



Маг. инж. Лъчезар Начков Божков

**ПРИЛОЖЕНИЕ НА МЕТОДИТЕ ЗА МАШИННО
ОБУЧЕНИЕ ЗА СЪЗДАВАНЕ НА НЕИНВАЗИВЕН
МОЗЪЧНО-КОМПЮТЪРЕН ИНТЕРФЕЙС**

АВТОРЕФЕРАТ

на дисертационен труд

за придобиване на образователната и научна степен **„доктор“** в
професионално направление: 5.3 Комуникационна и компютърна
техника и научна специалност: „Автоматизирани системи за
обработка на информация и управление“
(за нуждите на Факултета за Английско Инженерно Обучение)

Ръководители:

доц. д-р Румен Иванов Трифонов
доц. д-р Петя Георгиева Георгиева

София 2017



TECHNICAL UNIVERSITY OF SOFIA

APPLICATION OF MACHINE LEARNING METHODS FOR AFFECTIVE COMPUTING AND DEVELOPMENT OF NONINVASIVE BRAIN COMPUTER INTERFACE

MSc Eng. Lachezar Nachkov Bozhkov

A thesis submitted to the PhD students School of French Faculty for Electrical Engineering at the Technical University of Sofia in fulfillment of the requirements for acquisition of the degree of Doctor of Philosophy in the Technical University of Sofia. The thesis is for the needs of the English Language Faculty for Engineering with Dean Prof. Dr. Tasho Tashev.

Supervisors:

Assoc. Prof. Dr. Roumen Ivanov Trifonov, Technical University of Sofia, Bulgaria

Assoc. Prof. Dr. Petia Georgieva Georgieva, University of Aveiro, Portugal

Sofia 2017



universidade
de aveiro



IEETA

institute of electronics and informatics engineering of aveiro

© 2017

Lachezar Bozhkov

ALL RIGHTS RESERVED

Abstract

Electroencephalography (EEG) based affective computing is a new research field that aims to find neural correlates between human emotions and the registered EEG signals. Typically, emotion recognition systems are personalized, i.e. the discrimination models are subject-dependent. Building subject-independent models is a harder problem due to the high EEG variability between individuals. In this Ph.D. thesis, we propose a unified system for efficient discrimination of positive and negative emotions in a group of users. The users were exposed to high arousal affective images and the recorded brain signals differentiated according to their positive and negative valence. The experimental scenario was built on Event-Related Potentials (ERPs). ERPs are transient components in the EEG generated in response to stimulus (images with intensive emotional content in this study). The discrimination problem involves high dimensional, multi-channel noisy raw data, from which the spatiotemporal features are extracted.

A major challenge in building subject independent affective models is to identify the most discriminative features between subjects. Therefore, the first task of this thesis was to find a relevant feature selection approach that extracts features suitable for neurophysiological interpretation and validation. Spatial (channels) and temporal (brain waves peaks and their respective latencies) features were extracted from the EEG signals. The following feature selection strategies were explored: Principal Component Analysis (PCA), Independent spatial and temporal feature selection, Sequential Feature Selection, Feature Elimination based on descriptive data statistics, and Echo State Networks (ESN). The results obtained in this Ph.D. thesis are in line with the neurophysiological hypothesis of

visually elicited human emotions and related brain activity. The relevance of the selected features in discriminating the human emotion valence was validated through machine learning classification algorithms. Thus, the second task of this Ph.D. thesis was to build and optimize the following classifiers: Artificial Neural Networks (ANN), Logistic Regression (LogReg) Linear Discriminant Analysis (LDA), k-Nearest Neighbors (kNN), Naive Bayes (NB), Support Vector Machines (SVM), Decision Trees (DT), and ensemble of classifiers based on voting principle. The final research problem considered in this thesis was to apply the novel deep learning approach for the development of noninvasive brain-computer interface in the emotion recognition context.

Acknowledgements

I would like to thank all those who supported me throughout this degree. First and foremost, I would like to thank Prof. Dr. Petia Georgieva for all her time, dedication, generosity, and valuable guidance. She is an approachable supervisor who motivated me to achieve my goals.

I would like to thank Prof. Dr. Rumen Trifonov and Prof. Dr. Tasho Tashev for their support, administrative assistance and guidance.

I would like to thank Prof. Dr. Petia Koprinkova of the Bulgarian Academy of Sciences for her advice and collaboration on research in the field of Echo State Networks and Reservoir Computing.

I would like to thank the PsyLab from Departamento de Educação da UA, Portugal and particularly Dr. Isabel Santos, for providing the data sets.

I would like to thank BISITE group from the University of Salamanca, Spain for providing me with the accommodation grant for attending PAAMS 2015 conference in Salamanca, Spain.

I would like to thank TBI Info LTD for providing me grant to attend and present my research at SIMULTECH 2014 - 4th International Conference on Simulation and Modeling Methodologies, Technologies and Applications in Vienna, Austria.

I would like to thank the Technical University of Sofia for providing me two Erasmus+ scholarships to do internships at the University of Aveiro, Portugal.

Finally, a more general thanks to the teaching and administrative staff of the Technical University of Sofia and University of Aveiro, family and friends for their support.

Съдържание

Abstract	iv
Acknowledgements	vi
Съдържание	vii
Публикации	viii
1. Увод	1
2. Актуално състояние	7
3. Набор от данни.....	20
4. Декодиране на човешки емоции от ЕЕГ данните.....	24
5. Подробни данни и презентации	36
6. Заключение.....	55
Приложение А.....	57

Публикации

1. Bozhkov Lachezar, Overview of Deep Learning Architectures for Classifying Brain Signals, KSI Transactions on Knowledge society, ISSN 1313-4787, p59-66, Vol. IX, Number 1, March 2017
2. Lachezar Bozhkov, Petia Koprinkova-Hristova and Petia Georgieva, Reservoir Computing for Emotion Valence Discrimination from EEG signals, Neurocomputing, <http://dx.doi.org/10.1016/j.neucom.2016.03.108> (IF 2.392), March 2017
3. Lachezar Bozhkov, Petia Koprinkova-Hristova, Petia Georgieva, Learning to decode human emotions with Echo State Networks, Neural Networks, Volume 78, June 2016, Pages 112-119, ISSN 0893-6080, <http://dx.doi.org/10.1016/j.neunet.2015.07.005>. (<http://www.sciencedirect.com/science/article/pii/S0893608015001422>) (IF 3.216)
4. L. Bozhkov, P. Georgieva, I. Santos, A. Pereira, C. Silva (2015), EEG-based subject independent affective computing models. *Procedia Computer Science*, Elsevier, pp. 375-382, DOI: 10.1016/j.procs.2015.07.314
5. Lachezar Bozhkov, Petia Georgieva, Brain Neural Data Analysis with Feature Space Defined by Descriptive Statistics, Pattern Recognition, and Image Analysis, Vol. 9117 of the Series Lecture Notes in Computer Science (LNCS) p. 415-422, http://dx.doi.org/10.1007/978-3-319-19390-8_47 (2015)
6. Koprinkova-Hristova, P., Bozhkov, L. and Georgieva, P., Echo State Networks for Feature Selection in Affective Computing. Advances in Practical Applications of Agents, Multi-Agent Systems, and Sustainability (PAAMS), p.131-141, http://dx.doi.org/10.1007/978-3-319-18944-4_11 (2015)

7. Lachezar Bozhkov, Petia Georgieva, Classification models of emotional biosignals evoked while viewing affective pictures, International Conference on Simulation and Modeling Methodologies, Technologies and Applications (SIMULTECH), 2014, p. 601-606.
8. Bozhkov L., P. Georgieva, R. Trifonov, Brain Neural Data Analysis Using Machine Learning Feature Selection and Classification Methods. International Conference on Engineering Applications of Neural Networks (EANN) 2014, Sofia, Bulgaria, September 5-7, 2014.

1. Увод

1.1. Мозъчно-компютърен интерфейс

След първите изследвания с Електроенцефалография (EEG) върху хора, извършени от Ханс Бергер през 1929, идеята, че мозъчната активност може да се използва като канал за комуникация се появява бързо. Наистина, EEG е техника, която дава възможност да се измерят, върху кожата на главата и в реално време, микро токове, които отразяват активността на мозъка. Откритието EEG позволи на изследователите да измерват активността на мозъка на човека и да започнат опити за декодирането на тези сигнали.

През 1973г. първият прототип на мозъчно-компютърен интерфейс (BCI) се появява в лабораторията на д-р Видал (Vidal, 1973). BCI е система за комуникация, която позволява на човек да изпраща команди към електронно устройство само с помощта на доброволни вариации на мозъчната му дейност (Wolpaw, и др., 2002 г.) (Birbaumer, 2006) (Pfurtscheller, и др., 2005b) (Bell, и др., 2007 г.) (U. Hoffmann, 2007). Такава система се появява като особено обещаващ комуникационен канал за хора, страдащи от тежка парализа или за хора, които имат амиотрофична латерална склероза (Kübler, и др., 2001). В действителност тези лица може да бъдат засегнати от определен синдром и вследствие на това са „заклучени“ в тялото си без никакъв остатъчен контрол на мускулите. Следователно BCI изглежда като тяхно единствено средство за комуникация.

От 90-те години BCI изследванията започнаха бързо да се увеличават, като все повече и повече лаборатории в цял свят се занимават с тях.. Няколко международни BCI състезания се проведоха с цел да се идентифицират най-ефективните BCI системи в света (Sajda, и др., 2003 г.) (Blankertz, и др., 2006a). Оттогава са предложени множество BCI прототипи и приложения,

най-вече в лекарствения сектор (Rebsamen, и др., 2007) (Birbaumer, и др., 2000), както и в областта на мултимедията и виртуалната реалност (Krepki, и др., 2007 г.) (Ebrahimi, и др., 2003 г.) (Lécuyer, и др., 2008 г.) и други, но ВСИ може също да се използва за разграничаване на емоции.

1.2. Емоции и машини

Емоциите са част от всяко физическо общуване с участието на хората. Те могат да бъдат изразени устно, чрез емоционална лексика или чрез невербални знаци като интонацията на гласа, изражението на лицето и жестове. В този контекст декодирането на емоционалните сигнали е от съществено значение, за да се тълкува съобщението правилно. Например агресивно с викове "Млъкни" няма същото значение, както когато е казано през смях и с усмивка. Във втория случай, може да се тълкува, че говорителят не иска от своя събеседник да млъкне, а по-скоро, че намира забележката му забавна и в същото време на границата на социалното приемане. Въпреки това, отстраняването на двусмислието и обогатяването на комуникацията не е единствената роля на емоциите. Установено е, че те играят и основна роля в процеса на вземането на решения и че са силно свързани със склонността към действие. Това откритие със сигурност е една от причините за значението, което те имат в днешно време в невромаркетинга, чиято цел е разкриването на мозъчните механизми, водещи до решението за покупка. В своята книга бестселър (Goleman, 1997) не се колебае да говори за "емоционална интелигентност", т.е. за способността на човека да разбере, да общува и да управлява емоциите си, както и за неговото умение да разбира и да чувства емоциите на другите. Според автора тези качества и способности са толкова важни, колкото логиката и вербалните умения за "успех в живота". Разбира се определението за "успех в живота" може да се

обсъжда, но все пак успехът на книгата на Големан и много други книги, посветени на емоциите, ясно демонстрира важноста, която хората придават на този въпрос в нашето общество.

1.3. Приложения от оценката на емоция

Когато мислим за емоционално оценяване, едно приложение, което идва на ум е детекторът на лъжата. Със сигурност е така, защото това е първият инструмент, даващ възможност да се оцени истинското вътрешно състояние на човек, без той да го иска, което води до познати на всички дебати. Въпреки това, този раздел в дисертацията показва, че детекторът на лъжата е само върхът на айсберга и че изследванията за оценка на емоция могат да се насочат към много повече приложения. Ние вярваме, че повечето от тях са по-етични и по-малко предмет на дебат по същество, тъй като тяхната цел не е да разкрие информация, която може да се разглежда като лична, а по-скоро да се подобри начинът машини да реагират на човешките чувства, предотвратяване на аварии и рехабилитация на хората с увреждания. Списъкът от приложения в дисертацията, разбира се, не е изчерпателен, но по-скоро дава известна представа за възможностите и предимствата на технологии за оценка на емоция, както и за осигуряване на по-добро разбиране на контекста и залозите на тази теза.

1.4. Свързани въпроси / проблеми

Емоциите са изследвани от няколко гледни точки и в продължение на много векове, започващи с дискусии на философи като Аристотел (Goleman, 1997) (Lazarus, 1991). Дарвин е и пионер, който се опитал да обясни произхода на емоции и тяхното значение за оцеляването на вида. Въпреки това, едва наскоро (1950 - 1960), с появата на когнитивни науки в областта на психологията емоцията предизвика истински интерес. Така изследването на емоциите в психологията е по-скоро една нова област на изследвания и все още има много въпроси, които

остават нерешени. Тези въпроси имат силно значение за HMI изследователи, тъй като дефиницията, предизвикването и характеризирането на емоции са в основата на подходящата оценка, синтез и адаптация на емоции. В този раздел в дисертацията се набляга на въпросите, които са най-подходящи за оценка на емоция.

1.5. Преглед на дисертацията

Тази теза е разделена на шест глави.

Глава 2 представя актуалното състояние на техниката за регрупиране на важните понятия, свързани с оценка на емоция от физиологични сигнали и мозъчно-компютърни интерфейси. Насочена е към няколко модела и дефиниции на емоции, предложени в областта на психофизиологията и социологията. Различните физиологични сигнали, свързани с емоционални процеси, са разгледани заедно със съществуващите методи и сензори, които могат да се използват за регистриране на тези сигнали. Резултатите от проучвания, използващи физиологични сигнали за оценка на емоции, се отчитат и са обсъдени по няколко критерия. Главата описва и най-новите технологии за BCI. Разглеждат се също регистрирането и предварителната обработка на сигналите. На последно място са описани различни методи за извличане на характеристики и класификация чрез използване на машинно обучение (Machine Learning).

Глава 3 описва набора от данни, който се използва за извършване на експериментите. Главата първо представя използваната лабораторна среда за придобиване на физиологичните сигнали. Също така предоставя информация за предварителна обработка на сигнала и качеството на сигналите. След това са представени предикторите - фичъри, извлечени от сигналите за характеризиране на физиологична активност.

Глава 4 описва 3 от експериментите с помощта на набор от данни:

Казус 1: "Brain Neural Data Analysis Using Machine Learning Feature Selection and Classification Methods" представя работата ни върху класификацията на ефектното състояние. Сравняваме шест алгоритъма от машинно обучение за разграничаване на потенциали, предизвикани от събития, свързани с обработката на различни емоционални валенции, които са регистрирани при разглеждането на изображения с високи положителна и отрицателна емоционална възбуда. Основното постижение на това проучване, което превъзхожда по-рано публикувани резултати, е 98% точност при класификацията между субекти въз основа на по-голямата част от гласовете от всичките класификатори.

Казус 2: "Classification models of emotional biosignals" цели намирането на връзката между ЕЕГ-базирани био-сигнали и човешките емоции. Ние сравняваме два подхода за разграничаване: I) модел на класификация въз основа на всички характеристики на един канал и II) модел на класификация на базата на една характеристика на всички канали. Резултатите показват, че канали от тилния лоб (за първия модел класификация) и функции на латентност (за втория модел класификация) имат подобър разграничаващ капацитет, постигайки съответно 80% и 75% точност при класификация на тестови данни.

Казус 3: "Brain Neural Data Analysis with Feature Space Defined by Descriptive Statistics" Sequential Features Selection, представена в казус 1, е изчислително интензивен подход, който е трудно да се прилага за всеки модел класификация. В тази работа разширяваме реда на научните изследвания и предлагаме изчислително по-проста техника за подбор на фичъри въз основа на дескриптивна статистика на сигналите от мозъчната активност. Този подход

представлява добър компромис между точност и изчислителна сложност.

Глава 5 представя резултатите от оценката на емоция от физиологични сигнали от подробни данни, задълбочено обучение (deep learning), както и методи за класификация, чрез резервоарен компютютинг (reservoir computing). Първо, даваме кратко описание на автоенкодерите (autoencoders) и резервоарни изчисления и след това представяме два казуса:

Казус 4: "Echo State Networks for feature selection in affective computing" Показваме, че резервоарите от ESN могат да служат като ефективна процедура за подбор на характеристики, която подобрява определянето на човешката емоционална валентност от ЕЕГ сигнали. Задача, която принадлежи на изследователската област на афективни изчисления (Affective Computing). Редица контролирани и неконтролирани техники за машинно обучение (Supervised and Unsupervised Machine Learning), използващи за вход ново векторно представяне на сигналите, извлечено от ESN резервоарните, са сравнително проучени по отношение на тяхната дискриминационна точност. Това нововъведено приложение на ESN служи за доказване на концепцията за възможността за разширяване на използваемостта на ESN рамки за класификация или клъстеризация.

Казус 5: "Reservoir Computing for Emotion Valence Discrimination from EEG signals" Ние предлагаме нов подход за намаляване размерността на измеренията на базата на Reservoir Computing. Методът е потвърден с данни от ЕЕГ с цел да се идентифицират общите неврофизиологични сигнали, на базата на които положителна и отрицателна валенция на човешки емоции от различни субекти може да бъде надеждно разграничена. Ключовата стъпка в предложените мерки е техниката "Вътрешната

пластичност” (Intrinsic Plasticity) и адаптирането на резервоарните състояния. Тренирането на ESN с IP увеличава ентропията на разпределението на резервоарните вектори, при зададени статични входни данни с Гаусово разпределение. Равновесните вектори в резервоара се постигат чрез итеративно актуализиране на вектора за всеки статичен входен вектор, докато не достигне конвергенция. Стандартни модели за класификация и клъстеризация са снабдени с комбинации от два, три или повече от резервоарните неврони и се класират въз основа на тяхната дискриминационна производителност. ESN, настроен чрез IP, е мощна техника за представяне на високоизмерен входен сигнал в ниско измерна представяне и подобряване на точността при дискриминация на емоционална валентност в сравнение с класическите ESNs и дълбоки невронни енкодери.

Глава 5 представя заключенията в дисертацията и осигурява някои предложения за бъдеща работа и подобрения.

Приложение А представя част от работата ни по време на стаж в Университета в Авейро, Португалия. Описва софтуера, който разработихме, за да ни помогне да събираме, съхраняваме, маркираме и обработваме сигнал, записан от мобилен EEG апарат Epoch на Emotiv.

2. Актуално състояние

2.1. Представяне на емоции и модели

Преди разработването на система за представяне и разпознаване на емоциите е необходимо първо да се определи какво е емоция. В момента няма обща рамка, която да се използва, за да отговори на този въпрос. Това се дължи главно на факта, че емоциите са сложни явления, които оказват влияние върху много аспекти на ежедневиия живот: те помагат да се избегне опасност, да се вземат решения и също имат някои важни социални ценности.

Четири основни теории за емоциите са разработени през последното столетие (Cornelius, 2000).

От гледна точка на социалния конструктивизъм, емоциите са само продукти на социалните взаимодействия и културни норми (Cornelius, 2000). Това твърдение често се смята за твърде ограничаващо, но в днешно време повечето от изследователите в афективните науки признават, че социалните и културните норми поне регулират емоциите: човек няма да има едно и също емоционално поведение пред по-висшестоящ, както пред негов приятел. От една страна, тази гледна точка подчертава значението, което емоциите имат в обществото и разкрива подходи за оценка на емоции в социална среда, например в областта на електронните социални мрежи. От друга страна, тя също така предполага, че емоциите трябва да се оценяват с модели, които са културно и локално специфични, което прави оценката по-сложна.


Дарвинистите възприемат емоциите като явления, които са избрани от природата според стойността им за оцеляване, т.е. страхът съществува, защото ни помага да избегнем опасност. Това е един от най-старите възгледи относно емоциите и първоначално е предложен от Дарвин през 1872 г. (Cornelius, 2000) (Ortony, и др., 1990). Основният извод е, че емоциите трябва да имат еднакви конструкции при индивидите и в резултат еднакви емоционални изяви и начини на поведение може да се открият в различните култури. Тази гледна точка е определено противоположна на социалния конструктивизъм и подкрепя идеята, че е възможно съществуването на един единствен модел за оценка и универсално представяне на емоции.

За Jamesians емоциите еднозначно отговарят на усещането за телесни промени - например изменение на сърдечната честота и кръвното налягане, които следват емоционални стимули (


"Страхувам се, защото треперя") (Cornelius, 2000) (James, 1884). По този начин, ако механизмът за възприятие се наруши, няма възможност да се изпитват емоции вече. Въпреки че е спорен, този по-късен подход подчертава важната роля на физиологични реакции в изследването на емоциите. По-конкретно това означава, че всяка емоция съответства на уникален модел на физиологична активност, което силно насърчава за оценка на емоция от физиологични сигнали.

В когнитивната теория емоциите са издадени от когнитивен процес, наречен оценка. Този процес трябва да бъде "директен и не-отразяващ" и оценява стимул според няколко критерия, като значение и последици на събитие (Sander, и др., 2005 г.) (Scherer, 2001). Този подход подкрепя идеята, че мозъкът е основният орган, въвличен в емоциите чрез организиране на емоционални процеси и задействане на емоционални реакции. В резултат на това мозъчните сигнали не бива да бъдат пренебрегвани, като източник за анализ и откриване на емоции. Едно от предимствата на тази теория, от гледна точка на компютърните науки, е че тя дава възможност за изчислително-възприемчиви модели на емоции (виж раздел 2.1.3).

От всички споменати теории са се появили различни модели и начини на представяне на емоциите. Има и някои опити за обединяване и хармонизиране на различните гледни точки, но все още са закотвени в една от посочените по-горе теории. В следващите секции ще бъдат подчертани два вида презентации на емоции: така наречените основни емоции и непрекъснатите представяния. Ясно е, че те са най-използваните в общността за оценка на емоции. Модели на емоциите са разгледани в раздел 2.1.3, но те са по-сложни и по-малко използвани за целите на оценката на емоция само от физиологични сигнали.



Фиг. 2.1 Колело от емоции Plutchik. (Вляво) Основните емоции представени, като квадранти и възможни комбинации на основни емоции. (Десен) Същото колело с добавената концепцията за интензивност.




Фиг. 2.2 Пространство на непрекъснатите представяния за валенсия и възбуда с асоциирани етикети, като (а) точки и (б) области.

2.2. Физиологични сигнали и централната нервна система (CNS)

Като физиологични сигнали могат да бъдат определени сигнали, които изразяват количествено физични и химични явления, срещайки се в органи и тъкани. Това определение подчертава наличието на устройство, което може да определи количествено физически и химически феномен: сензора. Целият апарат

позволява визуализация и запис на (много) физиологични сигнали и се нарича система за придобиване. Описана е подробно на фигура 2.6.



Фиг. 2.6. Система за придобиване, визуализация и съхраняване на физиологични данни

Има голямо разнообразие от физиологични сигнали в зависимост от техния източник (органа под наблюдение) и феномен, който се измерва. Например сърдечна активност може да бъде измерена чрез записване на електрически потенциали на определени позиции на тялото, сърдечния пулс и кръвното налягане в коронарните артерии. В тази дисертация, тъй като всички органи са свързани и контролирани от нервната система, ние избрахме да ги разделим съгласно следната таксономия: централната нервна система (CNS) и периферната нервна система (PNS). Така дейности на органи, които се контролират от ПНС ще бъдат посочени като периферни дейности, докато активността на други органи (в това изследване само мозъка) ще се нарича централна активност. Забележете, че тази таксономия ни дава възможност да се разделят на две системи, които се очаква да бъдат в центъра на когнитивните и Jamesian теориите на емоции.

Централната нервна система се състои от мозъка, малкия мозък, мозъчния ствол и гръбначния мозък. Тъй като в нашето проучване

е анализирана само мозъчната активност, описанието ще се фокусира върху мозъчните структури и дейности, свързани с емоции, както и върху устройствата, които биха могли да бъдат използвани за измерване на тези дейности.




Figure 2.8 Изображение на мозъка, мозъчния ствол и малкия мозък с различните лобове подчертани (Purves, и др., 1997).

2.2.1. Измерване на мозъчната дейност

Тъй като невроните комуникират чрез акционни потенциали, е възможно да се наблюдава мозъчната дейност чрез измерване на електромагнитни полета. Тези методи са известни като **директни методи**, защото директно измерват активността, произведена от невроните и могат да бъдат разделени на два типа:

- електроенцефалографията (EEG) измерва електрически потенциали чрез поставяне на електроди на скалпа (повърхностен EEG) или чрез прерязване на черепа на повърхността на мозъка (ElectroCortico-Graphic електроди - ECOG), или директно в интересующите ни неврони (интра-кортикални електроди);
- магнитоенцефалографията (MEG) измерва магнитната активност на невроните. Чрез използване на

специализирани устройства (Superconducting QUantum Interference Devices - SQUID) могат да се открият малки промени в магнитни полета.

Индиректни методи наблюдават други параметри, които са свързани с невронална активност, като например изкуствени маркери инжектирани в тялото и ресурси, консумирани от неврони (например кислород):

- Позитронно-емисионна томография (PET) измерва позитрон емисии на малко по-радиоактивен изотоп;
- Еднофотонна емисионна компютърна томография (SPECT), подобно на PET, изисква инжектиране на радиоактивен изотоп, излъчващ гама-лъчи, които се измерват с камера за гама-лъчи;
- С изображения от функционален магнитен резонанс (fMRI) се откриват промените на оксигемоглобин и дезоксигемоглобин чрез прилагане последователни магнитни полета по главата, които принуждават протони да освободят енергия при определена честота, която се регистрира от системата;
- функционална близо-инфрачервена спектроскопия (fNIRS) също следи промените на оксидезоксигемоглобин чрез измерване на отражението на близо-инфрачервен диод (0.7-1.5 μm дължина на вълната), поставен върху скалпа, като близо-инфрачервен сензор се поставя в непосредствена близост до диода.

Всички тези методи може да бъдат оценявани по няколко критерия: пространствена разделителна способност, резолюция време, финансови разходи, необходими размери на машини / тегло, инвазивност, хирургична намеса, експлоатация и / или

техническа подготовка. Таблица 2.3 оценява различните споменати по-горе методи в съответствие с тези критерии. Високите пространствени и времеви резолюции са необходими за точен анализ на сигнали, но съвременните методи не позволяват едновременно висока пространствена и времева разделителна способност. Въпреки това, последните проучвания се опитват да изпълняват мултимодален запис на мозъчната дейност, за да се съчетаят предимствата на преки и косвени методи.

Таблица 2.3 Сравнение на различни методи за мониторинг на мозъчната дейност.

	Method	Spatial resolution	Time resolution	Financial cost	Machinery size/weight	Invasive	Preparation
Direct methods	Surface EEG	Low	High	Low	Low	None	
	EcoG	Low	High	High	Low	High	Surgical incision of the skull
	Intra-cortical	High	High	High	Low	High	Surgical incision of the skull and insertion of the electrode in the brain
	MEG	Low	High	High	High	None	
Indirect	PET	Low	Low	High	High	Low	Injection of a radioactive trace
	SPECT	High	Low	High	High	None	Injection of a radioactive trace
	fMRI	Low	Low	Low	Low	None	

Критериите също могат да се разглеждат като ограничения при използването на устройства за мозъчно-компютърен интерфейс. Така например сравнително ниска стойност на разходите е задължителна за търговското приложение на система за откриване на емоция. Лесното носене и неинвазивността също са от съществено значение за тези устройства, тъй като е малко вероятно, че потребителите ще приемат да се подложат на инжекции или операции само за да използват нов BCI. Поради тази причина, както може да се види от таблица 2.3, повърхностен EEG със сигурност е най-приложимият метод за използване в BCI системи. В резултат именно този датчик е избран за откриване на емоция в настоящото проучване. Въпреки това, все още EEG изисква доста подготовка, като например прилагането на проводим гел върху повърхността на кожата на главата, за да се осигури контакт между кожата и електродите и поставянето на всеки електрод в плътно монтирана шапка по главата. Това може да се разглежда като сериозно ограничение за търговски приложения, но вече има безжични химически електроди системи, предлагани на пазара, които не изискват толкова много подготовка и са доста евтини (например устройствата NeuroSky и Emotiv).

Тъй като в тази дисертация повърхностни EEG се използват за наблюдение на мозъчната дейност, терминът EEG ще е за справка към този вид измерване, а не ECOG и интра-кортикални измервания. Електрическата активност на невроните трябва първо да премине през няколко слоя от различни материи, за да достигне EEG електрод (сиво вещество, бялото вещество, цереброспинална течност, кости и кожа). По този начин сигналът, измерван с електрод от EEG, обединява сигналите, излъчвани от всички неврони, които са достатъчно близо, за да се запишат.

Въпреки това, учените са установили, че има конкретни честотни ленти (често наричани ритми в литературата), представляващи интерес при тълкуването на ЕЕГ сигнали: делта (2-4 Hz), тета (4-8 Hz), алфа (8-12 Hz), бета (12-30 Hz) и гама (> 30 Hz) групи. Забележете, че честотните ленти, свързани с всеки ритъм, може да варират от едно проучване в друго и от един човек на друг. Освен това, понякога се прилагат и различни имена за честотни ленти според функцията, която е свързана с даден ритъм. Например лента алфа е наричана също мю-ритъм при разглеждането на активността в двигателния кортекс. Причината, поради която тези ритми се наблюдават и се колебаят, все още е неясна, но се предполага, че синхронизирането на няколко популации от неврони може да бъде източник на тези явления (Pfurtscheller, и др., 1999a).

Понастоящем ЕЕГ системите могат да записват сигнали с повече от 250 електрода. Увеличаването на броя на електродите може да подобри пространствената разделителна способност, но се увеличава времето, необходимо да се прилага гел и да се прикрепят електроди, както и броят на променливите за анализиране. За да има известни стандарти по отношение на разположението и наименованието на електроди, е предложена система 10-20 (Oostenveld, и др., 2001). Името идва от факта, че предният и заден среден електрод са разположени на 10% от разстоянието отinion-nasion, докато другите електроди са разделени един от друг с 20% от същото разстояние. Inion е кост на гърба на черепа, а nasion е пресечната точка на костите точно над носа. По-късно други системи разширяват системата 10-20, за да се определят местата и имената на повече електроди: системата 10-10 (74 места) и системата 10-5 (345 места) (Oostenveld, и др., 2001).

Шумът е критичен проблем в измерването на ЕЕГ. Според (Kronegg, 2006 г.) има най-малко три потенциални източника на

шумове. Към тези от околната среда спадат всякакви електрически шумове, които съпътстват записа - например шум 50Hz електропровод. Като физиологични се определят шумовете от тялото - мускулните контракции. Последният източник на шум е фоновата дейност на мозъка и обхваща всички мозъчни дейности, които са записани, но не са свързани с конкретната мозъчна функция в процес на проучване.


2.3. Мозъчно-компютърен интерфейс (BCIs)

Проектирането на BCI е сложен процес, който изисква мултидисциплинарни умения и знания в областта на компютърните науки, обработката на сигнали, невронауките и на психологията. BCI дизайнът се състои от две основни фази: 1) предварителна фаза на обучение, за да се калибрира системата и 2) онлайн фаза, която използва BCI да разпознае мозъчни психични състояния и да ги преобразува в машинните (компютърни) команди. И двете офлайн и онлайн BCI фази следват процес на затворен цикъл, който обикновено се състои от шест стъпки: (. Mason, и др, 2003) за измерване на мозъчната дейност, предварителна обработка на данни, извличане на характеристики, класификация, превод на команда и обратна връзка:

1. **Измерване на мозъчна активност:** На този етап се използват различни видове сензори, за да се получат сигнали, отразяващи мозъчната активност на потребителя (Wolpaw, и др, 2006). В тази дисертация ние се фокусираме върху ЕЕГ като технологията на измерване.
2. **Предварителна обработка:** Този етап предвижда почистването и отстраняването на шума от входните данни за подобряване на информацията, постъпваща от сигналите. (Bashashati, и др, 2007b)

3. **Извличане на характеристики (фичъри):** Има за цел описване на сигнали чрез няколко съответстващи стойности, наречени “характеристики” (features) (Bashashati, и др, 2007b.).
4. **Класификация:** Етапът на класификация определя класа на базата на извлечените характеристики от сигнала (Lotte, и др, 2007a.). Класът съответства на вида на идентифицираното психическото състояние. Този етап може също да бъде обозначен като “превод на характеристиките” (Mason, и др., 2003). Класификационните алгоритми са известни като "класификатори".
5. **Превод на команда / приложение:** След като се идентифицира психическото състояние, с него се свързва команда, за да се контролира дадено приложение - например правопис (текстов редактор) или робот (Kübler, и др, 2006).

6. **Обратна връзка:** И накрая, тази стъпка предоставя на потребителя обратна информация за идентифицираното психическо състояние. Това има за цел да помага за контролиране на мозъчната му дейност и да подобри BCI (Wolpaw, и др., 2002 г.). Общата цел е да се подобрят изпълненията на потребителя.



Цялата структура е обобщена на фигура 2.10. Тези стъпки определят онлайн BCI. Въпреки това, както е споменато по-горе, следва да се отбележи, че преди извършване на такава BCI, необходимо е да се калибрира моделът. Подобна работа обикновено се извършва онлайн и има за цел калибриране на алгоритъма за класификация, калибриране и избор на оптимални характеристики, избор на подходящи датчици и т.н. За да се направи това, потребителят предварително трябва да усвои набор от обучаващи данни. Всъщност EEG сигналите са силно

индивидуално-специфични и настоящите BCI системи трябва да бъдат калибрирани и адаптирани към всеки потребител. Наборът от данни за обучение трябва да съдържа ЕЕГ сигнали, записани, докато субектът извършва всяка умствена задача, представляваща интерес, по няколко пъти според дадените указания. Записаните ЕЕГ сигнали ще бъдат използвани като примерни психически състояния, за да се намерят най-добрите параметри за калибриране за субекта.


3. Набор от данни

Грануларността на човешката емоция може да бъде схематично представена в две измерения: I) валентността, варираща от отрицателната към положителната и II) възбуда (интензитет на емоция), варираща от ниско до високо. Комбинацията от тези емоционални измерения образува четири емоционални категории, които включват няколко отделни човешки емоции като радост, удоволствие, вълнение, тъга, гняв, страх, отвращение и т.н. По този начин всеки био-сигнал, свързан с емоция, може да се диференцира в зависимост от нейните измерения валентност или възбуда (Santos, и др., 2008).

Въз основа на мозъчната активност на хора ние изучаваме класификацията на техни емоционални състояния, характеризирани чрез потенциали, свързани със събития (Event Related Potentials - ERP система). ERPs са преходни компоненти в ЕЕГ, генерирани в отговор на стимули. ERP системите са събрани, докато са преглеждани изображения с висока възбуда, съдържащи положително или отрицателно емоционално съдържание. Този проблем е от значение, защото такива класификатори представляват "виртуални сензори" на скрити емоционални състояния, които са полезни в областта на

психологично-научни изследвания и клинични приложения (Calvo, и др., 2010), (Georgieva, и др., 2014 г.).


Общо 26 жени доброволки взимат участие в проучването, 21 канален ЕЕГ (виж фигура 3.1, таблица 3.1), разположен по системата 10-20 (виж фигура 2.12) и 2 EOG канали (вертикални и хоризонтални) регистрират проби с 1000Hz и данните се съхраняват. Сигналите са били записани, докато на доброволците са показвани снимки, избрани от “International Affective Picture System”. Общо 24 изображения с висока възбуда (> 6) са избрани, изображения с положителна валентност (7.29 ± 0.65) и отрицателна валентност (1.47 ± 0.24). Всяко изображение се представя три пъти в псевдо-случаен ред и всеки опит е с продължителност 3500ms: през първите 750ms се представя фиксиращ кръст, след това едно от изображенията се показва за време от 500ms и най-накрая черен екран за време от 2250ms (виж фигура 3.2).



Фиг 3.1: 21 ЕЕГ канали

Сигналите са предварително обработени (филтрирани, коригирани от движение на очите, изходно компенсирани и нарязани на

епохи, чрез софтуер NeuroScan). Продължителността на един процес на сигнала е 950ms с 150ms преди началото на стимула. Изчислява се средната стойност (виж Фигура 3.3) за всяко състояние и се филтрира, като се използва схема за филтриране нулева фаза. Откриват се максималните и минималните стойности на ансамбъла от средни сигнали. Локализира се първият минимум в сигналите и характеристиките се определят от латентността и амплитудата на последователни минимуми (A_{min1} , A_{min2} , A_{min3}) и последователни максимуми (A_{max1} , A_{max2} , A_{max3}), и свързаната с тях латентност (L_{min1} , L_{min2} , L_{min3} , L_{max1} , L_{max2} , L_{max3}). Три схеми са реализирани чрез избора на три различни филтри и засичане на N максимуми и N минимуми на изхода от филтрите. Когато този модел не е осъществен, вектор функцията се запълва с нули.



Фиг. 3.2: Експериментална постановка. (Вляво: придобиване EEG сигнал; дясно: стимул презентационна схема)

1. Чрез Бътъруърт филтър от четвърти порядък с лентова честота $[0,5 - 15]$ Hz. Броят на запазените характеристики е 12, съответстващи на латентност (време на възникване) и амплитудата при $N=3$ максимуми и минимуми. Виж Фигура 3.4; характеристиките съответстват на времето и амплитудни стойности на първите три минимуми, настъпили след $T = 0s.$, и съответните максимуми между тях.

2. Чрез Бътървурт филтър от четвърти порядък с лентова честота [0,5 - 4] Hz, която съответства на честотния диапазон на Делта мозъчна активност. Броят на съхранените характеристики е осем, съответстващи на латентността (време на възникване) и амплитудата - два максимума и минимума.

3. Чрез Бътървурт филтър от четвърти порядък с лентова честота [4 - 8] Hz, която съответства на честотния диапазон за Тета активност. Броят на характеристиките е 12, съответстващи на латентността (време на възникване) и амплитудата при $N=3$ максимума и минимума.

Броят на запазените характеристики на канал е 12, съответстващ на латентността (време на възникване) и амплитудата за $N=3$ максимума и минимума; характеристиките съответстват на времето и амплитудните стойности на първите три минимума, настъпили след $T = 0s$, и съответните максимума между тях. Общият брой на характеристики на опит е 252. Данните се запамятват във файлове със следната структура: 252 колони: 12 характеристики за 21 канала, 52 реда: 26 души x 2 класа - 0 (отрицателни) и 1 (положителен клас).




Figure 3.4: Филтриран сигнал (чрез Бътървурт филтър от четвърти порядък) и откриване характеристики: положителен (линия) и отрицателен (точка). Лентова честота: 0.5-15 Hz.

В резултат първоначалният набор от данни е матрица X с размери от 252 колони (21 канали x12 характеристики) и 52 реда (осреднени положителни и отрицателни класове от изпитвания на 26 субекти). Векторното пространство X след това се нормализира чрез изваждане на средната стойност за всяко измерение и разделяне на стандартното отклонение на всяка колона, вижте формулата в (3.1).

$$\bar{X} = \frac{X - \text{mean}(X)}{\text{std}(X)} \quad (3.1)$$

Благодарности: Бихме искали да изразим благодарност на PsyLab от Departamento de Educação da University of Aveiro, и по-специално на д-р Изабел Сантос, за предоставяне на набора от данни.

4. Декодиране на човешки емоции от ЕЕГ данните

4.1. Изследване 1: Анализ на невронни данни с методите за избор на харектристики и класификация от машинно обучение

Електроенцефалограмата (EEG) е мощен инструмент за събиране на огромни количества данни за човешката мозъчна активност. Типичният ЕЕГ експеримент може да произведе с данните двумерна матрица, свързана с човешката невронна активност всяка милисекунда, проектирана по повърхността на главата при пространствена разделителна способност от няколко сантиметра. Както и в други съвременни емпирични науки, инструментите за ЕЕГ доведоха до поток от данни и съответна необходимост от нови методи за анализ на данните. Това изследване обобщава резултатите от приложението на методите за надзорно машинно обучение (Supervised ML) към проблема за класифициране на емоционалните състояния на хора, базирани на ЕЕГ. По-специално

сравняваме шест ML алгоритъма, за да разграничим потенциали, свързани със събития (ERP), свързани с обработката на различни емоционални валенции, записани, докато субектите гледат високо възбуждащи изображения с положително или отрицателно емоционално съдържание. 98% интра-субектна точност на класификацията, основана на мнозинството от гласовете на всички класификатори, е основното постижение на това проучване, което надминава резултатите, публикувани в досегашните статии.

4.1.1. Методология и техники

В изследването са приложени следните техники и методологии:

Данните се нормализират, за да се улеснят максимално алгоритмите за обучение. За да се максимизират примерите за обучение, се използва техника за кръстосано валидиране. Изследвани са следните модели за машинно обучение: Изкуствени невронни мрежи (ANN), Логистична регресия (LogReg), Линеен дискриминационен анализ (LDA), Съпорт вектор машини (SVM), Най-близки съседи (kNN), Наивен Бейс (NB), Дървета за вземане на решения (DT) и агрегиране на зареждането на дърветата за решения (Tbagger) (виж раздел 2.3.5). За намаляване на входното пространство или за избиране на най-типичната характеристика са използвани методите: Анализ на основните компоненти (PCA) и Избор на последователни характеристики (SFS). Накрая направихме ансамбъл от класификаторите и предоставяме решение на базата на гласуване от всички класификатори.

4.1.2. Резултати

В таблица 4.1 са обобщени базовите резултатите от всички класификатори. В таблица 4.4. се наблюдават резултатите след оптимизиране на моделите и избиране на най-подходящите за класификация характеристики. В дисертацията могат да се видят разширените резултати от всички изследвания.

Таблица 4.1: Точността на прогнозиране в резултат от класификационните модели, използващи всички характеристики.

Model	ANN	LogReg	LDA	kNN	NB	SVM	DT	Tbagger
Accuracy X_{TEST}	71,2	67,31	71,2	59,6	69,2	50	69,2	75
Accuracy X_{TRAIN}	75,6	100	100	100	93	100	96,2	100

Table 4.4: Точност след оптимизиране на моделите и използвайки техниката SFS за избор на най-релевантните характеристики.

Model	LDA	kNN	NB	SVM	DT
Accuracy X_{TEST}	92,3	90,38	86,5	88,5	88,5
Accuracy X_{TRAIN}	94,2	100	91,2	100	97,4

Комбинацията от SFS и петте класификатори в предходния раздел донесе много близки или дори малко по-добри резултати от най-добрите класификационни проценти, публикувани в по-ранните изследвания. Въпреки това направихме интуитивна крачка напред, за да изградим ансамбъл от класификатори, базиран на мнозинството от петте обучени модели. Така, процентите на прогнозиране, постигнати от отделните класификатори в диапазона от [87-92]%, са значително подобрени и новият окончателен резултат е 98%. В дисертацията може да се прочете разширено обсъждане на резултатите.

4.1.3. Заключение

В това изследване представихме резултати, демонстриращи осъществимостта на ML техниките за класифициране, за да разграничим обработката на стимули с положителна и отрицателна емоционална валентност, базирана на наблюдения на ERPs. Този проблем е интересен както поради връзката му с изучаването на човешките емоции, така и като казус при надзорно

машинно обучение (Supervised ML) в среда на големи измерения на данните. Фокусът на нашата работа е да се проучи възможността за обучение на интер-субектни класификатори, за да се прогнозира данните на множество човешки субекти. Изборът на характеристиките е важен аспект на дизайна на системите за разпознаване, особено в интер-субектна рамка. Комбинацията от адекватни характеристики и избор на канали има потенциала да намали вариабилността между отделните субекти и да подобри изучаването на представените модели.

Може да се заключи, че машинното обучение е мощна техника за разкриване на мозъчната активност и за тълкуване на човешките емоции. Има много допълнителни възможности за ML изследвания в контекста на афективната невронаука като разграничаване на повече от две емоционални състояния, свързани не само с емоционалната валентност, но и с емоционалната възбуда. Разграничаването на високия срещу ниския невротичен тип на личността също е предизвикателство, с което ML може да се справи.

4.2. Изследване 2: Класификационни модели за емоционални биосигнали

Това изследване има за цел да намери връзката между базираните на ЕЕГ биосигнали и човешките емоции. Потенциали, свързани със събития (ERP), се регистрират от 21 канала на ЕЕГ, докато субектите разглеждат емоционални снимки. 12 времеви характеристики (амплитуди и латентности) са изчислени и използвани като дескриптори на положителните и отрицателните емоционални състояния у множество субекти. В тази работа сравняваме два подхода за разграничаване: i) класификационен модел, базиран на всички характеристики на един канал и ii) класификационен модел, базиран на една характеристика по всички канали. Резултатите показват, че оксипиталните канали (за

първия модел на класификация) и характеристиките на латентност (за втория модел за класификация) имат по-добър капацитет за разграничаване, достигащ съответно 80% и 75% точност при класификация за данните от тестовото множество.

4.2.1. Методология

Използваната методологията е сходна с методологията в изследване 4.1 и е описана детайлно в дисертационния труд секция 4.2.

4.2.2. Резултати

Таблица 4.6: Точност на класифицирането на данните от теста (един канал - всички характеристики) - съкратена.

Channel Number	Channel Name	True Negative	True Positive	Total Accuracy
14	P7	80,77	80,77	80,77
20	Oz	85,71	74,19	78,85
...	...	...	...	...
4	F7	53,57	54,17	53,85
8	F8	42,86	41,67	42,31

Таблица 4.7: Точност на класифицирането на данните от теста (единична характеристика - всички канали) - съкратена.

Feature Number	Feature Name	True Negative	True Positive	Total Accuracy
12	Lmax3	72,41	78,26	75,00
10	Lmax2	67,74	76,19	71,15

...	...	...	...	...
9	Lmin2	52,00	51,85	51,92
5	Amin3	47,06	48,57	48,08

От резултатите в таблици 4.6 и 4.7 е видимо, че париеталните, оксипиталните и темпорални канали носят повече дискриминационен сигнал от централните и фронтални канали. Както и характеристиките, свързани с латентност, успяват да разграничат сигнала по-добре от характеристиките, свързани с големина на амплитудата. Резултатите са дискутирани обширно в дисертационния труд.

4.2.3. Заключение

В това изследване предлагаме алтернативен подход към предизвикателството за разпознаването на човешките емоции въз основа на мозъчните сигнали. За разлика от повечето системи за разпознаване, при които се търсят най-добрите пространствено-времеви характеристики, ние разглеждаме избора на пространствени характеристики (каналите) и избора на времеви характеристики (амплитуди/латентности) отделно, за да разграничим обработката на стимулите с положителни и отрицателна емоционална валентност, базирана на наблюденията на ERP. В основата на настоящото изследване е проучването на възможността за обучение на интер-субектни класификатори, за да се прогнозираат сигналите от множество човешки субекти. Изборът на париеталните и оксипитални (по-специално канал ОЗ и Р7) или изборът на временните характеристики, свързани с латентността на пиковете на амплитуда по всички канали (Lmax2, Lmin3, Lmax3), има потенциала да намали между-субектната променливост и да подобри изучаването на представените модели.

Въпреки това, преди да направим по-силни изводи за капацитета на i.) Един канал или ii) единична характеристика за декодиране на емоциите, са необходими допълнителни изследвания, за да се отговори на по-сложни въпроси като разграничаване на повече от две емоции. Всъщност това е валиден въпрос за всички докладвани изследвания и статии за афективна невронаука (Calvo, et al., 2010) (Hidalgo-Muñoz et al., 2013) (Hidalgo-Muñoz et al., 2014). Разграничаването обикновено е ограничено до две, три и максимум четири емоционални класове на валентност-възбуда. Интересен проблем е и класификацията на човешката личност, основана на ЕЕГ, например високия спрямо ниския невротичен тип на личността.

Също така броят на участниците в експериментите е важен за разкриването на стабилни кръстосани характеристики при субектите. В прегледаните референции средният брой участници е около 10-15, като максималният е 32. Нуждаем се от обществено достъпни набори от данни, за да сравним различните техники и по този начин да ускорим напредъка на афективните изчисления.

4.3. Изследване 3: Анализ на мозъчно неврологични данни чрез характеристики, дефинирани извлечени с дескриптивна статистика

Разграничаваме емоционалните състояния на човешките субекти въз основа на тяхната мозъчна активност, наблюдавана чрез Електроенцефалограма (EEG). ЕЕГ сигналите се събират, докато субектите гледат високо възбуждащи изображения с положително или отрицателно емоционално съдържание. Този проблем е значителен, защото такива класификатори представляват "виртуални сензори" на скрити емоционални състояния, които са полезни в психологическите научни изследвания и клиничните

приложения. Изборът на характеристики има важна роля в класификацията на сигнали.

В предишно изследване (4.1) предложихме процедура за селектиране на последователни характеристики (SFS), която намали присъщата вариабилност на данните сред субектите и доведе до висока точност на разпознаване на емоциите между тях (98%), (Bozhkov et al., 2014). Въпреки това, SFS е изчислително интензивен подход, който е трудно да се приложи към всеки модел на класификация. В настоящото изследване ние разширяваме тази линия на изследване и предлагаме техника за подбор на характеристики, базирана на описателни статистически данни (средно и стандартно отклонение) на невронните подписи по субекти. Този подход представлява добър компромис между точността на предсказване и числената сложност.

4.3.3. Методология


Предлагаме да се намали пространството от данни въз основа на централната тенденция (аритметична средна стойност) и дисперсията (стандартното отклонение) на разпределението на отделните времеви характеристики.

Всяка графика от Фигури 4.5 и 4.6 представлява една временна характеристика за всички ЕЕГ канали. 21 колони от точки са разпределението на съответната характеристика в участващите 26 субекта. Червените и сините линии включват средната стойност на положителните и отрицателните маркирани изпитвания. Има характеристики с почти идентични средна стойност или стандартно отклонение и за двата класа и характеристики като латентност 4 (L_{max2}), латентност 6 (L_{max3}), амплитуда 3 ($A_{min 2}$), амплитуда 6 ($A_{max 3}$) със статистически добре разграничаващи положително и отрицателно разпределение на класа. Освен това наблюдаваме, че каналите (5, 6, 7, 9, 10, 11 и 20) са като цяло консистентни по


отношение на статистическото разграничаване чрез латентността и канали (5, 6, 7, 9, 10, 11 и 12) по отношение на амплитудата.

4.3.4. Резултати

Разпределението на отделните субекти, представено във фигури 4.5 и 4.6 показва, че класификацията може да бъде облагодетелствана чрез изваждане на характеристики със статистически еднакво разпределение между отделните предмети. За да изпробваме тази хипотеза, използваме ансамбъл от класификатори на база гласуване за всяка временна характеристика, свързана с канала (252 изпълнявания). Точките във фигура 4.7 съответстват на отделните пускания на експеримента за всяка характеристика. Повечето от характеристиките имат относително малко разстояние между положителните и отрицателните класови среди, а точността на кръстосано валидиране е в диапазона 35-65%. Точността на класификатора се увеличава за характеристики с по-голямо разстояние и малкото характеристики с разлика за класа си над 0,6 постигат 75% точност.




Фигура 4.5: Средна и стандартно отклонение на разпределението на характеристиките на латентността по субекти и канали. Позитивен клас (червена линия) и отрицателен клас (синя линия).



Фигура 4.6: Средна и стандартно отклонение на разпределението на амплитудата на субектите и каналите. Позитивен клас (червена линия) и отрицателен клас (синя линия).

линия).



Фигура 4.7: Точност на класифицирането спрямо разстоянието между характеристиките за класа.




Figure 4.9: Точността на класификация за последователно увеличените най-добри характеристики. Характеристиките се класират според разстоянието между техните среди за разпределение на класа (синьо) или разликата между тяхната дисперсия на класовото разпределение (червено).

4.3.5. Заключение


Основният принос на това изследване е методът за идентифициране на най-важните характеристики, които максимизират разграничаването между човешките положителни и отрицателни емоции въз основа на невронните данни, произведени от мозъка. Предлаганият метод е бърз, прост и интуитивен. Той се справя с основна статистическа информация (средно и стандартно отклонение) на индивидуалното разпределение на характеристиките в множество обекти. Методът може лесно да бъде приложен при други задачи по класифициране, особено при наличието на висока вариабилност на данните, което обикновено се случва при проучване между отделните субекти.

5. Подробни данни и презентации

5.1. Резервоарни изчисления и задълбочено обучение

5.1.1. Автоенкодери

Автоенкодерът е невронна мрежа, която е обучена да копира своя вход в изхода си. Вътрешно той има скрит слой h , който описва код, използван за представяне на входа. Мрежата може да се разглежда като състояща се от две части: функцията на енкодер $h = f(x)$ и декодер, който произвежда реконструкция $r = g(h)$. Тази структура е представена във фигура 5.1. В дисертацията са обобщени различни видове автоенкодери и техните предназначения.



Фигура 5.1 Общата структура на автоенкодера с два компонента: енкодера f (проектиране x до h) и декодера g (проектиране h до r).

5.1.2. Резервоарни изчисления

При машинното обучение, структури за обратна връзка, като изкуствени невронни мрежи, графични базови модели и методи на ядрото, са широко изследвани за обработката на не-времеви проблеми. Тези архитектури са добре разбрани благодарение на feed-forward и не-динамичната си природа. Много приложения обаче са времеви, като например прогнозиране (време,

динамични системи, финансови данни), системен контрол или идентификация, адаптивно филтриране, намаляване на шума, роботика (генериране на ходене, планиране), зрение и реч (разпознаване, обработка, производство). Накратко, много реални задачи. Възможно е да се решат времеви проблеми, като се използват feed-forward структури. В областта на моделирането на динамичните системи (F. Takens, 1981) предполага, че (скритото) състояние на динамичната система може да бъде реконструирано чрез адекватно забавено вграждане. Това изрично вграждане превръща времевия проблем в пространствен. Недостатъците на този подход са изкуствено въведен времеви хоризонт, много параметри са необходими, когато се въведе дълго закъснение и не е "естествен" начин за представяне на времето. Възможно решение на този проблем е добавянето на повтарящи се връзки към архитектурите за обратна връзка, споменати по-горе. Тези повтарящи се връзки превръщат системата в потенциално много сложна динамична система. В основната работа на (Hopfield, 1982) динамиката на рекурентната невронна мрежа (RNN) се контролира чрез конструиране на много специфични топологии със симетрични тегла. Въпреки че тази система е - общо взето - хаотична, архитектурата на Хопфилд зависи критично от наличието на привличащи точки. Използва се и по автономен начин: начално състояние се налага, а след това динамичната система остава да работи, докато се стигне до един от многото си атрактори. Друга линия на изследване, иницирирана от правилото за обратно разпространение във времето за повтарящи се мрежи (Werbos, 1990), е да обучи всички тежести в напълно (или рядко) свързана периодична невронна мрежа. В литературата се описват множество възможни приложения, включително изучаването на контекстно-свободни и контекстно чувствителни езици (Maass et al., 2002), контрол и моделиране на сложни динамични системи (J. Suykens, 1996) и разпознаване на реч (A. Graves, 2004). Известно е,

че RNNs са еквивалентни на Тюринг (Siegelmann, 1996) за общи активиращи функции, могат да приближават произволни фини автоматизирани състояния (Giles, 1994) и са универсални апроксиматори (Funahashi, 1993). Така че теоретично RNNs са много мощни инструменти за решаване на сложни времеви задачи за машинно обучение. Независимо от това, прилагането на тези правила към проблемите в реалния свят не винаги е осъществимо (поради високите разходи за компютърно обучение и бавната конвергенция) и докато е възможно постигането на най-съвременни резултати, това е запазено само за експерти в областта. Друг важен проблем е така нареченият градиент на затихване, при който градиентът на грешката се изопачава, като се вземат предвид много времеви стъпки наведнъж, така че само кратки примери могат да се използват за обучение. Едно възможно решение е специално конструираната архитектура за дългосрочна памет Long-Short Term Memory (LSTM) (Hochreiter., 1997), която въпреки това не винаги надхвърля времето, забавяно невронни мрежи. В ранната работа на (Buonomano, et al., 1995), където е използвана случайна мрежа от импулсни (spiking) неврони с краткосрочна пластичност (известни също като динамични синапси), е показано, че тази пластичност въвежда много по-бавна динамика, отколкото може да бъде подкрепена от повтарящата се топология. Той използва надзорно правило за обучение, базирано на корелация, за да обучи отделен изходен слой, за да демонстрира това. Идеята за използване на произволна повтаряща се мрежа, която е оставена нетренирана и която е обработена чрез проста техника на класифициране / регресия, е по-късно самостоятелно преоткрита от (Jaeger, 2001) като Echo State Network и (Maass et al., 2002) като машина за течни състояния. ESN се състои от произволна, повтаряща се мрежа от аналогови неврони, която се управлява от (един или многомерни) времеви сигнали, а активирането на невроните се използва за

линейна класификация / регресия. ESN беше въведен като подобър начин да се използва изчислителната мощност на RNNs, без да се налага да се тренират вътрешните тегла, но от тази гледна точка резервоарът действа като сложен нелинеен динамичен филтър, който трансформира входните сигнали с помощта на висока величина времева топология. Възможно е дори да се решат няколко задачи по класификацията на входен сигнал чрез добавяне на множество показания към един резервоар. Jaeger смята, че ESNs резервоарът трябва да бъде мащабиран така, че да работи на ръба на стабилността, като настройва спектралния радиус на свързващата матрица близо до, но по-малко от единица. Машината с течни състояния Liquid State Machine (LSM) от (Maass, et al., 2002) първоначално е представена като обща рамка за изчисляване в реално време на времеви сигнали, но повечето описания използват абстрактен модел на колоритния микроколон. В дисертацията има допълнително обяснение на *reservoir computing*.

5.2. Изследване 4: Echo State Networks за избор на характеристики в афективните изчисления

ESN са динамични структури, създадени първоначално за улесняване на обучението в периодични невронни мрежи, които обикновено се прилагат за моделиране на динамични серии. В тази работа показваме, че резервоарите ESN могат да служат като ефективна процедура за избор на функции, които подобряват разграничаването на човешката емоционална валентност от ЕЕГ сигналите, задача, която спада към изследователската област на афективните изчисления. Редица контролирани и ненаблюдавани техники за машинно обучение, снабдени с новия фундаментен вектор, извлечен от запаси от ESN, са проучени по отношение на тяхната точност на разграничаване. Това ново приложение служи като доказателство за концепцията за възможността за

разширяване на използваемостта на ESN в класификацията или клъстерирането.

5.2.1. Въведение

Echo State Networks (ESN) представляват клас от рекурентни невронни мрежи (RNN), където е формулиран така нареченият подход за обучение с "резервоар за изчисление" (Lukosevicius, et al., 2009). Основната идея на този биологически вдъхновен подход е да имитира структури в човешкия мозък, които изглеждат съставени от произволно свързани динамични нелинейни неврони, наречени резервоари, чиято продукция обикновено е линейна комбинация от настоящите състояния на резервоарните неврони. Основното предимство на ESN е опростеният алгоритъм за тренировка, тъй като само тренировки на връзките от резервоара към невроните за четене се подлагат на обучение. По този начин вместо градиентното спускане може да се използва много по-бързо метод с най-малките квадрати. По-задълбочено представяне на ESN може да се прочете в дисертацията.

5.2.3. ESN за избор на характеристики

Оригиналната характеристика на матрицата (7) беше обработена чрез резервоара ESN, следвайки процедурата, разработена в (Koprinkova-Hristova, et al., 2013c) (Koprinkova-Hristova, et al., 2013a) (Koprinkova-Hristova, et al., 2013d) (Koprinkova-Hristova, et al., 2013b) (Koprinkova-Hristova, et al., 2014b) (Koprinkova-Hristova, et al., 2014a). Алгоритъмът в две стъпки е описан в Таблица 5.1:

Стъпка 1: IP настройка на резервоара ESN с използването на оригинален набор от данни;

Структурата на ESN се определя в зависимост от размера на оригиналната матрица (7), така че размерът на входния вектор ESN съответства на броя на оригиналните характеристики (в този случай 252 признаци). Тъй като изследваме само изхода на

резервоара, размерът на показанието няма значение и той е настроен на единица. Размерът на резервоара варира от 10 до 500 неврони, за да проучим влиянието му върху точността на емоционалната валентна дискриминация. Нашите експериментални резултати с 10, 30, 50, 100, 150, 300 и 500 неврони са визуализирани в следващия раздел. IP тунингът беше направен чрез представяне един по един на функционалния вектор на всички примери за обучение към ESN входа за предварително определен брой итерации (използвахме десет повторения) и коригиране на печалбата и термините на пристрастия, използвайки градиентните правила от (Schrauwen et al., 2008).

Стъпка 2: Изчисляване на равновесното състояние на всички резервоарни неврони.

Тъй като е трудно да се анализира аналитично уравнението за равновесни състояния, съответстващи на всяка входна информация:

$$r_e = \tanh \left(\text{diag}(a) W_{in_c}^{in} + \text{diag}(a) W_e^{res} r_e + b \right) \quad (5.11)$$

Равновесните състояния r_e се определят чрез симулации за предварително избран брой стъпки до достигане на равновесно състояние (в нашите експерименти бяха достатъчни 25 стъпки). Постигнатите равновесни състояния на резервоарните неврони се запазват като нов елемент на функция, наречен по-нататък *esn_features*.

Таблица 5.1: Алгоритъм за получаване на новия фундаментен вектор, като вектор на равновесни състояния на неврони в резервоара ESN.

```

in(1:features number,1:examples number)=original_features;
nin=features number; nout=1; nr=chosen number;
esn=generate_esn(nin, nout, nr);
for it=1:number of IP iterations
    for i=1:examples number
        esn=esn_IP_training(esn, in(:,i));
    end
end
end

```

5.2.4. Разграничаване на емоционалната валентност - експериментални резултати

В тази секция ние използваме произведените от ESN характеристики (esn_features), за да разграничим положителната и отрицателната емоционална валентност, прилагайки контролирани (класифициращи) или безконтролни (клъстерийни) техники за обучение. Бяха изследвани два подхода, свързани с новото пространство:

Подход 1: Използване на всички възможни 2D комбинации между равновесни състояния $re(i)$ и $re(j)$ на всеки два неврона i и j от резервоара ESN като 2D фундаментен вектор.

Този подход картографира оригиналния набор от данни за характеристиките в по-голямо пространство на равновесие на резервоарите, т.е. първо разширяваме набор от данни и след това


избираме най-добрите 2D прогнози измежду всички възможни комбинации.

Подход 2: Използвайки всички равновесни състояния на резервоарите esn_features като нов векторен елемент.

За разлика от първия подход, подход 2 картографира оригиналния набор от данни за характеристиките в резервоар с по-малък размер и по този начин новият набор от функции има по-нисък размер. Този подход е аналогичен на PCA (Основен компонентен анализ), при който първо се извършва намаление на характеристиките преди класифицирането или групирането.

В следващия раздел, подход 1 и подход 2 се прилагат към два основни алгоритъма за клъстеризиране, к-среди и размити среди C (FCM).

5.2.4.1. *Клъстериране (събиране и групиране) на данни*




Фигура 5.3: Точност на всички алгоритми за клъстериране, използващи различни набори от характеристики.

Във Фигура 5.3 са обобщени дискриминационните точности на к-среди и FCM. Трябва да се отбележи, че подход 1 произвежда разнообразие от 2D набор от характеристики и във фигура 5.3 са представени резултатите за точност само за най-добрите 2D

комплекти от функции. Сред огромния брой комбинации от 2D функции само някои от тях постигат тези резултати. За сравнителни цели представяме и точността на клъстериране на k-средни и FCM, използвайки матрицата на оригиналните характеристики (7).

5.2.4.2. *Класифициране на данни*

Същите модели на ENS бяха тествани за случая на надзорно обучение, за да се разграничат двете емоционални валенции. За да премахнем проблема с избора на "грешен" или "щастлив" модел, ние приложихме редица стандартни класификатори, а именно Linear Discriminant Analysis (LDA), k-Най-близки съседи (kNN), Naïve Bayes (SVM) и дърветата за решения (DT). Поради ограничения брой примери (само 26 субекта), се приема кръстосано валидиране с "leave-one-out". За да се увеличи статистическата достоверност на получените резултати, беше извършена и класификация, основана на мнозинството от гласовете на класификаторите (LD, kNN, NB, SVM и DT). Ние наричаме тази йерархична методика за класификация ГЛАС.



Фигура 5.4: Точност на всички алгоритми за класификация, използващи различни набори от функции.

5.2.5. Заключение

В това изследване ние предлагаме ESN като механизъм за избор на функции в два сценария: i) да очертаем оригиналните характеристики в разширено функционално пространство, определено от броя на невроните на резервоара (повече неврони от ENS входовете) и да изберем най-добрата комбинация от два неврона (2D проекция) като нови функции; ii) картографиране на оригиналните характеристики в намалено пространство, дефинирано от броя на невроните на резервоара (по-малко неврони от ENS входовете), които да се използват като нови функции. И двата сценария бяха тествани по представляващия предизвикателство проблем на афективното изчисляване на базата на данни от невронния мозък (ERPs). В 2D проекционния сценарий винаги е възможно да се намери комбинация от функции, които да групират или класифицират данните с разумна точност (близо до 80% за клъстера и близо до 89% за задачата за класификация).

Компютърната сложност обаче е неизбежен проблем, особено когато размерът на резервоара се увеличава. Освен това, се оказва, че само няколко от огромния брой комбинации от неврони (например 124750 комбинации за $n_r = 500$) са правилният избор.

Въпреки това, тези доказателства за концептуални резултати ни насърчават да тестваме ESN по-нататък като стъпка за избор на функции преди класификацията / клъстеризирането на данни в други приложения.

5.3. Изследване 5: Резервоарни изчисления за разграничаване на емоционални валентности от ЕЕГ сигнали

В този раздел предлагаме нов подход за намаляване на измерението на размерите на базата на Reservoir Computing.

Методът се валидира с данни от ЕЕГ, за да се идентифицират общите невронни подписи, въз основа на които положителната и отрицателната валентност на човешките емоции в множество субекти може да бъдат надеждно разграничени. Ключовата стъпка в предложения подход е адаптирането на състоянието на резервоарите (Intrinsic Plasticity (IP)). Изучаването на ESN с IP максимизиране на ентропията на разпределението на векторите на резервоарите, като статичните данни се определят като фиксиран вход, който се предполага, че следва гаусовото разпределение. Векторът на равновесния резервоар се екстрахира за всеки статичен входен вектор чрез повтаряеми актуализации на резервоарния вектор, докато се сравни. Стандартните модели за класифициране и клъстеризиране, осигурени с комбинации от два, три или повече неврони на резервоарите, се класират въз основа на дискриминационното им представяне. IP настроените ESN са по-мощна техника за нанасяне на вектора на големите величини на входния елемент в нискоразмерно представяне и подобряване на дискриминацията на емоционалната валентност в сравнение с класическите ESN и Deep Neural Encoders.

5.3.3. Групиране с ESN - експериментални резултати

Резултатите показват, че винаги получаваме подобрение в производителността след IP-адаптирането на резервоара. Също така виждаме, че ефектът от IP обучението е по-осезаем, когато се сравняват нискоразмерни комбинации от състояния на резервоари със и без обучение по IP. Числените стойности, свързани с фигура 5.11 и фигура 5.12, са дадени съответно в таблица 5.4 и таблица 5.5.




Figure 5.9: K-means accuracy (%) for varying ESN reservoir dimension. Feature sets: i) all equilibrium states- ESN all (from ESN10 to ESN500); ii) combinations of equilibrium states (2D, 3D, 4D, 5D, 6D, 7D); iii) initial feature matrix (252D).




Figure 5.10: FCM accuracy (%) for varying ESN reservoir dimension. Feature sets: i) all equilibrium states- ESN all (from ESN10 to ESN500); ii) combinations of equilibrium states (2D, 3D, 4D, 5D, 6D, 7D); iii) initial feature matrix (252D).

5.3.4. Класификация с ESN - експериментални резултати

5.3.4.1.

Общото наблюдение във всички сценарии е, че увеличаването на измерението на резервоара подобрява точността на

класифициране. Тази тенденция е свързана с нарастващия брой комбинации и следователно с по-висока разделителна способност за търсене и откриване на най-добрите дискриминационни черти на вектори. Обърнете внимание обаче, че сценарият i) изглежда, не се влияе от вариацията на резервоара. Друго интересно наблюдение е, че като цяло класификационните техники превъзхождат методите на клъстеризиране, особено когато всички равновесни състояния се разглеждат като характеристики.




Figure 5.13: Classification accuracy with all reservoir equilibrium states for varying reservoir size




Figure 5.14: The best classification accuracy (%) with 2D combinations of reservoir equilibrium states for varying reservoir size




Figure 5.15: The best classification accuracy (%) with 3D combinations of reservoir equilibrium states for varying reservoir size




Figure 5.16: The best classification accuracy (%) with 4D combinations of reservoir equilibrium states for varying reservoir size




Figure 5.17: The best classification accuracy (%) with 5D combinations of reservoir equilibrium states for varying reservoir size




Figure 5.18: The best classification accuracy (%) with 6D combinations of reservoir equilibrium states for varying reservoir size

5.3.4.2. Модел на дълбока невронна мрежа за разграничаване на емоционалната валентност




Figure 5.19: Deep Neural Network (DNN) structure

Изградихме DNN класификационни модели с един, два и три авто-енкодера (Фигура 5.19). Размерът на входния вектор DNN съответства на броя на оригиналните елементи (252). Размерът на първия еncoder варира между 10 и 500 неврони. Резултатите от единични автоенкодерни DNN с 10, 30, 50, 100, 150, 300 и 500 неврони са визуализирани на Фигура 5.20. Когато размерът на еncoderа е по-малък от размера на входа (т.е. еncoderи с 10, 30, 50, 100 и 150 неврони), автокодиращият научава компресирано представяне на входа. В обратния случай (т.е. еncoderи с 300 и 500 неврони) авто-кодиращият проектира входните данни в по-висока величина, подобно на трансформацията на данни на базата на ядрото. Резултатите от фиг. 16 не показват ползи от разширяване

на входните данни в сравнение с представянето на компресирани данни.




Figure 5.20: Classification accuracy of DNN with one autoencoder




Figure 5.21: Classification accuracy of DNN with two autoencoders




Figure 5.22: Classification accuracy of DNN with three autoencoders

5.3.5. Заключение

Демонстрираме, че използването на предварителна подготовка за изчисляване на резервоарите е от полза за избора на най-важните дискриминационни характеристики и постигането на най-съвременните резултати за разпознаване на емоционалната валентност на индивида. Това изследване потвърждава наблюдението, че подходът за изчисляване на резервоарите може да се използва не само за обработка на времеви серии, но и за представяне на статични данни с големи размери. Също така представихме експериментални доказателства, че IP-настройките ESN може да повиши производителността в сравнение с класическата (без предварително обучение) ESN както при решаването на клъстериране, така и при класификационните задачи. Накрая демонстрирахме, че IP-настройването превъзхожда

предварително обучените дълбоки авто-енкодери и всъщност може да постигне почти 100% точност на тестване. Разходите за това значително подобрение са изчислителното време, необходимо за тестване на всички комбинации от векторни елементи и извличане на най-дискриминиращите. Този проблем е особено важен за големите резервоари. Например за резервоар с 500 неврони трябва да бъдат анализирани 124750 комбинации от състояния на 2D равновесие. Следователно ние предложихме да се справим с този проблем, като класираме комбинациите от неврони при всяка итерация и избираме само най-добрите комбинации за следващата итерация.

Резултатите от това изследване могат потенциално да допринесат за текущия дебат относно алгоритмите за представяне и обучение на данни, особено дали DNN са по-подходящи за мащабни проблеми с машинното обучение. Следователно прилагането на алгоритъма, представен в раздел 2, относно ESN в различен контекст, изглежда атрактивна линия на бъдещи изследвания.

6. Заключение

6.1. Заключение и последващи задачи

Може да се заключи, че ML е мощна техника за разкриване на мозъчната дейност и тълкуване на човешките емоции. Има много допълнителни възможности за ML изследвания в контекста на афективната невронаука като разграничаване на повече от две емоционални състояния, свързани не само с емоционалната валентност, но и с емоционалната възбуда. Разграничаването на високия срещу ниския невротичен тип на личността също е сериозен проблем, с който ML може да се справи. Също така броят на участниците в експериментите е важен за разкриването на стабилни общовалидни предиктори. В прегледаните референции средният брой участници е около 10-15, като максималният е 32. Нуждаем се от обществено достъпни набори от данни за сравняване на различни техники и по този начин ускоряваме напредъка на афективното изчисляване.

6.2. Научни приноси

1. Предложен е подход за определяне на конкретни характеристики, получени от ЕЕГ сигнали, които да се използват за оценка на емоционално състояние с оглед осигуряване на необходимата дискриминативност при изграждане на човеко-машинен интерфейс.
2. Предложен е метод, който използва машинно обучение с Echo State Networks (ESN) за определяне на дискриминативни характеристики за оценка на емоционално състояние.

6.3. Научно-приложни приноси

1. Предложени са алтернативни подходи за разпознаване на човешки емоции на базата на регистрирани физиологични сигнали с използване на машинно обучение от гледна точка на възможностите за извличане на релевантни характеристики за разграничаване на положителна и отрицателна емоционална валентност.
2. Предложени са релевантни параметри за измерване на ЕЕГ сигнали, чрез които да се осигури нужната дискриминативност на характеристиките за оценка на емоционално състояние.

6.4. Приложни приноси

1. Изследвани са и са експериментално оценени предложените алтернативни подходи за разпознаване на човешки емоции на базата на регистрирани физиологични сигнали с използване на машинно обучение.
2. Изследвани са и са експериментално оценени предложените параметри за измерване на ЕЕГ сигнали, осигуряващи нужната дискриминативност на характеристиките за оценка на емоционално състояние.
3. Изследван е и е експериментално оценен предложеният подход за машинно обучение за разпознаване на човешки емоции с ESN като механизъм за избор на характеристики с релевантни дискриминативни свойства, адекватни на изискванията за машинно обучение и разпознаване на емоционална валентност

Приложение А

Хубави, изчистени и означени масиви от данни за класификация на EEG и MEG стават все по-достъпни заради отвореното публикуване от изследователски институции и университети, както и от онлайн състезания, организирани от Kaggle и подобни платформи. Тези набори от данни обаче са силно специфични за един проблем, например, състезанията на Kaggle Predict seizures in intracranial EEG recordings¹ и Grasp-and-Lift EEG Detection². В много случаи колоните в тези набори от данни са разбъркани и изследователите не могат да имат познания за показателите, откъдето идват сигналите. В други случаи сигналът е предварително обработен с неизвестни методи.

Последните постижения в областта на EEG, сензори и мобилни технологии доведоха до появата на компании, произвеждащи икономични и ефективни мобилни EEG устройства: Emotiv, NeuroSky и Muse - фигура А.1. Софтуерът, доставен с тези устройства е ограничен във функционалност. Обикновено устройствата идват със софтуер, който демонстрира някои способности на устройството или показва EEG сигнали в реално време, без възможност за записване на сигнала на диск или за маркиране на събития по време на генерирането на сигнала или за интегриране с други софтуери за извършване на експерименти.

¹ <https://www.kaggle.com/c/seizure-prediction> accessed on 30 September 2016

² <https://www.kaggle.com/c/grasp-and-lift-eeeg-detection> accessed on 30 September 2016



Фигура А.1 От ляво на дясно: Мобилни EEG устройства от Emotiv, NeuroSky и Muse.

Необходимостта от записване и съхранение на EEG сигнала по време на експерименти с устройството Emotiv Epoc ни накара да разработим собствен софтуер за получаване на EEG сигнал от Emotiv Epoc.

През стажантската си програма "Еразмус +" в Университета в Авейро, Португалия под ръководството на доц. инж. Петя Георгиева, разработихме софтуер за записване на EEG сигнал и съхранение на диска.


Основните функционалности на този софтуер са:

- Интеграция с вътрешните библиотеки от Emotiv, за получаване сигналите от сензорите на устройството през Bluetooth в реално време.
- Запис на сигналите в лесен за интерпретиране формат (CSV).
- Лесен за работа потребителски интерфейс, показващ текущо състояние на сензорите.
- Функционалност за лесна анотация на събития. Пример: използвахме микрофона на компютъра, като сензор за да регистрираме много точно потупвания от пръстите върху бюро и да отбележим събитията в потока от сигнал доставан от устройството. Друга възможност е

Софтуерът, който разработихме е подходящ за по-нататъшно извличане на данни и експериментиране и е достъпен в Лабораторията за машинно обучение в Университета в Авейро, Португалия. Студенти продължиха да изследват контрола на малки работи с мисъл в реално време, като използват този софтуер като връзка за регистриране на мозъчни вълни от устройството Emotiv Epoch. Фигура A.2 представлява снимки на двама души, носещи слушалките и техните мозъчни вълни се записват. Фигура A.3 показва потребителския интерфейс на рекордера EEG, който разработихме.



Figure A.2 People using Emotiv Epoch headset at ML Lab at University of Aveiro, Portugal.



Фигура A.3 EEG Recorder потребителски интерфейс.