

# Analiza signalov EKG z globokimi nevronskimi mrežami

Jani Bizjak  
Odsek za inteligentne sisteme, Institut  
Jožef Stefan  
Jamova cesta 39  
1000 Ljubljana, Slovenija  
+386 1 477 3147  
jani.bizjak@ijs.si

Igor Kononenko  
Laboratorij za kognitivno modeliranje,  
Fakulteta za računalništvo in  
informatiko  
Večna pot 113  
1000 Ljubljana, Slovenija  
+386 1 479 8230  
igor.kononenko@fri.uni-lj.si

## POVZETEK

V tem prispevku je na kratko obrazloženo delovanje srca ter zaznavanje srčnih bolezni s pomočjo elektrokardiografije. Predstavljena je ideja globokih nevronskih mrež, natančneje povratnih nevronskih mrež ter nekaj optimizacijskih metod, ki so nujno potrebne za učenje velikih mrež. V zadnjem delu prispevka so predstavljeni rezultati klasifikacije kompleksa QRS, kjer povratna nevronska mreža doseže 99 odstotno klasifikacijsko točnost.

## Ključne besede

povratne nevronske mreže, RNN, elektrokardiografija, EKG

## 1. UVOD

Kljub napredku medicine v zadnjem stoletju, je še vedno kar 30 odstotkov vseh smrti povezanih s kardiološkimi težavami. Ena glavnih metod za zgodnje odkrivanje srčnih obolenj je uporaba elektrokardiograma (EKG). Kljub temu, da je diagnostika s pomočjo elektrokardiograma uspešna, se veliko simptomov pokaže skozi daljše časovno obdobje opazovanja, na primer, ko je telo dlje časa v stresu. Da bi lahko zanesljivo ugotovili, ali ima oseba okvaro na srcu bi tako bilo potrebno daljše (več dnevno) snemanje EKG. Samo snemanje v tem primeru ni problem, problem je količina podatkov, ki jih tako snemanje vrne. Medicinskemu osebju bi preverjanje več urnih (dnevni) izpisov iz EKG vzelo preveč časa, poleg tega bi zaradi monotonega dela in posledično popuščanja koncentracije prihajalo do številnih napak. Reševanja problema se je potrebno lotiti s pomočjo strojnega učenja.

Čeprav je področje zaradi pomembnosti zelo raziskano, trenutni state-of-the-art algoritmi še vedno ne dosegajo dovolj visoke klasifikacijske točnosti, ki je še posebej pomembna v medicini. V tem prispevku smo predstavili pristop k analizi signala EKG s pomočjo globokih nevronskih mrež, natančneje povratnih nevronskih mrež (ang. Recurrent neural network - RNN).

Najprej smo se lotili enostavnejšega problema detekcije kompleksov QRS v signalu EKG. Kompleks QRS predstavlja najvišjo amplitudo nihanja sledi v signalu EKG. S pomočjo kompleksa QRS je najlažje razbrati število utripov na minuto (ang. Beats per minute – BPM), katero se poleg ostalih simptomov pogosto uporablja pri diagnozi bolezni.

Delovanje mreže smo testirali na podatkovni bazi MIT-BIH [1]. Podatkovna baza vsebuje 48, 30 minutnih posnetkov, ki so bili posneti med letom 1975 in 1979 v sklopu laboratorija za aritmijo BIH na 47 različnih ljudeh. 23 posnetkov je bilo izbranih naključno, ostalih 25 iz enake skupine ljudi pa tako, da so vsebovali redkejšje primere aritmij. Skupno je v bazi označenih približno 110.000 primerov na kanalu V1 in II odvodu.


## 2. ELEKTROKARDIAGRAM

Srce s prehajanjem ionov v in iz celice spreminja električni potencial ter s tem tvori električni pulz, ki potuje skozi srce in povzroča krčenje srčnih mišic. Ta vrsta električnega pulza je tako močna, da jo lahko zaznamo tudi na koži po celem telesu. Elektrokardiogram je naprava, ki s pomočjo elektrod pritrjenih na kožo meri električne spremembe, ki so posledica bitja srca.

Odvisno od števila ter pozicije elektrod kardiogram prikazuje srce iz različnih perspektiv. Najbolj pogosta je uporaba 10 elektrod, ki delovanje srca prikazuje v 12 sledih (ang. leads).

Signal na posnetku EKG tvori značilne valove imenovane PQRST (Slika 1). Srčni utrip se začne z valom P, ki predstavlja depolarizacijo atrija. Kompleks QRS je najznačilnejši del signala, nastane zaradi krčenja ventriklov, ki kri črpajo nazaj v telo.

S pomočjo kompleksa QRS lahko ugotovimo BPM ter nekatere bolezni srca, ki popačijo obliko kompleksa. V tem prispevku bomo obravnavali le iskanje normalnega kompleksa QRS in neenakomeren utrip, ki oblike kompleksa QRS ne spreminja.



Slika 1: Kompleks PQRST [2],[1]

## 3. ARHITEKTURA MREŽE


Pri analizi signalov EKG niso pomembne le značilke v trenutnem oknu temveč tudi tiste, ki so se zgodile nekaj sekund pred tem. Standardne nevronske mreže (npr. večplastni perceptron) niso zmožne prepoznavati časovne odvisnosti med podatki. Povratne nevronske mreže so posebna vrsta globokih nevronskih mrež, ki so se zmožne naučiti časovnih odvisnosti med podatki. To omogočajo posebne povratne plasti, kjer so nevroni znotraj ene plasti povezani med seboj ter sami nase (Slika 2).

Zaradi arhitekture, je RNN podvržen problemu izginjajočega (ang. vanishing) ali eksplozivnega (ang. exploding) gradienta. To se

zgodí, ko se zaradi globine mreže in napak pri zaokroževanju vrednost gradienta približa ničli, hkrati pa se poveča napaka, kar onemogoči učenje takšnih mrež. RNN zato ni zmožen učenja (uporabe) podatkov, ko so le ti preveč narazen. Ta problem rešuje tako imenovane kratko-dolgo ročna spominska mreža (ang. long-short term memory – LSTM).

### 3.1 Učenje povratnih nevronske mreže

Za učenje povratnih nevronske mreže je potrebno spremeniti standardno vzvratno razširjanje tako, da deluje na rekurzivnih povezavah povratne plasti [3]. Povratno plast si lahko predstavljamo kot več standardnih skritih nevronske plasti, ki so skrčene v eno plast. Vsaka naslednja plast v tem konstruktu predstavlja podatke iz prejšnjih učenj ( $t_k$ ). Pri učenju tako najprej razširimo povratno plast za  $k$  časovnih enot,  $k$  v tem primeru predstavlja število časovnih enot, ki si jih mreža lahko zapomni. Na razširjeni mreži lahko nato uporabimo standardno vzvratno razširjanje. Ko konstrukt nato ponovno skrčimo, povprečimo uteži vseh plasti konstrukta ter povprečje uporabimo za uteži povratne plasti.



Slika 2: Nevroni so v RNN povezani znotraj ene plasti (L1).

### 3.2 Optimizacija gradientnega spusta

Zaradi dolgih časov učenja globokih nevronske mreže je nujno potrebna optimizacija posodabljanja uteži, ki pripomore k hitrejši konvergenci.

Splošno uporabljena optimizacija je stohastični gradientni spust (SGD), ki za vsak vhodni podatek in vsak parameter posebej posodablja vrednosti uteži. Takšnega načina učenja, se kljub temu, da je relativno dober, ne da paralelizirati zato je čas učenja zelo dolg. To se lahko do neke mere reši z uporabo blokovega gradientnega spusta. Ta vrednosti gradientov ne računa za vsak par podatkov posebej, temveč izračuna povprečje za manjši blok.

SGD tekom učenja uporablja fiksno stopnjo učenja ( $\alpha$ ) vse parametre pa posodablja globalno. S pristopom ohlajanja (ang. annealing) lahko pri SGD spreminjamo stopnjo učenja - navadno je v začetku učenja večja proti koncu pa konvergira k 0.

$$\theta = \theta + \alpha(\Delta f)$$

Metoda ADAGrad spreminja velikost gradienta za vsak parameter posebej. To stori z uporabo normalizacije na podlagi velikosti gradientov.

$$v = v + (\Delta f)^2$$

$$\theta = \theta + \alpha \frac{\Delta f}{\sqrt{v} + \epsilon}$$

Pri tem nastane problem, ko so gradienti zelo visoki, navadno se to pojavlja v začetku učenja ter po določenem času učenja, saj se gradienti akumulirajo iz prejšnjih iteracij. Rahlo spremenjena metoda ADADelta [4] to popravi z vpeljavo dodatnih uteži v normalizacijsko funkcijo ter omejitvijo intervala, ki ga uporablja akumulator. Če v spodnji enačbi za  $m$  vzamemo vrednost iz intervala  $[0,1]$ , se bo vpliv preteklih vrednosti eksponentno zmanjševal. Prav tako z uporabo prirejene sigmoidne funkcije, močno zmanjšamo vpliv prvih nekaj normalizacijskih uteži.

$$v = v * m + \frac{1}{1 + e^{-\frac{v}{5}}} (\Delta f)^2; m \in (0,1)$$

Na podoben način deluje tudi metoda RMSProp [5], ki v akumulator gradienta doda parameter razpada  $\beta$  (ang. decay) ter s tem omili vpliv normalizacije. V naših testih se je izkazalo, da RMSProp najhitreje konvergira k rešitvi, razlika v klasifikacijski točnosti pa je minimalna.

$$v = \beta v + (1 - \beta)(\Delta f)^2$$

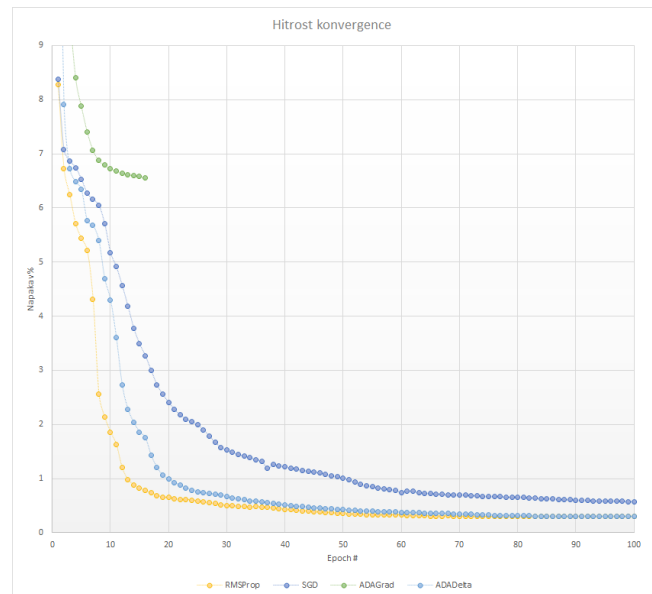
$$\theta = \theta - \alpha \frac{\Delta f}{\sqrt{v} + \epsilon}$$

## 4. EKSPERIMENTALNI REZULTATI

### 4.1 Primerjava optimizacijskih metod

Čas učenja je, kljub izvajanju algoritmov na grafični kartici s 1000 jedri kjer je procesorska zasedenost večino časa 100%, zelo dolg. Za mrežo z 200 skritimi nevroni ter učno množico z 400.000 okni je učenje potekalo več dni. Preverili smo, kako se obnesejo različne metode za optimizacijo gradientnega spusta.

Za najhitrejšo se je izkazal RMSProp, ki je konvergirala skoraj 10 krat hitreje od bločnega SGD. ADAGrad se je zaradi visokih gradientov v začetku učenja ustavil predčasno, modifikacija ki smo jo naredili za ADADelta pa se je izkazala za relativno dobro. Na Slika 3 je prikazana hitrost konvergence za prvih 100 iteracij učenja.

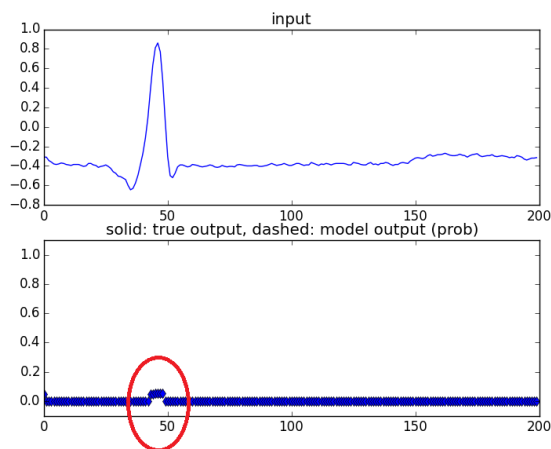


Slika 3: RMSProp konvergira najhitreje.

## 4.2 Iskanje kompleksa QRS

Podatke iz posameznih posnetkov smo razdelili v okna velikosti 200. Pri tem smo morali biti pozorni, da okno med sabo nismo premešali, saj so podatki časovno odvisni med seboj. Za testiranje natančnosti smo uporabili princip prečnega preverjanja leave-one-patient-out. Učili smo se na vseh posnetkih, brez posnetka na katerem smo testirali natančnost učenja. Zaradi časovne zahtevnosti učenja smo od vsakega posnetka vzeli le prvih 5.000 oken s po 200 signali, za testno množico pa smo vzeli prvih 40.000 oken posnetka.

Za klasifikacijo v en oz. drugi razred, smo preverili točnost metode pri različnih mejah verjetnosti, za najboljšo se je izkazala meja 6%, za klasifikacijo v pozitivni razred. V splošnem so bile verjetnosti s katerimi je mreža prepoznala kompleks QRS zelo majhne. Primer pravilne klasifikacije je prikazan na Slika 4.



Slika 4: Detekcija kompleksa QRS.

V Tabela 1 so prikazani rezultati testiranja. Kljub visoki povprečni točnosti 99,7% vidimo, da sta preciznost in senzitivnost zelo nizki. Pri nekaterih posnetkih se mreža zelo slabo nauči prepoznavati komplekse QRS, zaradi veliko večjega števila negativnih primerov v signalu (vse kar ni QRS vrh) je točnost kljub vsemu visoka.

Tabela 1 Rezultati prečnega preverjanja detekcije kompleksov QRS

Datoteka	Preciznost	Senzitivnost	Specifičnost	Točnost
100	1	1	1	1
101	1	0,9739	1	0,9999
102	0,9688	0,7266	0,9999	0,9989
103	1	1	1	1
104	0,9660	0,9930	0,9999	0,9998
106	0,9826	0,9496	0,9999	0,9998
107	0,8014	0,9915	0,9991	0,9991
108	1	0,0099	1	0,9971
109	1	0,0067	1	0,9956
111	0	0	1	0,9958
113	1	0,9891	1	1


114	0	0	1	0,9974
115	0,9905	1	1,0000	1,0000
116	1	0,9776	1	0,9999
117	0,8929	0,9843	0,9996	0,9995
119	0,6752	0,9550	0,9985	0,9984
121	0	0	1	0,9969
122	1	0,9793	1	0,9999
123	1	0,7059	1	0,9993
124	0,3481	0,6267	0,9947	0,9931
201	1	0,9603	1	0,9998
202	1	0,9882	1	1,0000
203	1	0,4136	1	0,9966
205	1	0,0067	1	0,9956
207	0,1338	0,9661	0,9662	0,9662
209	1	1	1	1
210	1	0,1477	1	0,9962
212	1	1	1	1
213	1	1	1	1
214	0,1764	1	0,9733	0,9734
217	0,0859	0,1339	0,9946	0,9914
219	0,7561	0,9394	0,9988	0,9986
220	1	1	1	1
221	1	0,7836	1	0,9991
222	0,8658	1	0,9994	0,9994
228	0,2143	0,2903	0,9961	0,9935
230	1	0,9420	1	0,9998
231	1	0,9189	1	0,9997
232	0	0	1	0,9971
233	1	1	1	1

Povprečje:	0,7714	0,7090	0,9980	0,9969
Mediana:	1	0,9576	1	0,9993


## 4.3 Detekcija neenakomernega utripa

Pri detekciji neenakomernega utripa (PAC) se je izkazalo, da so si kompleksi QRS preveč narazen, da bi se jih naša mreža lahko naučila. Pogosto se je dogajalo, da je gradient postal ničen po le nekaj iteracijah učenja. Poleg tega smo imeli težave z velikostjo učne množice. Odločili smo se, da bomo to vrsto podatkov sintetizirali. Naredili smo umetne QRS-komplekse, ki so bili med seboj oddaljeni približno polovico manj kot v pravem signalu. Razdaljo med dvema kompleksoma smo določili naključno, znotraj 40% dolžine (umetnega) intervala RR. Na Slika 5a je prikazan primer normalnega utripa, na Sliki 5b pa primer zakasnelega utripa. Zelena črta predstavlja verjetnost, da gre za zakasneli utrip. Prva

slika zaradi negativnih vrednosti, ki jih signal doseže zaradi šuma, izgleda kot da ima verjetnost višjo kot 0.



Slika 5a: Normalen utrip.




Slika 5b: Zapozneli utrip.

V primeru ko sta kompleksa QRS preblizu ali predaleč (20% okrog robov naključnega intervala), vrh označimo kot neenakomeren utrip. Izkazalo se je, da se je RNN sposoben naučiti najprej prepoznavati komplekse QRS, nato pa še, ali je razdalja med dvema sosednjima kompleksoma pravilna. V Tabela 2 so prikazani rezultati pri prepoznavanju neenakomernega utripa. Tudi tukaj opazimo večjo razliko med senzitivnostjo ter specifičnostjo. Na Slika 6 je prikazan primer pravilne klasifikacije prezgodnjega utripa. V zgornjem delu slike je prikazan signal, v spodnjem delu pa verjetnost, da gre za neenakomeren utrip.

Tabela 2 Točnost prepoznavanja neenakomernega utripa

Št. Nevronov	Senzitivnost	Specifičnost	Klas. Točnost
150	0,928	0,965	0,929
200	0,945	0,974	0,947
400	0,918	0,960	0,918



Slika 6: Pravilno klasificiran prezgodnji utrip.

## 5. Zaključek

Pokazali smo, da se povratne nevronske mreže lahko uporabljajo za analizo signalov EKG. Poleg prepoznavanja statičnih lastnosti (kompleks QRS) lahko prepoznajo tudi časovne odvisnosti med podatki (PAC). Izkaže se, da so podvržene problemu dolgotrajnega spomina, njihova klasifikacijska točnost pa nekoliko zaostaja za ostalimi state-of-the-art metodami [6],[7]. Kot možno rešitev tega problema predlagamo uporabo LSTM, ki omogoči poljubno dolgo hranjenje informacij.

## 6. Reference

- [1] Moody, G. B., & Mark, R. G. (2001). The impact of the MIT-BIH arrhythmia database. *Engineering in Medicine and Biology Magazine, IEEE*, 20(3), 45-50.
- [2] Wikimedia Commons, Schematic diagram of normal sinus rhythm for a human heart as seen on ECG (2007) [obiskano 15.9.2015], URL [https://commons.wikimedia.org/wiki/File:SinusRhythmLabel\\_s.svg](https://commons.wikimedia.org/wiki/File:SinusRhythmLabel_s.svg)
- [3] Werbos, P. J. (1990). Backpropagation through time: what it does and how to do it. *Proceedings of the IEEE*, 78(10), 1550-1560.
- [4] M. D. Zeiler, ADADELTA: an adaptive learning rate method, *CoRR abs/1212.5701*. URL <http://arxiv.org/abs/1212.5701>
- [5] T. Tieleman, G. Hinton, Lecture 6.5-rmsprop: Divide the gradient by a running average of its recent magnitude, COURSERA: Neural Networks for Machine Learning 4.
- [6] Ka, A. K. (2011). ECG beats classification using waveform similarity and RR interval. *arXiv preprint arXiv:1101.1836*.
- [7] Yu, S. N., & Chou, K. T. (2008). Integration of independent component analysis and neural networks for ECG beat classification. *Expert Systems with Applications*, 34(4), 2841-2846.