

ემოციის ამოცნობა ელექტროენცეფალოგრაფიული სიგნალებიდან ღრმა სწავლების გამოყენებით: ერთ სუბიექტზე დაფუძნებული კვლევა

მარიამ წიკლაური, თათია წმინდაშვილი

საქართველოს ტექნიკური უნივერსიტეტი

m.tsiklauri@gtu.ge, tsmindashvili.tatia@gtu.ge

რეზიუმე

ნაშრომის მიზანია ხელოვნური ინტელექტის გამოყენების შესწავლა ემოციების ამოცნობის პროცესში, ლაბორატორიული მოწყობილობით გენერირებული სიგნალების ანალიზის საფუძველზე. გამოყენებულია კვლევის დიზაინი, რომელიც ხასიათდება EEG მონაცემების მრავალფეროვნებით და ეფუძნება მრავალპიროვნულ მონაცემთა ბაზას. კვლევა მიზნად ისახავს ერთი ინდივიდის მონაცემებზე დაფუძნებული, მაღალსიზუსტიანი და პერსონალიზირებული ხელოვნური ინტელექტის მოდელის შექმნას, რომელიც პროგნოზირებს მის ემოციურ მდგომარეობას.

საბოლოოდ, ნაშრომი ადასტურებს, რომ ზუსტი, სანდო და პერსონალიზებული ემოციის ამოცნობა მიღწევადია ლაბორატორიული EEG მოწყობილობისა და რეალური პირობების კვლევითი პროტოკოლების გამოყენებითაც კი. ეს ფოკუსირებული მიდგომა პრაქტიკულ საფუძველს ქმნის უფრო ფართო პოპულაციებზე მასშტაბირებისათვის და ემოციების ამოცნობის ინტეგრაციისათვის ადამიან-კომპიუტერის ურთიერთქმედების (HCI) მრავალფეროვან მოდულებში.

საკვანძო სიტყვები: EEG სიგნალი, ხელოვნური ინტელექტი - ხელოვნური ინტელექტი, CleveLabs. ადამიან-კომპიუტერის ურთიერთქმედების (HCI) მოდულები

1. შესავალი.

თანამედროვე ციფრულ ეპოქაში, ხელოვნური ინტელექტისა (AI) და ნეირომეცნიერების კონვერგენციამ გახსნა ახალი შესაძლებლობები ადამიანის ემოციების უფრო ღრმა გაგებისა და ინტერპრეტაციისთვის. ყველაზე ინფორმაციულ ფიზიოლოგიურ სიგნალებს შორის, ელექტროენცეფალოგრაფიული (EEG) სიგნალები გვაწვდის მნიშვნელოვან ინფორმაციას ტვინის აქტივობის შესახებ, რაც მათ ემოციური მდგომარეობების ამოცნობისა და მოდელირების ძლიერ ინსტრუმენტად აქცევს. EEG მონაცემებზე დაფუძნებული ემოციების ამოცნობა გახდა კრიტიკული კომპონენტი თანამედროვე ადამიან-კომპიუტერის ურთიერთქმედების (HCI) სისტემების განვითარებაში, რომელთა გამოყენება მოიცავს ფსიქოლოგიური მხარდაჭერის სისტემებს, სათამაშო გარემოს, ვირტუალურ რეალობას და ადაპტირებულ მომხმარებლის ინტერფეისებს [1,2].

ამ მიზნის მისაღწევად, კვლევა მოიცავს რამდენიმე ძირითად სფეროს:

- EEG მონაცემების შეგროვება კონტროლირებად ექსპერიმენტულ პირობებში;
- EEG-ით ემოციების ამოცნობის თანამედროვე პრაქტიკისა და საჯაროდ ხელმისაწვდომი მონაცემთა ნაკრებების მიმოხილვა;
- EEG სიგნალების წინასწარი დამუშავების მეთოდები მონაცემების ხარისხისა და სანდოობის უზრუნველსაყოფად;
- მონაცემების ეფექტური წარმოდგენისთვის ნიშნების ამოღებისა და შერჩევის მეთოდები;
- მანქანური სწავლების რამდენიმე მოდელის ტრენინგი, ვალიდაცია და შედარებითი შეფასება;

- ექსპერიმენტული შედეგების კომპლექსური ანალიზი და ინტერპრეტაცია.

2. მასალები და მეთოდები

მონაცემთა ჩასაწერად შეირჩა მამრობითი სქესის სუბიექტი. ამისათვის გამოვიყენეთ ტექნიკური უნივერსიტეტის ლაბორატორია და CleveLabs-ის ელექტროენცეფალოგრაფი შვიდი ელექტროდის ნაკრებით. ელექტროენცეფალოგრამის მონაცემები ჩაიწერა ოთხ არხში: ორი მათგანი იწერდა შუბლის წილიდან მომავალ სიგნალს, ხოლო დანარჩენი ორი - კეფის წილიდან. სუბიექტი ლაბორატორიაში დილით მივიდა და არ მიუღია კოფეინის შემცველი დანამატები. სურათი 1 გვიჩვენებს ბიორადიოსა და თავზე განთავსებული 10/20 ელექტროდების სისტემის დიაგრამას [4].



სურათი 1. ექსპერიმენტის მიმდინარეობა

ჩვენი ვიდეოჩანაწერის ექსპერიმენტი დაახლოებით 3 საათს გაგრძელდა, თითოეული ვიდეო არ აღემატებოდა 3 წუთს, ზოგი კი 15 წამსაც კი. ექსპერიმენტის დროს ჩვენ არ შევკმენით ხმაურის ჩახშობისთვის განსაკუთრებული პირობები, რადგან მიზანი ასევე არის ემოციების ამოცნობის შესაძლებლობის შემოწმება რეალურ ცხოვრებაში და არაექსპერიმენტულ პირობებში.

ამ კვლევის მთავარი მიზანი იყო ემოციების ამოცნობის ხელოვნური ინტელექტის მოდელის შემუშავება და ინტეგრირება EEG მონაცემების გამოყენებით. ამის გასაადვილებლად გამოყენებული იქნა „EEGAIN“ ჩარჩო. ეს ჩარჩო სპეციალურად შექმნილი იყო ემოციების ამოცნობის ამოცანებისთვის EEG სიგნალების დამუშავების გასამარტივებლად და სტანდარტიზაციისთვის ხელოვნური ინტელექტის ტექნიკის გამოყენებით. EEGAIN შედგება ექვსი ჩაშენებული EEG მონაცემთა ნაკრებისა და ოთხი წინასწარ დანერგილი ღრმა სწავლების მოდელისგან. თუმცა, რადგან ამ კვლევაში გამოყენებული EEG მონაცემები შეგროვდა სხვადასხვა შეგროვების სისტემის გამოყენებით (მაგ., CleveLabs მოწყობილობა), საჭირო იყო მონაცემთა დამუშავების მორგებული მექანიზმის დანერგვა ჩარჩოსთან თავსებადობის უზრუნველსაყოფად [5,6].

ამის მისაღწევად შემუშავდა სპეციალიზებული Python კლასი, სახელწოდებით CleveLabs. ეს კლასი აფართოებს EEGAIN ჩარჩოს მიერ მოწოდებულ საბაზისო EEGDataset კლასს, რომელიც განსაზღვრავს EEG მონაცემების მართვის ძირითად ფუნქციონალს. Get-trials მეთოდი, კლასის კრიტიკული კომპონენტი, მორგებული იყო CleveLabs მოწყობილობის გამოყენებით ჩაწერილი სესიებიდან მონაცემების ამოსაღებად და დასამუშავებლად. ეს მეთოდი ასრულებს რამდენიმე

დავალებას, მათ შორის სესიის ფაილების სახელების წაკითხვას, EEG სიგნალის მონაცემების ჩატვირთვას და მის სტრუქტურირებას MNE ბიბლიოთეკასთან თავსებად ფორმატში, რომელიც ფართოდ გამოიყენება Python ბიბლიოთეკაში EEG-სა და სხვა ნეიროფიზიოლოგიური მონაცემების დასამუშავებლად [7].

3. მსჯელობა:

ექსპერიმენტული ცვლადები მოიცავდა:

- ხელოვნური ინტელექტის მოდელები: გამოცდილი იქნა ღრმა სწავლების ოთხი არქიტექტურა - TSception, EEGNet, DeepConvNet და ShallowConvNet [8,9,10].
- სწავლის სიჩქარე: გამოცდილი იქნა ორი მნიშვნელობა - 0.001 და 0.0001.
- რეგულარიზაციის პარამეტრები: ხელახალი სწავლების კონტროლისთვის გამოყენებული იქნა 0,1 და 0 მნიშვნელობები.
- ტრენინგის ეპოქები: შედარებული იქნა ტრენინგის სამი ხანგრძლივობა - 10, 40 და 500 ეპოქა.

სულ, ჩატარდა 50 სხვადასხვა ექსპერიმენტი ამ პარამეტრების სისტემატური ვარიაციით. შედეგებმა მოგვაწოდა ღირებული ინფორმაცია მოდელის ქცევის შესახებ სხვადასხვა კონფიგურაციაში და აჩვენა მისი უნარი, ამოიცნოს ემოციები EEG სიგნალების გამოყენებით რეალურ პირობებში. შედეგები კიდევ უფრო ამყარებს იმედს, რომ ხელოვნური ინტელექტი ნეირომეცნიერებასთან ინტეგრირდება ემოციური ინტელექტის მქონე სისტემების განვითარების მიზნით.

ექსპერიმენტული ანალიზის ჩასატარებლად შემუშავდა მოდულური Python სკრიპტი, რომელიც საშუალებას იძლევა ცალკეული ექსპერიმენტების ჩასატარებლად გარკვეული პარამეტრების ცვლილებებით. ვინაიდან თითოეული გაშვებისთვის საჭირო იყო პარამეტრების მხოლოდ შეზღუდული ნაკრების შეცვლა, როგორცაა მოდელის ტიპი, ტრენინგის სიჩქარე, რეგულარიზაციის კოეფიციენტი და ტრენინგის ეპოქების რაოდენობა, ყველა 50 ექსპერიმენტი განისაზღვრა ერთ ფორმატში. ეს ექსპერიმენტები ჩატარდა Google Collaboratory-ის (Google Colab) გამოყენებით - Google-ის ღრუბლოვანი პლატფორმის გამოყენებით, რომელიც გთავაზობთ Jupyter Notebook გარემოს, რომელზეც წვდომა პირდაპირ ვებ ბრაუზერის საშუალებითაა შესაძლებელი.

4. შედეგები:

საწყისი ექსპერიმენტული შეფასებების გარდა, ჩატარდა დამატებითი ტესტები შედეგების შემთხვევითობის შესაფასებლად. ამ ეტაპს გადამწყვეტი გავლენა ჰქონდა იმის დადასტურებაზე, რომ დაკვირვებული შედეგები ნამდვილად განპირობებულია მოდელის ეფექტური ტრენინგით და არა შემთხვევითობით ან ზედმეტი ტრენინგით.

Model	LR	REG	Epoch	Acc	F1	F1_weighted
RANDOM				0.31	0.31	0.32
Tsception	0.001	0	40	0.60	0.63	0.57
DeepConvNet	0.0001	0.1	40	0.65	0.65	0.57
ShallowConvNet	0.001	0	10	0.57	0.58	0.53
EEGNet	0.001	0.1	500	0.72	0.71	0.68

ცხრილი 1. 50 ექსპერიმენტული ცდის შედეგების ნიმუში. ცხრილის სვეტები ასახავს შემდეგ პარამეტრებს:

- მოდელი - ღრმა სწავლებისთვის გამოყენებული არქიტექტურა (მაგ., EEGNet, TSception და ა.შ.);
- LR - სწავლის სიჩქარე;
- REG - რეგულარიზაციის პარამეტრი;
- ეპოქა - ტრენინგის ეპოქების რაოდენობა;
- მეტრიკა F1 - სტანდარტული შეფასება F1, რომელიც ასახავს მოდელის სიზუსტეს და სისრულეს;
- შეწონილი მეტრიკა F1 - ყველა კლასის F1 ქულების შეწონილი საშუალო, კორექტირებული კლასის დისბალანსისთვის.

მოდელის ქცევის სანდო და რეალისტური გაგების მისაღებად აუცილებელია სამივე მეტრიკის - სიზუსტის, F1-ისა და F1-შეწონილის - ფრთხილად შეფასება.

ექსპერიმენტული შედეგების ანალიზმა გამოავლინა რამდენიმე ძირითადი ტენდენცია

- რეგულარიზაციის პარამეტრის ჩართვამ მუდმივად გააუმჯობესა მოდელის მუშაობა ზედმეტი ვარჯიშის შემცირების გამო, რითაც მოდელი სტიმულირებული იყო უფრო ეფექტური განზოგადებისთვის და არა ვარჯიშის მონაცემების დამახსოვრებისკენ.
- სხვადასხვა გამოცდილ კონფიგურაციებს შორის, EEGNet არქიტექტურამ 500 ვარჯიშის ეპოქით უზრუნველყო ყველაზე ეფექტური და სტაბილური მუშაობა ყველა შეფასების მეტრიკაზე.
- შედეგების ხარისხი შთამბეჭდავია, გამოყენებული EEG ელექტროდების შეზღუდული რაოდენობისა და ჩაწერის დროს ფონური ხმაურის არსებობის გათვალისწინებით - ორივე ფაქტორი ასახავს რეალისტურ, არალაბორატორიულ პირობებს.

ეს შედეგები ხაზს უსვამს EEG-ზე დაფუძნებული ემოციების ამოცნობის სისტემების მნიშვნელოვან პოტენციალს, განსაკუთრებით რეალურ აპლიკაციებში, სადაც უპირატესობა ენიჭება იაფ აღჭურვილობას და მინიმალურ შეზღუდვებს. ამ მიდგომის წარმატება ადასტურებს ხელოვნური ინტელექტის გამოყენების უფრო ფართო პერსპექტივას EEG-ზე დაფუძნებულ პერსონალიზებულ ემოციების ამოცნობის სისტემებში.

5. დასკვნა.

ამ კვლევაში გამოკვლეული იქნა ხელოვნური ინტელექტის მეთოდების გამოყენება ემოციების ამოცნობისთვის ელექტროენცეფალოგრაფიული (EEG) სიგნალების გამოყენებით. შედეგები აჩვენებს, რომ თანამედროვე ხელოვნური ინტელექტის მეთოდები, მათ შორის ნეირონული ქსელების და მანქანური სწავლების ალგორითმების შესწავლა, მნიშვნელოვნად ზრდის ემოციების კლასიფიკაციის სიზუსტეს და ეფექტურობას EEG მონაცემებზე დაყრდნობით.

ექსპერიმენტების შედეგები მოწმობს იმ ფაქტს, რომ ემოციების ზუსტი ამოცნობის მიღწევა შესაძლებელია წინასწარი დამუშავების მეთოდების, მონაცემთა სეგმენტაციის სტრატეგიების და ტრენინგის პარამეტრების ფრთხილად შერჩევით. აღსანიშნავია, რომ EEGNet მოდელი მუდმივად აჩვენებდა მაღალ შედეგებს, რაც ადასტურებს მის პოტენციალს რეალურ სამყაროში ინტეგრაციისთვის.

კვლევა ასევე ხაზს უსვამს ემოციების ამოცნობის სიცოცხლისუნარიანობას რეალისტურ, არალაბორატორიულ პირობებში, სადაც გარე ხმაური და გამარტივებული ელექტროდების

კონფიგურაციები განზრახ არ იყო ჩახშობილი. ეს პრაქტიკული მიდგომა ზრდის კვლევის აქტუალობას, რადგან ის შეესაბამება გამოყენების სცენარებს.

კვლევის შედეგები პერსპექტიულ შესაძლებლობებს ქმნის EEG-ზე დაფუძნებული ემოციების ამოცნობის სხვადასხვა სფეროში, როგორცაა სამედიცინო დიაგნოსტიკა, ფსიქიკური ჯანმრთელობის მონიტორინგი, ადაპტური ადამიან-კომპიუტერის ინტერფეისები და აფექტური გამოთვლითი სისტემები. გარდა ამისა, ეს ერთი ობიექტის, ხმაურისადმი მდგრადი მოდელი შეიძლება გახდეს საფუძველი მომავალი კვლევებისთვის, რომლებიც მიზნად ისახავს პოპულაციის უფრო ფართო განზოგადებას და უფრო რთული მრავალ-ობიექტიანი მოდელების შექმნას.

გამოყენებული ლიტერატურა:

1. Britton, Jeffrey W, and Frey, Lauren C, and Hopp, Jennifer L, and Korb, Pearce, and Koubeissi, Mohamad Z., and Lievens, William E, and Pestana-Knight, Elia M, and St Louis, Erk. Electroencephalography (EEG): An introductory text and atlas of normal and abnormal findings in adults, children, and infants (2016).
2. M. Teplan. Fundamentals of EEG measurement (2002).
3. Dzedzickis, Andrius and Kaklauskas, Artras and Bucinskas, Vytautas. Human emotion recognition: Review of sensors and methods (2020).
4. G. Gigilashvili, I. Gotsiridze, Z. Mgaloblishvili, Z. Ghurtskaia, M. Tsiklauri. Medical Engineering Laboratory System (2012). https://gtu.ge/book/clevemed_lab.pdf
5. N.Kukhilava, T.Tsmindashvili, R.Kalandadze, A.Gupta, S.Katamadze, F. Brémont, L.M. Ferrari, P. M Müller, and B. E. Wirth. Evaluation in EEG Emotion Recognition: State-of-the-Art Review and Unified Framework (2025). <https://github.com/EmotionLab/EEGain>
6. Gramfort, Alexandre, and Luessi, Martin, and Larson, Eric, and Engemann, Denis A, and Strohmeier, Daniel, and Brodbeck, Christian, and Parkkonen, Lauri, and Hinen, Matti. MNE software for processing MEG and EEG data (2014).
7. Ji, Shuiwang and Xu, Wei and Yang, Ming and Yu, Kai. 3D convolutional neural networks for human action recognition (2012).
8. Ding, Yi, and Robinson, Neethu, and Zhang, Su, and Zeng, Qiuhaio, and Guan, Cuntai. TSception: Capturing Temporal Dynamics and Spatial Asymmetry From EEG for Emotion Recognition (2022).
9. Lawhern, Vernon J, and Solon, Amelia J, and Waytowich, Nicholas R., and Gordon, Stephen M, and Hung, Chou P., and Lance, Brent J. EEGNet: a compact convolutional neural network for EEG-based brain-computer interfaces (2018).

Emotion Recognition from Electroencephalography Using Deep Learning: A Single-Subject Study

Mariam Tsiklauri, Tatia Tsmindashvili

Georgian Technical University, Georgia.

m.tsiklauri@gtu.ge, tsmindashvili.tatia@gtu.ge

Abstract

This paper investigates the use of artificial intelligence for emotion recognition from EEG signals collected with a low-cost headset in ecologically valid conditions. We adopt a design with substantial variability of EEG data, which is a large, multisubject dataset. By concentrating on one individual, we aim to build a highly accurate, personalized AI model that predicts that person's emotional states.

Overall, this paper demonstrates that precise, reliable, and personalized emotion recognition is achievable even with a lightweight headset and real-world protocols. This focused approach provides a practical springboard for scaling to larger populations and integrating emotion detection into diverse human-computer interaction (HCI) modules.

Keywords: EEG signal, AI-artificial intelligence, CleveLabs. Human-Computer Interaction (HCI) modules.