



ТЕХНИЧЕСКИ УНИВЕРСИТЕТ – СОФИЯ
Факултет по Компютърни системи и технологии
Катедра „Компютърни системи“

маг. инж. Ивайло Емилов Ивайлов

**ИЗСЛЕДВАНЕ НА МЕТОДИ И АЛГОРИТМИ
ЗА МОЗЪЧНО-КОМПЮТЪРНО ВЗАИМОДЕЙСТВИЕ**

А В Т О Р Е Ф Е Р А Т

на дисертация за придобиване на образователна и научна степен
„ДОКТОР“

Област: 5. Технически науки
Професионално направление: 5.3. Комуникационна и компютърна техника
Научна специалност: Системи с изкуствен интелект

Научни ръководители:
проф. д-р инж. Милена Кирилова Лазарова–Мицева
доц. д-р инж. Агата Христова Манолова

СОФИЯ, 2022 г.

Дисертационният труд е обсъден и насочен за защита от Катедрения съвет на катедра „Компютърни системи“ към Факултет по Компютърни системи и технологии на ТУ–София на редовно заседание, проведено на 22.02.2022 г.

Публичната защита на дисертационния труд ще се състои на 09.06.2022 г. от 15 часа в Конферентната зала на БИЦ на Технически университет–София на открито заседание на научното жури, определено със заповед № ОЖ-5.3-07/07.03.2022 г. на Ректора на ТУ–София в състав:

1. проф. д-р Румен Иванов Трифонов – председател
2. доц. д-р Иво Руменов Драганов – научен секретар
3. доц. д-р Милена Николова Милева–Карова
4. проф. д-р Станимир Михайлов Садинов
5. доц. д-р Филип Атанасов Цветанов

Рецензенти:

1. проф. д-р Румен Иванов Трифонов
2. доц. д-р Милена Николова Милева–Карова

Материалите по защитата са на разположение на интересуващите се в канцеларията на Факултет по Компютърни системи и технологии на ТУ–София, блок 1, кабинет №1443а.

Дисертантът е редовен докторант към катедра „Компютърни системи“ на Факултет по Компютърни системи и технологии. Изследванията по дисертационната разработка са направени от автора, като някои от тях са подкрепени от научноизследователски проекти.

Автор: маг. инж. Ивайло Ивайлов

Заглавие: Изследване на методи и алгоритми за мозъчно-компютърно взаимодействие

Тираж: 30 броя

Отпечатано в ИПК на Технически университет – София

I. ОБЩА ХАРАКТЕРИСТИКА НА ДИСЕРТАЦИОННИЯ ТРУД

Актуалност на проблема

Разпространените и използвани потребителски интерфейси за взаимодействие човек-компютър се базират основно на използване на традиционни периферни устройства, но този подход за комуникация не е подходящ или е напълно неприложим за хора с някои видове увреждания, както и при комуникация с компютър или машина в определени среди. При проектирането на потребителски интерфейси за взаимодействие човек-компютър се спазват основни принципи и методологии, които осигуряват проектирането и изграждането на ефективен, ефикасен и надежден потребителски интерфейс. Използването на мозъчно-компютърно взаимодействие (Brain-Computer Interface, BCI) за декодиране на умствено намерение на потребител чрез измерване на активността на невронни сигнали, без да се използват естествените нервно-мускулни пътища на човешкото тяло, позволява изграждане на потребителски интерфейси за взаимодействие човек-компютър, които намират приложение в много разнообразни области и приложения и са обект на активен изследователски интерес в последните години.

Цел на дисертационния труд, основни задачи и методи за изследване

Цел на научните изследвания в дисертационния труд е да се проучат и изследват методи и алгоритми за мозъчно-компютърно взаимодействие и да се предложат ефективни модификации на избрани методи и алгоритми за моторни мислени задачи.

За постигане на поставената цел следва да бъдат изпълнени следните задачи:

1. Да се направи литературно проучване на подходи, методи и алгоритми за мозъчно-компютърно взаимодействие
2. Да се изберат подходящи методи и алгоритми, за които да се предложат модификации за постигане на ефективно решение за моторни мислени задачи
3. Да се оцени ефективността чрез експериментално изследване за предложените модификации на избраните методи и алгоритми

Научните методи, които са използвани, са свързани с проучване на литературни източници в областта на взаимодействие на човек с компютър чрез сигнали, генерирани от човешкия мозък; проектиране на процедура за създаване на набор данни за сигнали, генерирани от човешкия мозък; проектиране и имплементация на методи и алгоритми за обработване и класификация на сигнали, генерирани от човешкия мозък; провеждане на експеримент за оценка, валидация и верификация на предложените методи и алгоритми; статистически методи за обработка, оценка и представяне на получените експериментални резултати.

Научна новост

Предложен е подход за използване на уейвлетна трансформация на етапа на формиране на характеристичен вектор и експериментално е оценено влиянието му върху резултатите от класификация на тестово множество EEG сигнали за ментални моторни образи. Предложен е подход за използване на генетичен алгоритъм и двукратно кръстосано валидиране при селектиране на характеристики в EEG сигнали за BCI базирана класификация на мислени моторни образи и експериментално е оценено влиянието му върху точността на класификация. Предложени са две архитектури на дълбоки конволюционни невронни мрежи за класификация на EEG данни, които са експериментално оценени за анализ на P300 сигнали за мисловно изписване на символи и за разпознаване на емоционално състояние при анализ на мултимодални набори данни.

Практическа приложимост

Предложените модификации на методи за обработване и анализ на мисловни сигнали са експериментално оценени и могат да бъдат използвани за практическо приложение в реални BCI системи. Разработена е процедура за провеждане на експериментални измервания за създаване на собствени набори данни EEG данни за мисловни двигателни образи, която е приложима за създаване на собствени набор EEG данни. Създадени са две приложения за управление на движение на курсор на мишка и за управление на виртуални обекти в компютърни игри чрез мисловни образи за моторни действия с използване на EEG сигнали

Апробация

Резултатите от дисертационния труд са разглеждани, обсъждани и публикувани в:

1. Девета международна научна конференция „Computer Science '2020“, Велинград, България, 18–21 октомври, 2020.
2. XXVIII национална конференция с международно участие “TELECOM 2020”. София, България, 29–30 октомври 2020.
3. 56та IEEE международна научна конференция “Information, Communication and Energy Systems and Technologies (ICEST'2021)”, Созопол, България, 16–18 юни, 2021.
4. Списание “Computer and Communication Engineering”.
5. Списание “Electrotechnica & Electronica (E+E)”.
6. Списание “International Journal of Computing”.
7. Сборник трудове на Технически университет–София.
8. Научен семинар на докторанти във Факултет по Компютърни системи и технологии, 12 юни 2020, 25 юни 2021.

Публикации

Основни постижения и резултати от дисертационния труд са публикувани в 8 научни статии, като 2 от тях са самостоятелни. Научните статии са представени и публикувани в национални и международни конференции и международни реферирани и индексирани издания.

Структура и обем на дисертационния труд

Дисертационният труд е в обем от 128 страници, като включва увод, 4 глави за решаване на формулираните основни задачи, списък на основните приноси, списък на публикациите по дисертацията и използвана литература. Цитирани са общо 167 литературни източници, като 180 са на латиница, а останалите са интернет адреси. Работата включва общо 49 фигури и 20 таблици. Номерата на фигурите и таблиците в автореферата съответстват на тези в дисертационния труд.

II. СЪДЪРЖАНИЕ НА ДИСЕРТАЦИОННИЯ ТРУД

УВОД

Интерфейсът човек-компютър може да бъде описан като комуникация между потребител-човек и компютърна система, при което двупосочно се обменя поток от информация между човека и компютъра. Традиционните входни периферни устройства, чрез които потребителят взаимодейства с компютър, са стандартните ръчни устройства като мишка и клавиатура, изискващи използване на команден ред или графичен потребителски интерфейс. Този подход за комуникация не е подходящ или е напълно неприложим за хора с някои видове увреждания, както и при комуникация с компютър или машина в определени среди. Въпреки, че човеко-машинните интерфейси при съвременните компютри използват основно стандартни входни устройства като мишка и клавиатура в последното десетилетие активно се разработват алтернативни интерфейси за комуникация между човека и машината с използване на множество модалности, основани на използване на глас, поглед, допир за изпращане на информация към компютъра за потребителските намерения. Мозъчно-компютърното взаимодействие (Brain-Computer Interface, BCI) е технология, която има за цел да декодира умственото намерение на потребителя единствено чрез измерване на активността на невронни сигнали, без да използва естествените нервно-мускулни пътища на човешкото тяло. Мозъчно-компютърните интерфейси стават все по-популярни през последните години и се използват в различни приложения, включително за привличане на внимание и натоварване, както и за директен контрол на обекти с помощта на BCI.


ГЛАВА 1. Потребителски интерфейси за взаимодействие между човек и компютър

В първа глава на дисертационния труд са представени потребителските интерфейси за взаимодействие между човек и компютър. Организирана е в 3 части. В първата част се разглеждат потребителски интерфейси за взаимодействие между човек и компютър. Втората част представя мозъчно-компютърни интерфейси. В третата част е направен преглед на приложни области на системи с мозъчно-компютърен интерфейс.

1.1. Взаимодействие между човек и компютър

Терминът взаимодействие човек-компютър (Human Computer Interface, HCI) е широко използван едва от началото на 80-те години на миналия век, но има своите корени в потвърдени дисциплини. Систематичното изучаване на човешкото представяне започна сериозно в началото на миналия век във фабриките, с акцент върху ръчните задачи. Втората световна война даде тласък за изучаване на взаимодействието между хората и машините, тъй като всяка страна се стремеше да произвежда по-ефективни оръжейни системи. Това доведе до вълна от интерес към тази област сред изследователите и създаването на Изследователското дружество по ергономия през 1949 г. Традиционно ергономистите се интересуват преди всичко от физическите характеристики на машините и системите и от това как те влияят върху работата на потребителите. Човешкият фактор включва тези въпроси, както и повече когнитивни проблеми. Термините често се използват взаимозаменяемо, като ергономичността е предпочитаният термин в Обединеното кралство, а човешкият фактор в англоговорящите части на Северна Америка. И двете дисциплини се занимават с работата на потребителя в контекста на всяка система, независимо дали е компютърна, механична или ръчна. Тъй като използването на компютри става все по-широко, все по-голям брой изследователи се специализират в изучаването на взаимодействието между хората и компютрите, занимавайки се с физическите, психологическите и теоретичните аспекти на този процес. Това изследване първоначално премина под името взаимодействие човек-машина, но това се превърна в взаимодействие човек-компютър като признание за особения интерес към

компютрите и състава на потребителската популация! Взаимодействието човек-компютър е обяснено на Фигура 1.1.




Фигура 1.1. Верига на взаимодействие между човек и компютър

1.2. Мозъчно-компютърни интерфейси

Мозъчно-компютърният интерфейс (BCI) е система, която позволява на хората да взаимодействат със заобикалящата ги среда чрез използване на контролни сигнали, генерирани от мозъчна дейност, регистрирана с различни устройства, без намесата на периферни нерви и мускули на човешкото тяло. BCI предоставя възможност за предаване на индивидуалните цели на потребителя за извършване на определени действия към външни устройства като компютърни системи, синтезатори на реч, помощни медицински апарати и различни медицински протези без да се използват стандартни входни устройства, изискващи движение на потребителя, гласови команди и визуални интерфейси, а само с използване на неизречени думи и въображаеми движения. Системите за мозъчно-компютърен интерфейс позволяват енцефална дейност да контролира компютри или външни устройства като по този начин осигурят комуникационни възможности на хора с тежки увреждания, които са напълно парализирани или „заключени“ от неврологични невромускулни нарушения, като амиотрофична странична склероза, мозъчен инсулт или увреждане на гръбначния мозък. BCI системите са особено привлекателни за хора с тежки двигателни увреждания, тъй като такива системи биха подобрили качеството им на живот и в същото време биха намалили разходите за интензивно лечение.

Обикновено BCI е система, която може да разпознава определен набор от модели в мозъчните сигнали чрез обработването им в няколко последователни фази: регистриране на мозъчни сигнали, предварителна обработка на сигналите и подобряване на представянето им в подходяща форма за по-нататъшна обработка, извличане на функции за идентифициране на дискриминационна информация в записаните мозъчни сигнали, класификация на сигналите въз основа на извлечената дискриминационна информация и използване на резултатите от класификацията чрез преобразуването им в смислени команди на интерфейс за управление на конкретно устройство. BCI класификациите са обяснени на фигура 1.2.




Фигура 1.2. BCI класификации.

1.3. Приложни области на системи с мозъчно-компютърен интерфейс

Технологията Brain-Computer Interface (BCI) е мощен инструмент за комуникация между потребител и машина, чрез които се установява директна комуникация между мозъка и външно устройство. Първоначалното възникване на BCI за биомедицински приложения в последствие се разширява и за немедицински приложения в различни области на индустрията: образование, реклама, забавления, управление на устройства и други. Ограниченията, предизвикателствата и свързаните с тях съмнения за възможностите за реално използване на BCI за немедицински приложения се дължат основно на технически трудности: ниска скорост на предаване на информацията и ниска точност на трансформиране на ментални действия в реални команди, както и на недоверие и предизвикателства при приемането от страна на потребителите на мозъчно-базирано управление на устройства.

От друга страна BCI системите могат да бъдат полезни, особено за приложения за безопасност или приложения, при които времето за реакция е от решаващо значение както и за повишаване на точността на HCI системите. Въпреки очаквания успех, интерфейсите базирани на взаимодействие между човешки мозък и компютър трябва да преодолеят техническите трудности, както и предизвикателствата, породени от приемането на потребителите за използване на тази иновативна технология.

От друга страна, някои от предимствата на BCI за трудоспособни потребители са изяснени. BCI може да бъде полезен, особено за приложения за безопасност или приложения, където мигновено е трудно да се премести и времето за реакция е от решаващо значение. Освен това те могат да се използват и за повишаване на точността на HCI системите, което води до принос на BCI в различни области като индустрия, образование, реклама, забавления и интелигентен транспорт. Въпреки очаквания успех, взаимодействието между мозъка и компютъра трябва да преодолеят техническите трудности, както и предизвикателствата, породени от приемането на потребителите за справяне с такава новооткрита технология. BCI класификациите и приложенията са обяснени на фигура 1.3. и Фигура 1.4.



Фигура 1.3. Класификация на BCI системите по отношение на надеждността, метода на запис и режима на работа.



Фигура 1.4. Области за приложение на BCI системи.

1.4. Изводи

В резултат на направените проучвания в областта на потребителските интерфейси за взаимодействие между човек и компютър могат да бъдат направени следните по-важни изводи

1. Разпространените и използвани потребителски интерфейси за взаимодействие човек-компютър се базират основно на използване на традиционни периферни устройства, но този подход за комуникация не е подходящ или е напълно

неприложим за хора с някои видове увреждания, както и при комуникация с компютър или машина в определени среди.

2. При проектирането на потребителски интерфейси за взаимодействие човек-компютър се спазват основни принципи и методологии, които осигуряват проектирането и изграждането на ефективен, ефикасен и надежден потребителски интерфейс.
3. Използването на мозъчно-компютърно взаимодействие за декодиране на умствено намерение на потребител чрез измерване на активността на невронни сигнали, без да се използват естествените нервно-мускулни пътища на човешкото тяло, позволява изграждане на потребителски интерфейсът за взаимодействие човек-компютър, които намират приложение в много разнообразни области.
4. За регистриране на мозъчна активност за целите на мозъчно-компютърни интерфейси могат да се използват различни методи, най-често използван от които е електроенцефалографията (EEG), която осигурява висока времева и пространствена разделителна способност, безопасност, достъпност и лесно използване в системи за мозъчно-компютърно взаимодействие.
5. В системите за мозъчно-компютърно взаимодействие най-често се използват спонтанни управляващи сигнали, базирани на двигателни и сензо-моторни задачи, които изискват обработване и анализ на регистрираните EEG данни за генериране на контролни сигнали за взаимодействие с компютърна система.
6. В системите за мозъчно-компютърно взаимодействие регистрираните данни за мозъчната активност се трансформират в контролни сигнали за взаимодействие с компютърна система, като от съществено значение е изборът на методи и алгоритми, които да се комбинират и приложат на всеки от етапите на обработване на EEG сигнали за мозъчната активност.

На базата на направените проучвания е формулирана следната **цел на научните изследвания в дисертационния труд**: да се проучат, анализират, предложат и изследват методи и алгоритми за обработване на сигнали за мозъчна активност за изграждане на потребителски интерфейси за взаимодействие на човек с компютър чрез сигнали, генерирани от човешкия мозък.

За постигане на поставената цел следва да бъдат изпълнени следните задачи:

1. Да се проучат методи и алгоритми за обработване на сигнали за мозъчна активност за изграждане на потребителски интерфейси за взаимодействие на човек с компютър.
2. Да се предложат подходящи методи и алгоритми за обработване на сигнали за мозъчна активност на всеки от етапите, свързани с предварителна подготовка и филтриране на сигналите, откриване на характеристики и формиране на характеристичен вектор, намаляване на размерността на характеристичния вектор чрез селектиране на дискриминативни характеристики и класификация за определяне на мозъчно действие, което да се трансформира в управляващ сигнал за компютър или устройство, управлявано чрез мозъчно-компютърен интерфейс.
3. Да се проучат и изследват възможностите за използване на мултимодални набори данни за регистриране на мозъчна активност с хибридни сигнали за подобряване на класификацията на мисловни образи за целите на потребителски интерфейси за взаимодействие на човек с компютър.
4. Да се оценят експериментално възможностите за използване на предложените методи и алгоритми за обработване на сигнали за мозъчна активност за изграждане на потребителски интерфейси за взаимодействие на човек с компютър.

ГЛАВА 2. Етапи при обработка на данни за мозъчно-компютърно взаимодействие

Втора глава на дисертационния труд представя етапи при обработка на данни за мозъчно-компютърно взаимодействие. Организирана е в 4 части. В първата част е представена предварителна обработка. Втората част представя Откриване на характеристики. В третата част са описани класификация. В четвърта част е направен

преглед на дълбоки невронни мрежи за класификация в системи с мозъчно-компютърен интерфейс.

2.1. Предварителна обработка

Етапът на предварителна обработка включва разработването на алгоритмични процедури за нормализиране, филтриране и отстраняване на артефакти в записани EEG мозъчната активност. Целта е да се подобри информационното съдържание в получените сурови EEG данни с подобряване на съотношението сигнал/шум (Signal-to-Noise Ratio, SNR) и да се извлече необходимата полезна информация за успешно изпълняване на следващите етапи на обработване на данните. Извличането на необходимото полезно информационно съдържание от записани невронни отговори на този етап включва представяне на регистрираните сигнали с помощта на компактни математически функции и операции. Основният акцент е върху проектирането и разработването на ефективни системи за регистриране на сигнали и точни системи за обработка на сигналите, за да се предотврати загуба на данни. Често се използва филтрация на получени невронни данни, последвана от трансформация на сигнала по време на етапа на предварителна обработка. Основната цел на предварителната обработка на EEG данните е да се премахването на източниците на шум, за да се сведе до минимум зашумяването на основните полезни модели в данните. Един от най-силните източници на шум в EEG е околната електрическа активност в близост до записващото оборудване, като като компютърни и електронни устройства,, големи светлини източници или неправилно изолирани проводници. Тези сигнали се отделят лесно от сигналите за мозъчната дейност, тъй като честотните им характеристики обикновено са в диапазона 60 Hz или 50 Hz (съответно в Америка и Европа). За премахване на други източници на шум, характеризиращи се с ниско-честотни промени в регистрираните данни, които се дължат на изменения в електрическия профил на скалпа или сензорите, като увеличаване или намаляване на влажността, водещо до промяна в проводимостта се прилагат различни честотни филтри.

2.2. Откриване на характеристики

Различните мисловни дейности водят до различни модели на мозъчни сигнали. Системите за мозъчно-компютърно взаимодействие могат да се разглеждат като система за разпознаване на образи, която класифицира всеки модел на мозъчна активност в определен клас според негови съществени характеристики. Етапът на откриване на характеристиките включва определяне на дискриминационна информация за мозъчните сигнали като по този начин намалява размера на информацията, необходима за класифициране на невронната активност, измерена чрез регистрираните EEG данни. Целта е регистрираните мозъчни сигнали да се опишат количествено чрез няколко подходящи стойности, наричани „характеристики“ и да се извлече характеристичен вектор, описващ времеви и морфологични вариации в EEG сигналите, съответстващи на специфична невронна активност. Алгоритъмът за извличане на характеристики трябва да използва както линейни, така и нелинейни техники за анализ на сигнала, за да изгради вектор на характеристиките, състоящ се както от характеристики във времевата, така и в честотната област. Определянето на характеристики е в пряка връзка със следващия етап на обработка, свързан с категоризиране на мозъчната дейност по EEG данните и в този смисъл формирането на характеристичен вектор има голямо влияние върху качеството на класификацията и от там и върху ефективността на управление на устройства чрез мозъчно-компютърни интерфейси. Ефективността на системата за разпознаване на образи зависи както от характеристиките, така и от използвания алгоритъм за класификация. Формираният характеристичен вектор трябва да осигурява минимизиране на отклоненията на характеристиките в рамките на отделните класове мисловни дейности, като същевременно максимизира отклоненията между характеристиките на различните класове. Различните мисловни дейности водят до различни модели на мозъчните сигнали. BCI се разглежда като система за разпознаване на модели, която класифицира всеки модел

в клас според неговите характеристики. Ефективността на системата за разпознаване на образи зависи както от характеристиките, така и от използвания алгоритъм за класификация. Функциите представляват нова форма на изразяване на данните и могат да бъдат двоични, категорични или непрекъснати. Те представляват атрибути или директни измервания на сигнала.

2.3. Класификация

За да се използват системи с мозъчно-компютърен интерфейс, потребителят-човек трябва да създаде различни модели на мозъчна активност, които се регистрират чрез измерване на EEG сигнали, идентифицират се от системата и се преобразуват в команди към компютър или устройство. В повечето съществуващи BCI системи за идентификация и разпознаване на мозъчна активност, която съответства на конкретна команда, се използват различни алгоритми за класификация, които на базата на формираният на предните етапи характеристичен вектор определят категория, която свързва характеристичния вектор с модел на конкретна мисловна дейност. Класификацията включва използването на извлечен набор от характеристики от предварително обработени невронни сигнали и присвояване на определен клас или категория на мозъчните модели (напр. единично мигане на очите, двойно мигане на очите, движение на лявата ръка, движение на дясната ръка) с използване на различия и прилики в характеристиките на мозъчните сигнали. Етапът на класификация в BCI системите преобразува характеристичния вектор в оперативен сигнал за управление на устройство. Типичните класификатори, използвани за класификация, включително LDA, SVM, k-NN и логистична регресия, не отчитат данните от времевите серии, присъстващи в сигналите за EEG, въпреки че факторирането на този аспект на сигналите може да подобри точността на класификацията, тъй като сигналите за EEG са нестационарни. RNN обикновено се използват за използване на сигналите от времеви редове, но тези мрежи могат да страдат от изчезване на градиента или експлозия на градиента по време на обучение, а също така имат присъщо отклонение към нови данни.

2.4. Дълбоки конволюционни невронни мрежи за BCI класификации

EEG сигналите са най-често срещаният източник на данни за неинвазивни приложения на системи с мозъчно-компютърен интерфейс. За да работят надеждно такива приложения, EEG сигналът трябва да бъде декодиран с висока точност и трансформиран в подходящи оперативни управляващи команди.

Дълбокото обучение е широко използван подход за извличане на информация от данни в много различни области. Използването на конволюционни невронни мрежи (Convolutional Neural Networks, CNNs) и дълбоко обучение (Deep Learning, DL) се отличава с много добри възможности за класифициране на информация от необработени данни и намира широко приложение в различни области, например в разпознаване на изображения и обработка на текст на естествен език. За разлика от класическите подходи за машинно обучение, дълбокото обучение е ориентиран към данните подход за класификация. Ето защо усилията на много изследователи на системи с мозъчно-компютърен интерфейс са насочени към анализ на потенциалната полезност на методите за дълбоко обучение с използване на широк спектър от различни невронно-мрежови архитектури приложени към различни набори от EEG данни.

2.5. Изводи

Основните изводи от изследванията, представени във втора глава на дисертационния труд мога да бъдат формулирани както следва:

1. В системите за мозъчно-компютърно взаимодействие регистрираните данни за мозъчната активност се трансформират в контролни сигнали за взаимодействие с компютърна система.
2. От съществено значение е изборът на методи и алгоритми, които да се комбинират и приложат на всеки от етапите на обработване на EEG сигнали за

мозъчната активност: предварителна подготовка и филтриране, откриване на характеристики и формиране на характеристичен вектор, намаляване на размерността на характеристичния вектор чрез селектиране на дискриминативни характеристики и класификация за определяне на мозъчно действие, което да се трансформира в управляващ сигнал за компютър или устройство, управлявано чрез мозъчно-компютърен интерфейс.

3. Основните предизвикателства при избор на метод за класификация са ниско съотношение сигнал/шум на EEG сигналите, присъщата нестационарност за един или множество субекти, при която EEG сигналите силно варират в рамките на измерванията, ограничени количества данни за обучение.
4. Подходящите методи, използвани при предварителната обработка, откриването на характеристики, избора на характеристики и класификацията в BCI системите са много важни за осигуряване на възможност за използване на системи за мозъчно-компютърно взаимодействие в реални приложения.
5. С използване на дълбоки конволюционни невронни мрежи могат да бъдат решавани задачи за класификация на EEG данни, но за получаване на висока точност на моделите и за избягване на преобучение и недообучение на модела се изискват подходящи архитектури на невронните мрежи и подходящи набори с обучаващи данни.

ГЛАВА 3. Обработка и класификация на EEG сигнали за системи с мозъчно-компютърен интерфейс, управлявани с моторни ментални образи

Трета глава на дисертационния труд представя модифицирани методи и алгоритми за обработка на данни за BCI Организирана е в 6 части. В първата част се разглеждат класификация на моторни ментални образи. Втората част представя уейвлетна трансформация за формиране на характеристичен вектор. В третата част са описани генетичен алгоритъм за формиране на характеристичен вектор. Четвърти част представя експериментална оценка на предложените алгоритми за анализ на EEG данни за мозъчно-компютърно взаимодействие чрез моторни ментални образи. Пето част представя част представя класификация на моторни ментални задачи в системи с мозъчно-компютърен интерфейс с използване на мултимодални данни. Шесто част представя класификация на мисловни сигнали с конволюционни невронни мрежи.

3.1. Класификация на моторни ментални образи

За да се използват системи с мозъчно-компютърен интерфейс, управлявани с моторни ментални образи, обикновено се изискват две фази:

- (1) фаза на офлайн обучение, по време на която системата се калибрира;
- (2) оперативна онлайн фаза, в която системата може да разпознава моделите на мозъчна активност и да ги превежда в управляващи команди за компютърно устройство.

Използването на системата в онлайн фазата е затворен цикъл, при който потребителят генерира специфичен модел на EEG сигнали, например чрез мисловни двигателни образи, тези EEG сигнали се измерват и регистрират. След това EEG сигналите се обработват предварително с прилагане на различни пространствени и спектрални филтри, извличат се характеристики, които представят сигналите в компактна форма и на базата на тези характеристики на EEG сигналите се класифицират, след което резултатите от класификацията се трансформират в управляваща команда за конкретно приложение и се предоставена обратна връзка на потребителите с информация дали умствената команда е разпозната.

3.2. Уейвлетна трансформация за формиране на характеристичен вектор

EEG сигналите могат да бъдат обработвани с помощта на традиционни стратегии, но вариациите на EEG сигналите не могат добре да бъдат представени с използване на линейни аналитични функции, поради което техники, базирани на различни честотни

преобразувания често се използват за представяне и анализ на спектралната плътност на мощността и честотните компоненти на EEG сигналите в BCI системи. Потискането на EEG сигналите може да доведе до загуба на информация за определен период. От друга страна вълновата ентропия е важна променлива, която трябва да се вземе предвид при изследването на сигнали за мозъчна дейност, честотните преобразувания са широко използвани в различни приложения за анализ на EEG сигналите, тъй като ефективно представят данните чрез разлагане на всеки сигнал в честотни поддиапазони.

Уейвлетът (wavelet) е вълнообразно трептене с амплитуда, която започва от нула, увеличава се и след това намалява обратно до нула. Обикновено се визуализира като „кратко колебание“, подобно на това, записано от сеизмограф или сърдечен монитор. Уейвлетите имат специфични свойства, които ги правят полезни за обработка на сигнали. Уейвлетите са мащабиращи копия (известни като „дъщерни вълни“) на крайна дължина или бързо разпадаща се трептяща форма на вълната (известна като „майчината вълна“). Уейвлетът е математическа функция, използвана за разделяне на дадена непрекъсната функция или сигнал на различни мащабни компоненти, като всеки компонент съответства на честотен диапазон и на може да бъде разглеждан за резолюция, която съответства на неговия мащаб.

3.3. Генетичен алгоритъм за формиране на характеристичен вектор

В дисертационния труд се предлага използване на генетичен алгоритъм и k-Fold кръстосано валидиране за избор на характеристики за BCI класификация на EEG данни. На първия етап за извличане на характеристики от регистрираните EEG данни се предлага използване на k-Fold кръстосана валидация. Във втория етап се предлага използване на GA за избор на характеристики. На третия етап за класификация на данните са използвани и експериментално са оценени пет алгоритъма за класификация: логистична регресия, класификация с K най-близки съседа, класификация с опорни вектори с линейна регресия и с радиална базисна функция и Гаусова класификация. Изборът на класификационни алгоритми се основава на широкото им използване за класификация за различни приложения, свързани с обработка на сигнали и изображения. Кръстосаното валидиране е подход за оценка на точността на модели, създадени в резултат на машиноно обучение. Оценката се базира на прилагане на модел за ограничена извадка от данните, които не са използвани при обучението на модела.

Кръстосаното валидиране е подход за оценка на точността на модели, създадени в резултат на машиноно обучение. Оценката се базира на прилагане на модел за ограничена извадка от данните, които не са използвани при обучението на модела.

Алгоритъмът за кръстосана валидация е следния:

Псевдокод за k-fold кръстосана валидация

- 1: Случайно разбъркване на набора от данни
 - 2: Разделяне на набора от данни на k групи
 - 3: За всяка уникална група:
 - 4: Използване на групата като набор данни за валидация
 - 5: Използване на останалите групи като набор данни за обучение
 - 6: Определяне на модел с обучаващите данни и оценка на модела в валидационните данни
 - 7: Запазване на оценката
 - 8: Обобщаване на резултатите за точността на модела за всички k групи
-

Наборът данни се разделя на k на брой групи, всяка от които се използва еднократно за валидация на модела и k-1 пъти за обучение на модела. За да се приложи k-fold кръстосана валидация на етапа на извличане на характеристиките от EEG данни, входните EEG сигнали се сегментират на малки припокриващи се области, които на случаен принцип се разделят на обучаващи и валидиращи набори.

Генетичният алгоритъм е популационна метаевристика, основан на метафората за природния феномен на еволюция съгласно теорията на Дарвин и принципа за оцеляване на най-приспособените индивиди („survival of the fittest“). Процедурата на GA започва с набор от множество решения, представени като характеристичен вектор с променливи, чиито стойности са в определен диапазон. В контекста на еволюцията наборът от решения е еквивалентен на популация, всяко решение е аналогично на хромозома, всяка променлива на решението е аналогична на ген и всяка стойност на променливите е аналогична на алел.

3.4. Експериментална оценка на предложените алгоритми за анализ на EEG данни за мозъчно-компютърно взаимодействие чрез моторни ментални образи


За сравнителен анализ на методите за класификация при анализ на EEG данни за моторни ментални задачи в BCI системи е проведено експериментално изследване с използване на 6 класификационни алгоритъма: дърво на решенията (Decision Tree), линейен дискриминантен анализ (LDA), SVM с линейно ядро, Radial-SVM, логистична регресия, невронна мрежа, базирани на многослоен перцептрон.

Експерименталната процедура се състои от обучение и тестване на алгоритмите за класификация на множество данни „BCI competition III“. Наборът от данни е насочен към решаване на проблема за класификация на моторни ментални образи в асинхронен режим, т.е. не се предоставят сигнали заедно с данните, които да показват, че субектът е преминал към различен клас ментална задача. Наборът от данни съдържа периоди, в които субектът няма мисловна дейност, свързана с конкретна задача за контролен сигнал и следователно се очаква алгоритъмът за класификация да прави разлика между ляво и дясно моторно изображение, както и състояние на покой. Данните за EEG сигналите са регистрирани за всеки субект, седнал на удобен стол с подлакътници и се състои от 7 сесии, записани с помощта на 118 канала и 120 опита за ментални двигателни образи. Публично достъпните за анализ EEG данни са получени от оригиналните EEG сигнали след филтриране с честотен филтър в интервала от 0.05 и 200 Hz и скалиране при 100 Hz. Множеството данни съдържа EEG сигнали за следните ментални моторни задачи: 7 начални сесии; 3 моторни изображения (L) лява ръка, (F) десен крак, (Z) език; сесии 4 до 7 са тестови данни без никаква информация за целевия клас или времето на регистрация. Обучаващото множество се състои от 210 етикирани EEG екземпляра, които са разделени равномерно между двата класа. Тестовото множество съдържа 34 594 EEG екземпляра като 18 488 принадлежат към единия клас и 16 106 към другия.


Получените експериментални резултати за точността на класификация на тестовото множество са обобщени в табл. 3.1 и са графично показани на фиг. 3.1 и фиг. 3.2.

Таблица 3.1
Оценка на класификатори на EEG данни.

Класификатор	Тестова грешка [%]	Cohen kappa
LDA	13.02	0.737
Linear SVM	11.65	0.764
RBF-Kernel SVM	11.13	0.775
Neural Network	11.45	0.769
Decision Tree	16.53	0.671
Logistic Regression	12.98	0.739



Фигура 3.1. Тестова грешка при класификация на EEG сигнали




Фигура 3.2. Коефициент Cohen kappa при класификация на EEG сигнали


За експериментално изследване на влиянието на уейвлетната трансформация при формирането на характеристичен вектор за EEG сигнали с цел класификация на ментални моторни образи са използвани 5 класификатора: LDA, Linear SVM, RBF-kernel SVM, логистична регресия, дърво на решенията.

Експерименталната постановка е аналогична на използваната за сравнение на алгоритми за класификация: използва се същото множество данни „BCI competition III“ за оценка на влиянието на DWT върху точността на класификация на EEG сигналите за ментални моторни образи. За имплементацията на DWT за филтриране на сигналите на етапа на селектиране на характеристики се използва платформата Matlab 2020a с уейвлет Symlets 4 с медианен праг, който има свойствата симетрия, ортогоналност и биортогоналност. Нивото на декомпозиция се определя като $\log_2 N$, където N е броя на данните в съответното множество. В случая за използваното EEG множество „BCI competition III“ нивото на уейвлетна декомпозиция е 4. За избор на прагова стойност се използва емпиричен Байесов метод, който се основава на предположението, че разпределенията на EEG сигналите са независими.

Пример за необработен EEG сигнал от набора от данни е показан на Фиг. 3.3. и Фиг. 3.4. показва същия сигнал след премахване на шумове.



Фигура 3.3. Суров EEG сигнал.



Фигура 3.4. EEG сигнал след Wavelet.

Получените експериментални резултати за точността на от обработката на EEG данните с помощта на описания конвейер с всеки от петте класификатори без и с използване на уейвлетна трансформация са обобщени съответно в табл. 3.2 и табл. 3.3 и са представени графично на фиг. 3.5. – 3.8.

Таблица 3.2


Резултати при класификация на EEG сигнали без уейвлетна филтрация.

Класификатор	Тестова грешка [%]	Cohen kappa
LDA	13.02	0.737
Linear SVM	11.65	0.764
RBF-Kernel SVM	11.13	0.775
Decision Tree	16.53	0.671
Logistic Regression	12.66	0.745


Таблица 3.3

Резултати при класификация на EEG сигнали с уейвлетна филтрация.


Класификатор	Тестова грешка [%]	Cohen kappa
LDA	12.18	0.754
Linear SVM	11.52	0.766
RBF-Kernel SVM	10.86	0.781
Decision Tree	15.65	0.687
Logistic Regression	12.55	0.748




Фигура 3.5. Тестова грешка без уейвлетна филтрация



Фигура 3.6. Тестова грешка с уейвлетна филтрация



Фигура 3.7. Коефициент Cohen Карра без уейвлетна филтрация



Фигура 3.8. Коефициент Cohen Карра с уейвлетна филтрация

За експерименталната оценка на ефективността на предложения подход за класификация на EEG данни с използване на двукратна кръстосана валидация на етапа на селектиране на характеристики и генетичен алгоритъм на етапа на избор на характеристики с пет различни алгоритми за класификация, се използва множество EEG данни за класификация на мисловни моторни изображения BCI I. Наборът данни включва записи на ECoG сигнали за въображаеми движения на ляв малък пръст или на език, регистрирани с 8x8 ECoG платинена електродна мрежа с честота на измерванията 1000 Hz за 3 секунди. Етикетираният набор от данни за обучение се състои от две части: (i) мозъчна активност по време на 278 измервания, съхранени в 3D матрица със следния формат: [опити × електродни канали × проби от времеви редове], и (ii) етикети за 278 измервания, съхранени като вектор със стойности $\{-1, 1\}$. За да се приложи GA на етапа на избор на характеристика при класификацията на EEG данни се използват следните параметри за GA: размер на популацията 300, брой поколения 1000, вероятност за мутация 0,5.

За експерименталната оценка на класификация на данните се използва имплементация на стъпките от основния графичен конвейер на Python, версия 3.8.3 с Jupyter Notebook за операционна система Linux Fedora 33, 64 bit, на машина с Intel 12× Core I7-8750H, 2.20 GHz, 16 GB RAM. Поради големия размер на набора от данни експерименталната оценка е на базата на 25% от данните. Използвани са няколко библиотеки на Python: pandas, numpy, matplotlib.pyplot, scipy.io, random, matplotlib.pyplot, предупреждения, sklearn.metrics, sklearn.model_selection и sklearn.linear_model. Резултатите за точността на класификацията на EEG данни с всеки от петте избрани класификационни алгоритъма с и без използване на GA и двукратно кръстосано валидиране са дадени в табл. 3.4. и на фиг. 3.9. Времето за изпълнение на класификацията е също е представено в табл. 3.4. В табл. 3.5. за показани резултатите от експерименталната оценка на тестовия набор с SVC класификатор с линейна регресия.

Таблица 3.4


Резултати от класификацията с и без генетичен алгоритъм.

Класификатор	Точност на обучението		Време за изпълнение [ms]	
	без генетичен алгоритъм	с генетичен алгоритъм	без генетичен алгоритъм	с генетичен алгоритъм
Logistic Regression	0.86	0.94	51.4	66.1
K-neighbours	0.76	0.78	771	779
SVC Linear Regression	0.91	0.99	2.48	2.65
SVC RBF Regression	0.78	0.82	1.06	1.09
Gaussian Classification	0.50	0.59	14.1	16.4

Таблица 3.5

Оценка на точност при SVC класификатор с линейна регресия.

	Precision	Recall	F1-score	Support
Label (-1)	0.69	0.61	0.65	134
Label (+1)	0.49	0.57	0.53	87
Accuracy			0.60	221
Macro avg	0.59	0.59	0.59	221
Weighted avg	0.61	0.60	0.60	221



Фигура 3.9. Точност на класификацията с и без използване на генетичен алгоритъм

3.5. Класификация на моторни ментални задачи в системи с мозъчно-компютърен интерфейс с използване на мултимодални данни

За подобряване на работата на системи с мозъчно-компютърен интерфейс, управлявани с моторни ментални образи, могат да бъдат използвани мултимодални (хибридни) данни, получени от различни източници, измерващи мозъчната активност на потребителя, които имат за цел да избегнат недостатъците на всеки от сигналите и да повишават надеждността на системата.

За експериментална оценка на класификацията на мултимодалните данни е използвана имплементация на Python, версия 3.8.3 с Jupyter Notebook за операционна система Linux Fedora 33, 64 bit, на машина с Intel 12× Core I7-8750H, 2.20 GHz, 16 GB RAM. Използвани са Python pip библиотеките mne, pandas, numpy, matplotlib.pyplot, scipy.io, random, matplotlib.pyplot, warnings, sklearn.metrics, sklearn.pipeline, sklearn.discriminant_analysis, mne.channels, mne.io, mne.decoding, sklearn.model_selection и sklearn.linear_model. Експерименталната оценка на класификацията се базира на използване на пет класификатора: ции логистична регресия, класация с k най-близки съседи, Logistic Regression, K Neighbor regression, SVC с RBF регресия rbf regression и Гаусова класификация Gaussian.

Експерименталните резултати за точността при обучение и време за изпълнение за всеки от класификаторите с мултимодалния набор от данни за EEG и NIRS сигнали са показани в табл. 3.6.. Най-добри резултати за точността при класификация се постигат с SVC класификатор с RBF регресия – 0.95, докато при логистична регресия точността е 0.72, а при класификатор с k-най-близки съседи е 0.73. Резултатите за оценка на тестовата точност при класификация с SVC класификатор с RBF регресия са представени в табл. 3.7. От друга страна сравнението на времето за изпълнение за всеки от класификаторите показва, че най-бързи са изчисленията при логистична регресия, следвана от SVC класификатор с RBF регресия. Сравнение на точността на класификация за набор само с EEG сигнали и за мултимодалния набор с EEG и NIRS сигнали (фиг. 3.10) показва, че точността при класификация с логистична регресия и с SVC класификатор с линейна регресия за EEG набора данни превъзхожда точност при използване на хибриден набор от данни съответно с 16 % и 12%, което е свързано с изискването за по-добър избор на характеристики за EEG сигналите в хибридният набор данни с EEG и NIRS сигнали. Както се вижда от фиг. 3.11. точността на класификация с мултимодалния набор данни се подобрява при използване на генетичен алгоритъм за избор на характеристики за EEG сигналите за всички класификатори, като най-съществено влияние на предварителната обработка на данните с 8% се постига при SVC класификатор с линейна регресия.

Таблица 3.6


Оценка на точността при обучение EEG + NIRS набор от данни.

Класификатор	Точност	Време за изпълнение [ms]
Logistic Regression	0.72	2.73
K Nearest Neighbours	0.73	73.2
SVC Linear Regression	0.80	9.85
SVC RBF Regression	0.95	4.48
Gaussian Classification	0.83	2.33


Таблица 3.7

Оценка на тестова точност за класификация на EEG + NIRS набор от данни

	precision	recall	f1-score	support
left hand motor imagery	0.86	0.67	0.75	9
right hand motor imagery	0.40	0.67	0.50	3
accuracy			0.67	12
macro avg	0.63	0.67	0.62	12
weighted avg	0.74	0.67	0.69	12



Фигура 3.10. Точност за EEG и EEG + NIRS набори от данни



Фигура 3.11. Точност за EEG и EEG + NIRS данни с използване на GA

3.6. Класификация на мисловни сигнали с конволюционни невронни мрежи

В дисертационния труд е предложено използването на дълбоки конволюционни невронни мрежи за анализ на P300 сигнали за мисловно изписване на символи и за анализ на EEG сигнали за разпознаване на емоционално състояние.

На базата на проведени експериментални изследвания за проектиране на архитектура на CNN за анализ на P300 сигнали се предлага използването на дълбоко обучение чрез пет слойна конволюционна невронна мрежа, която съдържа следните типове слоеве (фиг. 3.12):

- Conv1D – едномерен конволюционен слой, които преобразува входните данни чрез ограничаване на областта на свързаност със следващия слой;
- Flatten – слой за преобразуване на входните данни чрез осредняване на стойностите им;
- Dense – пълно свързан слой.

Предложеният CNN модел съдържа общо 37 401 параметъра, които се настройват в процес на обучение на модела за входни P300 сигнали (табл. 3.8).



Фигура 3.12.
Архитектура на
CNN за анализ на
P300 сигнали.


Таблица 3.8
Параметри на слоевете на CNN за анализ на P300
сигнали

Слой (тип)	Изходен вектор	Параметри
Conv1D	Нито един, 78, 10	650
Conv1D	Нито един, 6, 50	6550
Flatten	Нито един, 300	0
Dense	Нито един, 100	30100
Dense	Нито един, 1	101


Експерименталните анализи за изследване на използването на предложената конволюционна невронна мрежа за класификация на P300 сигнали се базират на набора данни, съдържащ EEG данни, регистрирани в 64 канала в обхвата 0.1 – 60 Hz, получени при визуално предизвикани мисловни образи за 36 символа, формиращи 85 обучаващи и 100 тестови набора. За обработването на данните е използвана имплементация на CNN с предложената архитектура на Python, версия 3.8 с Jupyter Notebook за операционна система Linux Fedora 33, 64 bit, на машина с Intel 12× Core I7-8750H, 2.20 GHz, 16 GB RAM. Използвани са Python библиотеките mne, matplotlib.pyplot, seaborn, pandas, numpy, random, scipy.io, keras.layers, keras.models, keras, keras.callbacks, sklearn.metrics, sklearn.preprocessing. Резултатите за показателите за оценка на точността на модела за тестовия набор са представени в табл. 3.9. и на фиг. 3.13. и фиг. 3.14., а на фиг. 3.15 е показана матрицата на грешките (confusion matrix). Получените резултати показват задоволително високи стойности за точността при класификация и за валидационната грешка, особено за позитивните примери, при които коректно се разпознава всеки от символите на базата на предизвикани мисловни образи. Ниската точност за грешно разпознатите тестови символи и стойностите за валидационната грешка свидетелстват за недостатъчно обучение на модела поради малкия набор обучаващи данни в използвания набор EEG сигнали.

Таблица 3.9
Оценка на тестова точност за класификация на P300 сигнали с конволюционна НМ.


Точност	0.8339
Загуба	0.505
Пълнота	0.4547
Специфичност	0.9098
PPV	0.8345
NPV	0.6252



Фигура 3.13. Резултати за грешка при обучение на CNN за класификация на P300 сигнали.



Фигура 3.14. Резултати за точност на класификация за обучаващи и тестови данни.



Фигура 3.15. Матрица на грешките при класификация на P300 сигнали с конволюционна НМ .

На базата на проведени експериментални изследвания за проектиране на архитектура на CNN за разпознаване на емоции чрез EEG сигнали се предлага използване на дълбоко обучение чрез дълбока конволюционна невронна мрежа с 16 слоя. В допълнение на слоевете, използвани за анализ на P300 сигнали, CNN архитектурата съдържа следните типове слоеве (фиг. 41):

- слой BatchNormalization – нормализира входните данни от предходния слой с цел предотвратяване на преобучение на модела;
- слой MaxPooling1D – слой за обединяване по максимална стойност на входните данни от предходния слой;
- слой Dropout – добавя се след пълно свързани слоеве в архитектурата и се използва за предотвратяване на преобучението на модела чрез случайно премахване на връзки между елементите.

Предложеният CNN модел съдържа общо 111 066 параметъра, от които 110 554 се настройват в процес на обучение на модела с входни EEG данни, а 512 параметъра не подлежат на обучение (табл. 16).

Фигура 3.16.





Таблица 3.10

Параметри на слоевете на CNN за анализ на P300 сигнали


Слой (тип)	Изходен вектор	Параметри
Conv1D	Нито един, 70, 128	512
BatchNormalization	Нито един, 70, 128	512
MaxPooling1D	Нито един, 35, 128	0
Conv1D	Нито един, 35, 128	49280
BatchNormalization	Нито един, 35, 128	512
MaxPooling1D	Нито един, 17, 128	0
Conv1D	Нито един, 17, 64	24640
MaxPooling1D	Нито един, 8, 64	0
Flatten	Нито един, 512	0
Dense	Нито един, 64	32832
Dropout	Нито един, 64	0
Dense	Нито един, 32	2080
Dropout	Нито един, 32	0
Dense	Нито един, 16	528
Dropout	Нито един, 16	0
Dense	Нито един, 10	170

Невронната мрежа се обучава с обучаващите данни 100 епохи, а полученият след обучението модел е оценен на базата от тестови набор данни. Резултатите за обучаващата грешка и точност на модела за обучаващия и тестовия набор данни са показани на фиг. 3.17. и фиг. 3.18.

Получените резултати показват много висока точност при класификация на емоцията при възприемане на музикалните видеоклипове на базата на мултимодалния набор данни като валидационната грешка и валидационната точност имат стойности близки до грешката и точността за обучаващите данни. За сравнение на резултатите от използването на CNN за разпознаване на емоции с мултимодалния набор данни са използвани и класически класификатори за машинно обучение: класификатор с k най-близки съседа (KNN) и класификатор с опорни вектори (SVM) в комбинация с предварителна обработка на набора данни за избор на характеристики с принцитни компоненти (PCA).



Фигура 3.17. Резултати за грешката при класификация на емоции с конволюционна НМ.



Фигура 3.18. Резултати за точност на класификация на емоции със CNN.

Експерименталните анализи за изследване на използването на CNN за класификация на емоционално състояние се базира на използването на мултимодален набор данни DEAP, който съдържа данни за 32 участника: (1) физиологични данни (температура, кръвно налягане, дишане, ЕКГ, ЕОГ, ЕМГ), изображения на лице и EEG сигнали в 32 канала при възприемане на музикални видеоклипове; (2) данни за субективна емоционална оценка при възприемането на музикалните видеоклипове.


За обработването на данните е използвана имплементация на CNN с предложената архитектура на Python, версия 3.8 с Jupyter Notebook за операционна система Linux Fedora 33, 64 bit, на машина с Intel 12× Core I7-8750H, 2.20 GHz, 16 GB RAM. Използвани са Python библиотеките numpy, pyeeg, pickle, pandas, math, sklearn, sklearn.preprocessing, keras, keras.models, keras.layers, keras.layers.convolutional, keras.optimizers.

Получените резултати показват много висока точност при класификация на емоцията при възприемане на музикалните видеоклипове на базата на мултимодалния набор данни като валидационната грешка и валидационната точност имат стойности близки до грешката и точността за обучаващите данни. За сравнение на резултатите от използването на CNN за разпознаване на емоции с мултимодалния набор данни са използвани и класически класификатори за машинно обучение: класификатор с k най-близки съседа (KNN) и класификатор с опорни вектори (SVM) в комбинация с предварителна обработка на набора данни за избор на характеристики с принципни компоненти (PCA). Получените резултати за точността на класификация за 4 категории емоции съгласно субективната оценка на участниците при регистриране на данните от набора DEAP (valence, arousal, dominance, liking) са показани в табл. 3.11., матрицата на грешките е представена на фиг. 3.19., а на фиг. 3.20. са показани резултати за точността при обучение на моделите за всяка от емоционалните категории с класификатор KNN. Резултатите показват значително по-ниска точност на класификацията с класически алгоритми за машинно обучение в сравнение с дълбока конволюционна невронна мрежа с предложената архитектура.


Таблица 3.11

Точност при класификация на емоции с класификатори KNN и SVM


Accuracy	KNN	SVM	KNN-PCA	SVM-PCA
Valence	56.64	63.44	53.52	64.067
Arousal	56.25	63.91	58.60	64.30
Dominance	67.58	67.50	68.75	69.50
Liking	65.23	67.34	69.53	64.07




Фигура 3.19. Матрица на грешките при разпознаване на емоции с CNN.




максимална тестова точност за valence: 0.62



максимална тестова точност за arousal: 0.62



максимална тестова точност за dominance: 0.66



максимална тестова точност за liking: 0.70

Фигура 3.20. Обучаваща точност при разпознаване на емоции с класификатор KNN

3.7. Изводи към трета глава

Основните изводи от изследванията, представени в трета глава на дисертационния труд мога да бъдат формулирани както следва:

1. Успешното използване на EEG сигнали в системи с мозъчно-компютърен интерфейс, управлявани с моторни ментални образи изисква премахване на излишни артефакти и филтриране на сигналите при формиране на характеричен вектор, който да позволи висока точност на класификация и последващо коректно генериране на управляващи сигнали към компютър или устройство, управлявано чрез моторни ментални образи.
2. Експерименталните резултати от сравнителния анализ на използването на шест класификатора за решаване на задачата за класификация на моторни ментални образи по EEG данни показват, че нелинейните и по-сложни модели водят до

- получаване на по-добра тестова грешка, поради малкия размер на използвания характеристичен вектор и небалансирани обучителни и тестови множества.
3. За подобряване на точността на класификация на EEG сигнали за ментални моторни образи може да се използва по-добър метод за извличане и селектиране на характеристики.
 4. На етапа на избор на характеристики при обработването на EEG данните и формиране на характеристичен вектор, който да се използва при класификацията, успешно може да се приложи филтриране с уейвлетна трансформация. Експерименталните резултати от проведените изследвания показват подобряване на точността на класификация когато се прилага уейвлетна филтрация, при това увеличаването на точността се наблюдава за всички използвани класификатори.
 5. Използването на генетичен алгоритъм и двукратно кръстосано валидиране при селектиране на характеристики в EEG сигнали за BCI базирана класификация на мислени моторни образи подобрява точността на класификацията при всички изследвани алгоритми за класификация като допълнителните изчислителни разходи са незначителни.
 6. Използването на мултимодални набори данни за регистриране на мозъчна активност с хибридни EEG и NIRS сигнали води до подобряване на класификацията на мисловни моторни образи. Допълнителната предварителна обработка на EEG сигналите чрез избор на подходящи характеристики с използване на двукратно кръстосано валидиране и генетичен алгоритъм подобрява ефективността на класификация при всички изследвани класификатори.
 7. С използване на дълбоки конволюционни невронни мрежи могат да бъдат решавани задачи за класификация на EEG данни, но за получаване на висока точност на моделите и за избягване на преобучение и недообучение на модела се изискват подходящи набори с обучаващи данни. Разпознаването на емоции чрез дълбока конволюционна невронна мрежа, обучавана с мултимодални данни, съдържащи физиологични сигнали, EEG сигнали и визуални изображения води до получаване на по-висока точност на класификация в сравнение с класическите алгоритми за машинно обучение

ГЛАВА 4. Експериментална оценка с публични набори данни

Четвърта глава на дисертационния труд представя експериментална оценка с публични набори данни. Организирана е в 2 части. В първата част се представя процедура за създаване на набори EEG данни за мисловни двигателни образи. Втората част съдържа имплементиране на приложения, управлявани с мисловни образи за моторни действия.

4.1. Процедура за създаване на набори EEG данни за мисловни двигателни образи

В дисертационния труд е проектирана и изпълнена процедура за създаване на собствен набор EEG данни за мисловни двигателни образи, базирана на общите насоки за проектиране на експерименти за регистриране на EEG сигнали.

Използваното устройство за регистриране на EEG сигнали е EMOTIV EPOC+. Софтуерът за запис е Python скрипт с библиотеки websocket, datetime, json, ssl, time, sys и cortex. Софтуерът за запис е персонализиран скрипт на Python, използващ Python библиотеки за събиране, запис, трансфер и съхранение на данни: websocket, datetime, json, ssl, time, sys и cortex. Софтуерът използва Emotiv EPOC+ данни за даден потребител, име на запис, описание на запис, дължина на записа и регистрирани EEG сигнали. За извършване на измерванията е използван лаптоп с 4x Intel Pentium CPU N4200 @ 1.10GHz, 4 GiB RAM,

операционна система Windows 10 Pro. Всички експерименти са проведени в лаборатория в Технически университет–София през октомври 2021 г. във времевите интервали: T1 (9:30–12:00), T2 (12:30–15:00), T3 (15:30–18:00). Нивото на фоновия шум е 37–39 децибела. Експерименталната лаборатория е с чист въздух, удобен стол и бюро.

Съгласно общите изисквания и насоки за проектиране на EEG експерименти всички участници трябва да бъдат защитени от психически, психологически, физически, социални и правни рискове по време на експеримента. Всеки участник има право да не участва и да се оттегли от участие в експеримента. На участниците се предоставя пълна информация за изследователските експерименти, които ще бъдат проведени, като поверителността на техните данни и идентичност са защитени. Всеки участник попълва въпросник преди извършване на експерименталните измервания, който съдържа въпроси за ежедневен прием на лекарства, текущи здравословни проблеми, преживяни травми на главата или мозъчно разстройство, преживяни сърдечни заболявания, кожна алергия, навици за пушене, обичайна продължителност на нощен сън, обичайно времетраене на работа с компютър, обичайно посещение на кино, посещение на 3D филми, навици за игра на компютърни и видео игри, Nintendo DS, Nintendo 3DS, Sony Playstation и Sony Playstation 3D игри.

Всички данни се записват съгласно синхронна BCI парадигма за предизвикана мозъчна дейност. Използва се визуално въздействие, което провокира участника да възпроизведе даден мисловен образ, съответстващ на определена ментална задача за двигателно движение. Инструкциите за двигателните движения се представят на участниците като видео файл с обща продължителност 3 минути и 30 секунди и съдържание, представено в табл. 4.1. Видео инструкциите съдържат поредица от периоди на почивка и инструкции за ментална задача за движение на обект (баскетболна топка). Мисловните задачи са свързани с движение надясно, наляво, нагоре, надолу, бутане и дърпане на обекта. Въпреки, че участника се инструктира да не се движи и да се отпусне е възможно възникване на случайни недвигателни ментални образи за задачи, които не са свързани с видео инструкциите, както и други двигателни образи, като движения на очи, крака, ръце, устни, глава. За всеки участник данните за състояния, които не са свързани с мисловните двигателни задачи не се регистрират.

Таблица 4.1

Съдържание на видео файл с инструкциите за двигателни движения

Номер	Задача	Продължителност
1	Период на почивка	30 сек.
2	Период на почивка	10 сек.
3	Left движение за умствена задача left	16 сек.
4	Период на почивка	10 сек.
5	Right движение за умствена задача right	16 сек.
6	Период на почивка	10 сек.
7	Up движение за умствена задача up	16 сек.
8	Период на почивка	10 сек.
9	Down движение за умствена задача down	16 сек.
10	Период на почивка	10 сек.
11	Push движение за умствена задача push	16 сек.
12	Период на почивка	10 сек.
13	Pull движение за умствена задача pull	16 сек.
14	Период на почивка	10 сек.
15	Период на почивка	~30 сек.

Всеки запис на EEG сигнали се съхранява като csv файл, съдържащ време на записа и EEG данни в следните канали: AF3 (Theta, Alpha, BetaL, BetaH, Gamma), F7 (Theta, Alpha, BetaL, BetaH, Gamma), F3 (Theta, Alpha, BetaL, BetaH, Gamma), FC5 (Theta, Alpha, BetaL, BetaH, Gamma), T7 (Theta, Alpha, BetaL, BetaH, Gamma), P7 (Theta, Alpha, BetaL, BetaH, Gamma), O1 (Theta, Alpha, BetaL, BetaH, Gamma), O2 (Theta, Alpha, BetaL, BetaH, Gamma), P8 (Theta, Alpha, BetaL, BetaH, Gamma), T8 (Theta, Alpha, BetaL, BetaH, Gamma), FC6 (Theta, Alpha, BetaL, BetaH, Gamma), F4 (Theta, Alpha, BetaL, BetaH, Gamma), F8 (Theta, Alpha, BetaL, BetaH, Gamma), AF4 (Theta, Alpha, BetaL, BetaH, Gamma).

Размерът на всеки файл е около 2 MB и съдържа около 70 реда и 2 000 колони. Всеки набор от данни се именува с идентификатор на участника.

Съгласно представената експериментална процедура са регистрирани EEG данни за шест участника, трима мъже и три жени, на възраст между 22 и 39 години.

Наборът от данни е използван за класификация на мисловни двигателни образи с пет класификатора с използване на уейвлетна трансформация на етапа на филтриране на сигналите и генетичен алгоритъм с двукратно кръстосано валидиране за избор на характеристики. Получените експериментални резултати за точността на класификация на създадения набор от данни са показани в табл. 4.2.

Представените резултати показват задоволителна обща точност (над 50%) за всички класификатори, както и подобряване на точността при използване на уейвлетна трансформация и генетичен алгоритъм. Най-добра точност на класификация се постига с класификатор k-най-близки съседи с избор на признаци с генетичен алгоритъм. За повишаване на точността на класификация създадения набор от EEG данни трябва да се разшири с повече обучаващи данни чрез регистриране на няколко записа за всеки участник.

Таблица 4.2

Точност при класификация на мисловни двигателни образи			
Класификатор	Точност	Точност с използване на уейвлетна трансформация	Точност с използване на генетичен алгоритъм
Logistic Regression	0.585	0.552	0.602
K-nearest neighbors	0.685	0.696	0.700
SVC Linear Regression	0.594	0.552	0.605
SVC RBF Regression	0.620	0.610	0.538
Gaussian Classification	0.514	0.516	0.539

4.2. Имплементиране на приложения, управлявани с мисловни образи за моторни действия


В рамките на научните изследвания в дисертационния труд са разработени две примерни ВСІ приложения: за управление на курсор на мишка върху екран и за управление на виртуален обект в компютърни игри чрез мисловни образи за моторни действия.

Приложението за управление на курсор на мишка върху екран е имплементирано на език Python, версия 3.9, в среда за разработка Microsoft Visual Studio Code под операционна система Windows 10 Pro. Използвани са няколко Python библиотеки: time, cortex2, json, mouse. Хардуерното устройство за регистриране на EEG данни е Emotiv EPOC+, а експерименталните изследвания са направени на устройство с процесор 4x Intel Pentium N4200 @ 1.10GHz и оперативна памет 4 GB.

Регистрираните EEG данни за менталните моторни движения на курсора на мишката се обработват със следния алгоритъм:

Псевдокод на алгоритъм за управление на курсор на мишка с мисловни образи за моторни действия

```
while True:
    thought = client.receive_data()['com'][0]
    print("Mental Command : ",thought)
    x, y = mouse.get_position()
    if thought == "left":
        mouse.move(x-5, y)
    elif thought == "right":
        mouse.move(x+5, y)
    elif thought == "lift":
        mouse.move(x, y-5)
    elif thought == "drop":
        mouse.move(x, y+5)
    elif thought == "push":
        mouse.click('left')
```



```
Mental Command : neutral
Mental Command : neutral
Mental Command : neutral
Mental Command : neutral
Mental Command : neutral
Mental Command : neutral
Mental Command : neutral
Mental Command : left
Mental Command : left
Mental Command : left
Mental Command : left
Mental Command : left
Mental Command : left
Mental Command : left
Mental Command : left
Mental Command : left
Mental Command : left
Mental Command : left
Mental Command : left
```

Фигура 4.1. Приложение за управление на курсора на компютърна мишка.


Резултатите за регистрираните и трансформирани в управляващи сигнали мисловни образи са показани на фиг. 4.1. Експерименталните изследвания за работата на разработеното приложение показват коректно преобразуване на EEG данните в управляващи сигнали, като курсора на мишката е видим върху екрана и се движи гладко.

Приложението за управление на виртуален обект в компютърни игри чрез мисловни образи за моторни действия използва EEG данни, регистрирани с устройство Emotiv EPOC+.


Управлението на движението на обекта върху екрана се базира на разпознаване на ментални мисловни моторни образи за изразения на лицето на базата на регистрираните EEG сигнали, включително мигане с две очи, намигване с ляво око и с дясно око, повдигнати вежди (изненада), намръщени (набраздени) вежди, усмивка и стиснати зъби. При регистрирането на EEG данните се използва тренировъчен период с продължителност 8 секунди. Разпознатото изражение на лицето се преобразува в управляващ сигнал за движение върху екрана на виртуален обект.

Приложението е разработено с Python, версия 3.9, в среда за разработка Microsoft Visual Studio Code под операционна система Windows 10 Pro. За разработване на приложението вместо Cortex 2 API за устройството Emotiv EPOC+ се използва Python библиотеката cortex2, която позволява лесен достъп до регистрираните от устройството EEG данни, разпознаването им и трансформирателното им в управляващи сигнали. Допълнително са използвани и Python библиотеките websocket, datetime, json, ssl, time и sys.

Разработени са две компютърни игри, при които виртуален обект се управлява с EEG сигнали: игра за управление на обект „самолет“ (фиг. 4.2) и игра за управление на обект „змия“ (фиг. 4.3). За управление на обект „самолет“ се използват EEG сигнали за мисловни моторни образи за изразения на лицето, а за управление на обект „змия“ се използват моторни ментални команди, подобни на тези при управление на движението на курсор на мишка върху екран.



Фигура 4.2. Компютърна игра за управление на обект „самолет“ с мисловни моторни образи.



Фигура 4.3. Компютърна игра за управление на обект „змия“ с мисловни моторни образи.

4.3. Изводи

Основните изводи от изследванията, представени в четвърта глава на дисертационния труд мога да бъдат формулирани както следва:

1. Създаването на набори от EEG данни за мисловни двигателни образи изисква проектиране и внимателно изпълнение на процедура за провеждане на експериментални измервания.
2. Създаденият собствен набор EEG данни следвайки използваната процедура показва задоволителни резултати при класификация на мисловни двигателни образи с използване на машинно обучение.
3. Точността на класификация се повишава при използване на предварителна обработка на сигналите с уейвлетна трансформация и избор на характеристики с генетичен алгоритъм и двукратно кръстосано валидиране.
4. Разработените примерни BCI приложения за управление на движение на курсор на мишка и за управление на виртуални обекти в компютърни игри чрез мисловни образи за моторни действия показват приложимостта на мозъчно-компютърните интерфейси. Експерименталното използване на приложенията показва необходимостта от модификации на използваните алгоритми в конвейера за обработване на данните с включване на допълнителни операции за филтриране на шумове в регистрираните данни и подобряване на разпознаването на мисловните образи.

НАУЧНО-ПРИЛОЖНИ И ПРИЛОЖНИ ПРИНОСИ

Научно-приложни приноси:

- Предложен е подход за използване на уейвлетна трансформация на етапа на формиране на характеристичен вектор при обработването на EEG данните и експериментално е оценено влиянието му върху резултатите от класификация на тестово множество EEG сигнали за ментални моторни образи.
- Предложен е подход за използване на генетичен алгоритъм и двукратно кръстосано валидиране при селектиране на характеристики в EEG сигнали за BCI базирана класификация на мислени моторни образи и експериментално е оценено влиянието му върху точността на класификация.
- Предложени са архитектури на дълбоки конволюционни невронни мрежи за класификация на P300 сигнали и за разпознаване на емоции с мултимодални набори данни.

Приложни приноси:

- На базата на експериментални изследвания е оценена точността на класификация при използване на шест класификатора за решаване на задачата за класификация на моторни ментални задачи по EEG данни.
- На базата на експериментални изследвания е оценено влиянието на предложения подход за използване на уейвлетна трансформация на етапа на формиране на характеристичен вектор върху резултатите от класификация на EEG сигнали за ментални моторни образи.
- Експериментално е оценено влиянието на предложения подход за използване на генетичен алгоритъм и двукратно кръстосано валидиране при селектиране на характеристики при класификация на мултимодални данни с EEG и NIRS сигнали.
- Експериментално е оценена точността на класификация на P300 сигнали и на мултимодални набори данни, използвани за разпознаване на емоции с предложените архитектури на дълбоки конволюционни невронни мрежи в сравнение с използване на класически класификатори.
- Разработена е процедура за провеждане на експериментални измервания за създаване на собствени набори данни EEG данни за мисловни двигателни образи и следвайки предложената процедура е създаден собствен набор EEG данни, който показва повишаване на точността на класификация при използване на предварителна обработка на сигналите с уейвлетна трансформация и избор на характеристики с генетичен алгоритъм и двукратно кръстосано валидиране.
- Създадени са две приложения за управление на движение на курсор на мишка и за управление на виртуални обекти в компютърни игри чрез мисловни образи за моторни действия с използване на EEG сигнали.

СПИСЪК НА ПУБЛИКАЦИИТЕ ПО ДИСЕРТАЦИОННИЯ ТРУД

1. **I. Ivaylov**, *Overview of Brain-Computer Interfaces*, Journal Computer and Communication Engineering, Vol. 14, No. 1, 2020, pp. 9-19, ISSN 1314-2291.
2. **I. Ivaylov**, A. Manolova, M. Lazarova, *EEG Based BCI Applications*, Journal Computer and Communication Engineering, Vol. 15, No. 1, 2021, pp. 9-17, ISSN 1314-2291.
3. **I. Ivaylov**, A. Manolova, M. Lazarova, *Classification of EEG Data for Motor Imagery Mental Tasks*, 9th International Scientific Conference Computer Science'2020, Velingrad, Bulgaria, Oct. 18-21, 2020, pp. 36-44, ISBN: 978-619-167-433-6.
4. **I. Ivaylov**, M. Lazarova, A. Manolova, *EEG Classification for Motor Imagery Mental Tasks Using Wavelet Signal Denoising*, 28th National Conference with International Participation "TELECOM 2020", Oct. 29-30, 2020, Sofia, Bulgaria, doi: 10.1109/TELECOM50385.2020.9299532 (индексирана в Scopus).
- цитирана в: M. N. Alam, M. I. Ibrahimy and S. M. A. Motakabber, Feature Extraction of EEG Signal by Power Spectral Density for Motor Imagery Based BCI, 8th International Conference on Computer and Communication Engineering (ICCCE), 2021, pp. 234-237, doi: 10.1109/ICCCE50029.2021.9467141.
5. **I. Ivaylov**, *EEG Classification for BCI Using Genetic Algorithm and K-Fold Cross Validation*, Journal Electrotechnica & Electronica (E+E), Vol. 56, Issue 3–4, 2021, pp. 38-45, ISSN: 0861-4717 (Print), 2603-5421 (Online), <https://epluse.ceec.bg/eeg-classification-for-bci-using-genetic-algorithm-and-k-fold-cross-validation>.
6. **I. Ivaylov**, M. Lazarova, A. Manolova, *Multimodal Motor Imagery BCI Based on EEG and NIRS*, 56th IEEE International Scientific Conference on Information, Communication and Energy Systems and Technologies (ICEST'2021), Sozopol, Bulgaria, June 16-18, 2021, pp. 73-76, doi: 10.1109/ICEST52640.2021.9483551 (индексирана в Scopus).
7. **I. Ivaylov**, M. Lazarova, A. Manolova, *Convolutional Neural Network-Based BCI for Analysis of Human Affective States from EEG Data*, International Journal of Computing (подадена за рецензиране).
8. **I. Ivaylov**, A. Manolova, M. Lazarova, *Design of EEG Experiments for Motor Imagery Task Classification*, Proceedings of the Technical University of Sofia, Vol. 72, No. 1, 2022, ISSN: 2738-8530 (print), ISSN: 2738-8549 (online).

SUMMARY
INVESTIGATION OF METHODS AND ALGORITHMS FOR BRAIN-COMPUTER
INTERFACE

Ivaylo Emilov Ivaylov

Brain-computer interface (BCI) is aimed to decode the mental intent of a user only by measuring the activity of neural signals, without using the natural neuromuscular pathways of the human body. Brain-computer interfaces have become increasingly popular in recent years and are used in a variety of applications.

The objective of the dissertation is to investigate the methods and algorithms for processing of brain activity signals and building brain-computer interfaces for effective and efficient human-computer interactions.

A review of the state-of-the-art of the approaches for registration of electrical activity of the brain and the existing applications of BCI systems is made. The methods and algorithms for processing of brain activity signals are considered for each of the stages related to preliminary preparation and filtering, feature detection and feature selection, reduction of the dimensionality of the feature vector, classification of the brain activity and transformation into a control signal for a computer or a device controlled by a brain-computer interface. An approach for using wavelet transform at the stage of feature vector selection is proposed and its influence on the results of the classification of EEG signals is experimentally evaluated. A utilization of genetic algorithm and k-fold cross validation is proposed at the stage of feature selection in EEG signals for classification of mental motor images and its influence on the accuracy of classification is experimentally evaluated. A comparative analysis and experimental evaluation of six classifiers is also made and the possibilities for using hybrid multimodal EEG and NIRS datasets for brain activity in order to improve the classification of mental motor images is suggested and experimentally evaluated. Two architectures of deep convolutional neural networks for EEG data classification are proposed for BCI speller using P300 signals and for EEG based emotion recognition using multimodal datasets. A procedure for design of EEG datasets for classification of mental motor images is developed and applied for creation of a data set used for experimental evaluation of the suggested methods for feature detection, feature selection and classification of mental motor images. Two sample BCI applications are also developed for brain based mouse cursor control and for control of virtual objects in computer games.