prednost ovog pristupa jeste sistem za praćenje telesne temperature zasnovan na ovakvim modelima bio bi neinvazivan i pogodan za implementaciju u različite uređaje.

4. LITERATURA

- [1] P. N. Stuart Russell, Artificial Intelligence: A Modern Approach, Pearson, 2016..
- [2] Y. B. G. H. Yann LeCun, "Deep Learning," *Nature*, 2015.
- [3] H. B. Youngjoo Kim, Introduction to Kalman Filter and Its Applications, InTechOpen, 2018.
- [4] S. S. K. G. M. F. Shahin Tasoujian, Real-Time Cubature Kalman Filter Parameter Estimation of Blood Pressure Response Characteristics Under Vasoactive Drugs Administration, IEEE, 2020.
- [5] W. J. T. S. N. C. S. J. M. R. W. K. J. C. W. A. L. W. S. R. M. R. O. C. J. R. W. H. Mark J Buller 1, Estimation of human core temperature from, PubMed, 2013.
- [6] E. W. S. A. A. P. S. D. R. M. R. Reto Niedermann 1, "Prediction of human core body temperature using non-invasive," *Springer Nature Link*, 2013.

Kratka biografija:



Vukašin Pavković rođen je u Sr. Mitrovici 1999. god. Fakultet tehničkih nauka upisuje 2018. godine. Položio je sve ispite predviđene studijskim programom i ispunio sve fakultetske obaveze na master akademskim studijama kontakt: vukasinpavkovic@gmail.com