

KLASIFIKACIJA SLIK EEG SIGNALOV Z UPORABO GLOBOKEGA UČENJA

Grega Vrbančič, Vili Podgorelec

Inštitut za informatiko

Fakulteta za elektrotehniko, računalništvo in informatiko

E-pošta: grega.vrbancic@um.si

POVZETEK: *Analiza biomedicinskih signalov kot je EEG, za merjenje možganskih aktivnosti omogoča diagnosticiranje različnih kognitivnih nalog in nevroloških motenj. Pogosto so takšni signali pretvorjeni v vizualne predstavitve kot so spektrogrami, ki lahko razkrijejo karakteristične vzorce in služijo kot osnova za klasifikacijo. Za namen klasifikacije EEG signalov subjektov z in brez motoričnih okvar oz. motenj, smo oblikovali novo metodo, ki uporablja spektrogramске slike kot vhod v globoko konvolucijsko nevronsko mrežo, brez kakršnihkoli predhodnih izbir ali ekstrahiranj značilk. Rezultati, pridobljeni brez kakršnegakoli človeškega posega in z uporabo privzetih vrednosti parametrov, so se izkazali, da ne zaostajajo veliko za najsodobnejšimi metodami, ki izkoriščajo uporabo domenskega znanja za analizo EEG signalov.*

1. UVOD

V zadnjih letih je opaziti velik porast raziskav na področju procesiranja in analiziranja elektroencefalografskega (EEG) signala s ciljem, da bi z informacijami zbranimi iz teh signalov lahko diagnosticirali nekatere vrste nevroloških motenj. Nabor možnih diagnoz, ki jih je mogoče diagnosticirati na tak način se iz leta v leto povečuje in pokriva široko področje nevroloških bolezni, od blagih kognitivnih okvar [1], raznih neurodegenerativnih bolezni kot je Alzheimerjeva bolezen [2], pa do najbolj resnih oblik nevroloških motenj, kot so amiotrofična lateralna skleroza ali cerebralna paraliza, kjer je lahko bolnik resno telesno prizadet ali celo popolnoma paraliziran [3].

Osnovo EEG signalov predstavlja električna aktivnost merjena kot napetost na različnih točkah možganov. Te signale, ki so običajno časovno spremenljivi in v naravi nestacionarni lahko raziskujemo z uporabo različnih tehnik obdelave signalov. Čeprav je obseg analize signalov EEG zelo širok, je splošen način tak, da surove signale zajete iz elektrod na lasišču subjekta predhodno obdelamo in filtriramo, da ti postanejo berljivi [4]. Te signale lahko zatem analiziramo in/ali preoblikujemo z namenom pridobitve poglobljenega vpogleda v delovanje možganov. Po preoblikovanju, lahko signale tudi vizualno predstavimo v obliki spektrogramov za vsak posamezen kanal. Takšna vizualna

predstavitev nam lahko razkrije vzorce sprememb v aktivnosti nihanja možganov med opravljanjem vnaprej določenih aktivnosti ali nalog.

Z nedavnim napredkom na področju strojnega učenja, z uporabo globokega učenja in globokih arhitektur nevronske mreže (NN), je mogoče za opravljanje nalog klasifikacije slik, doseči enako dobre ali še boljše rezultate, kot jih dosegamo ljudje [5].

Glede na prej omenjene vzpodbudne rezultate pri klasifikaciji slik, predlagamo novo metodo za klasifikacijo spektrogramskih slik EEG signalov za zaznavo motoričnih motenj oziroma okvar, z uporabo globoke konvolucijske nevronske mreže. Glavna cilja raziskave sta bila raziskati ali se lahko predlagana metoda uporabi za uspešno klasifikacijo nevroloških motenj ter kako ustrezno pretvoriti surove EEG signale v spektrogramske slike, primerne za učenje NN.

Preostali del prispevka je organiziran sledeče. V poglavju 2 je podrobneje predstavljena predlagana metoda, poglavje 3 opisuje izveden eksperiment in njegove rezultate, poglavje 4 pa zaključuje naš prispevek z zaključnimi mislimi ter možnostmi za nadaljnje delo.

2. PREDLAGANA METODA

Predlagana metoda je sestavljena iz več korakov in sicer iz pred-procesiranja signala, pretvorbe signala v spektrograme ter učenja globoke konvolucijske mreže na ustvarjenih spektrogramskih slikah. V nadaljevanju so podrobneje opisani posamezni koraki predlagane metode.

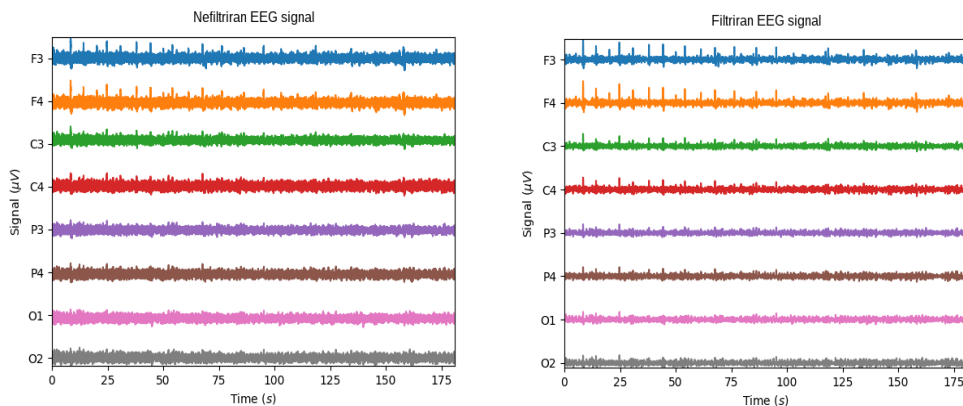
2.1 Pred-procesiranje EEG signala

Zajet EEG signal smo pred-procesirali in vizualizirali s pomočjo odprto-kodne programske platforme CEBL3. Posamezen posnetek EEG signala je dolg 3 minute in je zajet z osmimi elektrodami (C3, C4, F3, F4, O1, O2, P3 in P4) pri hitrosti vzorčenja 256Hz. EEG signalne ritme lahko okarakteriziramo kot [2]:

- delta valovi (0Hz – 4Hz),
- theta valovi (4Hz – 8Hz),
- alpha valovi (8Hz – 14Hz),
- nizki beta valovi (14Hz – 20Hz),
- visoki beta valovi (20Hz – 30Hz) in
- nizki gamma valovi (30Hz – 60Hz).


Na vsakem izmed kanalov smo opravili filtriranje v frekvenčnem pasu od 0.5Hz do 7.5Hz z uporabo Butterworth filtra (Slika 1), z namenom odstranitve šumov na nizkih in visokih frekvencah ter za odstranitev drugih artefaktov. Omenjen frekvenčni pas smo izbrali na podlagi že opravljenih raziskav na tem področju [2], [6], katerih izsledki kažejo, da je največ spektralnih sprememb moči mogoče zaznati na nivoju alpha in theta valov, kateri v večini primerov kažejo na neko vrsto možganske patologije. Za pretvorbo

filtriranega EEG signala v časovno-frekvenčno domensko predstavitev smo uporabili Hitro Fourierjevo transformacijo (angl. Fast Fourier Transformation), ki velja za eno najbolj primernih metod za transformacijo signalov med časovno in frekvenčno domeno [7].



Slika 1: Prikaz EEG signala po posameznem kanalu pred (levo) in po (desno) opravljenem filtriranju.

Po transformaciji signala v časovno-frekvenčno domensko predstavitev, smo za vsak posamezen kanal izrisali spektrograme, ki predstavljajo gostoto moči signala pri uporabi logaritemske normalizacije (Slika 2).



Slika 2: Spektrograma EEG signala na kanalu C3. Levo je prikazan spektrogram motene, desno pa nemotene možganske aktivnosti.

2.2 Učenje in klasifikacija z globoko konvolucijsko nevronske mrežo

Zadnjih nekaj let je strojno učenje, še posebej pa globoko učenje, v razcvetu. Globoko učenje je podmnžica splošnejšega področja umetne inteligence, ki mu pravimo strojno

učenje. Do nedavnega je večina strojnega učenja in tehnik procesiranja signalov izkoriščala plitvo strukturirane arhitekture, ki so navadno sestavljene iz enega oziroma največ dveh nivojev nelinearnih transformacij atributov (npr. logistična regresija, modeli z maksimalno entropijo). Slednje so se izkazale za zelo učinkovite pri reševanju lažjih ali zelo omejenih problemov, po drugi strani pa njihovo omejeno modeliranje in predstavitevna moč povzročata težave pri reševanju kompleksnejših problemov iz realnega sveta, ki vsebujejo naravne signale (govor, zvok, slika) [8], [9].

V splošnem je algoritem globokega učenja sestavljen iz hierarhične arhitekture s številnimi nivoji, od katerih vsak izmed njih predstavlja nelinearno enoto za obdelavo informacij. Globoke nevronske mreže (angl. Deep Neural Networks – DNNs), ki uporabljajo globoke arhitekture NN, lahko predstavljajo funkcije z večjo kompleksnostjo, v kolikor je število nivojev in število enot znotraj nivoja povečano [10].

Za namene klasifikacije slik (zaznava in prepoznavna obrazov [11], segmentacija bioloških slik [6], prepoznavna prometnih znakov [12]) se je še za posebej uspešno izkazala arhitektura globokih nevronskih mrež imenovana konvolucijska nevronska mreža (angl. Convolutional Neural Network – CNN), katere delovanje inspirira iz organizacije vizualnih korteksov pri živalih [10].

Standardna arhitektura CNN vsebuje konvolucijske nivoje, organizirane v obliki sklada, katerim opcijsko sledi nivo združevanja (poznani tudi kot nivo podvzorčenja), katerim sledi en ali več polno povezanih nivojev. Konvolucijski nivo je navadno sestavljen iz več polj značilk (angl. Feature maps), z drugačnimi vektorji utežmi, z namenom prepoznave več lastnosti na posamezni lokaciji. Zamikanje vhoda konvolucijskega nivoja, posledično zamakne tudi izhod, sicer pa ga ohrani nespremenjenega. Ko je značilka zaznana, njena točna lokacija postane manj pomembna, dokler njena relativna pozicija glede na ostale ostane približno enaka. Zato je pogosto, da vsakemu konvolucijskemu nivoju sledi dodatna plast, ki opravlja lokalno povprečenje in podvzorčenje. Rezultat tega je manjša ločljivost polja značilk in zmanjšana občutljivost vhoda na zamikanje in izkrivljanja. Sledeči si konvolucijski sloji in sloji pod-vzorčenja se običajno izmenjujejo, kar ima za posledico bi-piramido: na vsakem nivoju je število polj značilk povečano, medtem ko se prostorska ločljivost zmanjša [13]. Omenjenim, izmenjuje sledečim si nivojem, tipično sledi eden ali več polno povezanih nivojev, kateri imajo polne povezave do vseh aktivacij v prejšnjem nivoju, kot pri klasičnih NN.

3. EKSPERIMENT IN REZULTATI


V tem poglavju je podrobneje predstavljena uporabljena podatkovna množica, arhitektura CNN ter nastavitve učenja. V zadnjem podpoglavju so predstavljeni rezultati opravljenega eksperimenta.

3.1 Podatkovna množica

Uporabljena je bila podatkovna množica BCI [14], zbrana s strani Colorado State University. EEG signali so bili zajeti z uporabo g.GAMMASys aktivnih elektrod (8 kanalov), z frekvenco vzorčenja 256Hz in strojnim filtriranjem signala frekvenčnega pasu od 0.5Hz – 100Hz [15]. Dolžina posameznega zajetega posnetka je 3 minute. Podatkovna množica vsebuje posnetke skupno 13 subjektov, od katerih 9 subjektov nima nobenih znanih zdravstvenih težav (t.i. unimpaired), preostali pa trpijo za hudimi motoričnimi motnjami (t.i. impaired).

3.2 Konvolucijska nevronska mreža

Naša CNN arhitektura (Slika 3) temelji na LeCun-ovi petnivojski LeNet arhitekturi [16] z manjšimi prilagoditvami parametrov konvolucijskih nivojev in učnimi parametri. CNN sestoji iz dveh konvolucijskih nivojev z filtrom velikosti 5 x 5 ter zamikom velikosti 1 x 1. Vsakemu izmed njiju sledi nivo podvzorčenja z uporabo maksimizacijske funkcije s filtrom in zamikom velikosti 2 x 2. Na prvem konvolucijskem nivoju je apliciranih 20, na drugem pa 50 filtrov. Za tem skladom nivojev imamo en polno povezan nivo z 500 izhodnimi filtri povezan z izhodnim nivojem, kateri klasificira posamezno sliko kot »impaired« ali »unimpaired«.



Slika 3: Uporabljena arhitektura konvolucijske nevronske mreže.

3.3 Učenje

Zaradi omejenega, malega števila učnih primerkov, smo za učenje CNN uporabili in validacijo uporabili princip »izpusti enega«. Učenje je bilo izvedeno ločeno za vsak kanal v zajetem posnetku EEG signala, s čemer smo ustvarili 8 modelov, ki smo jih nato z uporabo algebralnega kombinacijskega pravila – glasovanje večine, združili v ansambel. Ansambel je podan subjekt klasificiral kot »impaired«, v kolikor ga je več kot polovica kanalov klasificirala kot »impaired«, sicer ga je klasificiral kot »unimpaired«. Učenje je bilo izvedeno z uporabo enega paketa dvanajstih slik, ter eno sliko za testiranje. Za stopnjo učenja smo uporabili vrednost 1×10^{-6} , uteži smo inicializirali z uporabo inicializacijske sheme Xavier [17], za aktivacijsko funkcijo pa smo uporabili ReLU [18]. Za vsako učenje CNN smo izvedli 50 ponovitev z 1 iteracijo.

3.4 Rezultati

Rezultati klasifikacije pridobljeni na testnih primerkih za vsak kanal posamezno in združeno z uporabo glasovanja večine so predstavljeni v tabeli 1. Subjekti označeni s s21 – s25 predstavljajo osebe brez kakršnikoli znanih nevroloških motenj (označeno z F – negativni primeri), medtem ko subjekti označeni s s11 – s16 predstavljajo paciente z motoričnimi okvarami oziroma motnjami (označeno s T – pozitivni primeri).

Tabela 1: Rezultati klasifikacije za posamezen kanal kot tudi končna klasifikacija z uporabo glasovanja večine.

| subjekt→ kanal ↓ | s21 | s24 | s23 | s27 | s28 | s22 | s26 | s20 | s25 | s11 | s13 | s15 | s16 |
|---------------------|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|
| C3 | F | F | F | F | F | F | F | F | F | F | F | F | T |
| C4 | F | F | T | T | F | F | T | F | T | T | F | F | F |
| F3 | T | T | T | F | F | F | F | F | F | F | F | F | F |
| F4 | T | F | F | F | T | F | T | F | F | F | F | F | T |
| O1 | T | T | T | F | T | T | F | F | F | F | F | F | F |
| O2 | F | F | T | F | F | T | F | F | F | F | T | T | T |
| P3 | F | F | T | F | F | F | T | F | T | F | T | F | T |
| P4 | F | T | T | F | F | F | T | T | T | F | T | F | T |
| razred | F | F | T | F | F | F | F | F | F | F | F | F | T |

Kot je razvidno, je naša metoda pravilno klasificirala 8 izmed 9 subjektov brez znanih nevroloških motenj in 1 od 4 pacientov z motoričnimi okvarami oziroma motnjami. S čimer smo dosegli splošno natančnost 69,23%, F1 vrednost 65,64%, občutljivost 25% ter specifičnost 88,89%. V primerjavi z najnaprednejšo klasifikacijsko metodo [15], ki je dosegla splošno natančnost okrog 74%, lahko ugotovimo, da naša predlagana metoda ne zaostaja veliko (manj kot 5%). Še posebej, če ob tem upoštevamo popolnoma samodejno pretvorbo EEG signalov v spektrogramske slike ter klasifikacijo brez domenskega znanja ter ročne izbire ali ekstrakcije značilk.

4. ZAKLJUČEK

V tem članku smo predstavili proces transformacije EEG signala v slike spektrogramov z uporabo Butterworth filtriranja frekvenčnega pasu od 0.5Hz – 7.5Hz, Hitro Fourierjevo transformacijo in logaritmično normalizacijo za predstavitev gostote moči transformiranega signala. Tako ustvarjene slike, smo zatem uporabili za učenje naše CNN z uporabo principa »izpusti enega«. Pridobljeni rezultati so obetajoči, še posebej če upoštevamo popolno avtomatizirano naravo predlagane metode.

V prihodnosti, bi želeli naše delo razširiti z uporabo večjih podatkovnih množic, različnih časovno-frekvenčnih domenskih transformacij signalov, različnih CNN arhitektur in nastavitve parametrov učenja.

LITERATURA

- [1] M. Kashefpoor, H. Rabbani, and M. Barekatin, "Automatic Diagnosis of Mild Cognitive Impairment Using Electroencephalogram Spectral Features.," *J. Med. Signals Sens.*, vol. 6, no. 1, pp. 25–32, 2016.
- [2] V. Podgorelec, "Analyzing EEG Signals with Machine Learning for Diagnosing Alzheimer ' s Disease," no. X, pp. 61–64, 2012.
- [3] C. Neuper, G. . Müller, A. Kübler, N. Birbaumer, and G. Pfurtscheller, "Clinical application of an EEG-based brain–computer interface: a case study in a patient with severe motor impairment," *Clin. Neurophysiol.*, vol. 114, no. 3, pp. 399–409, Mar. 2003.
- [4] J. Kaur and A. Kaur, "A review on analysis of EEG signals," in *2015 International Conference on Advances in Computer Engineering and Applications*, 2015, pp. 957–960.
- [5] D. Cireşan, U. Meier, and J. Schmidhuber, "Multi-column Deep Neural Networks for Image Classification," Feb. 2012.
- [6] K. Kamnitsas, C. Ledig, V. F. J. Newcombe, J. P. Simpson, A. D. Kane, D. K. Menon, D. Rueckert, and B. Glocker, "Efficient Multi-Scale 3D CNN with Fully Connected CRF for Accurate Brain Lesion Segmentation," Mar. 2016.
- [7] M. Akin, "Comparison of wavelet transform and FFT methods in the analysis of EEG signals," *J. Med. Syst.*, vol. 26, no. 3, pp. 241–247, 2002.
- [8] L. Deng and D. Yu, *Deep Learning: Methods and Applications*. 2014.
- [9] N. Buduma and N. Locascio, *Fundamentals of Deep Learning*, First Edit. O'Reilly Media, Inc., 2017.
- [10] W. Liu, Z. Wang, X. Liu, N. Zeng, Y. Liu, and F. E. Alsaadi, "A survey of deep neural network architectures and their applications," *Neurocomputing*, vol. 234, pp. 11–26, 2017.
- [11] Y. Taigman, M. Yang, M. Ranzato, and L. Wolf, "DeepFace: Closing the Gap to Human-Level Performance in Face Verification," in *2014 IEEE Conference on Computer Vision and Pattern Recognition*, 2014, pp. 1701–1708.
- [12] D. C. Cireşan, A. Giusti, L. M. Gambardella, and J. Schmidhuber, "Mitosis Detection in Breast Cancer Histology Images with Deep Neural Networks," Springer, Berlin, Heidelberg, 2013, pp. 411–418.
- [13] Y. LeCun and Y. Bengio, "Convolution Networks for Images, Speech, and Time-Series," in *The handbook of brain theory and neural networks*, M. A. Arbib, Ed. MIT Press, 1995.
- [14] Colorado State University, "EEG dataset from BCI at CSU." [Online]. Available: http://www.cs.colostate.edu/eeg/main/data/2011-12_BCI_at_CSU. [Accessed: 31-Jan-2018].
- [15] E. M. Forney, C. W. Anderson, W. J. Gavin, P. L. Davies, M. C. Roll, and B. K. Taylor, "Echo State Networks for Modeling and Classification of EEG Signals in

- Mental-Task Brain-Computer Interfaces,” 2015.
- [16] Y. Le Cun, L. D. Jackel, B. Boser, J. S. Denker, H. P. Graf, I. Guyon, D. Henderson, R. E. Howard, and W. Hubbard, “Handwritten digit recognition: applications of neural network chips and automatic learning,” *IEEE Commun. Mag.*, vol. 27, no. 11, pp. 41–46, 1989.
 - [17] B. Xu, N. Wang, T. Chen, and M. Li, “Empirical Evaluation of Rectified Activations in Convolution Network,” *ICML Deep Learn. Work.*, pp. 1–5, 2015.
 - [18] K. G. Pasi and S. R. Naik, “Effect of parameter variations on accuracy of Convolutional Neural Network,” in *2016 International Conference on Computing, Analytics and Security Trends (CAST)*, 2016, pp. 398–403.