

ემოციის ამოცნობა ელექტროენცეფალოგრაფიული სიგნალებიდან ხელოვნური ინტელექტის გამოყენებით

მარიამ წიკლაური¹, თათია წმინდაშვილი², ლევან ლაზარაშვილი³

¹PhD, ასისტენტ პროფესორი, საქართველოს ტექნიკური უნივერსიტეტი; ²MD, ბიოსამედიცინო ინჟინერიის მაგისტრი, საქართველოს ტექნიკური უნივერსიტეტი; ³PhD, პროფესორი, საქართველოს ტექნიკური უნივერსიტეტი

აბსტრაქტი

თეზისი იკვლევს ხელოვნური ინტელექტის გამოყენებას ემოციების ამოცნობაში, EEG სიგნალების საშუალებით. ფოკუსირებულია ერთ სუბიექტურ მოდელზე - ერთ კონკრეტულ ადამიანზე. ერთი სუბიექტის მიდგომის არჩევა განპირობებულია EEG მონაცემების თანდაყოლილი სუბიექტთაშორისი არსებითი ცვალებადობით. ასეთი ცვალებადობა ხშირად საჭიროებს დიდი რაოდენობით მონაცემთა მოგროვებას, რათა მოვახერხოთ განზოგადება სხვადასხვა ინდივიდებს შორის, რაც ამ ეტაპზე არაპრაქტიკულია მონაცემების შეგროვებასთან დაკავშირებული სირთულეების გათვალისწინებით. ერთი ინდივიდის EEG სიგნალებზე კონცენტრირებით, ეს კვლევა მიზნად ისახავს ძლიერი ხელოვნური ინტელექტის მოდელის შემუშავებას, რომელსაც შეუძლია ზუსტად განსაზღვროს ემოციური მდგომარეობა ერთი კონკრეტული ადამიანისთვის.

კვლევის მეთოდოლოგია მოიცავს EEG მონაცემების სისტემატიურ შეგროვებას კონტროლირებად ექსპერიმენტულ პირობებში ერთი ინდივიდისთვის, რომელიც შექმნილია განსხვავებული ემოციური რეაქციების გამოსაწვევად. შეგროვებული EEG მონაცემები შემდეგ წინასწარ მუშავდება ხმაურის და არტეფაქტების მოსაშორებლად, რაც უზრუნველყოფს სიგნალების ხარისხსა და საიმედოობას. მანქანური სწავლებისა და ღრმა დასწავლის ალგორითმები გამოიყენება EEG მონაცემებში წარმოდგენილი ემოციური მდგომარეობის კლასიფიკაციისთვის.

რომ შევაჯამოთ, კვლევა წარმოადგენს ემოციების ამოცნობის ახალ მიდგომას, EEG სიგნალებისა და ხელოვნური ინტელექტის გამოყენებით. აჩვენებს ზუსტი, საიმედო და პერსონალიზებული ემოციების ამოცნობის სისტემების შემუშავების პოტენციალს. ერთ სუბიექტზე დახვეწილი კვლევა კარგი საწყისია მომავალში ბევრ ადამიანზე განზოგადებისთვის და ამ ეტაპზე უკვე შესაძლებელია

მისი გამოყენება სხვადასხვა ადამიანის-კომპიუტერის ურთიერთქმედების მოდულებში.

საკვანძო სიტყვები: EEG - ელექტროენცეფალოგრამის სიგნალი, AI - ხელოვნური ინტელექტი, CleveLabs.

შესავალი

თანამედროვე ციფრულ ეპოქაში, ხელოვნური ინტელექტისა (AI) და ნეირომეცნიერების კონვერგენციამ ახალი გზები გახსნა ადამიანის ემოციების უფრო ღრმა გაგებისა და ინტერპრეტაციისთვის. ყველაზე ინფორმაციულ ფიზიოლოგიურ სიგნალებს შორის, ელექტროენცეფალოგრაფიული (EEG) სიგნალები ტვინის აქტივობის შესახებ ღირებულ ინფორმაციას გვაწვდის, რაც მათ ემოციური მდგომარეობების ამოცნობისა და მოდელირების ძლიერ ინსტრუმენტად აქცევს. EEG მონაცემებზე დაფუძნებული ემოციების ამოცნობა კრიტიკულ კომპონენტად იქცა მოწინავე ადამიან-კომპიუტერის ურთიერთქმედების (HCI) სისტემების განვითარებაში, რომელთა გამოყენება მოიცავს ფსიქოლოგიური დახმარების სისტემებს, სათამაშო გარემოს, ვირტუალური რეალობის გამოცდილებას და ადაპტირებულ მომხმარებლის ინტერფეისებს.

კვლევის მოტივაცია ორი სწრაფად განვითარებადი და გავლენიანი სფეროს ინტეგრაციაა: ხელოვნური ინტელექტი - რომელიც უკვე აჩვენებს ტრანსფორმაციულ ეფექტებს სხვადასხვა ინდუსტრიაში - და ნეირომეცნიერება, რომელიც მზადაა ექსპონენციალური განვითარებისთვის, რადგან ნეიროფიზიოლოგიისა და ტვინის სიგნალის გაზომვის ტექნოლოგიები აგრძელებს გაუმჯობესებას. ამ დისციპლინებს შორის სინერგია გვპირდება როგორც ტექნოლოგიური შესაძლებლობების, ასევე მომხმარებლის გამოცდილების გაუმჯობესებას იმ სისტემების საშუალებით, რომლებსაც შეუძლიათ ადაპტირება და ადამიანის ემოციურ მდგომარეობებთან ინტერპრეტაცია მზარდი სიზუსტით.

ნაშრომის მთავარი მიზანია ხელოვნური ინტელექტისა და ნეირომეცნიერების დაკავშირება ემოციური ამოცნობის უფრო ზუსტი, საიმედო და პროგნოზირებადი მოდელების შესაქმნელად. ასეთი ინტეგრაცია არა მხოლოდ ინოვაციური ტექნოლოგიების განვითარებას უწყობს ხელს, არამედ ხელს უწყობს ადამიანის ტვინისა და მისი ფუნქციების უფრო ღრმა გაგებას. ეს, თავის მხრივ, ფართო გავლენას ახდენს სხვადასხვა სფეროზე, მათ შორის მედიცინაზე, განათლებაზე, ფსიქიკურ ჯანმრთელობაზე და სხვა სფეროებზე.

მიზანი

კვლევის მთავარი მიზანია ელექტროენცეფალოგრაფიული (EEG) სიგნალების გამოყენებით ემოციების ამოცნობის მეთოდოლოგიის შემუშავება და ოპტიმიზაცია

ხელოვნური ინტელექტის (AI) ტექნიკის გამოყენებით. კვლევის მიზანია ემოციური მდგომარეობების კლასიფიკაციაში სხვადასხვა მანქანური სწავლებისა და ღრმა სწავლების ალგორითმების მუშაობისა და სიზუსტის ანალიზი და შეფასება - რაც არსებითი ნაბიჯია ადამიან-კომპიუტერის ურთიერთქმედების (HCI) სისტემების ეფექტურობის გაუმჯობესებისკენ.

ამ მიზნის მისაღწევად, კვლევა რამდენიმე ძირითად სფეროს მოიცავს:

- EEG მონაცემების შეგროვება კონტროლირებად ექსპერიმენტულ პირობებში;
- მიმდინარე პრაქტიკისა და საჯაროდ ხელმისაწვდომი EEG ემოციების ამოცნობის მონაცემთა ნაკრებების მიმოხილვა;
- EEG სიგნალების წინასწარი დამუშავების ტექნიკა მონაცემთა ხარისხისა და სანდოობის უზრუნველსაყოფად;
- მახასიათებლების ამოღებისა და შერჩევის მეთოდები მონაცემთა ეფექტური წარმოდგენისთვის;
- მრავალი მანქანური სწავლების მოდელის ტრენინგი, ვალიდაცია და შედარებითი შეფასება;
- ექსპერიმენტული შედეგების ყოვლისმომცველი ანალიზი და ინტერპრეტაცია.

ამ კვლევის შედეგად მიღებული დასკვნები და ინფორმაცია ხელს შეუწყობს მოწინავე განხორციელების სტრატეგიების შემუშავებას, რითაც გაუმჯობესდება ხელოვნურ ინტელექტზე დაფუძნებული ემოციების ამოცნობის სისტემების სიზუსტე, სანდოობა და გამოყენებადობა სხვადასხვა სფეროში.

მასალები და მეთოდები

მონაცემთა ჩასაწერად შევარჩიეთ ერთი მამრობითი სქესის სუბიექტი. გამოვიყენეთ ტექნიკური უნივერსიტეტის ლაბორატორია და CleveLabs-ის ელექტროენცეფალოგრამის ჩამწერი მოწყობილობა თავისი კომპლექტით, რომელიც მოიცავს შვიდ ოქროსფერ-წვერიან ელექტროდს და ელექტროგამტარ გელს. ელექტროენცეფალოგრამის მონაცემები ოთხი არხით ჩავწერეთ; აქედან ორმა არხმა შუბლის წილიდან წამოსული სიგნალი ჩაწერა, ხოლო დანარჩენმა ორმა - კეფის წილიდან; სუბიექტი ლაბორატორიაში დილით მივიდა და კოფეინის შემცველი დანამატები არ მიუღია. სურათი 1 გვიჩვენებს ბიორადიოსა და თავზე განთავსებული ელექტროდების 10/20 სისტემის სქემას.

ჩვენი ვიდეოჩანაწერის ექსპერიმენტი დაახლოებით 3 საათს გაგრძელდა, თითოეული ვიდეო 3 წუთს არ აღემატებოდა, ზოგიერთი მათგანი 15 წამსაც კი გრძელდებოდა. ექსპერიმენტის დროს ხმაურის ჩასახშობად რაიმე განსაკუთრებული პირობები არ შეგვიქმნია, რადგან მიზანი ასევე არის იმის

გადამოწმება, შესაძლებელია თუ არა ემოციების ამოცნობა რეალურ ცხოვრებაში და არაექსპერიმენტულ პირობებში.




სურათი 1. ექსპერიმენტის მიმდინარეობა

მოდელის არჩევა

კვლევაში მთავარი მიზანი იყო ხელოვნური ინტელექტის მოდელის შემუშავება და ინტეგრაცია ემოციების ამოცნობისთვის EEG მონაცემების გამოყენებით. ამის გასაადვილებლად, გამოყენებული იქნა "EEGain" ჩარჩო. ეს ჩარჩო სპეციალურად შექმნილია 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 (მაგ., CleveLabs მოწყობილობის) გამოყენებით, საჭირო იყო მონაცემთა დამუშავების მორგებული მექანიზმის დანერგვა ჩარჩოსთან თავსებადობის უზრუნველსაყოფად.

ამის მისაღწევად, შემუშავდა სპეციალიზებული Python კლასი სახელწოდებით CleveLabs. ეს კლასი აფარტოებს EEGain ჩარჩოს მიერ მოწოდებულ საბაზისო EEGDataset კლასს, რომელიც განსაზღვრავს EEG მონაცემების მართვის ძირითად ფუნქციონალურობას. `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 მათ სტრუქტურირებას MNE ბიბლიოთეკასთან თავსებად ფორმატში - ფართოდ გამოყენებადი Python ბიბლიოთეკა EEG-სა და სხვა ნეიროფიზიოლოგიური მონაცემების დასამუშავებლად.



სურათი 2. ფრეიმვორკის სტრუქტურა

კლასში განსაზღვრულია ძირითადი პარამეტრები, როგორიცაა არხის სახელები და შერჩევის სიხშირე, ჩაწერილი სიგნალების ზუსტი წარმოდგენის უზრუნველსაყოფად. მრავალი სესიიდან შეგროვებული მონაცემები გადის წინასწარი დამუშავების ტრანსფორმაციებს - არტეფაქტების მოშორებიდან ნორმალიზებამდე - სანამ მოდელის ტრენინგისა და შეფასებისთვის შესაფერის ფორმატში ორგანიზდება. შემდეგ ემოციის ეტიკეტები ენიჭება თითოეულ ცდას წინასწარ განსაზღვრული ლექსიკონის საფუძველზე, რომელიც ასახავს სუბიექტის მიერ თითოეულ სტიმულზე თვითშეფასებულ ემოციურ რეაქციებს.

სურათი 2 ასახავს EEGain ჩარჩოს საერთო არქიტექტურას და სამუშაო პროცესს, მათ შორის CleveLabs მონაცემთა კლასის ინტეგრაციას.

ექსპერიმენტი

ექსპერიმენტების ჩატარებამდე აუცილებელი იყო EEG მონაცემების წინასწარი დამუშავება და სეგმენტირება, რათა უზრუნველყოფილიყო თავსებადობა მანქანური სწავლების მოდელებთან და გაძლიერებულიყო შედეგების სანდოობა. წინასწარი დამუშავების საწყისი ეტაპი მოიცავდა ნედლი EEG სიგნალების ფილტრაციას. თავდაპირველად გამოყენებული იქნა ჭრილის ფილტრი 50/60 ჰც სიხშირის ელექტროგადამცემი ხაზის ჩარევის აღმოსაფხვრელად. შემდგომში, დანერგილი იქნა ზოლის გამტარი ფილტრი სიგნალის სიხშირეების 0.3–30 ჰც დიაპაზონში შესანარჩუნებლად - სიხშირეები, რომლებიც ჩვეულებრივ ასოცირდება კოგნიტურ და ემოციურ ტვინის აქტივობასთან. ამ პროცესმა მოითხოვა სიგნალების სიხშირის დომენში გარდაქმნა ფურიეს გარდაქმნის

გამოყენებით, რაც საშუალებას იძლეოდა სასურველი სიხშირის კომპონენტების იზოლირების.

იმის გათვალისწინებით, რომ EEG სიგნალები თავდაპირველად იწერებოდა 480 ჰც სიხშირით, მონაცემთა მოცულობა მნიშვნელოვანი იყო. ამის გადასაჭრელად, გამოყენებული იქნა შემცირებული შერჩევა, რათა შემცირებულიყო შერჩევის სიხშირე 128 ჰც-მდე, რითაც მონაცემები უფრო მართვადი გახდა გამოთვლითი დამუშავებისთვის სიგნალის ხარისხის მნიშვნელოვანი კომპრომისის გარეშე.

სიგნალის ფილტრაციისა და შემცირებული შერჩევის შემდეგ, გამოყენებული იქნა ფანჯარა, რათა უწყვეტი EEG სიგნალი დაყოფილიყო უფრო მცირე, ანალიზირებად კადრებად. ფანჯრის შექმნა კრიტიკული ნაბიჯია როგორც ხმაურის შემცირებისთვის, ასევე EEG სიგნალში დროებითი მახასიათებლების იდენტიფიცირებისთვის. ვინაიდან წამში 128 მონაცემთა წერტილი იწერება შემცირებული სიჩქარით, თითოეული წერტილის ინდივიდუალურად კლასიფიკაცია არაპრაქტიკულია. ამიტომ, მნიშვნელოვანი ნიმუშების აგრეგირებისთვის გამოიყენება ფიქსირებული სიგრძის სეგმენტები (ფანჯრები). ამ კვლევაში შეირჩა 2-წამიანი ფანჯარა, რომელიც დროებით გარჩევადობასა და სიგნალის სტაბილურობას შორის ბალანსს იცავს. ეს მიდგომა აძლიერებს დინამიური ემოციური ნიმუშების დროთა განმავლობაში აღმოჩენას და ხელს უწყობს უფრო ზუსტ კლასიფიკაციას.

შემდეგი ნაბიჯი მოიცავდა მონაცემთა სეგმენტაციას მოდელის ტრენინგისა და შეფასებისთვის. იმის გათვალისწინებით, რომ მონაცემთა ნაკრები შედგებოდა ერთი სუბიექტისა და 26 EEG ჩანაწერისგან, განხილული იქნა მონაცემების ტრენინგისა და ტესტირების ქვეჯგუფებად დაყოფის რამდენიმე სტრატეგია. შემთხვევითი შერჩევის ან ემოციური კატეგორიის მიხედვით დაყოფის ნაცვლად, კვლევაში გამოყენებული იქნა K-ჯერადი ჯვარედინი ვალიდაცია, მეთოდი, რომელიც განსაკუთრებით შესაფერისია მცირე მონაცემთა ნაკრებებისთვის. ამ მიდგომით, მონაცემები იყოფა k თანაბარი ზომის ქვეჯგუფებად (ნაკვეთებად). მოდელი ვარჯიშობს $k-1$ ქვეჯგუფზე და ვალიდირდება დარჩენილზე. ეს პროცესი მეორდება k -ჯერ, თითოეული ნაკვეთი ერთხელ წარმოადგენს ვალიდაციის ნაკვეთს. ყველა იტერაციის შედეგები საშუალოდ გამოითვლება მოდელის მუშაობის უფრო ზუსტი და მიუკერძოებელი შეფასების მისაღებად. ამ კვლევაში, K განისაზღვრა ისე, რომ თითოეული ნაკვეთი შედგებოდა 2 ვიდეო სესიისგან, რაც უზრუნველყოფდა მოდელის განზოგადების უნარის სამართლიან და სისტემატურ შეფასებას.

მონაცემების მომზადების შემდეგ, ჩატარდა ექსპერიმენტების სერია, რათა შესწავლილიყო სხვადასხვა პარამეტრის გავლენა მოდელის მუშაობაზე. ექსპერიმენტული ცვლადები მოიცავდა:

- ხელოვნური ინტელექტის მოდელები: გამოცდილი იქნა ღრმა სწავლების ოთხი არქიტექტურა - TSception, EEGNet, DeepConvNet და ShallowConvNet.
- სწავლების მაჩვენებლები: შემოწმდა ორი მნიშვნელობა - 0.001 და 0.0001.
- რეგულარიზაციის პარამეტრები: შეფასდა 0.1 და 0 მნიშვნელობები ზედმეტად მორგების კონტროლისთვის.
- ტრენინგის ეპოქები: შედარებული იქნა სამი ტრენინგის ხანგრძლივობა - 10, 40 და 500 ეპოქა.


სულ, ჩატარდა 50 განსხვავებული ექსპერიმენტი ამ პარამეტრების სისტემატურად ცვალებადობით. შედეგებმა ღირებული ინფორმაცია მოგვაცოდა მოდელის ქცევის შესახებ სხვადასხვა კონფიგურაციის პირობებში და აჩვენა ემოციების ამოცნობის შესაძლებლობა ელექტროენცეფალოგრამის სიგნალების გამოყენებით რეალისტურ გარემოში. შედეგები კიდევ უფრო აძლიერებს ხელოვნური ინტელექტის ნეირომეცნიერებასთან ინტეგრირების იმედს ემოციურად ინტელექტუალური სისტემების განვითარების მიზნით.

ექსპერიმენტული ანალიზის ჩასატარებლად, შემუშავდა მოდულური Python სკრიპტი, რომელიც ინდივიდუალური ექსპერიმენტების შესრულებას კონკრეტული პარამეტრების ცვლილებით უზრუნველყოფდა. ვინაიდან თითოეული გაშვებისთვის მხოლოდ შეზღუდული პარამეტრების ნაკრების - როგორცაა მოდელის ტიპი, სწავლის სიჩქარე, რეგულარიზაციის კოეფიციენტი და სასწავლო ეპოქების რაოდენობა - შეცვლა იყო საჭირო, ყველა 50 ექსპერიმენტი განისაზღვრა თანმიმდევრული ფორმატის გამოყენებით. ეს ექსპერიმენტები შესრულდა Google Collaboratory-ის (Google Colab) გამოყენებით, Google-ის მიერ მოწოდებული ღრუბელზე დაფუძნებული პლატფორმის გამოყენებით, რომელიც გთავაზობთ Jupyter Notebook გარემოს, რომელიც პირდაპირ ხელმისაწვდომია ვებ ბრაუზერის საშუალებით.

Google Colab განსაკუთრებით კარგად შეეფერება მანქანური სწავლებისა და მონაცემთა მეცნიერების აპლიკაციებს, რადგან ის უზრუნველყოფს თავისუფალ წვდომას მაღალი ხარისხის გამოთვლით რესურსებზე, მათ შორის GPU-ებსა და TPU-ებზე, რითაც მნიშვნელოვნად ამცირებს რთული ღრმა სწავლების მოდელების ტრენინგისთვის საჭირო გამოთვლით დროს. გამოთვლითი მხარდაჭერის გარდა, პლატფორმა საშუალებას იძლევა Python ბიბლიოთეკების სწრაფი ინსტალაციის, რეალურ დროში კოდის გაზიარებისა და თანამშრომლობითი განვითარებისთვის, რაც მას იდეალურს ხდის როგორც ინდივიდუალური კვლევითი პროექტებისთვის, ასევე გუნდური სამუშაოსთვის.

სასწავლო პროცესის განმავლობაში, დანაკარგების მრუდები კონტროლდებოდა ეპოქებში პროგნოზირების შეცდომის შემცირების თვალყურის დევნებისთვის. ეს ვიზუალიზაცია, როგორც ეს ნაჩვენებია ნახაზ 1-ში, აუცილებელია მოდელის

სწავლის პროგრესის შესაფასებლად და იმის დასადგენად, ეფექტურად ამცირებს თუ არა ის დანაკარგის ფუნქციას ვარჯიშის დროს.



ნახაზი 1. შეცდომების რაოდენობის შემცირება ეპოქების განმავლობაში

შედეგები

პირველადი ექსპერიმენტული შეფასებების გარდა, ჩატარდა დამატებითი ტესტები შედეგების შემთხვევითობის შესაფასებლად. ეს ნაბიჯი გადამწყვეტი იყო იმის დასადასტურებლად, რომ დაკვირვებული შედეგები ნამდვილად განპირობებული იყო მოდელის ეფექტური სწავლებით და არა შემთხვევითობით ან ზედმეტად მორგებით.

მოდელი	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. შედეგები

ცხრილი 1. წარმოადგენს 50 ექსპერიმენტული ცდიდან მიღებული შედეგების შერჩევას. ცხრილის სვეტები წარმოადგენს შემდეგ პარამეტრებს:

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

F1 მეტრიკა განსაკუთრებით ღირებულია კლასიფიკაციის შესრულების შესაფასებლად არაბალანსირებული მონაცემთა ნაკრებების კონტექსტში, სადაც ზოგიერთი კლასი (ანუ კონკრეტული ემოციური მდგომარეობები) უფრო გავრცელებულია, ვიდრე სხვები. ასეთ შემთხვევებში, სტანდარტული სიზუსტე შეიძლება შეცდომაში შემყვანი იყოს, რადგან შეიძლება ასახავდეს უმრავლესობის კლასების ძლიერ შესრულებას, ხოლო უმცირესობის კლასების უგულვებელყოფას. F1 შეწონილი მეტრიკა ამ საკითხს აგვარებს თითოეული კლასის F1 ქულის მისი სიხშირის პროპორციულად ჩართვით, რითაც გვთავაზობს მოდელის მუშაობის უფრო ყოვლისმომცველ და ობიექტურ შეფასებას მრავალკლასიანი კლასიფიკაციის ამოცანებში.

მოდელის ქცევის სანდო და რეალისტური გაგების მისაღებად აუცილებელია სამივე მეტრიკის - სიზუსტის, F1 და F1 შეწონილი - საფუძვლიანი შეფასება.

ექსპერიმენტული შედეგების ანალიზმა გამოავლინა რამდენიმე ძირითადი ტენდენცია:

- რეგულარიზაციის პარამეტრის ჩართვამ მუდმივად გააუმჯობესა მოდელის მუშაობა ზედმეტად მორგების შემცირებით, რითაც წაახალისა მოდელი უკეთესად განზოგადებულიყო სასწავლო მონაცემების დამახსოვრების ნაცვლად.
- გამოცდილ სხვადასხვა კონფიგურაციებს შორის, EEGNet არქიტექტურამ 500 სასწავლო ეპოქასთან ერთად უზრუნველყო ყველაზე ეფექტური და სტაბილური მუშაობა ყველა შეფასების მეტრიკაში.
- შედეგების ხარისხი აღსანიშნავია გამოყენებული EEG ელექტროდების შეზღუდული რაოდენობისა და ჩაწერის დროს გარემოს ხმაურის არსებობის გათვალისწინებით - ორივე ასახავს რეალისტურ, არალაბორატორიულ პირობებს.

ეს დასკვნები ხაზს უსვამს EEG-ზე დაფუძნებული ემოციების ამოცნობის სისტემების მნიშვნელოვან პოტენციალს, განსაკუთრებით რეალურ სამყაროში, სადაც უპირატესობა ენიჭება დაბალფასიან აპარატურას და მინიმალურ შეზღუდვებს. ამ მიდგომის წარმატება მხარს უჭერს ხელოვნური ინტელექტის გამოყენების უფრო ფართო სიცოცხლისუნარიანობას პერსონალიზებულ, ელექტროენცეფალოგრამაზე დაფუძნებულ ემოციების აღმოჩენის ჩარჩოებში.

დასკვნა

კვლევა შეისწავლის ხელოვნური ინტელექტის ტექნიკის გამოყენებას ემოციების ამოცნობისთვის ელექტროენცეფალოგრაფიული (EEG) სიგნალების გამოყენებით. შედეგები აჩვენებს, რომ თანამედროვე ხელოვნური ინტელექტის მეთოდოლოგიები - განსაკუთრებით ღრმა სწავლების ნეირონული ქსელები და მანქანური სწავლების ალგორითმები - მნიშვნელოვნად ზრდის ემოციების კლასიფიკაციის სიზუსტეს და ეფექტურობას EEG მონაცემებზე დაყრდნობით.

ჩატარებული ექსპერიმენტების შედეგები მიუთითებს, რომ ემოციების ზუსტი ამოცნობა მიიღწევა წინასწარი დამუშავების ტექნიკის, მონაცემთა სეგმენტაციის სტრატეგიების და ტრენინგის პარამეტრების ფრთხილად შერჩევით. აღსანიშნავია, რომ EEGNet მოდელი მუდმივად აჩვენებდა ძლიერ შესრულებას, 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 აძლიერებს კვლევის აქტუალობას, რადგან ის რეალურ სამყაროში გამოყენების შემთხვევებს შეესაბამება.

კვლევის შედეგები გვთავაზობს პერსპექტიულ შესაძლებლობებს EEG-ზე დაფუძნებული ემოციების ამოცნობის გამოყენებისთვის სხვადასხვა სფეროში, როგორცაა სამედიცინო დიაგნოსტიკა, ფსიქიკური ჯანმრთელობის მონიტორინგი, ადაპტური ადამიან-კომპიუტერის ინტერფეისები და აფექტური გამოთვლითი სისტემები. გარდა ამისა, ეს ერთსაგანი, ხმაურისადმი ტოლერანტული ჩარჩო შეიძლება გახდეს საფუძველი მომავალი კვლევებისთვის, რომლებიც მიზნად ისახავს პოპულაციის უფრო ფართო განზოგადებას და უფრო რთულ მრავალსაგნობრივ მოდელებს.

დასკვნის სახით, ეს ნაშრომი მნიშვნელოვან წვლილს შეიტანს ხელოვნური ინტელექტისა და ნეირომეცნიერების მზარდ გადაკვეთაში, რაც გზას უხსნის უფრო პერსონალიზებული, ეფექტური და ხელმისაწვდომი ემოციების ამოცნობის ტექნოლოგიების შემუშავებისკენ.

გამოყენებული ლიტერატურა

1. "Electroencephalography (EEG): An introductory text and atlas of normal and abnormal findings in adults, children, and infants" 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. (2016).
2. "Fundamentals of EEG measurement" M. Teplan. (2002).
3. "Electroencephalography". Andrea Biasucci, Benedetta Franceschiello, Micah M. Murray. (2019)
4. "Feature extraction from EEGs associated with emotions". T. Musha, Y. Terasaki, H. Haque, and G. Ivamitsky. (1997).
5. "Towards emotion recognition from electroencephalographic signals". K. Schaaff and T. Schultz. (2009)
6. "Toward an EEG-based recognition of music liking using time-frequency analysis". S. K. Hadjidimitriou and L. J. Hadjileontiadis (2012)
7. "Emotion recognition from EEG using higher order crossings". P. C. Petrantonakis and L. J. Hadjileontiadis. (2010)
8. "Remarks on emotion recognition from multimodal bio-potential signals,". K. Takahashi. (2004)
9. "EEG feature extraction for classifying emotions using FCM and FKM,". M. Murugappan, M. Rizon, S. Yaacob, I. Zunaidi, and D. Hazry. (2007)
10. "EEG-based emotion recognition using frequency domain features and support vector machines". X. Wang, D. Nie, and B. Lu. (2011)

Emotion recognition from electroencephalographic signals using artificial intelligence

Mariam Tsiklauri¹, Tatia Tsmindashvili², Levan Lazarashvili³

¹PhD, Asistent Professor. Georgian Technical University, Georgia. Email: m.tsiklauri@gtu.ge ²MD, Georgian Technical University, Georgia. Email: tsmindashvili.tatia@gtu.ge ³PhD, Professor. Georgian Technical University, Georgia. Email: levan.lazarashvili@ivermedi.com

Abstract

This thesis examines the application of artificial intelligence in emotion recognition using EEG signals, with a focus on a subjective model, specifically, one individual. The choice of a single-subject approach is due to the substantial inter-subject variability inherent in EEG data. Such variability often requires the collection of large amounts of data to allow generalization across individuals, which is currently impractical given the difficulties associated with collecting EEG data from multiple subjects. By focusing on the EEG signals of a single individual, this research aims to develop a powerful artificial intelligence model that can accurately predict the emotional state of a single individual.

The methodology of this study involves the systematic collection of EEG data under controlled experimental conditions for a single individual, designed to elicit different emotional responses. The collected EEG data is then pre-processed to remove noise and artifacts, ensuring the quality and reliability of the signals. Machine learning and deep learning algorithms are used to classify emotional states presented in EEG data.

To summarize, this thesis presents an approach to emotion recognition using EEG signals and artificial intelligence, demonstrating the potential for developing accurate, reliable, and personalized emotion recognition systems. Refined research on one subject is a good starting point for future generalizations to many people; from this point, it is already possible to apply it to various human-computer interaction modules.

Keywords: EEG signal, AI-artificial intelligence, CleveLabs.