

ივანე ჯავახიშვილის სახელობის თბილისის სახელმწიფო უნივერსიტეტი  
ზუსტ და საბუნებისმეტყველო მეცნიერებათა ფაკულტეტი



**დემური ლომსაძე**

**IoT BCI პერსპექტივა**

ინფორმაციული ტექნოლოგიები

ინფორმაციული ტექნოლოგიების მაგისტრის აკადემიური ხარისხის მოსაპოვებლად

ხელმძღვანელი: ასოცირებული პროფესორი ლელა მირცხულავა

თბილისი  
2021

## სარჩევი

ანოტაცია.....	2
Abstract.....	3
შესავალი.....	4
თავი I. ძირითადი კონცეფციები და დაკავშირებული კვლევები .....	7
1.1 ტვინის ტალღები .....	7
1.2 ტვინისა და კომპიუტერის ინტერფეისი, BCI .....	7
1.3 ელექტროენცეფალოგრაფია, EEG .....	8
1.4 ტვინის ტალღების კვლევები.....	9
თავი II. მეთოდები .....	13
2.1 EEGLAB -ით წინასწარი დამუშავება .....	13
2.2 მოდული ESP32 .....	14
2.2.1 ღია მოწყობილობები.....	16
2.2.2 სისტემის დიზაინი და არქიტექტურა .....	16
2.2.3 სიმძლავრის სპექტრული სიმკვრივის ანალიზი .....	18
2.2.4 მასალები და მეთოდები .....	18
2.2.5 მონაცემთა გადაცემა.....	21
2.3 ღრმა სწავლების ფრეიმვორკი, DL Framework.....	21
2.3.1 მეთოდი .....	23
2.3.2 ექსპერიმენტი .....	26
2.3.3 ტვინით აკრეფის სისტემა.....	27
2.3.4 კოგნიტური რობოტი .....	30
თავი III. განხილვა .....	32
დასკვნა .....	35
გამოყენებული ლიტერატურა.....	36

### ანოტაცია

ინფორმაციული ტექნოლოგიების სწრაფი განვითარების ტემპი უფრო და უფრო ამცირებს ადამიანის ყოველდღიურობაში რუტინულ იტერაციულ ქცევებს და სამომავლო პერსპექტივისთვის გვთავაზობს, ადამიანის, როგორც მომხმარებლის ეფექტორ მოწყობილობებთან არსებული ფიზიკური ინტერაქციის ტიპიური მეთოდების - ვიზუალური, ხმოვანი თუ აკრეფითი, ახალ დონეზე გადასვლას - განზრახვის გადამთარგმნი მოწყობილობებით ურთიერთქმედებას. ამ ნაშრომში განხილულია ელექტროენცეფალოგრაფიით (EEG) ტვინის ტალღების სიგნალების მოპოვებისა და შემდგომი დამუშავების არაინვაზიური ტვინი-კომპიუტერის ინტერფეისის (BCI) მეთოდოლოგიები, რომელთა ინტეგრირებაც შესაძლებელია როგორც მედიცინაში, ასევე ნივთების ინტერნეტის (IoT) გარემოში. მიღებული გადაუმუშავებელი მონაცემების დამუშავების წარმოდგენილ მეთოდებში გამოიყენება: MATLAB -ში ჩაშენებული EEGLAB -ის ხელსაწყო; ღია წყაროს (open source) პროგრამული უზრუნველყოფითა და შემცირებული კომპონენტებით აწყობილი მოწყობილობის ESP32 მიკროკონტროლერი; საკუთრების პროგრამული უზრუნველყოფის (proprietary software), ადვილად გამოსაყენებადი, კომერციალიზებული მოწყობილობით ერთიანი ღრმა სწავლების ფრეიმვორკი (DL Framework).

**საკვანძო სიტყვები** - ელექტროენცეფალოგრაფია, ნივთების ინტერნეტი, სიგნალის დამუშავება, ტვინი-კომპიუტერის ინტერფეისი

## IoT BCI Perspective

### Abstract

The rapid development of information technology is increasingly reducing the iterative behaviors routine in the daily life of human and for the foreseeable future offers the interaction of humans, as users with the effector devices by the typical physical human interaction methods - visual, audio or typing, to bring to the next level – interaction with the intention translation devices. This paper discusses non-invasive brain-computer interface (BCI) methodologies for obtaining and further processing brainwave signals recorded through Electroencephalography (EEG), that can be integrated into both medicine and Internet of Things (IoT) environment. The presented methods of processing the received raw data uses: EEGLAB built-in tool in MATLAB; ESP32 microcontroller with open source software and reduced components; An easy-to-use, commercialized, Proprietary software device with a unified deep learning framework (DL Framework).

**Keywords** - Brain-Computer Interface, Electroencephalography, Internet of Things, signal processing

## შესავალი

ნივთების ინტერნეტი (Internet of Things, IoT) პარადიგმა გულისხმობს გლობალურ განვითარებად ინფრასტრუქტურას, რომელიც ეფუძნება ურთიერთქმედებით საკომუნიკაციო პროტოკოლებს, რომლებიც აერთიანებს ფიზიკურ და ვირტუალურ ობიექტებს ინფორმაციულ ქსელში. სხვა პროგრამებთან ერთად, სახლის ავტომატიზაცია ან ჭკვიანი სახლები სწრაფად იჩენს ინტერესს. ამგვარი სისტემების მიზანია სახლის გარემო არა მხოლოდ კომფორტული და მარტივად გამოსაყენებელი გახდეს, არამედ ისეთი მოწყობილობების ოპტიმიზაცია და ავტომატიზაცია, როგორცაა ტელევიზორები, კონდიციონერები, ნათურები, ღუმელები ან სარეცხი მანქანები.

2020 წელს 20 მილიარდზე მეტი მოწყობილობა იყო დაკავშირებული IoT -ში. IoT -ის გავრცელება გავლენას მოახდენს და გააუმჯობესებს არა მხოლოდ სახლის ავტომატიზაციის ეფექტურობას, არამედ სხვადასხვა სფეროებს, როგორცაა წარმოება და მრეწველობა, ტრანსპორტირება და ჯანდაცვა. ინდივიდები შეძლებენ ყოველდღიური საგნების ფართო სპექტრთან ურთიერთქმედებასა და კონტროლს - ურთიერთქმედების სხვადასხვა საშუალებებით, მათ შორის შესაბამისი პროგრამებით, რომელიც ჩაწერილი იქნება მათ სმარტფონებში ან გასაკეთებელ მოწყობილობებში, ხმისა და ქესტების გამოყენებით.

ტვინი-კომპიუტერის ინტერფეისი (Brain-Computer Interface, BCI) მხარს უჭერს ინდივიდისა და IoT ობიექტებს შორის კავშირის დამყარებას. BCI ადგენს პირდაპირ საკომუნიკაციო გზას ადამიანის ტვინსა და გარე მოწყობილობას შორის, რითაც გამორიცხავს ინფორმაციის მიწოდების ტიპური მეთოდების საჭიროებას. BCI -ს კვლევის ბოლოდროინდელი ტენდენციები მოწმობს ადამიანის აზროვნების შესაძლებლობების გარდაქმნას ფიზიკურ ქმედებებში, როგორცაა გონებით-კონტროლირებადი ინვალიდის ეტლები, რობოტის ხელი და IoT -ში ჩართული აღჭურვილობა. ეს მაგალითები ცხადყოფს, რომ BCI იქნება მთავარი დამხმარე ტექნოლოგია ადამიანისა და ნივთების ურთიერთქმედებაში.

ურთიერთქმედების მოხერხებულობა და რეალური დროის ხასიათი BCI -ის ერთერთი ძირითადი უპირატესობაა, რადგან ადამიანს დაჭირდება მხოლოდ

ურთიერთქმედებაზე დაფიქრება შესაბამისი ფიზიკური მოძრაობების განხორციელების ნაცვლად (მაგ. საუბარი, აკრეფა, ჟესტი). ამასთან, BCI -ზე დაფუძნებული ადამიანი-ნივთის შემეცნებითი ინტერაქტიულობა გარკვეული გამოწვევების წინაშე დგას. ვინაიდან ტვინის სიგნალი შესაძლოა გაიზომოს რამდენიმე ტექნოლოგიის საშუალებით, როგორცაა: ელექტროენცეფალოგრამა (Electroencephalogram, EEG), ფუნქციური ახლო-ინფრაწითელი სპექტროსკოპია (Functional Near-Infrared Spectroscopy, fNIR) და მაგნიტოენცეფალოგრაფია (Magnetoencephalography, MEG). ყველა ეს მეთოდი მგრძნობიარეა დაბალი ერთგულებისათვის და ასევე ადვილად მოქმედებს გარემო ფაქტორების და სენტიმენტალური სტატუსის (მაგ. ხმაურის, კონცენტრაციის) გავლენაზე. სხვა სიტყვებით რომ ვთქვათ, თავის ტვინის სიგნალებს ზოგადად აქვთ ძალიან დაბალი სიგნალი-ხმაურთან პროპორცია და არსებითად არ გააჩნიათ საკმარისი სივრცული ან დროებითი გარჩევადობა და ტვინის ღრმა სტრუქტურების საქმიანობის შესახებ ცოდნა. მიუხედავად იმისა, რომ კოგნიტური ამოცნობის ამჟამინდელ სისტემებს შეუძლიათ 70-80% სიზუსტის მიღწევა, ეს არ არის საკმარისი პრაქტიკული სისტემების შესადგენად. ასევე შრომატევადია მონაცემთა წინასწარი დამუშავება, პარამეტრის შერჩევა (მაგ., ფილტრის ტიპი, ფილტრაციის ზოლი, სეგმენტის ფანჯარა და გადაფარვა) და მახასიათებლების ინჟინერია (მაგ., მახასიათებლის შერჩევა და მოპოვება როგორც დროსთან, ისე სიხშირესთან მიმართებაში).

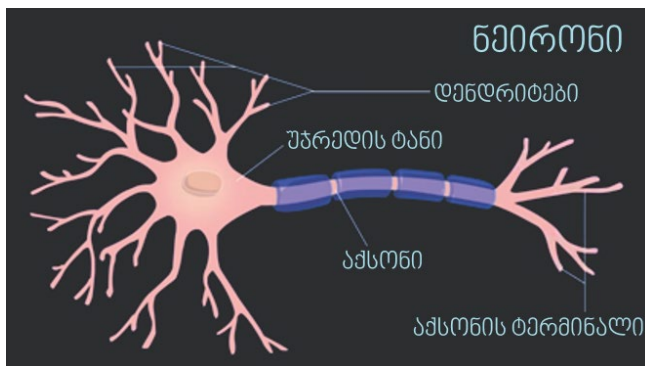
IoT შემოღებით განხორციელებული ყოველდღიური მოწყობილობების ფართო კავშირით, BCI საშუალებას აძლევს ინდივიდებს, გააკონტროლონ ისეთი საგნები, როგორცაა ჭკვიანი საყოფაცხოვრებო ტექნიკა ან დამხმარე რობოტები, უშუალოდ მათი აზრებით. თუმცა ამ ხედვის რეალიზება მრავალი გამოწვევის წინაშე დგას. BCI ტექნოლოგიის ერთ-ერთი ყველაზე მნიშვნელოვანი საკითხია ინდივიდის განზრახვის ინტერპრეტირების სიზუსტე ტვინის გადაუმუშავებელი ტალღებიდან, რომელიც ხშირად არის დაბალი სიზუსტის მქონე და ხმაურის ტოლფასი. უფრო მეტიც, ტვინის სიგნალების წინასწარი დამუშავება და შემდგომი მახასიათებლების ინჟინერია შრომატევადი საქმეა და უაღრესად დამოკიდებულია ადამიანის ცოდნა-გამოცდილებაზე ამ სფეროში. BCI -სთვის ასევე დიდი გამოწვევაა მინიმალურად

ინვაზიური და მცირე ტრენინგით გამოსაყენებელ მზადყოფნაში მოყვანილი სატარებელი და პორტაბელური ელექტროდი მოწყობილობების შექმნა. მაგალითად, EEG ტექნიკის პოტენციალით, რომლის საშუალებითაც ხდება მომხმარებლის განზრახვასთან დაკავშირებული ტვინის აქტივობის ჩაწერა. ეს მოითხოვს რეალურ დროში ოპერირებადი და მრავალფეროვანი მოტორული ფუნქციების მქონე ადამიანებისათვის ადაპტირებადი მეგობრული მოწყობილობების შექმნასა და განვითარებას.

## თავი I. ძირითადი კონცეფციები და დაკავშირებული კვლევები

### 1.1 ტვინის ტალღები

თავის ტვინის ქერქის შიგნით არის ასობით მილიარდი ნეირონი ნერვული უჯრედების სახით (სურათი 1). ნეირონებს აქვთ აქსონები, ანუ ნერვული ბოჭკოები რომლებსაც გადააქვთ ნეირომედიატორები, და ასევე აქვთ დენდრიტები, ანუ ნეირონის განტოტვილი ნაწილი, რომელიც იღებს ამ ნეირომედიატორებს. როდესაც დენდრიტები მიიღებენ ნეირომედიატორებს აქსონებით სხვა ნეირონებისაგან, ხდება მიმღები ნეირონების სტიმულაცია და იწყება ელექტრული იმპულსების გავრცელება. უამრავი ნეირონის ერთმანეთთან კომუნიკაციის შედეგად წარმოქმნილი სინქრონიზებული ელექტრული იმპულსებით მიიღება ტვინის ტალღები, ნეირომეცნიერულად - ნეირონული რხევები. ტვინის ტალღების გაზომვის ერთ-ერთი მეთოდია ელექტროენცეფალოგრამა (Electroencephalogram, EEG), რომელიც იწერს ტვინში არსებულ ელექტრულ აქტივობებს.



სურათი 1. ნეირონი

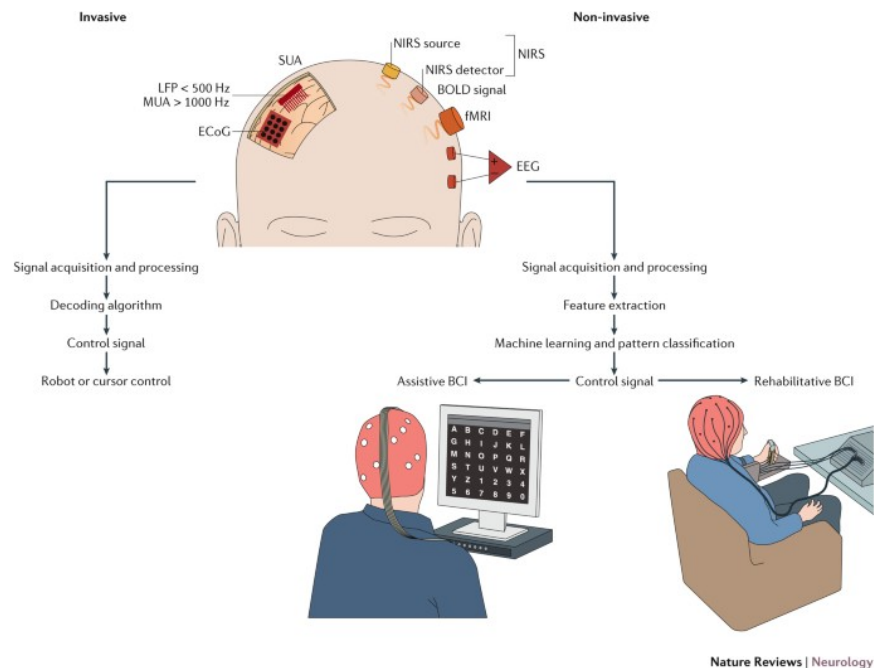
### 1.2 ტვინისა და კომპიუტერის ინტერფეისი, BCI

ტვინი-კომპიუტერის ინტერფეისი (Brain-Computer Interface, BCI) არის საკომუნიკაციო სისტემური მოწყობილობა, რომელიც მაგრდება ადამიანის თავზე, ინვაზიური ან არაინვაზიური გზით, სადაც ტვინის ნაწილები განისაზღვრება ელექტროდების პოზიციებით. BCI იღებს მომხმარებლის განზრახვის შესაბამის ცერებრულ აქტივობის სიგნალებს, ანალიზებს და გარდაქმნის მათ მოწყობილობის



კონტროლის ბრძანებებად, რომლებიც გადადის აქტივაციის კომპიუტერულ მოწყობილობებზე სასურველი მოქმედებების განსახორციელებლად.

არსებობს BCI -ის სამი მთავარი ჯგუფი: ინვაზიური, ნახევრად ინვაზიური და არაინვაზიური (სურათი 2). ინვაზიური ტექნიკა გულისხმობს მოწყობილობების გამოყენებას ტვინის მიერ წარმოქმნილი სიგნალების დასაფიქსირებლად, სადაც მათი ტვინში ჩასასმელად საჭიროა ქირურგიული ოპერაცია. ნახევრად ინვაზიური ტექნიკა გულისხმობს მოწყობილობის თავის ქალაში ჩასმას და არა ტვინში. არაინვაზიური ტექნიკის დროს კი ელექტროდები იდება სკალპზე.



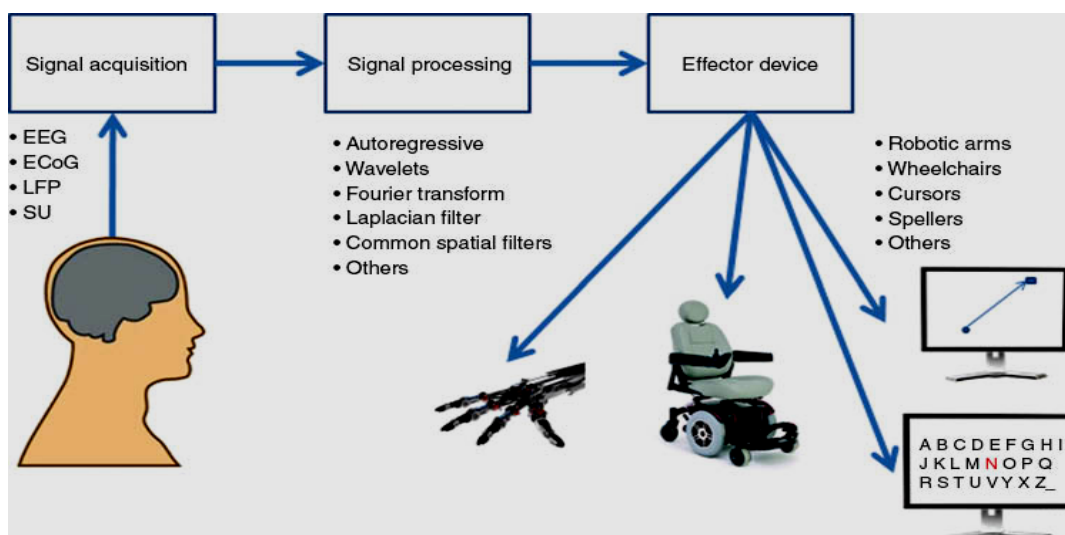
სურათი 2. ინვაზიური და არაინვაზიური BCI

### 1.3 ელექტროენცეფალოგრაფია, EEG

ნეირონული მონიტორინგის ერთერთი ხერხია BCI -ით ტვინის ტალღების მონიტორინგი, რომლის დროსაც ნეირონული აქტივობის ჩაწერა ხდება EEG -ის საშუალებით. EEG არის ძალიან ეფექტური ნეირო დასურათების ტექნიკა. მისი სიძლიერის მაჩვენებლებია: სისწრაფე, შეუძლია ტვინის აქტივობის ჩაწერა მილიწამებში; უსაფრთხოება, EEG სინამდვილეში ტვინს არაფერს უკეთებს, ის

უბრალოდ იწერს ტვინის ელექტრონულ აქტივობებს, რომლებსაც ტვინი ისედაც გამოსცემს; მოხერხებულობა, EEG ინტერფეისი მარტივი გასაკეთებელია და თავიდან იცილებს ქირურგიულ ჩარევას. სისუსტე: EEG -ის აქვს დაბალი სივრცითი გარჩევადობა. მას არ შეუძლია გამოიყენოს მაღალი სიხშირის სიგნალები, რადგან თავის ქალას შეუძლია დაახშოს და დაასუსტოს ისინი. ეს ნიშნავს რომ, EEG -ის საშუალებით ვერ გავიგებთ ზუსტად სად ხდება აქტივობა.

ტვინის აქტივობები ზოგადად იზომება ელექტროენცეფალოგრაფიით (EEG -ით), რაც სკალპის ზედაპირზე განთავსებული ელექტროდების საშუალებით თავის ტვინის აქტივობების ჩაწერის ფიზიოლოგიური მეთოდია და ფართოდ გამოიყენება მისი არაინვაზიური ხასიათის გამო.



სურათი 3. BCI სქემა

#### 1.4 ტვინის ტალღების კლუგები

ტვინი არის ადამიანის სხეულის ცენტრალური კონტროლის განყოფილება, რომელიც აკონტროლებს ფიქრებს, მეტყველებას, მოძრაობებს და მეხსიერებას. ტვინი პასუხისმგებელია ადამიანის ორგანოების ფუნქციონირების მოწესრიგებაზე. ტვინი მუშაობს ეფექტურად და ავტომატურად, როდესაც ის ჯანმრთელია, მაგრამ ტვინის დარღვევებმა შეიძლება გამოიწვიოს დამანგრეველი შედეგები.

ტვინის დაავადების გლობალური ზრდა და ჯანდაცვის სისტემების გაუმჯობესების მიზნით მთავრობის მიერ დაფინანსების ზრდა ხელს უწყობს BCI -ის გლობალური ბაზრის ზრდას. მსოფლიო სტატისტიკით BCI -ის ბაზრის შემოსავლის ყველაზე დიდ ნაწილს შეადგენს არაინვაზიური BCI. არაინვაზიური ტექნიკა ყველაზე პოპულარული ხდება მისი არაინვაზიური ბუნებიდან გამომდინარე. შესაბამისად ექიმებს საშუალება ეძლევათ ჩაანაცვლონ ინვაზიური მეთოდი გასაკეთებელი მოწყობილობებით, რომლებსაც შეუძლიათ ადვილად გაზომონ ნეირონული აქტივობა. ჩვეულებრივ თავის ტვინის ქერქიდან მოპოვებული ნერვული აქტივობა გამოიყენება ხელოვნური (პროთეზირებული) კიდურების კონტროლისთვის.

სამედიცინო მონიტორინგი მოიცავს დროთა განმავლობაში ერთი ან რამდენიმე სამედიცინო პარამეტრის დაკვირვებას კონკრეტულ დაავადებაზე ორიენტაციით. ამ ცვლადების მოდელების გამომავალი შაბლონები არაწრფივი და დროში ცვალებადია. დაფიქსირებული ნიმუშებიდან მოსალოდნელი საფრთხის ონლაინ პროგნოზირება ხელს შეუწყობს კლინიკურ ექიმებს გადაწყვეტილების წინასწარ მიღებაში. სამედიცინო მონიტორინგი კლასიფიცირდება სამიზნე ინტერესის მიხედვით.


ამ ნაშრომში განხილულია ტვინის ტალღების მონიტორინგი EEG –ის მეშვეობით, რომელიც ნეირონული მონიტორინგის ყველაზე პოპულარული მეთოდია ისეთი ნევროლოგიური დაავადებების მონიტორინგისა და დიაგნოზირებისთვის, როგორცაა აუტიზმი, ალცჰაიმერი, ეპილეფსია, ინსულტი და ა.შ.

ტვინის ტალღების ანალიზი და მონიტორინგი გადამწყვეტ როლს ასრულებს ნევროლოგიური დარღვევების სამკურნალოდ და შესაძლებელს ხდის ფატალური შემთხვევის თავიდან აცილებას. ინსულტი შეიძლება მოხდეს ნებისმიერ დროს, ზოგიერთ შემთხვევაში ძილის დროსაც კი. ინსულტის დაწყების დრო ღამით ნაკლებად არის აღმოჩენილი. ინსულტის დაწყების დადგენა სასიცოცხლოდ მნიშვნელოვანია, რადგან ბევრი მათგანი წარმოიქმნება თავის ტვინის სისხლძარღვებში სისხლის შედედების, თრომბის გამო და ექვემდებარება მკურნალობას. ლ. მირცხულავამ და სხვებმა <sup>[1]</sup> აჩვენეს, რომ ინსულტის დაწყების

დრო გადამწყვეტია, რადგან შეიძლება გავლენა იქონიოს კიდურებზე და შესაბამისად, გამოიწვიოს მოტორული ფუნქციის დაკარგვა.

ამრიგად, EEG –ის საშუალებით ტვინის ტალღების მონიტორინგი, სიხშირის ნებისმიერი ცვლილების ჩაწერით საშუალებას იძლევა განისაზღვროს ინსულტის დაწყების დრო, თუნდაც ეს მოხდეს ძილის დროს. მონაცემთა ნაკრები BDF ფორმატში გამოიყენებოდა ძილის კვლევის დროს, სადაც ტვინის ტალღები ხასიათდებოდა მათი სიხშირეებით და ამპლიტუდები გაიზომა ჰერცებში. ამ სიხშირის მნიშვნელობების მიხედვით შესაძლებელია განისაზღვროს დაავადებების სიმპტომები. ჩატარებული მსხვილი კვლევითი პროექტები კარგად ასახავს იმას, რომ ტვინის მაღალი აქტივობები არსებითად უკავშირდება მაღალ სიხშირეს და მცირე ამპლიტუდას და შესაბამისად ტვინის დაბალი აქტივობები - დაბალ სიხშირეს და მაღალ ამპლიტუდას.

არსებობს ტვინის ტალღების ხუთი ძირითადი ტიპი (სურათი 4.)



სურათი 4. სიხშირის ნიმუშები ტვინში

თვალის მდგომარეობის იდენტიფიკაცია და თვალის დაჟინებული მზერის ანალიზი ბოლო წლების განმავლობაში აქტიური კვლევითი სფერო გახდა, ადამიანურ-მანქანურ ინტერფეისებში მათი გავლენის გამო. კერძოდ, EEG -ით თვალის მდგომარეობის გამოვლენა წარმატებით იქნა გამოყენებული მრავალი

მიმართულებით, როგორცაა ძილიანობაში მართვის გამოვლენა, ახალშობილთა ძილ-  
დვიძილის მდგომარეობის კლასიფიკაცია, სტრესის მახასიათებლების  
იდენტიფიკაცია და სხვა.

კვლევების შედეგად შესწავლილ იქნა IoT მოწყობილობების კონტროლი cE და oE  
მდგომარეობების გამოვლენის გამოყენებით. თითოეული მდგომარეობის  
დასადგენად გაანალიზდა EEG სიგნალის ალფა და ბეტა ტალღები. ალფა ტალღები,  
რომელთა სიხშირე 8 ჰერციდან 13 ჰერცამდე მერყეობს, ასოცირდება ტვინის ყველაზე  
მოდუნებულ და სტაბილურ მდგომარეობასთან; ხოლო ბეტა ტალღები, სიხშირის  
დიაპაზონში 13 ჰერციდან 30 ჰერცამდე, ასოცირდება სიფხიზლის მდგომარეობებთან.  
EEG ჩანაწერი გვიჩვენებს სუბიექტის ფსიქიკურ ან ფიზიკურ მდგომარეობას. თუ EEG  
აჩვენებს ტვინის ალფა ტალღებს კეფის მიდამოში მაღალი ამპლიტუდით, ეს ნიშნავს  
რომ სუბიექტი მოდუნებულია და თვალები დახუჭულია. ხოლო თვალების  
გახელისას ალფა-ტალღები ქრება.

## თავი II. მეთოდები

### 2.1 EEGLAB -ით წინასწარი დამუშავება

EEG სიგნალების მიღების შემდეგ შესაძლებელია მათი დამუშავება კომპიუტისთვის გასაგებ, კონტროლის ბრძანებების მისაღებად. EEG სიგნალების დამუშავება რთული ამოცანაა მაღალი ხარისხის BCI -ს შესაქმნელად.

EEG –დან მიღებული მონაცემების წინასწარი დამუშავების ერთ-ერთი ხერხია EEGLAB –ის გამოყენება. EEGLAB არის MATLAB –ის მძლავრი ინსტრუმენტი, რომელიც საშუალებას გვაძლევს დავამუშავოთ მაღალი სიმკვრივის EEG მონაცემთა ბაზა: ინტერაქტიული მომხმარებლის გრაფიკული ინტერფეისის (GUI, Graphical User Interface) მეშვეობით, დამოუკიდებელი კომპონენტის ანალიზის (ICA, Independent component analysis), დროის / სიხშირის ანალიზის (TFA, Time frequency analysis) და გასაშუალოების სტანდარტული მეთოდის მეშვეობით.

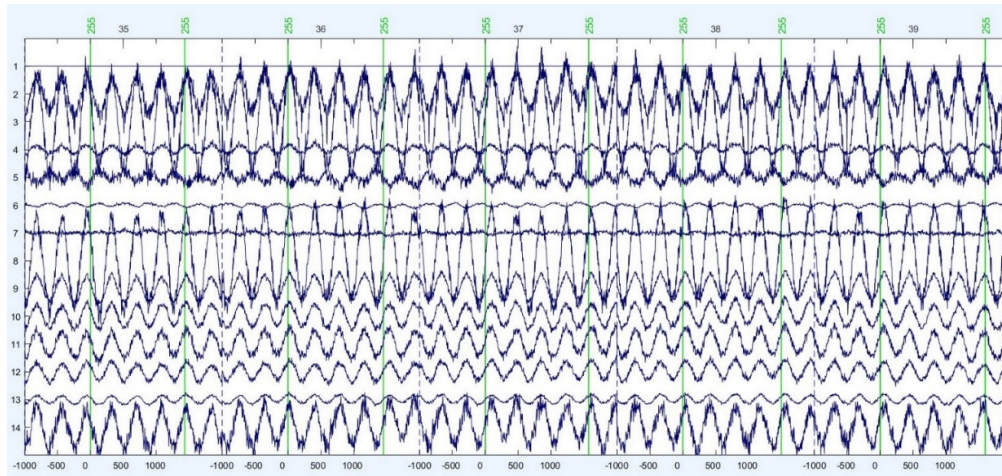
EEGLAB არის ინტერაქტიული ხელსაწყოების კრებული, რომელიც შენდება Matlab –ში, EEG –დან მიღებული მონაცემების დამუშავების გასაგრძელებლად. EEGLAB ატყურვილია ინტერაქტიული GUI -ით, რაც საშუალებას იძლევა დამუშავდეს EEG -დან მიღებული მაღალი სიმკვრივის ტვინის მონაცემები ორი გზით, ICA და TFA. EEG მონაცემები ჩამწერი მოწყობილობიდან არის უწყვეტი პროცესის სიგნალი. ეს გავს ოსცილოსკოპზე პოტენციალის სხვაობის გაზომვას (სურათი 5). მონაცემების გასაგებად საჭიროა:

- 1) ტვინის ტალღების რხევებიდან მნიშვნელოვანი ნაზომების ამოღება
- 2) ტვინის მონაცემების სხვადასხვა პირობებში შედარება
- 3) გარე სტიმულებზე დაყრდნობით საიმედო ცვლილებების შეფასება

რაც მოიცავს შემდეგ პროცესებს:

- 1) EEG მონაცემების შეგროვება
- 2) EEGLAB -ში იმპორტი
- 3) მოვლენების მარკერების და არხების ადგილმდებარეობების იმპორტი
- 4) ხელახლა მითითება / ნიმუშის-ჩამოტვირთვა
- 5) მაღალსიხშირიანი ფილტრი (~ 0.5 - 1 ჰერცი)
- 6) დაუმუშავებელი მონაცემების შემოწმება, გამოკვლევა

- 7) ცუდი არხების იდენტიფიცირება / უარყოფა
- 8) დიდი არტეფაქტის დროის წერტილების უარყოფა
- 9) ICA გაშვება და კომპონენტების უარყოფა



სურათი 5. კომპონენტის აქტივობები

## 2.2 მოდული ESP32

ჩატარებულია სამუშაოები ღია წყაროს მოწყობილობითა და პროგრამული უზრუნველყოფით თვალის მდგომარეობის კლასიფიკაციისა და IoT -სთვის გარკვეული პროტოკოლით ინტეგრირების შესასრულებლად. გახელილი თვალების (open eyes, **oE**) და დახუჭული თვალების (closed eyes, **cE**) მდგომარეობის გამოვლენის მიზნით შემოთავაზებულ იქნა მეთოდი, მოპოვებული სიგნალის სხვადასხვა სიხშირის ხაზებს შორის დენის თანაფარდობის გამოთვლის საფუძველზე.

ფ. ლაპორტმა, ა. დაპინამ და სხვებმა თავის ნამუშევარში <sup>[7]</sup> წარმოადგინეს EEG მოწყობილობის პროტოტიპი, რომელიც შედგება ძალიან დაბალი ღირებულების შემცირებული გამოყენებითი კომპონენტებისგან. მოწყობილობაში გამოყენებულია სენსორების შემცირებული რაოდენობა სიგნალების მოსაპოვებლად, შესაბამისად უფრო კომფორტული და მოხერხებელი გამოსაყენებელია მომხმარებლისთვის დიდი ხნის მანძილზე და ყოველდღიური ცხოვრებისეული საქმიანობის დროს. უფრო მეტიც, ისინი იყენებენ შედარებით ნაკლები რაოდენობის ტრენინგებს. სისტემა ასევე


შეიცავს ორ ბირთვიან მიკროკონტროლერს, რომელიც საშუალებას იძლევა შესრულდეს ყველა სიგნალის კლასიფიკაციასთან დაკავშირებული ოპერაცია და ამავდროულად გადაეცეს მონაცემები IoT გარემოს.

ამ კვლევის პირველი მიზანი მდგომარეობს მისი მუშაობის შეფასება მომხმარებლის თვალის მდგომარეობების, ანუ გახელილი თვალების (oE) ან დახუჭული თვალების (cE) განსაზღვრაში, მოკლე ტრენინგების საფუძველზე სხვადასხვა სტრატეგიის გამოყენებით. ეს სტრატეგიები შემდეგია:

- რეალურად შეფასებული რთულად შეფასებული გარდაქმნების ნაცვლად, ვინაიდან, ზოგადად, რთულად შეფასებული სიგნალების გამოყენება საჭიროებს ორჯერ მეტ გამოთვლით ოპერაციების რაოდენობას
- მცოცავი ფანჯრები გადაფარვით ტრადიციული მიდგომის გადაუფარავი ფანჯრების ნაცვლად, რითიც შემცირდა შეყოვნებები მოპოვებასა და გადაწყვეტილებას შორის
- კლასიფიკატორი, რომელიც დაფუძნებულია ორიდან ერთერთ მეთოდზე:
  1. ბარიერზე დაფუძნებული მეთოდი
  2. ხაზოვანი დისკრიმინაციული ანალიზი (Linear Discriminant Analysis, LDA)
- კორექტირების სისტემა გადაწყვეტილების შეცდომების შემსუბუქებისათვის მეორე მიზანია მოპოვებული ინფორმაციის გამოყენება მომხმარებლის თვალის მდგომარეობების შესახებ IoT მოწყობილობების კონტროლისთვის ON / OFF ოპერაციების მნიშვნელობით.



## 2.2.1 ღია მოწყობილობები




სურათი 6. მოწყობილობის დეტალები:

(1) გამამღიერებელი, (2) ESP32 მოდული, (3) სენსორები

სურათი 6 -ზე ნაჩვენებია შემუშავებული EEG მოწყობილობის ელემენტები. პროტოტიპს აქვს სამი სენსორი: შემავალი, მითითება და დამიწება. შემომავალი სიგნალი გაძლიერებულია და გამტარობა გაფილტრულია 4.7-29.2 Hz სიხშირეში. EEG სიგნალების შერჩევა ხდება 250 Hz -ზე. ამ მოწყობილობიდან შეძენილი მონაცემები კი, გაფილტრულია 3 –დან 45 Hz -მდე.

## 2.2.2 სისტემის დიზაინი და არქიტექტურა



სურათი 7. EEG სისტემის პროტოტიპის არქიტექტურა IoT სთვის

სურათი 7-ზე ნაჩვენებია BCI მოწყობილობის ინტეგრაციის არქიტექტურა IoT გარემოში. ამ სისტემის მიზანია cE ან oE აღმოჩენა და ამ ინფორმაციის გამოყენება სხვადასხვა მიმდებარე მოწყობილობების სამართავად. IoT ეკოსისტემა შედგება ზემოთ აღწერილ EEG მოწყობილობისა და მისი BCI პროგრამისგან, სხვა

საყოფაცხოვრებო მოწყობილობებთან ერთად, რომელთა ქცევა დამოკიდებულია წარმოებულ ინფორმაციაზე.

სხვადასხვა IoT აგენტებს შორის კომუნიკაცია ემყარება Message Queue Telemetry Transport (MQTT) პროტოკოლს. ეს არის გამოქვეყნება / გამოწერის, მარტივი და მსუბუქი შეტყობინებების პროტოკოლი, რომელიც შექმნილია შეზღუდული მოწყობილობებისა და დაბალი გამტარობის ქსელებისათვის. გამოქვეყნება / გამოწერის მოდელი აგებულია ცენტრალური ბროკერისა და რიგი კლიენტების გარშემო, რომლებიც ბროკერს უკავშირდება. გამომქვეყნებლები ბროკერს უზრუნველყოფენ შეტყობინებებს კონკრეტულ საგანზე და გამომწერები ბროკერთან რეგისტრირდებიან, მათთვის საინტერესო ერთი ან რამდენიმე საგნის მიმართ. ბროკერი მოქმედებს როგორც შუამავალი აგენტი, რომელიც პასუხისმგებელია გამომქვეყნებლების მიერ გამომწერ კლიენტებთან ინფორმაციის დაკავშირება-მიწოდებაზე, ასევე პასუხისმგებელია ავტორიზაციასთან დაკავშირებულ საკითხებზე და აკონტროლებს, თუ ვინ რომელ საგანს აქვეყნებს ან იწერს. საგნების შექმნა და კომბინირება მარტივია, ამიტომ სისტემა ადვილად გაფართოვდება ახალი მოწყობილობებისა თუ პროგრამების ახალ საგნებში ჩართვით.

ნაჩვენები არქიტექტურისთვის, BCI პროგრამა, რომელიც მუშაობს ESP32 –ზე, არის IoT ეკოსისტემის პირველი გამომქვეყნებელი კლიენტი. მას ევალუატირება მომხმარებლის თვალის მდგომარეობის დადგენა და ჩაშენებული Wi-Fi მოდულის გამოყენებით ბროკერისთვის ამოღებული ინფორმაციის გამოქვეყნება. MQTT ბროკერი ამუშავებს BCI აპლიკაციიდან მიღებულ შეტყობინებებს და გზავნის მათ დაინტერესებულ აბონენტებთან. გადაცემული მონაცემები შეესაბამება ერთ ბაიტ ინფორმაციას, რომელიც ასახავს მომხმარებლის თვალის მდგომარეობას. ბროკერი განლაგებულია Raspberry Pi 2 B მოდელში და მესხიერებაში შეტანა ხდება Eclipse Mosquitto გამოყენებით. მსუბუქი, ღია წყაროს MQTT ბროკერი.

მონაცემთა გადაცემა MQTT პროტოკოლში ხორციელდება MQTT საკონტროლო პაკეტების (Control Packets, CP) სერიების გაცვლის გზით. ეს CP შედგება სამი ნაწილისგან:

1. ფიქსირებული სათაური, რომელიც ყოველთვის არის წარმოდგენილი ყველა CP –ში
2. არასავალდებულო ცვლადის სათაური
3. არასავალდებულო სასარგებლო დატვირთვა

CP -ს ამ ბოლო ნაწილს იყენებს პროგრამა სისტემის მიერ მოპოვებული ინფორმაციის გამოსაქვეყნებლად. პროტოკოლის მიხედვით CP ზომები ნებადართულია 256 მბ-მდე. სისტემაში შეიძლება შევიდეს მრავალი სახის საყოფაცხოვრებო მოწყობილობები, როგორც გამომწერი კლიენტები (მაგ. ნათურები, სამზარეულოს სანთურები, გათბობის სისტემა). ეს მოწყობილობები იღებენ ინფორმაციას ბროკერისგან და შესაბამისად რეაგირებენ მასზე, მაგალითად, თუ სამზარეულოს სანთურების კლიენტი აღმოაჩენს, რომ მომხმარებელს უკვე დიდი ხანია დახუჭული აქვს თვალები, ეს ნიშნავს რომ მას ჩაეძინა და გამომწერ კლიენტმა უნდა გათიშოს სანთურები, რათა თავიდან აიცილოს ნებისმიერი რისკი.

### 2.2.3 სიმძლავრის სპექტრული სიმკვრივის ანალიზი

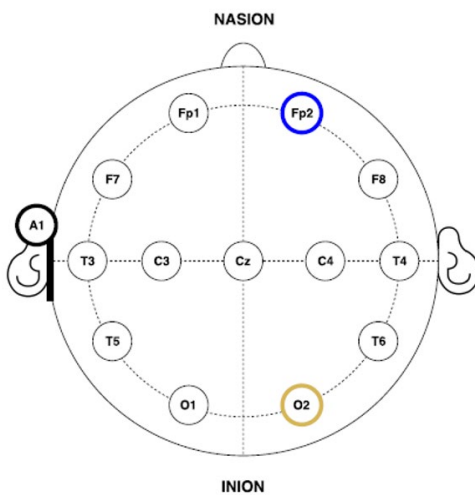
სიმძლავრის სპექტრული სიმკვრივის ანალიზი (Power Spectral Density Analysis, PSDA), რომელიც ეფუძნება EEG სიგნალის სიხშირის ანალიზს, არის ერთ-ერთი ყველაზე ფართოდ გამოყენებული EEG კლასიფიკაციისთვის მახასიათებლის მოპოვების მეთოდი. PSD წარმოადგენს სიგნალის ენერჯის განაწილებას სხვადასხვა დიაპაზონში. კერძოდ, მომხმარებლის თვალის მდგომარეობის დასადგენად გამოყენებულ იქნა ალფა და ბეტა სიხშირის დიაპაზონებს შორის ენერჯის კოეფიციენტი.

### 2.2.4 მასალები და მეთოდები

მონაწილეთა ჯგუფში შედიოდა სულ შვიდი მოხალისე (მამაკაცი), რომლებიც თანახმა იყვნენ მონაწილეობა მიეღოთ კვლევაში. მათი საშუალო ასაკი იყო 29,67 (24–56 დიაპაზონში). მონაწილეებმა აღნიშნეს, რომ მათ არ აქვთ სმენის და მხედველობის დარღვევები. მონაწილეობა იყო ნებაყოფლობითი და მიღებულ იქნა

ინფორმირებული თანხმობა თითოეული მონაწილისგან, რათა მომხდარიყო მათი EEG მონაცემების გამოყენება საკვლევო დანიშნულებით.

აღწერილი EEG პროტოტიპით მოპოვებულ იქნა სუბიექტების ტვინის აქტივობა. ოქროს თასის ელექტროდები მოთავსდა ელექტროდების განლაგების 10–20 საერთაშორისო სისტემის შესაბამისად (სურათი 8) და მიმაგრდა სუბიექტების სკალპებზე გამტარი შემადგენლობის გამოყენებით. ელექტროდის კანის წინააღმდეგობა გადამოწმდა, რომ ყველა ელექტროდში 15 k $\Omega$  (კილო ომი) –ზე ნაკლებია. კვლევებმა დაადასტურა, რომ ალფა რიტმი ჭარბობს თავის ტვინის კეფის მიდამოში, როდესაც სუბიექტებს თვალები დახუჭული აქვთ და მცირდება ვიზუალური სტიმულაციის დროს. ამ სამუშაოების შესაბამისად, პროტოტიპის შეყვანის არხი მდებარეობდა O2 პოზიციაზე. უფრო მეტიც, დაყენების დროის შესამცირებლად და EEG სიგნალის ხარისხის გასაუმჯობესებლად, მითითებისა და დამიწების ელექტროდები მოთავსდა შესაბამისად FP2 და A1 პოზიციებში, სადაც თმის არარსებობა ხელს უწყობს მის განთავსებას.




სურათი 8.

ანატომიური ელექტროდის განაწილება სტანდარტული 10–20 განლაგების სისტემის შესაბამისად, რომელიც გამოიყენება EEG გაზომვების დროს.

(ყვითელი წრე წარმოადგენს შეყვანის არხს, ხოლო ლურჯი და შავი წრეები, შესაბამისად, მითითებას და დამიწებას)

ყველა ექსპერიმენტი ჩატარდა ხმა შესუსტებულ და კონტროლირებად გარემოში. მონაწილეები ისხდნენ კომფორტულ სავარძელში და სთხოვეს მოდუნებულიყვნენ და დავალებაზე კონცენტრირებულიყვნენ, რაიმე ყურადღების გამფანტავი ან გარეგანი სტიმულის თავიდან აცილების მცდელობის მიზნით. ექსპერიმენტები შედგებოდა 2 დავალებისგან: პირველი, 60 წმ თვალგახელილი (oE) და მეორე, 60 წმ თვალდახუჭული (cE). თითოეული დავალება გამოყოფილი იყო მინიმუმ 3 წამიანი პაუზით, რათა უზრუნველყოფილიყო მონაწილის დასვენება ახალი დავალების შესრულებამდე (სურათი 9). რეალური ცხოვრების გარემოების სიმულირებისათვის, სუბიექტს შეეძლო თავისუფლად გადაეტანა მზერა oE დავალების დროს, იმგვარად რომ საჭირო არ ყოფილიყო ფიქსირებულ წერტილზე მზერის მიპყრობა. პროცედურა წინასწარ მოხერხებულად იყო განმარტებული, რაც საშუალებას აძლევდა მონაწილეებს კომფორტულად ეგრძნოთ თავი და სცოდნოდათ სატესტო გარემო. შესაძლო არტეფაქტები მინიმუმამდე იქნა დაყვანილი, რადგანაც მათ სთხოვეს, არ ესაუბრათ, არ ემოძრავათ და არ დაეხამხამებინათ თვალი (შეძლებისდაგვარად, რაც შეიძლება ნაკლებად) oE ამოცანის განმავლობაში.



სურათი 9. მონაწილეთა ექსპერიმენტული სქემა

თითოეული მონაწილისთვის ჩაიწერა სულ 10 დავალება (ანუ 10 წთ), ხუთი წუთი oE და შესაბამისად ხუთი წუთი cE დავალებები.

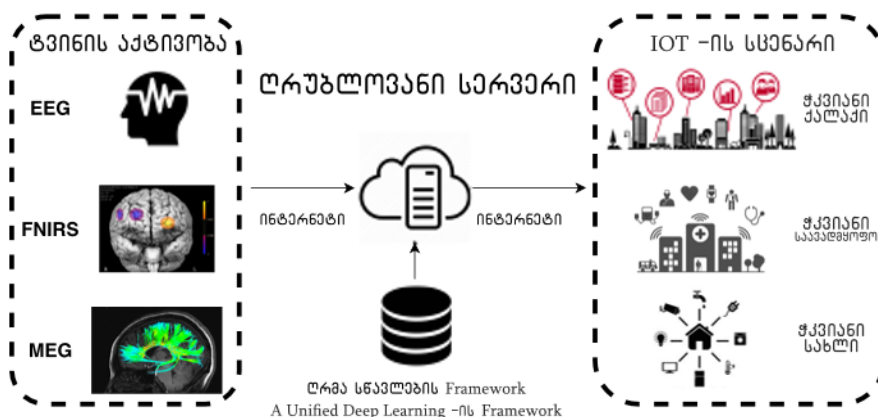
რამდენადაც ამ არქიტექტურის მთავარი მახასიათებელია მისი მარტივი გამოყენებადობა და მომხმარებლების კომფორტი, ამ სისტემის მთავარი მიზანია უზრუნველყოს, რომ პროტოტიპმა მიაღწიოს კარგ შესრულებებს მოკლე სასწავლო პერიოდების გამოყენებით. შემდგომ, სისტემა გაიწრთვნა ჩაწერილი მონაცემების გამოყენებით შემუშავებული ექსპერიმენტებისათვის.

### 2.2.5 მონაცემთა გადაცემა

ამ ექსპერიმენტში, ESP32 მიკროკონტროლერი ასრულებს სიგნალის მონაცემთა შერჩევას და დისკრეტიზაციას. ამ არქიტექტურაში, რომელსაც უწოდებენ არქიტექტურა 1 -ს, ESP32 ასევე ასრულებს მდგომარეობის კლასიფიკაციას და შედეგების გადაცემას. ალტერნატიული არქიტექტურა, რომელსაც უწოდებენ არქიტექტურა 2 -ს, მოიცავს BCI პროგრამას მართვის კონტროლის განყოფილებაში, როგორცაა Raspberry Pi ან PC რომელსაც ESP32 უშუალოდ გადასცემს ნიმუშებს.

### 2.3 ღრმა სწავლების ფრეიმვორკი, DL Framework

მონაცემთა წინასწარი დამუშავების, პარამეტრის შერჩევის, მახასიათებლების ინჟინერიისა და ინდივიდის IoT ობიექტებთან კავშირის დამყარების მიზნით სიანგ ჟანგის, ლინა იაოს და სხვების [8] ჩატარებულ კვლევაში შემოთავაზებულია ერთიან ღრმა სწავლებაზე დაფუძნებული ფრეიმვორკის (A Unified Deep Learning based Framework, UDL based Framework) გამოყენება ადამიანის-ნივთთან ეფექტური კოგნიტური ინტერაქტიულობის დამყარებისათვის. ეს ფრეიმვორკი ზომავს მომხმარებლის ტვინის აქტივობას სპეციალური ტვინის სიგნალების შემკრები აღჭურვილობით როგორც არის EEG, FNIRS და MEG (სურათი 10).



სურათი 10.

დაუმუშავებელი ტვინის სიგნალი იგზავნება ღრუბლოვან სერვერზე (cloud server) ინტერნეტის წვდომის საშუალებით. ღრუბლოვანი სერვერი იყენებს პიროვნებაზე დამოკიდებულ წინასწარ მომზადებული ღრმა სწავლების მოდელს დაუმუშავებელი სიგნალების გასაანალიზებლად. ანალიზის შედეგების ინტერპრეტირებული სიგნალების გამოყენება შესაძლებელია აქტივიზაციის ფუნქციონირებისათვის IoT მოხმარების ფართო სპექტრში, როგორცაა ჭკვიანი ქალაქი (მაგალითად, ტრანსპორტირების კონტროლი, დღის წესრიგის განრიგი), ჭკვიანი საავადმყოფო (მაგ., გადაუდებელი ზარი, ანომალიის სწავლება) და ჭკვიანი სახლი (მაგ., მოწყობილობების კონტროლი, დამხმარე რობოტების კონტროლი).

შემოთავაზებული ღრმა სწავლების ერთიანი ფრეიმვორკის მიზანია სუბიექტების განზრახვის ინტერპრეტირება და მისი დეკოდირება შესაბამის ბრძანებებად, რომლებიც აშკარად გარჩევადი იქნება IoT მოწყობილობებისათვის. არსებულ კვლევებზე დაყრდნობით, ტვინის სიგნალის თითოეული ნიმუშისათვის თვით მსგავსება ყოველთვის უფრო მაღალია ვიდრე ჯვარედინი მსგავსება, რაც იმას ნიშნავს, რომ განზრახვათა შინაგანი კავშირი ნიმუშებისა, უფრო ძლიერია, ვიდრე განზრახვათაშორისი კავშირი. ამ კვლევაში შემოთავაზებულ იქნა საშუალოდ შეწონილი სივრცული გრძელი ხანმოკლე მეხსიერება (weighted average spatial Long Short-Term Memory, WAS-LSTM), რომ დამუშავდეს ლატენტური კორელაცია (ფარული ურთიერთქმედება) სიგნალის განზომილებებს შორის. შემოთავაზებულ end-to-end ფრეიმვორკს შეუძლია შეადგინოს მაღალი დონის, ძლიერი და შესამჩნევი მახასიათებლების მქონე გამოსახულებები, რომლებიც იმალება ადამიანის გადაუმუშავებელი ტვინის სიგნალის ნაკადებში და აფიქსირებს რთულ კავშირს მონაცემებში. ამ კვლევის ძირითადი საყურადღებო წვლილია:

- ადამიანი-ნივთის კოგნიტური ინტერაქტიულობის გასააქტიურებლად UDL ზე დაფუძნებული ფრეიმვორკის გამოყენება
- BCI -სა და IoT -ს შორის კავშირის გაბმა, end-to-end ტვინი-ნივთთან შემეცნებითი ურთიერთქმედების გამოსაკვლევად
- ღრმა დაჯილდოებითი სწავლების (Deep Reinforcement Learning, deep RL -ის) გამოყენება (რომელიც შემუშავებულია ჯილდოს, მდგომარეობისა და

მოქმედების მოდელის საშუალებით) ტვინის სიგნალებისგან ყველაზე გამორჩეული მახასიათებლების ავტომატურად აღმოჩენისათვის. აღმოჩენილი თვისებები გადაეგზავნება მოდიფიცირებულ ღრმა სწავლების სტრუქტურას, კერძოდ, შემოთავაზებულ WAS-LSTM -ს, მოხმარებლის განზრახვის ამოცნობის მიზნით ჯვარედინგანზომილებიანი დამოკიდებულების დასაფიქსირებლად

- შემოთავაზებული ფრეიმვორკის ორი ოპერაციული პროტოტიპი: ტვინით აკრფის სისტემა (a brain typing system) და შემეცნებით კონტროლირებადი ჭკვიანი სახლის მომსახურე რობოტი, რომელიც აჩვენებს ამ მიდგომის ეფექტურობასა და პრაქტიკულობას

ამ კვლევაში განხილულია დაჯილდოებით სწავლებაზე (Reinforcement Learning) დაფუძნებული შერჩევითი ყურადღების მექანიზმი (Selective Attention Mechanism, SAM) ტვინის შემომავალი სიგნალების განმასხვავებელი მახასიათებლების დასადგენად. გარდა ამისა შემოთავაზებულია მოდიფიცირებული გრძელი ხანმოკლე მეხსიერება (Long Short-Term Memory, LSTM) SAM -იდან წამოსული განზომილებათაშორისი ინფორმაციის გასარჩევად. აღნიშნული ფრეიმვორკის ეფექტურობის შესაფასებლად და ამ მიდგომის მიზანშეწონილობის დასადასტურებლად განვიხილავ ჩატარებულ ორ ექსპერიმენტს, პრაქტიკულ რეალურ დროში ადამიანი-ნივთის შემეცნებითი (კოგნიტური) ურთიერთქმედების პროგრამების წარმოდგენით.

### 2.3.1 მეთოდი

განვიხილოთ შემეცნების გამოვლენის ფრეიმვორკი. სუბიექტის ტვინის აქტივობის გაზომვა შესაძლებელია რამდენიმე მეთოდით, როგორცაა EEG, fMRI, MEG. ამ კვლევაში წარმოდგენილ ექსპერიმენტში გამოყენებულია EEG მისი უნიკალური მახასიათებლების გამო, როგორცაა სიიფე, დაბალი ენერჯის მოხმარება, კონფიდენციალურობა და პორტაბელურობა.

შემოთავაზებული მიდგომის ძირითადი აქცენტი არის, თუ როგორ გამოვიყენოთ ლატენტური კავშირი EEG სიგნალის განზომილებებს შორის.

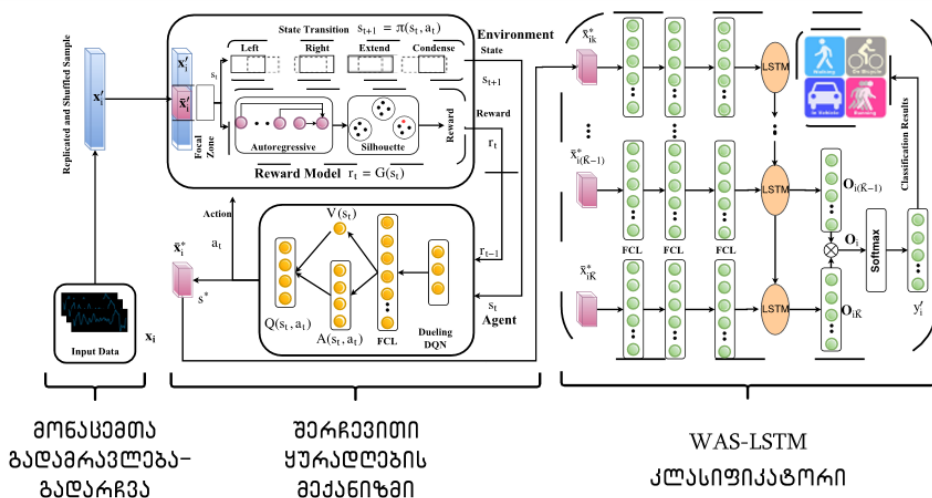


სხვადასხვა შემეცნების კუთვნილ სიგნალებს უნდა ჰქონდეთ განსხვავებული განზომილებათაშორისი ურთიერთდამოკიდებულება, რომელიც შეიცავს მდიდარ და განმასხვავებელ ინფორმაციას, რაც გადამწყვეტია სიგნალის დამახასიათებელი შაბლონის აღმოჩენის გასაუმჯობესებლად.

პრაქტიკაში, EEG სიგნალი ხშირად არის მოწყობილი, როგორც ერთ განზომილებიანი (1d) ვექტორი, სიგნალი ნაკლებად ინფორმაციულია შეზღუდული და ფიქსირებული ელემენტის განლაგებისათვის. ელემენტების რიგითობა და თითოეული სიგნალის ვექტორში ელემენტების რაოდენობამ შეიძლება გავლენა იქონიოს ელემენტების დამოკიდებულებაზე. მაგალითად, განზომილებათაშორისი დამოკიდებულება  $\{0,1,2,3,4\}$  და  $\{1,2,3,4,0\}$  -ში არ არის თანაბარი. ანალოგიურად,  $\{0,1,2,3,4\}$  და  $\{0,1,1,2,3,4\}$  არ არის ექვივალენტური. მრავალ რეალურ სცენარში, EEG – ის მონაცემები გაერთიანებულია ბიოსამედიცინო EEG არხების განაწილების შესაბამისად. სამწუხაროდ, არხების პრაქტიკული თანმიმდევრობა, ფიქსირებული რიგითა და რიცხვით, შეიძლება არ იყოს სათანადო განზომილებათაშორისი დამოკიდებულების ანალიზისათვის. ამ ნაკლის გასაუმჯობესებლად და სიგნალის განსხვავებულ განზომილებებს შორის ლატენტური დამოკიდებულების დამუშავების მიზნით გამოყენებულ იქნა შემდეგი სამი ტექნიკა (სურათი 11):

1. შემომავალი EEG სიგნალის ვექტორის გადამრავლება და გადარჩევა განზომილების მიხედვით, იმისათვის, რომ უზრუნველყოს რაც შეიძლება მეტი ლატენტური დამოკიდებულება მახასიათებლის განზომილებებს შორის
2. ფოკალური ზონის შემოღება, როგორც შერჩევითი ყურადღების მექანიზმი (SAM), სადაც თითოეული ნიმუშისათვის განზომილებათაშორისი ოპტიმალური დამოკიდებულება დამოკიდებულია მხოლოდ მახასიათებლების მცირე ქვეჯგუფზე. აქ, ფოკუსური ზონა ოპტიმიზირებულია ღრმა დაჯილდოებითი სწავლებით (deep RL), რომელიც ნაჩვენებია, რომ მიაღწევს როგორც კარგ შედეგს, ასევე სტაბილურობას მეთოდის სწავლების პროცესში.

3. WAS-LSTM კლასიფიკატორის გამოყენება განმასხვავებელი განზომილებათაშორის დამოკიდებულების გამოყოფისათვის




სურათი 11. შემთავაზებული ფრეიმვორკის დიაგრამა

ფოკალური ზონა  $\bar{X}_i$  ზონა შერჩეულია ფრაგმენტი  $\bar{X}'_i$  -დან რომ მომარაგდეს მდგომარეობის გადასვლაში და დაჯილდოების მოდელში. თითოეულ  $t$  ნაბიჯზე, ერთი მოქმედება ირჩევა მდგომარეობის გადასვლიდან, რომ განახლდეს  $S_t$  აგენტის უკუკავშირის საფუძველზე. ჯილდოს მოდელი აფასებს ფოკუსური ზონის ხარისხს  $r_t$  ჯილდოსკენ. დუელი DQN გამოიყენება ოპტიმალური ფოკალური ზონის  $\bar{X}_i$  -ის მოსაძებნად, რომელიც მომარაგდება LSTM -ზე დაფუძნებული კლასიფიკატორით, რომ აღმოაჩინოს განზომილებათაშორისი დამოკიდებულება და იწინასწარმეტყველოს ნიმუშის იარლიყი  $y_i^*$ . FCL აღნიშნავს სრულად დაკავშირებულ შრეს (Fully Connected Layer). მდგომარეობის გადასვლა შეიცავს 4 მოქმედებას: მარცხნივ გადაწევა, მარჯვნივ გადაწევა, გაფართოება და კონდენსაცია. წყვეტილი ხაზი მიუთითებს ფოკუსურ ზონას მოქმედებამდე, ხოლო სავსე ხაზი - კეროვანი ზონის პოზიციაზე მოქმედების შემდეგ.

### 2.3.2 ექსპერიმენტი

აღნიშნული ფრეიმვორკის ევექტურობისათვის განვიხილოთ რეალური სამყაროს ექსპერიმენტული მაგალითი. ამ მაგალითის მიხედვით განხორციელებულია EEG -ის მიღება ადვილად გამოსაყენებელი კომერციული თავზე გასაკეთებელი მოწყობილობის, Emotiv Epoc + -ის გამოყენებით, რომელიც იწერს ტვინის აქტივობას 14 ელექტროდის საშუალებით, რაც ხელს უწყობს შედარებით მაღალი სიზუსტის მონაცემების მოპოვებას. ეს მოწყობილობა შეიცავს 14 არხს და შერჩევის მაჩვენებელი (sampling rate) არის 128 ჰერცი (128 Hz). ამ ექსპერიმენტში მონაწილეობდა 23 -დან 26 წლამდე ასაკის 7 სუბიექტი (4 კაცი და 3 ქალი). ექსპერიმენტის დროს სუბიექტს თავზე ეკეთა EEG შემკრები მოწყობილობა Emotiv Epoc +, უყურებდა კომპიუტერის ეკრანს და ფოკუსირდებოდა შესაბამის მინიშნებაზე, რომელიც ჩნდებოდა ეკრანზე (სურათი 12 -ზე). EEG სიგნალები იწერებოდა, როდესაც სუბიექტი წარმოიდგენდა გარკვეულ მოქმედებებს (ყოველგვარი ფიზიკური მოქმედების გარეშე). განსაზღვრული მოქმედებების შემცველობა იყო: ზედა ისარი, ქვედა ისარი, მარცხენა ისარი, მარჯვენა ისარი და წრე. ამას გარდა, იწერებოდა EEG სიგნალებიც რომელიც მიიღებოდა სუბიექტის რელაქსაციის დროს, როდესაც მას თვალი ჰქონდა დახუჭული. ეს უკანასკნელი კლასი გამოირჩევა სამუშაოს შესრულების მაღალი მაჩვენებლით სხვა დანარჩენ კლასებთან შედარებით. რაც გამომდინარეობს იქიდან, რომ თვალ დახუჭული მდგომარეობა უფრო ადვილი ამოსაცნობია. გონივრულია რადგან სხვა კლასები თვალ ღია მდგომარეობებში იმყოფებიან და ადვილია მათი შეფერხება მომატებულ გარემო ფაქტორებთან გადაკვეთით. ესეიგი ექსპერიმენტში სულ იყო 6 კატეგორიის EEG სიგნალი. საერთო ჯამში, ეს ექსპერიმენტი შეიცავდა 241,920 ნიმუშს 34,560 ნიმუშით თითოეული სუბიექტისათვის. თითოეული მონაწილისათვის მონაცემთა ნაკრები დაყოფილი იყო საწვრთნელ და სატესტო ნაკრებებად. საწვრთნელი კომპლექტი შეიცავდა 31,104 ნიმუშს, ხოლო ტესტირების კომპლექტი შეიცავდა 3,456 ნიმუშს.

EEG მონაცემთა შებროვება:



ნარმოდგენილი მოქმედება ასოცირებული ტვინის აქტივობებთან და შესაბამის იარაღებთან, შესაბამისი ბრძანებები

ნარმოდგენილი მოქმედება	იარაღი	ასაკრეფი ბრძანებები	რობოტის ბრძანებები
ზემოთ	0	მალა	წინ
ქვემოთ	1	ბაქმება	მარცხნივ მოზრუნება
მარცხნივ	2	მარცხნივ	ხელის ჩაჭიდება
მარჯვნივ	3	მარჯვნივ	ხელის ბაქმება
შუა წრე	4	არაფერი	არაფერი
თვალ დახუჭული	5	დადასტურება	დაწყება / დასრულება

სურათი 12.

ღრმა სწავლებაზე დაფუძნებული ტექნიკის დახმარებით, ლატენტური მდგომარეობიდან გამომდინარე საერთო შეყოვნება აღნიშნული ექსპერიმენტისათვის იყო ერთ წამზე ნაკლები.

განვიხილოთ ადამიანის განზრახვის ამოცნობისათვის შემოთავაზებული ფრეიმვორკის, მაღალი სიზუსტისა და დაბალი შეყოვნების შთაგონებით შემუშავებული ორი რეალური კოგნიტური IoT პროტოტიპი, კერძოდ:

- 1) ტვინით აკრეფის სისტემა
- 2) გონებით კონტროლირებადი დამხმარე რობოტი ჭკვიანი სახლისათვის (კოგნიტური რობოტი)

2.3.3 ტვინით აკრეფის სისტემა

განზრახვის ამოცნობის მაღალი სიზუსტიდან გამომდინარე, ამ პროტოტიპისათვის შემუშავებულ იქნა ტვინით აკრეფის ონლაინ სისტემა, მომხმარებლის განზრახვათა ტექსტში გადასაცვანად. ტვინით აკრეფის სისტემა (სურათი 13) შედგება ორი კომპონენტისაგან:

- წინასწარ გაწვრთნილი ღრმა სწავლების მოდელი (the pre-trained deep learning model)
- ონლაინ BCI სისტემა (the online BCI system)

წინასწარ გაწვრთნილი ღრმა სწავლების მოდელი, რომელიც გაწვრთნილია ოფლაინ რეჟიმში, მიზნად ისახავს ზუსტად ამოიცნოს მომხმარებლის აკრეფის განზრახვა რეალურ დროში.

ონლაინ სისტემა შეიცავს 5 კომპონენტს:

- 1) EEG მოწყობილობა
- 2) კლიენტი 1 (მონაცემთა შემგროვებელი)
- 3) სერვერი
- 4) კლიენტი 2 (აკრეფის ბრძანების მიმღები)
- 5) აკრეფის ინტერფეისი

მომხმარებელი იკეთებს Emotiv EPOC+ მოწყობილობას, რომელიც აგროვებს EEG სიგნალებს და აგზავნის მათ კლიენტი 1 -თან Bluetooth კავშირის საშუალებით. გადაუმუშავებელი EEG სიგნალები კი იგზავნება სერვერზე TCP -ის კავშირით.

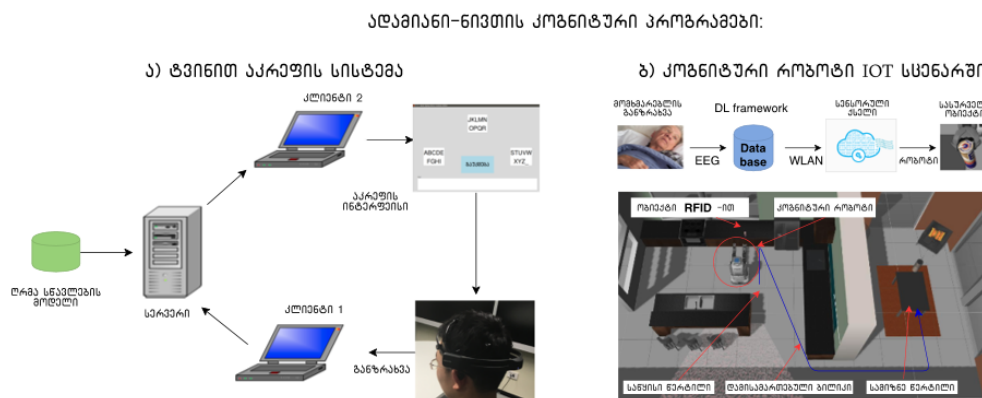
კერძოდ, აკრეფის ინტერფეისი (სურათი 13 ა) ზედა მარცხენა) შეიძლება დაიყოს სამ დონედ:

- 1) საწყისი ინტერფეისი;
- 2) ქვეინტერფეისი;
- 3) ქვედა ინტერფეისი.

ყველა ინტერფეისს აქვს მსგავსი სტრუქტურა: სამ სიმბოლოიანი ბლოკები (ცალ-ცალკე ნაწილდება მარცხენა, ზედა და მარჯვენა მიმართულებით), გამოსახვის ბლოკი და გაუქმების ღილაკი. გამოსახვის ბლოკი აჩვენებს აკრეფილ შედეგს, ხოლო გაუქმების ღილაკი აუქმებს ბოლო ოპერაციას. აკრეფის სისტემა ჯამში მოიცავს  $27 = 3 * 9$  სიმბოლოს (26 ასო ინგლისური ანბანიდან და ინტერვალი (space bar)), ყველა მათგანი გამოყოფილია 3 სიმბოლოიან ბლოკებად (თითოეული ბლოკი შეიცავს 9 სიმბოლოს) საწყის ინტერფეისში. საერთო ჯამში, გვაქვს 3 ალტერნატიული არჩევანი და თითოეულ არჩევანს მივყავართ კონკრეტულ ქვეინტერფეისთან, რომელიც შეიცავს 9 სიმბოლოს. კიდევ ერთხელ,  $9 = 3 * 3$  სიმბოლო იყოფა 3 სიმბოლოიან

ბლოკებად და თითოეული მათგანი დაკავშირებულია ქვედა ინტერფეისთან. ქვედა ინტერფეისში, თითოეული ბლოკი წარმოადგენს მხოლოდ ერთ სიმბოლოს. ტვინის აკრეფის სისტემაში არსებობს 5 ბრძანება ინტერფეისის გასაკონტროლებლად: "მაღლა", "გაუქმება", "მარცხნივ", "მარჯვნივ" და "დადასტურება". თითოეული ბრძანება შეესაბამება სპეციალური მოტორული წარმოსახვის EEG კატეგორიას. რადგანაც მომხმარებელი დიდხანს ვერ ახერხებს კონცენტრირებას (ჩვეულებრივ, 10 წამზე ნაკლები), თავის ტვინის აქტივობა ზოგჯერ ვერანაირ მოქმედ ბრძანებას გამოსახავს. მიუხედავად იმისა, რომ, შემოთავაზებული ღრმა სწავლების ფრეიმვორკი ვერ არჩევს ტვინის არასწორ აქტივობას, დატოვებულია ერთი სპეციფიკური კატეგორია, რომელმაც უნდა წარმოადგინოს არასწორი სიგნალი. თუ ინდივიდის ტვინის სიგნალი არ არის 5 მოქმედი კატეგორიიდან რომელიმე, ის კლასიფიცირდება, როგორც არასწორი კატეგორია და ტვინის აკრეფის სისტემა არაფერს მოიმოქმედებს ამ სიტუაციაში. უფრო მეტიც, ზემოთ განხილული ექსპერიმენტის საფუძველზე, თვალის დახუჭულ მდგომარეობას აქვს ყველაზე მაღალი სიზუსტე და სისწორე, ამიტომ ეს მდგომარეობა შეირჩა როგორც, დადასტურების ბრძანება, იმ მიზეზით, რომ "დადასტურება" არის ყველაზე მნიშვნელოვანი ბრძანება აკრეფის სისტემაში. თითოეული სიმბოლოს აკრეფისათვის, ინტერფეისმა უნდა მიიღოს 6 ბრძანება. მაგალითად, განვიხილოთ ასო "I" -ს აკრეფა. შემომავალი ბრძანებების თანმიმდევრობა შემდეგია: "მარცხენა" (აირჩევა მარცხენა ბლოკი, სიმბოლოებით {A, B, C, D, E, F, G, H, I} ), "დადასტურება", "მარჯვენა" (აირჩევა მარჯვენა ბლოკი, სიმბოლოებით {G, H, I} ), "დადასტურება", "მარჯვენა" (აირჩევა მარჯვენა ბლოკი, სიმბოლო {I} -ით), "დადასტურება". პრაქტიკულ განლაგებაში, Emotiv EPOC + მოწყობილობის შერჩევის მაჩვენებელი განისაზღვრება 128Hz -ით, რაც ნიშნავს, რომ სერვერს შეუძლია წამში მიიღოს 128 EEG ჩანაწერი. რადგანაც, ტვინის ტალღის სიგნალი სწრაფად იცვლება და იგი შეიძლება ძალიან მარტივად მოექცეს ხმაურის გავლენის ქვეშ, EEG მონაცემთა ნაკადის გაგზავნა ხდება სერვერზე ყოველ ნახევარ წამში, რაც ნიშნავს, რომ სერვერი ყოველ ჯერზე იღებს 64 EEG ნიმუშს. EEG -ის 64 ნიმუში კლასიფიცირდება ღრმა სწავლების ფრეიმვორკით და იქმნება განზრახვათა 64 კატეგორია. გამოითვლება 64 განზრახვის რეჟიმი და გათვალისწინებული იქნება

რეჟიმი, როგორც საბოლოო განზრახვის გადაწყვეტილება. გარდა ამისა, სტაბილურობისა და საიმედოობის მისაღწევად, სერვერი აგზავნის ბრძანებას კლიენტი 2 -თან მხოლოდ იმ შემთხვევაში, თუ ზედიზედ სამი გადაწყვეტილება დარჩება თანმიმდევრული. ბრძანების გაგზავნის შემდეგ, ბრძანებების სია გადაიტვირთება და სისტემა დაელოდება მომდევნო სამი თანმიმდევრული გადაწყვეტილების მიღებას.



სურათი 13.

### 2.3.4 კოგნიტური რობოტი

BCI –ს მიერ ინსპირირებული ნივთების ინტერნეტის კიდევ ერთი მნიშვნელოვანი პროგრამაა ინტერესის ნივთების (things of interest, TOI) ეფექტური კონტროლისათვის ჭკვიანი სახლების ორიენტაციის გაფართოება სუბიექტის განზრახვისა და რეალურ სამყაროში არსებული IoT ობიექტების ინტეგრირებით. შემოთავაზებული ფრეიმვორკის მიზანშეწონილობის დემონსტრირებისათვის, გავცნოთ მეორე გამოყენების შემთხვევას, როგორც კოგნიტური ინტერაქტიულობის განხორციელებას IoT -ზე დაფუძნებული ჭკვიანი სახლის სისტემაში. IoT –ზე დაფუძნებული ჭკვიანი სახლი აღჭურვილია სენსორებით: ინფრაწითელი (IR), გარემოს ხმა, სიტბო და კონტაქტი. სენსორები დამონტაჟებულია ავეჯზე და გამოიყენება სახლის გარემოში არაინვაზიური გზით. ამ შემთხვევაში, ჭკვიანი სახლის გარემოში, რომელიც აღიქმება ჩადგმული სენსორული ქსელების მიერ, იმიტირებული

რობოტის ნავიგაცია რუტინული ამოცანის შესასრულებლად ხდება კოგნიტურად. კონკრეტული სცენარის მიხედვით, რობოტი შეიტყობს მომხმარებლის განზრახვას EEG -ის ჩანაწერებიდან შემოთავაზებული ფრეიმვორკის საშუალებით, IoT ობიექტის (მაგ. სასმელის ქილის) აღება სამზარეულოში არსებული მაგიდიდან და მისი განთავსება მისაღებში არსებულ მაგიდაზე. სასურველი ობიექტი გაერთიანებულია RFID ნიშნთან, რაც ეხმარება მდებარეობის დადგენაში (IoT სცენარი ასახულია სურათი 13 ბ) ზედა მარჯვენა). მომხმარებლის განზრახვა ხორციელდება EEG ჩანაწერებში, რომლებიც ინტერპრეტაციისათვის გადაეცემა ღრმა სწავლების ფრეიმვორკს. ამოცნობილი განზრახვის გაგზავნა ხდება სენსორის ქსელში WLAN -ის საშუალებით, სასურველი ობიექტის მისაღებად რობოტის დამისამართებისათვის. სამზარეულოს მახლობელი მაგიდადან დაწყებული, PR2 რობოტი იღებს სამოქმედო ბრძანებებს და მიდის წინ, სანამ არ შეხვდება კონკრეტული პოზიცია RFID დამხმარე ნიშნით. შემდეგ, რობოტი იღებს ობიექტს, ბრუნდება უკან და მიუყვება მისაღებ მაგიდასთან მისასვლელ ბილიკს და უშვებს ხელს სასმელის ქილის მაგიდაზე დასადებად. სიმულაციურ შედეგმა აჩვენა, რომ რობოტს შეუძლია 100% ზუსტად აიღოს და დადოს ობიექტი სუბიექტის გონებაში დაგეგმილი გზის შესაბამისად. სიმულაციური პლატფორმა მოთავსებულია Gazebo -ს toolbox -ში, ხოლო რობოტების მართვის პროგრამა მუშაობს Robot Operating System (ROS) -ზე. ამ კონკრეტული შემთხვევისათვის ხდება სუბიექტი 1 -ის მონაცემთა ნაკრებიდან შემთხვევითობის პრინციპით შერჩევა რამოდენიმე EEG გადაუმუშავებელი მონაცემისა, როგორც სიმულაციური მასალა.



### თავი III. განხილვა

ამ ნაშრომში განხილულია შემოთავაზებული ტვინის ტალღების სიგნალების წინასწარი დამუშავების მეთოდებიდან ESP32 მიკროკონტროლერით აწყობილი open source პროგრამული უზრუნველყოფის მოწყობილობა და ადვილად გამოსაყენებადი, კომერციულიზებული DL Framework -ზე დაფუძნებული proprietary software მოწყობილობა, შესაბამის კვლევით ექსპერიმენტებზე დაყრდნობით, რომელთა შემდგომი გამოყენებაც შესაძლებელია მომხმარებლის განზრახვის გარდასაქმნელად ეფექტური მოწყობილობებისათვის გასაგები ბრძანების სიგნალებად.

ESP32 მიკროკონტროლერით აწყობილი EEG მოწყობილობა მოიპოვებს სუბიექტების ტვინის EEG აქტივობის სიგნალებს მხოლოდ ერთი შეყვანის არხის გამოყენებით, რომელიც განთავსდა O2 პოზიციაზე, cE ან oE თვალის მდგომარეობის დასადგენად. საბოლოო სისტემისათვის მოთხოვნებია:

- oE აღმოჩენა, როგორც წესი, უფრო მნიშვნელოვანია კომფორტის უზრუნველსაყოფად
- სიზუსტე უნდა იყოს მაღალი, რათა თავიდან იქნას აცილებული არასასურველი სიტუაციები, რომლის დროსაც მოხდება მოწყობილობების უმიზეზო ჩართვა / გამორთვა
- სიმტკიცე გარემოს ცვლილებებისა და მომხმარებლის ტვინის აქტივობის მიმართ
- გამოსაყენებლად მზადყოფი პროგრამა მოკლე სატრენინგო დროით, რაც ხელს უწყობს მის ყოველდღიურობაში ინტეგრირებას და გამოყენებას

შედარებულ იქნა რამდენიმე რეალურად და კომპლექსურად შეფასებული გარდაქმნები გადაწყვეტილების ორი სტრატეგიით: ბარიერზე დაფუძნებული მეთოდით, რომელიც იყენებს ალფა და ბეტა სიხშირის ხაზების სიმძლავრეებს შორის თანაფარდობას და ხაზოვანი დისკრიმინაციული ანალიზით (LDA). სიმულაციის შედეგებმა აჩვენა როგორც კლასიფიკატორის სიზუსტე, ისევე შესაბამისი სისტემური შეფერხებები.

ექსპერიმენტზე დავაკვირვებით გამოჩნდა, რომ ბარიერზე დაფუძნებული კლასიფიკატორი მნიშვნელოვნად უკეთესად მოქმედებს oE მდგომარეობისთვის,

ვიდრე LDA, რომელიც აღწევს 90% -ზე ნაკლებ სიზუსტეს 7 სუბიექტიდან 4 –ისთვის და აჩვენებს უფრო დიდ გადახრებს. LDA –ს მიერ მიღებულ შედეგებმა cE –სთვის კი პირიქით, უფრო მაღალი სიზუსტე და მოკლე გადახრები აჩვენა, ვიდრე ბარიერზე დაფუძნებულმა მეთოდმა, მაგრამ ეს განსხვავებები გაცილებით მცირეა, ვიდრე oE –ს ექსპერიმენტებისა. ამრიგად, ბარიერზე დაფუძნებული კლასიფიკატორი უზრუნველყოფს უფრო მეტ სიმტკიცეს გადაწყვეტილების მისაღებად, ამიტომაც სასურველია სისტემის დანერგვისთვის მისი გამოყენება.

შედეგების გათვალისწინებით, შესაძლოა შეფასდეს, რომ 2 წამიანი დაგვიანებისთვის, ბარიერზე დაფუძნებული მეთოდით მიიღება 90% -ზე მეტი სიზუსტე შვიდივე სუბიექტისთვის oE სცენარში და 7 სუბიექტიდან 6 -სთვის cE სცენარში. ეს ნიშნავს, რომ სისტემის რეაგირების დრო შესაფერისია არაკრიტიკული პროგრამების განსახორციელებლად. თუმცა, გარკვეული გარემოებისთვის, ამ შეფერხებამ შეიძლება გამოიწვიოს მომხმარებლის უთანხმოება ან შესაძლო არტეფაქტები და შესაბამისად უნდა შემცირდეს მომავალ განვითარებებში.

Emotiv Epoc + მოწყობილობისა და DL Framework -ის გამოყენებით ჩატარებულ კვლევაში, SAM კომპონენტი ფოკუსური ზონით არის შექმნილი, რათა ავტომატურად შეისწავლოს EEG მონაცემების შეტანის ლატენტური განზომილების თანმიმდევრობა, მიუხედავად ამისა, SAM –ის გამოყენება ზრდის ტრენინგის დროს LSTM უჯრედის მეტი განმეორების შედეგად. რაც მთავარია, გადამრავლება-გადარჩევის ეტაპი ამრავლებს შეყვანის განზომილებების რაოდენობას და ცვლის წესრიგს, რათა აღმოაჩინოს ოპტიმალური წყობა საუკეთესო შედეგის მისაღწევად, მაგრამ ოპტიმალური წყობის აღმოჩენა გარანტირებული არ არის გადამრავლება-გადარჩევის შემდეგ, ამიტომ უფრო მეტი მცდელობაა საჭირო, თუ კლასიფიკაციის შედეგი არადადამაკმაყოფილებელია. WAS-LSTM -ის გამოყენებით, მოპოვებულ იქნა შემომავალი ადამიანის ტვინის სიგნალების განზომილებათაშორისი დამოკიდებულება, რომლებიც შეირჩა SAM -ით. WAS-LSTM იყენებს სივრცით ინფორმაციას EEG არხებს შორის, ამიტომ საჭიროა მრავალი არხი საკმარისი ინფორმაციის მისაწოდებლად. კვლევაში ნაჩვენებია ორი შემთხვევის სწავლება,

კერძოდ ტვინის აკრეფის სისტემისა და კოგნიტური რობოტის შემუშავების ერთ-ერთი ექსპერიმენტული გამოცდილება.

### დასკვნა

ტვინი-კომპიუტერის ინტერფეისისა (BCI) და ნივთების ინტერნეტის (IoT) დაკავშირების მიზანშეწონილობა კოგნიტური ინტერაქტიულობის უზრუნველსაყოფად დადასტურებულია განხილულ კვლევებში წარმოდგენილი მეთოდებით. EEG –ის გამოყენება IoT –სთვის არის დამწყები განვითარებადი სფერო. უფრო დიდი და მრავალფეროვანი მონაცემთა ბაზაა საჭირო შემოთავაზებული მოდელების ეფექტების საილუსტრაციოდ. მოცემული სასწავლო ექსპერიმენტები შეიცავდა მხოლოდ 7-7 სუბიექტს, რომელიც შეზღუდული იყო პრაქტიკული პირობებით. სამომავლო სამუშაოებისთვის უკეთესი იქნება ექსპერიმენტებში მონაწილეთა რაოდენობების გაზრდა, გარდა ამისა, ექსპერიმენტები უნდა ჩატარდეს რეალური ცხოვრების სცენარებში, რათა შესწავლილ იქნას მათი შესრულება რეალური ცხოვრების პირობებში და ასევე მნიშვნელოვანია მობილობის დარღვევის მქონე სუბიექტების გათვალისწინება.

### გამოყენებული ლიტერატურა

1. David Al-Dabass, Lela Mirtskhulava, Chapter 1 - Application of dynamical systems based deep learning algorithms to model emergent characteristics for healthcare diagnostics, Editor(s): Janmenjoy Nayak, Bighnaraj Naik, Danilo Pelusi, Asit Kumar Das, Handbook of Computational Intelligence in Biomedical Engineering and Healthcare, Academic Press, 2021, Pages 1-29, ISBN 9780128222607.
2. Karam, Jalal, Al-Majeed, Salah, Yalung, Christofer and Mirtskhulava, Lela (2016) Neural Network for Recognition of Brain Wave Signals. International Journal of Enhanced Research in Science, Technology and Engineering, 5 (10). pp. 36-42.
3. Lela Mirtskhulava. Monitoring Brain Attacks using AI Diagnosis. AIMed Magazine #001 – Decision Support & Hospital Monitoring. CA. US. 06/14/2018
4. Lela Mirtskhulava, Julian Wong, Gillian Pearce, Salah Al-Majeed. Artificial Neural Network Model in Stroke Diagnosis. DOI: 10.1109/UKSim.2015.33 Conference: 2015 17th UKSIM-AMSS International Conference on Modelling and Simulation, Cambridge University, UK.
5. Gillian Pearce, Lela Mirtskhulava, Julian Wong, Salah Al-Majeed, Koba Bakuria, Nana Gulua. Artificial Neural Network and Mobile Applications in Medical diagnosis DOI: 10.1109/UKSim.2015.34 Conference: 2015 17th UKSIM-AMSS International Conference on Modelling and Simulation, Cambridge University, UK
6. Lela Mirtskhulava, Salah Al-Majeed, Gillian Pearce, Tamar Gogoladze, Ivane Javakhishvili. Blood Clotting Prediction Model Using Artificial Neural Networks and Sensor Networks. GESJ: Computer Science and Telecommunications 2014| No. 3(43). Reviewed Electronic Scientific journal. [http://gesj.internet-academy.org.ge/en/list\\_artic\\_en.php?b\\_sec=comp](http://gesj.internet-academy.org.ge/en/list_artic_en.php?b_sec=comp)
7. A Prototype of EEG System for IoT Francisco Laport. Adriana Dapena\*, Paula M. Castro, Francisco J. Vazquez-Araujo and Daniel Iglesia Department of Computer Engineering CITIC Research Center & University of A Coruña Campus de Elviña, A Coruña 15071, Spain \*adriana.dapena@udc.es. Accepted 5 February 2020 Published Online 4 May 2020. International Journal of Neural Systems, Vol. 30, No. 7 (2020) 2050018 (15 pages) c\_ The Author(s) DOI: 10.1142/S0129065720500185.

8. Internet of Things Meets Brain-Computer Interface: A Unified Deep Learning Framework for Enabling Human-Thing Cognitive Interactivity. Xiang Zhang, Student Member, IEEE, Lina Yao, Member, IEEE, Shuai Zhang, Student Member, IEEE, Salil Kanhere, Member, IEEE, Michael Sheng, Member, IEEE, and Yunhao Liu, Fellow, IEEE. JOURNAL OF LATEX CLASS FILES, VOL. 14, NO. 8, AUGUST 2015