

Department of Computer Architecture and Technology
Konputagailuen Arkitektura eta Teknologia saila
Departamento de Arquitectura y Tecnología de Computadores



Universidad Euskal Herriko
del País Vasco Unibertsitatea

University of the Basque Country

INFORMATIKA FAKULTATEA
FACULTAD DE INFORMÁTICA

Konputazio fisiologikorako ekarpenak ikasketa automatikoaren bidez

Doktorego-tesiaren egilea:
Asier Salazar Ramírez

Doktorego-tesiaren zuzendariak
Andoni Arruti Ilarramendi
Jose Ignacio Martín Aramburu

Donostia, 2020ko martxoa

Department of Computer Architecture and Technology
Konputagailuen Arkitektura eta Teknologia saila
Departamento de Arquitectura y Tecnología de Computadores



Universidad Euskal Herriko
del País Vasco Unibertsitatea

University of the Basque Country

INFORMATIKA FAKULTATEA
FACULTAD DE INFORMÁTICA

Konputazio fisiologikorako ekarpenak ikasketa automatikoaren bidez

Doktorego-tesiaren egilea:
Asier Salazar Ramírez

Doktorego-tesiaren zuzendariak
Andoni Arruti Ilarramendi
Jose Ignacio Martín Aramburu

Donostia, 2020ko martxoa

Lan honek finantziaketa jaso du hainbat iturri desberdinetatik. Eusko Jaurlaritzako hezkuntza saileko unibertsitateak eta ikerketa atalak sustengatzen duen ADIAN ikerketa taldetik (IT980-16 erreferentzia) eta Espainiako Gobernuako Zientzia, Berrikuntza eta Unibertsitate Ministeriotik, ERDFak lagunduta (PhysComp project, TIN2017-85409-P).

*“Intelligence is an accident of evolution,
and not necessarily an advantage.”*

Isaac Asimov

Abstract

Since the last decades the world's population is suffering a shift in the age distribution of its demography. There is no doubt that this change in the demographic distribution is going to have a great impact on various aspects of society, as are, for example, education, the size and productivity of the labour force and public health. In fact, it is already possible to observe certain consequences of this phenomenon, as it can be seen, for instance, in the debate around the quantity and sustainability of the pensions. In this way, it is clear that, in the coming decades, our society is going to face serious challenges towards maintaining the life-quality and autonomy levels that today's elderly population is having.

Taking this premise as a base, this doctoral thesis intends to do its little contribution to the state of the art of physiological computing. This discipline is found in an intermediate point between medicine and engineering and its objective is to enable the automatic processing of the changes in the physiological signals of the human body. This way, the final objective of applying computation techniques in the world of physiology is not other than being able to give a technological solution to the diverse problems that people with special needs and their caregivers face in their everyday life.

In this sense, the work presented in this thesis works on two main lines. The first line is focused on the computation of different variables of the body to detect those situations in which an individual could be getting involved in a situation of maintained stress. Besides, this line also develops its work in the opposite direction to the detection of stress, the detection of relaxation. After all, the detection of the changes that relaxation produces in the body can be useful in the area of preventive medicine and, as such, the new tendencies in modern medicine highlight the importance of both physical and mental well-being for avoiding the appearance of certain diseases. Being able to automatically detect when and how a subject is getting relaxed will undoubtedly make it easier to know which relaxation techniques fit best and bring better results to that person.

On the other hand, the other research line present in this thesis focuses on the search for alternative ways to interact with machines beyond the use of the mouse or the keyboard. More precisely, this second line gets into the world of Brain-Computer Interfaces or, as is best known in the literature, BCI. In this context, this document presents the work developed in the field of the classification of encephalographic patterns for imaginary movement problems. The work related to this subject focused on maximising the accuracy of motor ima-

gery movement classification while maintaining the number of false movement intentionality detections within acceptable values.

Laburpena

Azkenengo hamarkadetatik hona munduko biztanleria zahartze prozesu nabari bat sufritzen ari da. Zalantza barik, distribuzio demografikoan ematen ari den aldaketa honek eragin handia izango du sozietateko zenbait esparrutan, hara non, hezkuntzan, biztanleria aktiboaren tamainan eta bere produktibitatean edota osasun publikoan. Izan ere, bada posible zenbait ondorio aurkitzea, adibidez, pentsioen kopuruaren eta iraunkortasunaren inguruan egunero ikusten dugun tirabiretan. Hortaz, argi dago datorren hamarkadetan biztanleriak erronka sozial eta teknologiko handiak aurrean izango dituela gaur egungo hirugarren adinekoek disfrutatzen dituzten bizi kalitate eta autonomia mailak mantentzeko.

Premisa hau oinarritzat hartuta, tesi honek bere ekarpen txikia egin nahi dio konputazio fisiologikoko esparruari. Diziplina hau medikuntzako eta injinerutzako munduen artean aurkitzen da eta giza gorputzeko seinale fisiologikoen ematen diren aldaketak automatikoki prozesatzea du helburu. Hau honela izanda, fisiologiako munduari konputazio teknikak aplikatzearen xede nagusia behar bereziak dituztenek eta euren begiraleek egunero aurkitzen dituzten arazoei irtenbide teknologiko bat ematea da.

Zentzu honetan, tesi honen bidez aurkezten ari den lan honek bi ildo nagusi jorratuko ditu. Lehenengo ikerketa lerroak gorputzeko aldagai ezberdinen konputazioa du ardatz bezala pertsona bat luzaroan mantendutako estres egoera batean sartzen ari den detektatzeko. Era berean, ikerketa lerro honek estresaren detekzioaren kontrakoa ere lantzen du, hara non, erlaxazioaren detekzioa. Azken finean, erlaxazioaren eraginez gorputzean ematen diren aldaketak detektatzea baliogarria izan daiteke medikuntza prebentiborako, eta, horrela izanda, medikuntzako tendentzia berriek ongizate fisiko eta psikologikoaren garrantzia nabarmentzen dute zenbait gaixotasunen agerpena ekiditeko. Zalantza barik, noiz erlaxatzen garen eta nola egiten dugun detektatzeak erabat erraztuko du norberari hobekien egokitzen zaizkion eta onura gehien egiten dizkion erlaxazio teknikak aurkitzearen bidea.

Bestalde, tesi honetan ageri den beste ikerketa lerroak makinekin interakzionatzeko bide alternatiboak bilatzearen ildotik jarraitzen du, arratoiaren eta teklatuaren erabilera alde batera uzten duena. Zehazki, bigarren lerro hau Burmuin-Konputagailu Interfazearen munduan barneratzen da. Mundu honi Literaturan Brain-Computer Interface bezala ezagutzen zaio (edo, are sinpleago, BCI siglen bitartez). Testuinguru honetan, dokumentu honek imajinario motorrerako patroik entzefalografikoen klasifikazioan egindako lana aurkeztuko

du. Gai honen inguruan egindako lanak imajinazio motorreko mugimenduak klasifikatzerakoan ahal bezain zehaztasun handiena lortzea bilatzen du, detekzio faltsuen kopurua tarte onargarri baten barruan mantenduz.

Resumen

Durante las últimas décadas la población mundial ha estado sufriendo un claro envejecimiento en su distribución demográfica. Sin duda, este cambio en la distribución de la demografía traerá consigo un gran impacto en varios aspectos de la sociedad, como por ejemplo, la educación, el tamaño de fuerza laboral y su productividad o la sanidad pública. De hecho, ya es posible observar ciertas consecuencias en el día a día, como se puede ver en el cada vez más común debate alrededor de la cuantía y sostenibilidad de las pensiones. De esta manera, queda patente que en las décadas venideras la sociedad se enfrentará a importantes retos sociales y tecnológicos y cuyo objetivo será el mantenimiento del nivel de calidad de vida y autonomía de los cuales disfruta la actual tercera edad.

Tomando esta premisa como base, esta tesis doctoral pretende aportar su granito de arena al estado del arte de la computación fisiológica. Esta disciplina se encuentra en un punto intermedio entre los mundos de la medicina y de la ingeniería y tiene como objetivo posibilitar el procesamiento automático de los cambios en las distintas señales fisiológicas del cuerpo humano. De esta manera, el objetivo final de la aplicación de las técnicas de la computación al mundo de la fisiología no es otro que poder dar solución tecnológica a los diversos problemas a los que se enfrentan las personas con discapacidades especiales y sus cuidadores.

En este aspecto, el trabajo presentado en esta tesis trabajará dos líneas principales. La primera línea se centra en la computación de diferentes variables corporales para detectar las situaciones en las que una persona se esté viendo implicada en un estrés continuado. Así mismo, la línea también desarrolla el aspecto opuesto a detectar estrés, esto es, la detección de la relajación. Después de todo, la detección de los cambios producidos por la relajación en el cuerpo puede ser útil en el área de la medicina preventiva y como tal, las nuevas tendencias de la medicina moderna están haciendo especial hincapié en la importancia del bienestar corporal y mental para prevenir la aparición de ciertas enfermedades. Discernir de manera automática cuándo nos relajamos y cómo lo hacemos, sin duda alguna allanará el camino para que cada uno halle las técnicas de relajación que mejor se adapten a su ser y que mayor beneficio le aporten.

Por otra parte, la otra línea presente en esta tesis se centra en el ámbito de la búsqueda de formas alternativas de interacción con las máquinas más allá del uso del teclado o del ratón. Más concretamente, esta segunda línea se adentra en el mundo del Interfaz Cerebro Computadora, más conocido en la literatura como

Brain-Computer Interface o simplemente por sus siglas, BCI. En este contexto, este documento presentará el trabajo realizado en el ámbito de la clasificación de patrones encefalográficos en problemas de imaginación motora. El trabajo realizado sobre este tema se centra en obtener la máxima precisión posible en la detección de movimientos imaginarios, intentando al mismo tiempo mantener la cantidad de falsas detecciones de movimientos intencionados dentro de márgenes aceptables.

Eskerrak

Eskerrak eman nahi dizkizut zuri, irakurleari, puntu honetara iristeagatik. Doktoetzako beste ikasle bat zarela, ala ez, dokumentu hau zure eskuetan baduzu, arlo honetan nolabaiteko interesa duzula esan nahi du. Tesiaz gozatzea espero dut eta, ere, irakurri ostean, ni hil nahi ez izatea. Zorte on ;)

- Lehenik eta behin, eskerrak eman nahi dizkiet nire tesi-zuzendariei eta tutoreari, emandako laguntza handiagatik. Tesi-prozesu osoan zehar gutian gidatu naute, eta, zalantzarik gabe, haien laguntzagatik ez balitz, lana askoz zailagoa izango zen niretzat. Eskerrik asko, Natxo, Andoni eta Javi.
- Eskerrak eman nahi dizkiet Aldapa eta Adian taldeetako kidei. Hemengo jendea hain da atsegina... Nork esango lioke Bilbotar bati hain ondo sentituko zela Donostian!
- Eskerrak eman nahi dizkiet tesi honetako epaimahaiari, hemen egoteagatik eta hain azkar etortzeko ahalegina egin duelako.
- Gainera, bereziki eskertu nahi diot Raqueli, beti nigan sinesteagatik. Gehiago ez ikertzea erabaki nuenean ere, berak gauzak bidaltzen jarraitu zuen nik lan egiteko. Berak aurkitu zuen ni Aldapako ikerketa-taldeko kide izateko aukera. Eskerrak ematea ez da nahikoa nigatik egin duzunaren truke.
- Orain, eskerrak eman nahi dizkiet Lisboako jendeari hain jende ona izan zirelako. Eskerrik asko: Hugo, Ana, Patricia, Mariana, Andre, Joana, Agaph... eta ezagutu nuen Erasmus jendea. Eskerrik asko, halaber, Joaori Castelo Brancon ni jasotzeagatik.
- Ondoren, eskerrak eman nahi dizkiet Eloyri, Unairi eta Mikeli, ni GICIk ikerketa-taldeko kidea naizela sentiarazteagatik. Onak zarete, mutilak.
- Eskerrak eman nahi dizkiet Ainhoa Yerari eta Ainhoa Etxautzi tesi hau amaitu baino lehen izan ditudan krisi uneetan eman didaten laguntzagatik. Eskerrik asko Ainhoak :)
- Musika taldeko kideek ere aipamen bat merezi dute, nirekin ulerkorrak izan direlako. Azkenik, entseguetara itzuliko naiz. Raust!

-
- Eskerrik asko, lagun guztiei nire tesirako eta laguntza-eskaintzetarako interesagatik. Eskerrik asko, halaber, Txarraska Gaztetxeari, hango jendea niretzat familia modukoa delako. Urte askotarako.

Mila esker nire senideei. Beti pentsatu izan dute hau egiteko gai nitzela, eta aurrera bultzatu naute beti.

Eskerrik asko, Maria. Zu izan zara nire euskarri psikologikoa. Zurekin bizitzeak hobeto eta seguruago sentiarezten dit.

Eskerrik asko, Jon, nire anaia maitea. Zurekin egoteak barre eragiten dit beti.

Eskerrik asko, aita. Pazientzia amaigabeagatik. Niretzat janaria prestatzea-gatik. Nigan sinesteagatik. Aita eta ama biak batera izateagatik. Denagatik. Onena zara.

Eta, azkenik, bereziki... Eskerrik asko, ama. Zure falta sentitzen dut. Hau zuretzat da.

Gaien Aurkibidea

I. Sarrera	xix
1. Konputazio fisiologikorako sarrera	1
1.1. Disertazioaren antolakuntza	3
II. Testuingurua: gizakiaren anatomia, fisiologia and horiei lotutako konputazioa	5
2. Gizakiaren oinarritzko anatomia eta psikologia	7
2.1. Sarrera	7
2.2. Organo sistemak	8
2.2.1. Tegumentu sistema	8
2.2.2. Nerbio sistema	10
2.2.3. Zirkulazio aparatua	19
2.2.4. Arnas-aparatua	24
3. Seinale fisiologikoak, logika lausoa, ikasketa automatikoa eta BCI sistemak	27
3.1. Sarrera	27
3.2. Seinale fisiologikoak eta ezaugarrien ateratzea	27
3.2.1. Elektrokardiograma (ECG)	28
3.2.2. Aktibitate elektrodermikoa (EDA)	33
3.2.3. Arnasketa (RESP)	37
3.2.4. Elektroentzefalograma (EEG)	39
3.3. Fuzzy-logika (logika lausoa)	46
3.3.1. Membresia-funtzioak	46
3.3.2. Erregela sistema	48
3.3.3. Azaleren bateraketa eta defuzzifikazioa	49
3.4. Ikasketa automatikoa	51
3.4.1. Gainbegiratutako ikasketa	52
3.4.2. Gainbegiratu gabeko ikasketa	65
3.4.3. Balioztatzeko datuen zatiketa partizioetan	67
3.4.4. Portaera ebaluatzeko neurriak	68
3.4.5. Sarri erabilitako beste erremintak	72

3.5.	Burmuin-konputagailu interfazeak (BCI)	73
3.5.1.	Gertaerei lotutako potentzialak (ERP)	74
3.5.2.	Bisualki eragindako potentzial egonkorak (SSVEP)	75
3.5.3.	ERD/ERS imajinazio motorreko sistemak	76
III.	Ekarpenak	79
4.	Estres-maila era jarraian zenbatesteko ekarpenak	81
4.1.	Sarrera	81
4.2.	Testuingurua eta erlazionatutako lanak	82
4.3.	Protokolo esperimentalak	83
4.4.	Seinale fisiologikoen prozesamendua	85
4.4.1.	ECG-a prozesatzen: R pikoien detekzio hobetua	85
4.4.2.	RESP seinalearen prozesamendua	89
4.4.3.	EDA prozesatzen	94
4.5.	Estres-maila zenbatesteko logika lausoko sistema	94
4.5.1.	Logika lausoko menbresia-funtzioen diseinua	94
4.5.2.	Erregela-sistema	96
4.6.	Emaitza esperimentalak	97
4.7.	Laburpena	99
5.	Contributions to detection of responses towards relaxation	101
5.1.	Introduction	101
5.2.	Context and related work	102
5.3.	Experimental setup and data analysis	103
5.3.1.	Data collection and preparation	103
5.3.2.	Qualitative analysis	106
5.3.3.	Quantitative analysis	111
5.4.	Application of machine learning	113
5.4.1.	Selection of the best classifying algorithm	113
5.4.2.	The synthesized rule system	114
5.5.	Summary	120
6.	Contributions to ERD/ERS Brain-Computer Interfaces	123
6.1.	Introduction	123
6.2.	Context and related work	124
6.3.	Data and experimental methodology	125
6.3.1.	The original dataset	125
6.3.2.	Expansion and preprocessing of the original dataset	127
6.4.	Previous approaches of the classification	130
6.4.1.	One-level system based on supervised learning	131
6.4.2.	Two-level system based on supervised learning	132
6.5.	Two-level hierarchical classification system using unsupervised learning	134
6.5.1.	First level: detection of movement intentionality	135

6.5.2. Second level: intentional movement classification	135
6.6. Experimental results	137
6.6.1. Testing the hierarchical two level system	137
6.6.2. Comparison of the results in the literature	139
6.6.3. Other results	141
6.7. Summary	143
IV. Konklusioak	147
7. Conclusions	149
7.1. Physiological computing	150
7.1.1. Continuous estimation of stress	150
7.1.2. Detection of physiological changes towards relaxation . . .	151
7.2. Motor imagery BCI systems	152
7.3. Future lines	153
7.4. Related publications	155
Bibliography	157

I. Atala
Sarrera

1. Kapitulua

Konputazio fisiologikorako sarrera

Elektronikak, eta bereziki ordenagailuek, izugarrizko garapena izan dute azken hamarkadetan. Aretu osoak okupatzen zituzten ordenagailuetatik gaur egungo mugikor adimendun txikietaraino, ordenagailuen potentzia konputazionala esponentzialki hazi da eta, beraz, gaur egun bada posible aurreko mendean pentsaezinak ziren kalkulu konplexuak eta algoritmoak implementatzea. Hori horrela izanik, ordenagailuen erabilerak aspaldi utzi zuen laborategiaren ingurune esperimentalak, eta gure bizitzaren parte bihurtu da; izan ere, Internetarako konexioa galtzeak galera ekonomiko handiak ekar diezazkioke pertsona batzuei.

Iraultza teknologiko honek diziplina profesional guztietan eragina izan du, ez bakarrik arlo teknikoetan, baita gizakiak arreta guztia hartzen duen dizipline-tan ere, hala nola medikuntzan edo psikologian. Ildo horretatik jarraituz, ohikoa da medikuek pazienteen gorputzetatik datozen seinaleak nola biltzen dituzten ikustea. Seinale horiek medikuei, erizainei eta beste profesional batzuei aukera ematen diete haien pazienteen osasuna ebaluatzeko. Gainera, giza seinaleen analisiarekin lotutako teknologiek konplexutasun oztopoak eta oztopo ekonomikoak hautsi dituzte, eta uste baino urrunago heltzea lortu dute. Adibidez, gero eta ohikoagoa da paziente diabetiko gazteek beso batean glukosa-sentsore bat uneoro eramatea. Sentsore horiek haien mugikorretara konektatzeko gaitasuna dute, eta azkenengo hauek, hurrengo injekziorako intsulina-kantitaterik egokiena kalkulatzeko aplikazio baten bitartez.

Hala ere, teknologia eta konputazio tekniken hedapenak oraindik ez ditu gizakion eta gizartearen behar guztiak asetu. Alde horretatik, badira oraindik arazo batzuk irtenbide teknologiko baten zain daudenak, gizartearen zati baten bizi-kalitatea hobetzeko. Adibidez, ikertzaile askok garuneko jarduera neuronala eta burumuin-konputagailu interfazeak aztertzen dituzte, neuroendekapenezko gaixotasunak dituzten pertsonen beraien ingurunearekin elkarreragiten lagunduko dieten sistemak aurkitzeko [1]. Gainera, asko lor daiteke ezgaitasun kognitiboak dituzten pertsonen ulermena eta elkarreragina hobetzeko, pertsona

horiek nola sentitzen diren zehazteko modu bat aurkituko balitz. Horri dagokionez, ikertzaile batzuen ustez emozioak eta sentimenduak detektatzeko aukera seinale fisiologikoen analisi automatikoan datza, konputazio-teknikak erabiliz.

Batzuetan, teknika konputazionalen eta ingeniartzako beste teknika batzuen aplikazioak ez ditu laborategiko mugak zeharkatzen. Horretarako arrazoi bat izan liteke konpondu beharreko arazoak konplexuak direla eta, beraz, konponbideen emaitzak oraindik ere ez direla perfektuak. [2]en adierazten den moduan, gizaki-makina interfazeak eraginkorra, efiziente, segurua eta ikasteko eta gogoratzeko erraza izan behar du. Nolanahi ere, literaturan proposatzen diren konputazio fisiologikoko soluzio gehienek sentsoreak, erreminta eta algoritmoak erabiltzea eskatzen dute. Zoritzarrez, hauek ez dira ohiko gauzak erabiltzaile arrunterako, eta, beraz, soluzio horiek ezin dira aplikatu bizitza errealeko egoeretan. Beraz, alde zurretik existitzen diren konponbideak hobetzeko ikertu behar da; edo, are gehiago, oraindik tratatu gabeko arazoei soluzio bat emateko proposamen berriak sortzeko. Adierazpen hau motibazio gisa hartuta, tesi honetan aurkeztutako lanaren helburu nagusia konputazio fisiologikoarekin zerikusia duten bi arazo espezifiko hobetu eta konpontzea izan zen.

Tesi honetan aurkeztutako lehen ekarpena estres mentalaren detekzio eta estimazioarekin lotuta dago. Estresa oso sindrome arrunta da, sintoma fisiko eta psikologikoak sortzen dituena eta egunero genero eta adin guztietako pertsonen sufritzen dutena. Osasun-arazo arrunta den arren, oraindik ere zaila egiten zaie ikertzaileei estres maila kalkulatzeko metodo automatikoak erabiliz. Horrenbestez, lehenengo ekarpen honek estres mailaren estimazio jarraitua lortzeko metodologia bat proposatzen du, artefaktuen aurka sendoa dena. Hasteko, elektrokardiogramen R pikoak detektatzeko metodo automatiko bat aurkezten du, artefaktuak eta offset zaratak errefustazen dituena eta bihotz-erritmoaren eta bihotz-erritmoaren aldakortasunaren seinale fidagarriak ematen dituena. Gainera, arnas seinalearen ezaugarri berri bat ateratzea proposatzen du ekarpenak. Egoera estresagarrietan ezaugarri honek ematen dituen balioak ezberdinak dira egoera lasai batean ematen dituenekin alderatuta, eta beraz, estresa ebaluatzeko hautagai ona da. Azkenik, ekarpen honek alde zurretik existitzen zen logika lausoko sistema baten aldaketa aurkezten du, estresatu gabeko adimen-egoeren eta estresatutako adimen-egoeren arteko trantsizioak kalkulatzeko ematen dituena, aurreko soluzioarekin alderatuta, modu ez oldarkor batean. Hau lortzeko, sistemari menbresia-funtzio berriak erantsi zitzaizkion eta, baita ere, inferentzia-erregelen sistema sinplifikatu zen. Laburbilduz, ekarpen honek logika lausoko sistema bat eman zuen, estres mentala era jarraituan ebaluatzeko balio duena eta bat-bateko aldaketa fisiologikoen aurrean bortizki erreakzionatzen ez duena.

Jarraipen gisa, estresaren gaiari lotuta, bigarren ekarpenak estresaren kontrako fenomeno mentalaren detekzioa jorratzen du, erlaxazioa, alegia. Literaturan, erlaxazioaren azterketa ez da maiz ikuspegi tekniko batetik aztertu, eta, egin denean, estresaren azterketari lotuta egon da, erlaxazioa bera automatikoki detektatzen saiatu beharrean. Nolanahi ere, Osasunaren Mundu Erakundeak honako hau dio [3]: osasuntsu egoteko, gaixotasunik ez izateaz gain, ongizate bai fisiko zein psikologikoa izan behar dela ere. Bizimodu azkarreko garai hauetan,

erlaxazioa lortzea funtsezkoa da osasun mental ona izateko. Beraz, gai horri buruzko azterlanak falta zirela ikusita, ikerketaren zati honetan, taldeak psikologo eta fisiologo talde batekin lankidetzan jardun zuen, erlaxazioa ematen denean fisiologian gertatzen diren aldaketak aztertzeko. Azterketa honek aldaketa fisiologiko horiek aztertzen ditu, bai erlaxazioa egoera estresagarri baten barruan ematen denean zein erlaxazio teknikak erabiltze direnean estresagarria ez den egoera batean. Taldeak aldaketa horiek nola detektatu aztertu zuen, izerdiaren aktibitate elektrodermikoaren seinalea soilik erabiliz. Seinale horretatik, konputazionalki garestiak ez diren bi ezaugarri atera zituzten. Ondoren, ezaugarri horiek ikaskuntza automatikoko teknika desberdinetan erabili ziren, erlaxazioaren adierazgarriak diren aldaketa fisiologiko horien presentzia detektatzeko eta euren intentsitate-maila sailkatzeko.

Azkenik, tesiaren azken ekarpenak beste azterketa-arlo bat jorratu zuen. Gizakiaren eta makinaren arteko interakzio sistema alternatiboak aurkitzeari lotuta dago. Zehazkiago, irudimen motorreko burmuin-konputagailu interfaze (BCI) sistemak ditu ardatz. Sistema hauek erabiltzailearen burmuinaren aktibitatea aztertzen dute, erabiltzaileak gorputzaren zati jakin bat mugitzeari buruz pentsatzen duenean sortzen diren seinale-patrioak detektatzeko helburuarekin. Sistema hauen funtzionamendu-printzipioa sinplea da. Lehenik eta behin, erabiltzaileak mugimendu batean pentsatzen duenean zein seinale-patrio errepikatzen diren ikasiko du ordenagailuak. Gero, ikasi ondoren, ikasitako patroien bat detektatzean, konputagailuak erabiltzaileak definitutako aginduak emango dizkio eragingailu bati ingurumenarekin elkarrengaitzeko. Beraz, BCI sistemek erabiltzaileari muskulu-jarduerarik gabe ingurumenarekin elkarrengaitzeko aukera ematen diote. Honek, behar bereziak dituzten pertsonen laguntzeko ez ezik, helburu industrial edo komertzialetarako ere balio du, bideo-jokoen industrian bezala. Ekarpen honetarako, taldeak literaturan ongi ezagutzen den datu-multzo bat hartu zuen, gorputzeko lau atal ezberdin mugitzeari buruzko pentsamenduak sailkatzeko problema proposatzen duena: eskuineko eskua, ezkerreko eskua, hizkuntza eta oinak. Gainera, sistema hauek geldirik egon behar dutenez erabiltzailea mugitzeari buruz ez duenean pentsatzen, taldeak aparteko patroia bat erantsi zion arazoari: mugitzeko asmo eza. Gero, taldea problema ebatzen saiatu zen ikasketa automatikoko soluzio ezberdinak erabiliz: lehenik, soilik gainbegiratutako ikaskuntza-algoritmoak erabiliz topologia ezberdinetako sistemetan; bigarrenik, clustering-a eta gainbegiratutako ikaskuntza-algoritmoak konbinatzen zituen sailkapen hierarkikoko topologia erabiliz. Azkenik, bigarren proposamen honek emaitza onak lortu zituen, literaturako beste soluzio batzuekin alderatu zen eta emaitza konparatibo onak lortu zituen.

1.1. Disertazioaren antolakuntza

Sarrera honi dagokion atalaz gain, tesi hau beste hiru zatitan banatu da. Tesi honetan aurkeztuko diren ekarpenak geroago ulertzeko beharrezkoak diren anatomiciarekin, fisiologiarekin, konputazio fisiologikoarekin eta ikaskuntza automati-

1. KAPITULUA - KONPUTAZIO FISIOLÓGIKORAKO SARRERA

koarekin zerikusia duten funtsezko alderdiak aurkeztuko dira II. Atalan. 2. Kapituluarekin hasiko da. Kapitulu horretan, anatomiaren eta fisiologiaren funtsezko printzipioak azalduko dira, lan honen azterketan parte hartzen duten organo-sistemen funtzionamendua arautzen dutenak. Ondoren, 3. Kapitulan, tesi honetan egindako azterketekin zerikusia duten giza gorputzaren aldagaiak neurtzen dituzten seinaleak aurkeztuko dira. Kapitulu honetan, halaber, seinale horietatik atera ohi diren ezaugarriak aztertuko dira.

II. Atalaren ondoren, tesiak literaturari egindako ekarpenen atalarekin jarraituko du: III. Atala. Atal hau hiru kapitulutan banatu da, tesi honen ekarpen lan nagusi bakoitzeko bat. Hasteko, 4. Kapitulan, erabiltzailearen estres mentalaren maila etengabe estimatzeko metodologia sortzeko egindako lana aurkeztuko da. Bigarrenik, estresaren aurkako erreakzioa aztertuko da 5. Kapitulan: erlaxazioa. Kapitulu honetan, giza erlaxazioaren adierazgarri diren erreakzio fisiologikoko patroien azterketa eta sailkapena aztertuko dira. Azkenik, III. Atala 6. Kapituluarekin amaituko da, zeinean irudimen motorreko burmuin-konputagailu interfazeei egindako ekarpenak azalduko diren.

Azkenik, IV. Atalako 7. Kapitulan, dokumentu honek, egileak bere doktoregoaldian lortutako ondorio nagusiak aurkeztuko ditu. Gainera, kapitulu honek, tesi honetako gaiak ikertzen ziren bitartean zabaldu ziren etorkizuneko ildoak azalduko ditu ere. Bukatzeko, 7. Kapituluak tesia itxiko du, tesia literaturan sostengatzen duten lanen erreferentzien zerrenda emanaz.

II. Atala

Testuingurua: gizakiaren
anatomia, fisiologia and
horiei lotutako konputazioa

2. Kapituluia

Gizakiaren oinarrizko anatomia eta psikologia

2.1. Sarrera

Zenbait zientzia-diziplina gorputzaren azterketan datza. Ezagunenetako bat anatomia da, gorputzaren beraren egituren oinarritzen dena. Seguruenik, anatomia medikuntzaren diziplinarik zaharrena da, eta antzina ere garatu zen, soldadu kaltetuen zauriak behatuz. Geroago, zientzia garai modernoagoetan sartu zen, eta medikuak ere hasi ziren giza gorputzaren barne-osaera aztertzen disezioei esker. Hasieran, disezioa debekatuta zegoen, baina denborarekin medikuei esparru akademikoetan praktikatzeko utzi zitzaien. Gaur egun, adibidez, tumoreen egitura aztertzeko erabiltzen den teknika da. Ikertutako gaiaren arabera, anatomia hainbat adarretan banatzen da, hala nola, anatomia makroskopikoan (mikroskopiorik gabe ikus daitezkeen egitura handien azterketa), anatomia mikroskopikoan (zelulen eta ehunen morfologiaren azterketa) edo anatomia topografikoa (gorputzaren eskualde bereko egituren arteko azterketa-elkarreraginak dira, burua, esaterako), besteak beste.

Anatomiak, egituren azterketan arreta jartzen duen bitartean, beste diziplina batek, berriz, gorputzeko atal garrantzitsuenen funtzioak aztertzen ditu. Fisiologia da diziplina horren izena. Fisiologoek gorputzaren funtzioak eskala guztietan aztertzen dituzte, ikuspegi zabalago batetik (adibidez, organo osoen azterketa), baita maila molekularrean iristen diren fenomeno txikiak ere. Anatomian bezala, fisiologia ere adar desberdinetan banatzen da, azterketa-eremuaren arabera. Adibidez, neurofisiologoek garunak, bizkarrezur-muinak, nerbioek eta abarrek osatzen duten nerbio-sistema aztertzen dute. Hala ere, lan honetan jorratutako eduki gehiena elektrofisiologiaren adarrarekin lotuta dago. Elektrofisiologiak gorputzeko osagaien propietate elektrikoak aztertzen ditu hainbat mailatan, eskala molekular eta zelularretik organismoaren sistema osora.

Bi diziplina handi hauek aurkeztu ondoren, 2.2. Atalean, gorputzeko organo eta funtzio batzuei buruzko informazio gehiago emango da. Eduki horiek

2. KAPITULUA - GIZAKIAREN OINARRIZKO ANATOMIA ETA PSIKOLOGIA

konputazio-diziplinekin zerikusirik ez dutela dirudien arren, tesi honetan aurkezten den lana giza gorputzean gertatzen diren fenomeno batzuk automatikoki prozesatu, detektatu edo sailkatzea da. Beraz, interesgarritzat (eta beharrezkoztat ere jo da) anatomiaren eta fisiologiaren oinarriko eduki batzuk ematea, eta, hartara, irakurleari laguntzea geroago metodo konputazionalen bidez aztertuko diren fenomeno batzuk ulertzen.

2.2. Organo sistemak

Giza gorputza aztertzeko hainbat modu daude. Aztertutako osagaien mailen eta funtzioen arabera, gorputzaren egitura osagai txikienetatik, hau da, zeluletatik, organismo osora azter daiteke. Beraz, gorputza atal txikieneteik handienera antola daiteke. Horrela, atomoak eta molekulak gorputzaren zatirik txikiena dira eta organismoa osoa. Irizpide hauei jarraiki, molekulak zelulak osatzeko konbinatzen dira, eta, aldi berean, zelulak beste zelula batzuekin elkartzen dira, ehunak sortuz. Ondoren, bi ehun-mota edo gehiago biltzen dituen konbinazio anatomiko bakoitzak organo bat osatzen du. Organo bakoitza berariazko eginkizun fisiologiko baten edo gehiagoren arduraduna da, eta funtzio fisiologiko nagusiekin lotutako organo horien konbinazioek organo-sistema bat sortzen dute. Azkenik, organismoa sailkapen horren goiko mailan dago, hau da, organo-sistema guztien baturan.

Arestian aipatutako maila horietan guztietan gorputzaren antolaketa azterteza lan zabalegia denez, tesi hau organo-sisteman zentratuko da batez ere. Hamaika organo-sistema daude giza gorputzean: gihar sistema, eskeleto sistema, immunitate sistema, sistema endokrinoa, gernu aparatua, ugalketa aparatua, digestio aparatua, tegumentu sistema, nerbio sistema, zirkulazio aparatua eta arnas aparatua.

Hala ere, tesi hau azken lauretan soilik oinarrituko da, 2.2.1., 2.2.2., 2.2.3. eta 2.2.4. Azpiataletan. Kontuan hartu behar da lan honen edukia medikuntzarekin estu lotuta dagoen arren, lan honen helburua informatikarekin lotua dagoela. Beraz, osasunarekin zerikusia duten arloetan trebatutako irakurleek atal hauetako edukia sinple samarra dela pentsa lezakete. Dokumentu honek lehen aipatutako organo-sistemekin zerikusia duten alderdiak soilik eztabaidatuko ditu, autoreak garrantzitsutzat jotzen dituenak III. Atalean azalduko diren ekarpenak ulertzeko. Kapitulu honetako eduki gehienak [4] eta [5] iturrietatik atera dira. Bi iturriak oso zabalak dira eta informazio baliotsua daukate, beraz, irakurleak dokumentu honetan aipatutako ezagutza zabalduta nahi badu, horra jo beharko luke. Gainera, besterik adierazi ezean, kapitulu honetako irudi guztiak [4]tik atera dira.

2.2.1. Tegumentu sistema


Tegumentu sistema azala, ilea eta azazkalak osatzen dituen sistema da. Ileari dagokionez, gorputza UV erradiatziotik babesteko funtzioa du eta gorputzaren erregulazio termikorako ere baliagarria da, airea larruazaletik gertu mantentzen

2.2. ORGANO SISTEMAK

laguntzen baitu, gorputza hoztu ez dadin. Azazkalek, aldiz, babestu egiten dute, atzamarren eta behatzen muturra gogortzen dute eta jendeari objektuak manipulatzeko eta harraskatzen uzten diote.

Hala ere, tesi honetarako tegumentu sistemaren zatirik interesgarriena azala da. Larruazala da gorputzeko organorik handiena, gorputzaren pisu osoaren %16 inguru pisatzen baitu. Itxura fisikoa emateaz gain, azala eta haren elementu osagarriak beste bizi-funtzio batzuen erantzule dira, hala nola, gorputzaren barne-organoak babestea edo detektatzeko gaitasuna ematea (azala garunari lotutako nerbio-zuntzez beteta dago, 2.2.2. Azpiatalean azalduko da).

Egituraren arabera, azala hiru geruza nagusitan bana daiteke (ikus 2.1. Irudia): epidermisa, dermisa eta hipodermisa. Epidermisa kanpoko geruza da eta hipodermisa, berriz, larruazalaren barruko geruza; dermisa, berriz, beste bien artean dagoen geruza da, eta guztietan lodiena.



2.1. Irudia. Azalaren hiru geruzak: epidermisa, dermisa eta hipodermisa.

2.1. Irudian ikus daitekeenez, epidermisa da larruazalaren zatirik meheena (0,1 mm inguruko lodiera du), eta gorputzeko ia gainazal guztia estaltzen du. Epidermisean ez dago odol-hodirik, eta haren zeregin nagusia beheko geruza, dermisa, babestea da. Keratinozitoak dira epidermiseko zelula motarik arruntak (zelula guztien %90 inguru), eta, beste zelula mota batzuekin batera, zeregin horren erantzuleak dira, keratinozitoak keratina ekoitzi eta metatzen espezializatuta baitaude. Proteina horrek keratinozitoei gogortasuna eta urarekiko erresistentea izateko gaitasuna ematen die.

Epidermisean badira beste zelula batzuk, hala nola melanozitoak, Langerhans

2. KAPITULUA - GIZAKIAREN OINARRIZKO ANATOMIA ETA PSIKOLOGIA

zelulak eta Merkel zelulak. Lehenak azala ez erretzeaz eta UV erradiazioetik babesteaz arduratzen dira. Bigarrenak, berriz, larruazalaren bidez gorputzean sartzen saiatzen diren patogenoak detektatu eta haiei aurre egiteko dira. Azkenik, hirugarrenak dira gutxien erabiltzen direnak. Dermisaren nerbioetara konektatuta daude eta azalaren kontaktuak sentitzeko gaitasuna ematen diote gorputzari.

Larruazalaren egiturarekin jarraituz, epidermisaren azpiko geruza dermisa da. Dermisa larruazalaren zatirik lodiena da ehunez, nerbioez eta odol-hodiez konposatuta dago. Odol-hodiz beteta dagoenez, epidermiseko zelulei elikagaiak eta oxigenoa emateaz arduratzen den geruza da. Gainera, epidermiseko detekzio-zelulen konexioa dermiseko nerbioetatik egiten da, eta ukipena (presioa), mina eta tenperatura detektatzeko erabiltzen dira. Gainera, dermisaren zatirik sakonena kolagenoa eta zuntz elastikoak dituzten ehunez osatuta dago. Ehun horiei esker, larruazala indartsua eta elastikoa da aldi berean.

Dermisean aipatu ditugun elementuez gain, izerdi-guruinak dermisean ere daude, eta aipamen berezia merezi dute, tesi honen ekarpen batzuekin lotura estua baitute. Oraingoan, azalpena izerdi-guruinen alderdi anatomiko eta fisiologikoetara mugatuko da, eta III. Atalan ikusiko du irakurleak izerdi-guruinen eta teknika konputazionalen arteko lotura.

Izerdi-guruin mota bi daude: ekrinoa (ikus 2.1. Irudia) eta apokrinoa. Alde batetik, guruin ekrinoak gorputzaren gainazal osoan daude (batez ere esku-ahurretan, oinazpitan eta bekokian) eta termorregulaziorako izerdia sortzen dute. Bestalde, apokrinoa eremu iletuetan egoten da, eta izerdia kanporatzen dute, nerbio eta hormonen kontrolpean. Hala, guruin horiek gorputzeko feromonen erantzunarekin ere zerikusia dute.

Azkenik, azalaren azken geruza hipodermisa da. Azalaren eta haren azpian muskuluen arteko konektore gisa jokatzen du geruza horrek. Geruzak biltegi modura ere jokatzen du; gorputzeko koipeak geruza horretan gordetzen dira normalean, eta horrek muskuluek sortutako beroa azalaren azpian mantentzen laguntzen dio gorputzari.

Tegumentuarekin bukatzeko, garrantzitsua da egiten dituen funtzio guztiak gogoratzea. Lehenik eta behin, eraso fisikoen, patogenoen eta erradiazioaren aurkako babesa du. Gainera, eginkizun garrantzitsua du zentzumenei lotuta, ukimena, mina eta tenperatura-sentsazioa ahalbidetzen baititu. Azkenik, nerbio-sistema sinpatikoarekin duen harreman estuari esker (etengabe monitorizatzen du azalaren tenperatura, eta aginduak ematen ditu horri erantzuteko), izerdiaren eiekzioaren bidez gorputzaren erregulazio termikoan laguntzen du tegumentu sistemak.

2.2.2. Nerbio sistema


Nerbio-sistema giza gorputzaren barruko beste organo-sistema bat da. Oso aparatu konplexua da. Oso funtzio ezberdinak ditu. Izan ere, nerbio-sistema garunak, bizkarrezur-muinak eta nerbio-adarkatzeek osatzen dute. Hala ere, garuna oso organo konplexua da, eta esan liteke garuna antzeko itxura duten

organo asko direla, baina, ikuspegi makroskopikotik gauza bera diruditen arren, bakoitzak oso funtzio ezberdinak ditu.

Hurrengo azpiatalaren bidez, dokumentu honek nerbio-sistema antolatzeko banaketaren deskribapen laburra egingo da. Geroago, hurrengo azpiatalean, nerbio-sistema autonomoa are gehiago azalduko da tesi honetako ikerketa lanarekin zerikusi gehien duen nerbio-sistemaren zatia baita.

Nerbio sistemaren egituraren antolaketa

Anatomikoki, oso modu sinplean hitz eginda, nerbio-sistema bi zatitan bana daiteke (ikus 2.2. Irudia): nerbio-sistema zentrala (ingelesez central nervous system, CNS, garunarekin eta bizkarrezur-muinarekin lotua) eta nerbio-sistema periferikoa (nerbioak eta ganglioak). Garrantzitsua da adieraztea zatiketa hori ez dela guztiz egia, burmuinean bertan nerbio-sistema periferikoari dagozkion elementuak badaudelako. Hala ere, ikuspegi ulertterraza eta erabilgarria da, eta horretarako prestatu da azalpen-atal hau.



2.2. Irudia. Nerbio-sistemaren banaketa anatomiko sinplista: nerbio-sistema zentrala (arrosa kolorea) eta nerbio-sistema periferikoa (hori kolorea).

Gainera, nerbio-sistema ikuspegi funtzional batetik ere sailka daiteke. Beste behin ere, ahalik eta xumeen mantendu nahian, bi modu daude nerbio-sistemaren funtzioak sailkatzeko. Lehenengo ikuspegiak nerbio-sistemaren atalak sailkatzen ditu elementu bakoitzak dituen oinarritzko funtzionaltasunekiko. Bigarren ikuspuntua gorputzaren kontrol-motarekin lotuta dago; kontrol-mota

2. KAPITULUA - GIZAKIAREN OINARRIZKO ANATOMIA ETA PSIKOLOGIA

hori somatikoa edo autonomikoa izan daiteke.


Oinarrizko funtzioen ikuspegitik nerbio-sistemara hurbilduz, funtsezko hiru funtzio nagusi daude: funtzioak atzematea, erantzutea eta integratzea. Atzematearen funtzioaren helburua gorputzaren barruan nahiz kanpoan informazioa lortzea da, aldagai fisiologikoen edo ingurunearen orekan gertatzen diren aldaketak erregistratzeko. Esan bezala, estimuluak gorputzetik kanpo etor daitezke, adibidez, fruitu ustel baten zapore txarra; edo gorputzaren barruan, organismoan zenbait hormona handitzearen ondorioz gosea sentitzea. Orduan, erantzun-funtzioak eragiten du estimuluarekiko zentzuzko erreakzioa. Estimuluen aurreko erreakzioak asko alda daitezke, besteak beste, muskulu-mugimendu batetik (eskeletikoa izan daiteke, muskulu leuna hesteetan edo bihotz-muskulua bihotzean) izerdia kanporatzeko aurretiaz aipatutako guruin ekrino edo apokrinoak aktibatzeraino. Azkenik, oinarrizko azken funtzioak, funtzio integratzaileak, beste fenomeno batzuetatik aldeztatik lortutako informazioaren estimulu eta erreakzioetatik lortutako informazioa erlazionatzen du. Funtzio horri esker, esperientziarekin eta aurreko oroitzapenekin korrelazioa ezar daiteke, pertsonak hobeto erantzun ahal izan dezan etorkizuneko egoeretan. Beraz, integrazioaren funtzioa prozesu kognitibo handiekin lotuta dago, hala nola ikaskuntzarekin, oroitzapenekin eta emozioekin.

Nerbio-sistema oinarrizko funtzioen arabera banatzeaz gain, bada beste ikuspegi bat, gorputzaren kontrola egiteko moduaren arabera sailkatzen duena. Nerbio sistemaren bi zatiketa nagusi daude, gorputzak erantzunak kontrolatzeko duen moduaren arabera: nerbio-sistema somatikoa eta nerbio-sistema autonomoa (ingelesez autonomic nervous system, ANS hemendik aurrera). Lehenak, nahita egindako erantzunak kontrolatzen ditu, beso bat nahita mugitzean gertatzen diren modukoak. Nerbio-sistema somatikoak ere zenbait erantzun kontrolatzen ditu, baina baliteke borondatezkoak ez izatea, erreflexu-mugimenduekin edo arnasketarekin gertatzen den bezala. Bestalde, ANSak gorputzaren nahi gabeko kontrola egiten du. ANSak organismoaren erantzunak erregulatzen ditu, aldagai fisiologikoak nolabaiteko oreka batera iritsi daitezen, gorputzak behar bezala lan egin dezan. Autoerregulazio-prozesu horri homeostasi ere esaten zaio. Beraz, ANSak gorputzaren kontrol homeostatikoarekin du zerikusia, batez ere, erregulazio termikorako edo bihotz-erritmoa azkartzeko izerdi eiekzioarekin.

Nerbio-sistema somatikoaz eta ANSaz gain, bada beste sistema bat, nerbio-sistema enterikoa izenekoa, eta digestio aparatuko gihar eta guruinen kontrolaren arduraduna da. Sistema hori nerbio-sistema periferikoaren mende baino ez dago, eta, batzuetan, ANSaren parte har daiteke (ez beti). Hala ere, ez nerbio-sistema somatikoak ez enterikoak ez dute garrantzi handirik tesi honetan aurkeztutako garapen teknikorako; batez ere ANSen erantzunetan oinarrituko da.

Laburpen gisa, 2.3. Irudia erabilgarria izan daiteke orain arte azpiatal honetan aipatutako nerbio-sistemaren zatiketa horien guztien arteko erlazioa grafikoki ikusteko.

2.2. ORGANO SISTEMAK



2.3. Irudia. Nerbio-sistemaren atal garrantzitsuenekin lotutako kokapenen eta funtzioen ikuspegi orokorra, aukeratutako antolakuntza-ikuspegiaren arabera. Irudi honetan, PNS nerbio-sistema periferikoaren siglak dira (ez nahastu gero aipatuko den nerbio-sistema parasinpatikoa-rekin).


Nerbio-sistema autonomoa (ANS)

Naturan, “borroka edo ihesa” esamodeak argi eta garbi definitzen ditu harropakinek beren harraparitik datorren mehatxu batekiko dituzten erreakzioak: korrika egiteko prestatu beharko lirateke, edo etsaiari aurre egin eta borrokatu? Adierazpen hori lehen aldiz esan zuen Walter Cannonek [6], gizakiek eta beste animalia batzuek naturan dituzten erreakzioen artean paralelotasuna ezarri. Harrapariek gizakiak jada mehatxatzen ez dituzten arren (salbuespenak egon daitezke), erreakzio hori gure genero-kodean inprimatzen da oraindik. Hala, pertsonen bihotz-erritmoa mehatxatuta sentitzen denean, handitu egiten da, adrenalinak gorputza prestatzen du alertarako, eta antzeko erreakzio asko gertatzen dira organismoan. Ikuspegi funtzional batetik aztertuz gero, nerbio-sistema autonomoak (ingelesez autonomic nervous system, ANS) sortzen ditu organismoan aldaketa horiek.

Hala ere, egoera batzuetan, gorputzak kontrako norabidean erantzuten du. Adibidez, ateratzen ari zen autobusera igotzeko korrika egin ondoren, gorputzaren erantzuna lasaitasunera itzultzea da, eta, hala, bihotzaren taupada-erritmoa murriztu, izerdia gutxitu eta arnasketa moteldu egiten da. Erantzun horiek lotura estuagoa dute “atsedena eta digestioa” basatiaren adierazpenarekin, eta ANSek ere kontrolatzen ditu.

2. KAPITULUA - GIZAKIAREN OINARRIZKO ANATOMIA ETA PSIKOLOGIA

Gainera, “borroka edo ihesa” eta “atsedena eta digestioa” egoerez gain, ANSk ere erreakzionatzen du egoera emozionaletako aldaketekin. Batez ere, sistema endokrinoen eta ANSen funtzionalitate homeostatiko gehienak hipotalamoan kontrolatzen direlako gertatzen da hori (garunaren zati jakin bat, ikus 2.4. Irudia, [7]tik lortua), eta, hurrenez hurren, hipotalamo oso konektatuta dagoelako amigdalarekin, zeina burmuinaren zatia baita memoria, erabakiak hartzeko eta erantzun emozionalak prozesatzeko [8].




2.4. Irudia. Hipotalamoaren kokapena eta amigdala garunean.

Hala, ANSak kontrolatzen ditu “borroka edo ihesa” eta “atsedena eta digestioa” bezalako aldaketa emozionalekin lotutako erantzun fisiologiko batzuk. Hala ere, erreakzioaren arabera, nerbio-sistemaren zati sinpatikoek edo parasinpatikoek erregulatzen dituzte.

Nerbio-sistema sinpatikoa (SNS)

Nerbio-sistema sinpatikoa (ingelesez sympathetic nervous system, SNS hemendik aurrera) “borroka edo ihesa” adierazpenarekin zerikusia duten erreakzioak kontrolatzen ditu. Presiopean edo mehatxuzko egoera batean sentitzen denean, SNSak hainbat organo funtzio aktibatzen ditu: bihotza eta arnasaa azkartu egiten dira, izerdi-guruinak aktibatu egiten dira, digestio-sistemak ez du funtzionatzen oxigeno guztia odolera joan dadin... Funtzio horiek guztiak aldi berean aktibatzen dira. Ahalbidetzeko, SNSa garunetik bizkarrezurrean zehar dauden ganglioatara adarkatzen da. 2.5. Irudian, ornoen izenak dituen bizkarrezurreko mapa bat ageri da.

2.5. Irudian ikus daitekeenez (Henry Grayk [9] erreferentzian garatua), “C” ornoak zerbikalak dira, “T”, torazikoak, “L”, lunbarrak eta “S”, eremu



2.5. Irudia. Bizkarrezurraren mapa.

sakrokoak. Interesgarria da nomenklatura-sistema horri buruz jakitea, nerbio-konexioek ere sistema horri jarraitzen baitiote. Irizpide horri jarraituz, nerbio torazikoak, lunbarrak eta sakroak, orduan, ornoaren gainetik zenbakitzen dira, adibidez, T1 nerbio espinala, T1 ornoaren azpian dagoena, T1 ganglioarekin konektatzen da, eta, hortik aurrera, organo eragileetara adarkatzen dira. Hori 2.6. Irudian ikus daiteke (azpiatalaren amaieran), non SNSren konexioak irudikatzen baitira.

2.6. Irudian ikus daitekeenez, SNSak oso funtzio garrantzitsuak dituzten organo-multzo zabal batekin ditu konexioak. Konexio guztiek ez dute berdin funtzionatzen. Batzuetan, nerbioak ganglioekin lotzen dira, eta, handik, zuzenean organoekin (bihotzarekin edo trakearekin gertatzen den bezala). Beste kasu batzuetan, nerbioak ganglio jakin bati lotzen zaizkio, eta, aldi berean, gan-

2. KAPITULUA - GIZAKIAREN OINARRIZKO ANATOMIA ETA PSIKOLOGIA


glio hori beste ganglio batzuekin konektatzen da azken organora iristeko. Adibidez, fenomeno hori begiekin gertatzen da, ezkerreko kateko ganglioak erabiliz bizkarrezur-muinera konektatzen baitira. Azkenik, hirugarren kasu batean, organoa ganglio bati konektatuta dago, zeina erdiko posizioan baitago bizkarrezur-muineko ganglioetarako bidean. Bizkarrezur-muinera iritsi baino lehen, gibela ganglio zeliakoarekin lotzen den konexio mota horren adibidea da.

Nerbio-sistema parasinpatikoa (PNS)

PNSak (ingelesez parasympathetic nervous system, PNS hemendik aurrera) SNSaren osagarri gisa lan egiten du gorputzak lasaitu behar duen kasuetan (“atsedena eta digestio” egoerak), borroka egiteko edo arazoetatik ihes egiteko prestatu beharrean. Beraz, SNSak bihotz-taupaden eta arnasketaren erritmoa azkartzen bazituen, PNS da urrats horiek kalifikazio normaletara murrizten dituen ANSaren zatia.


2.7. Irudian (azpiatal honen amaieran ere) ageri denez, PNS eta SNS konexioak ezberdinak dira; bizkarrezur-muinean adarkatu beharrean, organo eragile gehienak garuneko nerbio bidez konektatuta daude zuzenean garunera.

2.7. Irudian ikus daitekenez, izerdi-guruinak ez daude PNSari konektatuta, eta ANSaren alde sinpatikoari bakarrik konektatuta daude. Informazio hori baliagarria izango da gero III. Atalean azalpenak emateko.



2.6. Irudia. Nerbio sistema sinpatikoaren (SNS) konexioak.

2. KAPITULUA - GIZAKIAREN OINARRIZKO ANATOMIA ETA PSIKOLOGIA



2.7. Irudia. Nerbio sistema parasimpatikoaren (PNS) konexioak.

2.2.3. Zirkulazio aparatua

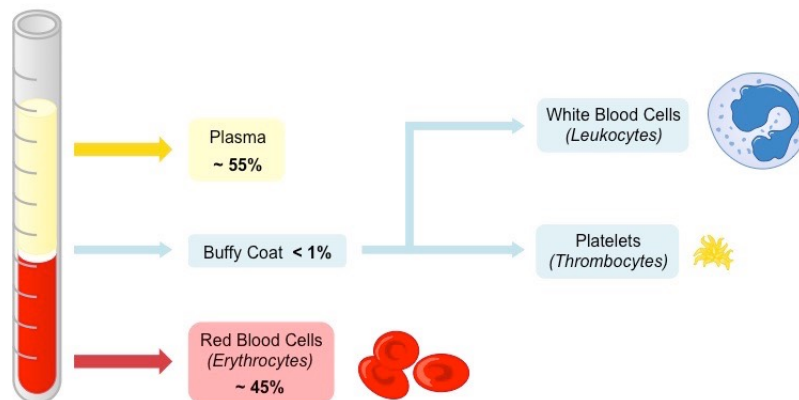
Dokumentu honetan aztertuko den hirugarren organo-sistema zirkulazio aparatua da. Zirkulazio-aparatua, sistema linfatikoa eta aparatua kardiobaskularrak osatzen dute.

Sistema linfatikoa sistema immunologikoaren zati nagusia da, baina gorputzaren gehiegizko gorputz-likidoa drainatzeaz ere arduratzen da, odolera itzuliz eta sistema immunologikoko zelulak gorputzaren bidez banatuz. Sistema linfatikoa sortzen duen likido fluxua ez du bihotzak modu aktiboan ponpatzen. Aldiz, gorputzaren mugimenduek, hala nola, muskulu-mugimenduek edo arnasketak, eragiten dute fluxu hori.

Zirkulazio-aparatuaren beste zatia aparatua kardiobaskularra da, dokumentu honen ardatz izango den zirkulazio-aparatuaren zatia. Aparatu kardiobaskularrak zelulek mantengaiak lortu eta hondakinetatik atera ahal izateko odola gorputzera atal guztietara banatzen du. Hiru osagai nagusik osatzen dute aparatua kardiobaskularra: odolak, bihotzak eta hodiekin.

Odola

Odola ehun konektibo bitxia da, likidoa den gorputzera ehun konektibo baxarra baita. Odolaren osagai nagusia plasma da (%92 ura da). Odolaren beste osagaiak globulu gorriak, globulu zuriak eta plaketak dira. Elementu horiek odolean dituzten batez besteko proportzioak [10]tik ateratako 2.8. Irudian ageri dira:



2.8. Irudia. Odolaren osagai nagusiak plasma eta globulu gorriak dira. Globulu zuriak eta plaketak odolaren osakeraren zati oso txikia baino ez dira.

Gorputzaren funtzioei dagokienez, funtzio ezagunena zelulen hondakinak hartzea da (karbono dioxidoa, adibidez), eta trukean mantengaiak eta oxi-

2. KAPITULUA - GIZAKIAREN OINARRIZKO ANATOMIA ETA PSIKOLOGIA

genoa ematea, behar bezala funtzionatzen jarrai dezaten. Funtzio hau nagusiki globulu gorriek egiten dute. Beste funtzio batzuetan, ordea, odolak zeregin garrantzitsua du. Adibidez, defentsarako garrantzitsua da, globulu zuriek kanpoko bakterioen aurka edo barne-mehatxuen aurka borroka egiten dute hala nola, birusen hedapenaren aurka. Gainera, hodi edo ehun bat hautsita dagoenean, plaketek eta plasman dauden proteina batzuek erreakzionatu egiten dute eremu hautsia ixteko eta odol-jarioa geldiarazteko. Azkenik, garrantzitsua da gorputzaren erregulazio termikorako ere. Gorputzaren nukleoa beroegi jartzenean, odol-fluxua handitu egiten da gorputz-adarretarantz, eta nukleoa murriztu. Gainera, nukleoa hozten ari denean, zirkulazio-sistemak kontrako norabidean erreakzionatzen du, gorputz-adarretara doan odol-fluxua murriztuz, nukleoa ahalik eta beroena mantentzeko.


Hodiak

Odol-hodiek zeregin garrantzitsua dute zirkulazio-sisteman, haiei esker iritsi baitaiteke odola gorputzeko atal nagusi guztietara. Nagusiki, bi hodi mota daude: arteriak eta zainak. Lehenengoak bihotzetik gorputzeko beste atal batera doazen hodiak dira. Zainak, aldiz, bihotzera gorputzaren beste alde batetik doazen hodiak dira.

Hodien, arterien eta zainen anatomian sakonduz, hodi txikiagoetan adarkatzen dira, hurrenez hurren: arterioletan eta benuletan. Bi horiek arterien eta zainen antzeko egiturak dituzte, txikiagoak dira batez ere. Azkenik, kapilarrak hodien adarkatze-maila baxuenean daude, eta hodi meheenak dira. Kapilarren bidez, elikagaiak eta oxigenoa odoletik beste zelula batzuetara transferitzen dira, eta karbono dioxidoa eta beste hondakin batzuk zeluletatik odolera pasatzen dira. Transferentzia horiek kapilarren iragazkortasunari (batzuk besteak baino iragazkorragoak dira) eta kapilarretako odolaren eta kanpoko ingurunearen arteko presio-diferentziari esker gertatzen dira.

Hodiak ikuspuntu estruktural batetik ikusita, arteriek eta zainek antzeko propietateak dituzte. Hala ere, arteriek bihotzetik odola atera ahala, odol horrek presio handiagoa du. Beraz, presio altuagoak maneiatzeko, arteriek paretan lodiagoak dituzte zainekin alderatuta. Alde handi horri esker, aipatutako gas- eta mantenugai-trukea gertatzen da. Hain zuzen, arterioletatik odola kapilarretara iristen da, horma kapilarren kontra 35 mmHg-ko presioa aplikatuz. Normalean, kapilarretatik kanpoko plasma 25 mmHg ingurukoa izaten da. Gero, kapilarren barruan presioa handiagoa denez, odoleko materia kanporantz mugitzen da. Hala ere, odol-fluxuak aurrera egin ahala, kapilarretako presioa txikiagoa da, eta kapilarreko zain-zatiaren hasieran 18 mmHg besterik ez da lortzen. Beraz, kapilarren zati horretan, presioa murriztearen ondorioz, materia kanpotik eremu kapilarrean igaro behar da; hala, karbono dioxidoa odolean xurgatzen da. Azkenik, erdiko puntu batean, kapilarren zati batean bi presioak berdinak dira kapilarren barruan eta kanpoan, eta, beraz, ez dago materia-trukerik. Garrantzitsua da aipatzea kapilarren arterietako presioaren eta kanpokoaren arteko aldeak handiagoak direla zati benereokoekin alderatu-

ta. Beraz, likido-truke handiagoa dago arteria-zatian. Hori dela eta, sistema linfatikoak ere parte hartzen du zirkulazio-aparatuan, likido-galera hori kontsatszen baitu odol-korrontean gehiegizko likidoak berreskuratzean. Materia trukatzeko prozesu guztia 2.9. Irudian adierazten da.




2.9. Irudia. Materia-iragazketak ingurune batetik bestera, horma kapilarren aldaketetan aplikatutako presio gisa.

Azkenik, odol-emariari dagokionez, odolak bi zirkuitu nagusi ditu: birika-zirkuitua eta zirkuitu sistemikoa. Birika-zirkuitua bihotzaren eta biriken artean odola garraiatzen duena da; zirkuitu sistemikoa, berriz, odola garraiatzen du bihotzaren eta gorputzeko gainerako ehunen artean. Oro har, arteriek oxigeno kontzentrazio handiagoko odola dute, eta zainek oxigeno gutxi eta karbono dioxido kontzentrazio handia duen odola dute. Zirkuitu sistemikoa handiagoa denez, jendea hari buruz ari da aurreko adierazpen hori egiten dutenean. Hala ere, biriketako zirkuituko arteriak eta zainak salbuespena dira arau horretan: biriketako arteriek bihotzetik odol desoxigenatua hartzen dute eta biriketara bidaltzen dute; biriketako zainek, berriz, kontrakoa egiten dute: biriketatik odol oxigenatua hartzen dute bihotzean.

Bihotza

Sistema kardiakoa biologiaren berri ez zuen norbaiti azalduko balitzaio, erraza izan liteke zirkuitu itxiko ur-sistema batekin alderatzea: odolak ur gisa jokatuko luke, hodiekin kenexioen lana egingo lukete eta bihotza izango litzateke mugimendu behartzen duena, hau da, ponpa. Organoa izateaz gain, bihotza ere muskulua da, eta barrunbe torazikoan dago, T5 eta T8 orno torazikoen artean (gogoratu 2.2.2. Azpiataleko 2.5. Irudia). Nolabait, bi biriken artean dago, 2.10. Irudian erakusten den bezala ([11]tik hartua).

2. KAPITULUA - GIZAKIAREN OINARRIZKO ANATOMIA ETA PSIKOLOGIA



2.10. Irudia. Bihotza biriken artean dago, barrunbe torazikoan erdian.

Bihotzean lau ganbera nagusi daude, bihotzaren ardatz simetrikoekiko lau koadrantetan banatuta egongo balira bezala. Goiko bi ganberak aurikulak dira, eta beheko bi ganberak bentrikuluak dira. Beraz, bihotzaren alde bakoitzean, ezkerrean eta eskuinean, aurikula bat eta bentrikulu bat dago.


Kamera horien funtzionaltasunari begira, aurikulek bihotzera iristen den odola jaso eta bentrikuluetara bultzatzen dute. Ondoren, bentrikuluek odola ponpatzen dute bihotzetik biriketara edo gorputzaren gainerakoetara, bentrikuluen aldearen arabera. Gero, oxigenoaren, mantenugaien eta hondakinen transferentzia guztiak egin ondoren, odola aurikulara itzultzen da zirkuitu itxiko sistema horretan beste ziklo bat hasteko. Hala ere, bihotzak odola jasotzen/ponpatzen duenez biriketatik eta gorputzaren gainerako ataletatik, zirkuitu hori ez da lehen begiratuan dirudien bezain simplea.

Eskuin-aurikula aukera genezake odola zirkuitu osoan zehar nola bidaiatzen den azaltzeko abiapuntu egokia izateko. Lehenik eta behin, gorputz osoko odol desoxigenatua eskuineko aurikulara iristen da, goiko eta beheko kaba zainen eta bidez. Han, odola balbula trikuspidetik igarotzen da eskuineko bentrikulurantz. Ondoren, bentrikuluak desoxigenatutako odola ponpatzen du biriketako balbula semilunarraren bidez, birika-enborrean eta biriketara doazen arterietan. Biriketean, odolak karbono dioxidoa askatzen du eta oxigenoz betetzen da. Gas-transferentzia amaitu ondoren, biriketako zainek berriro oxigenatutako odola bihotzera bidaltzen dute ezkerreko aurikulatik.

Puntu horretan, ezkerreko aurikulak balbula mitraletik ezkerreko bentrikulurantz bultzatzen du odola. Bentrikulua betetzen denean, uzkurto egiten da, eta, ondoren, odol oxigenatua ponpatzen du, aorta-arteriaren eta haren adar ugarien bidez gorputzaren gainerako zatian, balbula aortiko semilunarraren bidez. Azkenik, gorputzeko odolaren muturreko kapilarretan oxigenoa eta eli-

2.2. ORGANO SISTEMAK

kagaiak askatzen ditu, eta, tokiko zeluletatik karbono dioxidoa lortu ondoren, eskuineko aurikulara itzultzen da, zirkuituaren ziklo berri bati ekiteko.




2.11. Irudia. a) Bihotz-ganberen barruko odol-fluxuaren adierazpen grafikoa. b) Odol-zirkuitu itxia: zirkuitu sistemikoa horiz nabarmentzen da eta biriketakoa kolore moreaz nabarmentzen da.

Hala ere, garrantzitsua da ohartzea gorputzaren eskuineko eta ezkerreko aldeek batera lan egiten dutela: ezkerreko eta eskuineko aurikulek odola jasotzen dute aldi berean, eta, berdin gertatzen da bi bentrikuluen odola ponpaketarekin.

2.2.4. Arnas-aparatua

Orain arte, lan honek azaldu duenez, odola gorputzean zehar doa, ehunei oxigenoa emateko eta organismoetik karbono dioxidoa kentzeko. Ehunak zirkuituaren muga badira, esan daiteke birrikak zirkuituaren beste aldeko muturra direla. Hala ere, gas-transferentzia biriketan egiten den arren, bai oxigenoak bai karbono dioxidoak ziklikoki sartu eta atera behar dute gorputzetik. Arnas aparatua deitzen zaio gas horiek bildu eta kanporatzeko ardura duen organo-sistemari. Hala ere, beste organo-sistema batzuekin gertatzen den bezala, arnas-aparatuak beste funtzio batzuk betetzen ditu, hala nola zentzumena (usaimena), eztula edo hitz egitea. Azpiatal honek organo-sistemak nola funtzionatzen duen azalduko du labur, aurretik 2.2.3. Azpiatalean aipatutako gas-trukeari dagokionez.

Arnas-aparatuak bi zati nagusi ditu: eremu eroalea eta arnas eremua (ikus 2.12. Irudia). Haren izenetik ondoriozta daitekeenez, eremu eroalearen eginkizuna gasak biriketara sartu eta ateratzeko bidea ematea da. Gainera, eremu eroaleak sartzen diren gasak iragazi behar ditu, kanpoko mehatxuak organismo sar ez daitezen, eta biriketara presio, tenperatura eta hezetasun baldintza jakin batzuetan iristeko egokitu behar ditu. Bestalde, arnas eremuak gasa odolarekin trukatzeari eragiten du.



2.12. Irudia. Arnas-aparatuaren bi gune nagusiak.


Eremu eroalea sudurrean hasten da, eta airea gorputzean sartzen da sudur-hobietatik. Airearen sudurraren barrunbeetatik igaro ahala, sudurreko muki eta ileetatik iragazten da, gorputzean sartzeko kanpoko mehatxuak saihesteko. Gainera sudurrean, aireak gorputzerako behar diren tenperatura eta hezetasun baldintzak lortzen ditu.

Sudurraren ondoren, airea faringean sartzen da. Faringea, airea ematen duen muskulua da, gero gorputzetik jaitsi ahal izateko. Airean geratzen diren patogeneoak ezabatzen laguntzen duten zenbait linfozito ere baditu (globulu zuri mota

bat). Gainera, sudurrera ez ezik, ahora ere konektatuta dagoenez, faringetik sartzen da janaria gorputzean. Hala ere, faringearen behealdean, elikadurarako eta airerako bidea bereizi egiten da. Janaria digestio-aparatura bidaltzen da esofagoan zehar eta airea arnas aparatua hurrengo zatian sartzen da: laringean.


Laringea faringea trakearekin lotzen duen eremu eroalearen zatia da, eta arnas aparatuan sartzen eta irteten den aire-kantitatea kontrolatzen du. Irenstean, muskulua mugimenduek laringea ixtera behartzen dute; horrela, elikagaiak eta edariak arnas-aparatutik haratago joatea saihesten da. Gainera, ahots kor-dak laringean daude, beraz, soinu eta hotsak laringean sortzen dira.

Aire-fluxuari jarraituz, eremu eroalearen hurrengo zatia trakea da, airea igaro eta bronkio primarioekin konektatzen den muskulu malgua da, birika bakoitzeko bat dugu. Gero, airea bronkio primariotik bronkio-zuhaitzera doa, eta, izenak azaltzen duenez, bronkio primarioaren adarkatzea da, bronkio txikiagotan. Gero, zuhaitzaren adar bakoitza meheago bihurtzen da bronkioloetara iritsi arte. Puntu horretan eremu eroalea amaitu egiten da eta arnagunea hasten da. Gasek eremu eroalean egiten duten bidea 2.13. Irudian ikus daitezke (Estatu Batuetako jabari publikoko irudia).



2.13. Irudia. Arnagunea sudurrean hasi eta bronkioloetan amaitzen da.

Arnagunea tamaina txikieneko bronkioloetan hasten da, arnas bronkioloetan. Arnas bronkioloak albeoloei lotzen zaizkie. Albeoloak mahats tankerako muskulu leunak dira, eta horien bidez egiten da gas-transferentzia odolarekin. Beraz, gasa transferitzeko albeoloak zenbait kapilarrez inguratuta daude, eta, presio ezberdinei esker, oxigenoa bildu eta karbono dioxidoa askatzen dute. 2.14. Irudian, albeoloetatik eratortzen diren bronkioloak ikus daitezke eta hauek kapilarrez inguratuta daudela ere bai.



2.14. Irudia. Gasa albeoloen eta kapilarren artean transferitzen da.

3. Kapituluak

Seinale fisiologikoak, logika lausoa, ikasketa automatikoa eta BCI sistemak

3.1. Sarrera

Tesi honen aurreko kapituluak giza anatomiari eta fisiologiari buruz beharrezkoa den gutxieneko informazioa eman duen heinean, hirugarren kapitulu honek 2. Kapitulan aurkeztutako organo-sistemei lotutako seinale eta konputazio-teknikak jorratuko ditu.

Kapitulu honi hiru atal dagozkio. Lehenak, 3.2. Atalak, tesi honen ekarpenetarako erabili diren seinale fisiologikoak aurkeztuko ditu. Gainera, kapitulu honek seinale horietatik atera ohi diren ezaugarri batzuk aurkeztuko ditu. Ondoren, tesian zehar egindako lanean erabili zirenez, 3.3. eta 3.4. Atalek logika lausoa eta machine learning teknika batzuk aurkeztuko dituzte hurrenez hurren. Azkenik, kapitulu hau 3.5. Atalekin amaituko da. Bertan, hiru burmuin-konputagailu interfaz motak (BCI) aurkeztuko dira.

3.2. Seinale fisiologikoak eta ezaugarrien ateratzea

Atal honek 2.2. Atalan azaldutako organo-sistemen adierazgarriak diren seinale batzuk aurkeztuko ditu. Atal honetan 4., 5. eta 6. Kapituluetan (III. Atalean) aurkeztutako ekarpenetan erabili ziren seinaleak besterik ez dira aztertuko, organo-sistemei buruz informazioa ematen duten beste seinale batzuk existitzen diren arren (pletismografia edo larruazalaren tenperatura, adibidez).

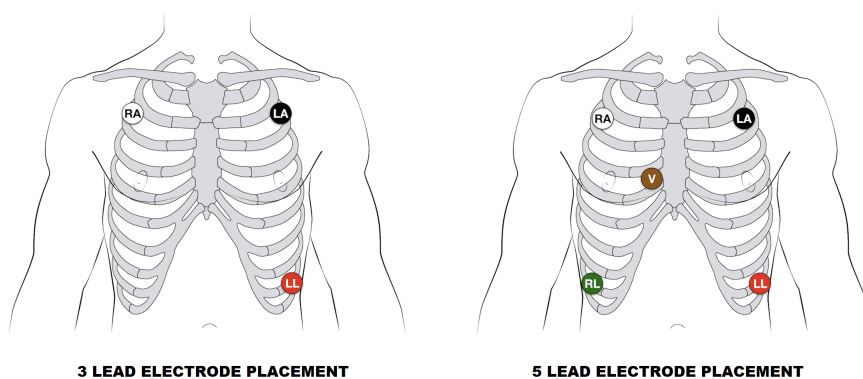
3. KAPITULUA - SEINALE FISIOLOGIKOAK, LOGIKA LAUSOA, IKASKETA AUTOMATIKOA ETA BCI SISTEMAK

Hasteko, 3.2.1. Azpiatalak eta 3.2.2. Azpiatalak elektrokardiograma eta aktibitate elektrodermiko (izerdiarekin erlazionatutako seinalea) aurkeztuko dituzte hurrenez hurren. Ondoren, 3.2.3. Azpiatalak arnasketari buruzko informazioa emango du. Amaitzeko, 3.2.4. Azpiatalak burmuineko jardueratik jaso daitezkeen seinale elektrikoak (elektroentzefalogramak) aztertuko ditu. Azpiatal horietako bakoitzean, tesi honek seinale bakoitzaren ezaugarri tipikoenek lorzeko erabiltzen diren prozesamendu-teknikak azalduko ditu, horien artean III. Atalaren ekarpenetan erabilitakoak daudelarik.

3.2.1. Elektrokardiograma (ECG)

Elektrokardiograma (ECG) bihotzaren jarduera elektrikoari lotutako seinalea da. Seinale honek bihotzaren funtzionamenduari buruzko informazio oso interesgarria ematen du. Horregatik, seinale hori zentro medikoetan, kirolotan eta beste esparru askotan sarri erabiltzen da.

Elektrokardiograma azalaren gainazalean elektrodoak jarriz harrapatzen da, elektrodo hauek bihotzeko estimulu elektrikoak islatzen dituztelarik. Aplikazioaren arabera, erabilitako elektrodoen kopurua 3 bideetatik 12 bideetara aldatzen da (ikus 3.1. irudiaren bi adibideak, [12]tik hartua). Hautatutako konfigurazioaren arabera informazio desberdina lor daiteke: bide gehien dituzten konfigurazioak dira bihotzaren egoerari buruzko informazio gehien ematen dutenak. Adibidez, ECGen erregistroen morfologia ikusita, mediku trebatuak bihotzaren funtzionamenduan anomaliak detektatzeko gai dira (buxadurak, takikardiak...). Hori dela eta, elektrokardiogramaren analisiak bihotzeko hainbat gaixotasun hautemateko lagungarria izan daiteke.




3.1. Irudia. ECG seinalea jasotzeko aukeratutako konfigurazioaren bide kopuruaren arabera, elektrodoak posizio ezberdinetan kokatuko dira.

Seinalea erabat periodikoa ez den arren, bere maiztasuna aldakorra delako, bere morfologiak PQRST izeneko seinaleak sortzen ditu behin eta berriz. Deiturara hau ziklikoki errepikatzen diren seinale edo gertakarietatik jasotzen dute: P

3.2. SEINALE FISIOLÓGIKOAK ETA EZAUGARRIEN ATERATZEA

seinalea, QRS konplexua eta T seinalea. 3.2. irudiak ECG bi zikloren adibidea ematen du, non gertakari horiek nabarmenduak izan diren:



3.2. Irudia. ECG seinalearen ziklo bi, gertakari errepikakor ezberdinak azpimarratuz.

Lehenago aipatu da ECGa bihotzeko jardura elektrikoaren adierazgarria den seinalea dela. ECGak aurikulak eta bentrikuluak nola polarizatzen eta despolarizatzen diren irudikatzen du. Dena den, bada posible ECGko gertakariaren eta bihotzeko mugimendu mekanikoen arteko lotura ezartzea. Bihotzeko zikloetan errepikakorrak diren bi zati nagusi bereiz daitezke: sistolea eta diastolea. Aurikulak edo bentrikuluak uzurtu eta odola kanporatzen duten zatiari sistolea deritzo. Aurikulak edo bentrikuluak erlaxatzen diren zatiari, ordea, diastolea deritzo. Diastoleak odolari une horretan dagokion kameran sartzea ahalbidetzen dio.


Bihotzeko zikloaren hasieran bihotzaren zati guztiak erlaxatuta aurkitzen dira. Zikloaren hasieratik, P uhinaren erdiko punturaino, odola aurikuletan sartzen da. Aldi berean, balbula mitrala eta balbula **hirukia** irekita daudenez, odola bentrikuluen barrena sartzen da, hauek bere ahalmenaren %70 edo %80raino betetzen. Ondoren, sistole aurikularra P uhinaren bigarren zatian gertatzen da eta R uhinaren tontorreraino irauten du. Aurikular sistolean, aurikulak uzurtu eta gainontzeko odola kanporatzen dute bentrikuluak erabat betez.

Ondoren, sistole bentrikularren lehen fasea R uhinaren erpinean hasten da eta bentrikuluak uzurtzen hasten dira. Uzurtzen hastean, bentrikuluen barruko presioa handitu egiten da eta odola aurikuletara itzultzen edo gorputzerantz ihes egiten saiatzen da. Bihotzetik kanpoko odol hodietako presioa bentrikuluen barrualdekoa baino handiagoa denez, **biriketako balbula** eta **balbula aortiko erdilunarrak** itxita mantentzen dira. Gainera, bentrikuluen horretan sortutako presioak indarra egiten du balbula **atriobentrikularren** aurka eta ixtera behartzen du. Beraz, hasierako uzurdura horretan odol bolumena konstante mantentzen da eta soilik presioa hazten da. Denborarekin, bentrikuluen barruko presioa hainbeste hazten da, ezen **aortako** eta **biriketako balbulak** irekitzera behartzen dituen. Horrela, odola bihotzetik kanporantz ponpatzen da. Prozesu hau sistole bentrikularren bigarren fasea dela kontsideratzen da.

Bukatzeko, diastole bentrikularra odola bihotzetik kanpora ponpatu ondoren hasten da (T uhina). Bentrikuluak lasaitzean, haien barruko presioa murriztuz

3. KAPITULUA - SEINALE FISIOLÓGIKOAK, LOGIKA LAUSOA, IKASKETA AUTOMATIKOA ETA BCI SISTEMAK

doa eta balbula **erdiilunarrak** itxi egiten dira. Nolanahi ere, balbula **atrio-bentrikularrak** itxita daude oraindik. Beraz, erlaxazio bentrikularren lehen fase honetan presioa gutxitu egiten da, baina bolumena konstante mantentzen da. Gero, bentrikuluek erlaxatzen jarraitzen dutenez, presioak behera egiten jarraitzen du, eta azkenean, balbula atriobentrikularrak irekitzen dira, odola berriz bentrikuluen barrura pasatzen utziz. Azken fase horrekin bihotzeko zikloa amaituko da, ziklo berri bati ekiteko.



3.3. Irudia. Gertakari mekanikoen eta bihotzeko muskulen polarizazio eta despolarizazioen arteko erlazioa (irudia [4]etik atera da).

ECG seinalearen prozesamendua eta ezaugarrien ateratzea

ECG seinalea prozesatzea praktika arrunta da konputazio fisiologikoen esparruan, biltzeko nahiko erraza den seinalea delako eta informazio oso baliotsua ematen duelako. ECGtik hainbat ezaugarri atera daitezke, analisiaren asmoaren arabera.

- **Bihotz-erritmoa (Heart-Rate, HR):** ezaugarri honek ondoz ondoko taupaden arteko denbora diferentzia adierazten du. Tradizionalki minutu bat oinarritzat hartuta adierazten da (pultsazioak minutuko, beats per minute ingelesez [bpm]). Bata bestearen atzetik sekuentzialki jarriak diren bi pultsu erabiliz kalkula daiteke, denboren arteko diferentzia kalkulatzeko R uhinen pikoak erreferentzia bezala erabiliz. Ohikoa da, baita ere, sekuentzialki jarriak diren hainbat pikoren arteko batez besteko diferentzia kalkulatzeko, eta ondoren emaitza minutu baten oinarriera eraldatzea, hain dinamikoa ez den seinale bat lortzeko.

Azaldu den bezala, nerbio-sistema sinpatikoaren aktibazioek bihotza azkarrago taupatzera behartzen dute eta, ondorioz, bihotz-erritmoa handitu egiten da. Bestalde, nerbio sistema parasinpatikoa aktibatzen denean kontrako efektua gertatzen da eta bihotzeko erritmoa moteldu egiten da. Beraz, bihotz-erritmoa alderantzizko proportzionaltasuna du taupaden arteko denbora-diferentziarekiko. 3.1 ekuazioarekin defini daite-

ke, non $\Delta t_{n,n-1}$ terminoak elkarren ondoko bi taupaden arteko denbora-diferentzia adierazten duen N taupada dituen multzo batean.


$$HR = \frac{60}{\left(\sum_{n=1}^N \Delta t_{n,n-1} \right) / N} \quad (3.1)$$

- **Bihotz-erritmoaren aldakortasuna (Heart-Rate Variability, HRV):** ezaugarri honek ematen duen informazioa ez du adierazten bihotzak nola taupadaka egiten duen, baizik eta nola aldatzen den taupada-erritmoa. Ezaugarria ezaguna da informazio esanguratsua emateagatik, hala nola bihotzak ahalegin fisiko nabarmenak kudeatzeko duen gaitasunari buruz [13] edo aldaketa psikologikoei lotutako gertaerak kudeatzeko duen gaitasunari buruz [14]. Logikak adierazten digunaren kontrari, bihotz-erritmoaren aldakortasun handia izatea bihotz osasuntsu baten dugunaren adierazle da. Horregatik, HRVa bihotzeko zenbait disfuntzio detektatzeko balio dezakeen ezaugarria da [15].

Parametro hau kalkulatzeko modu ezberdinak daude, baita hau ikusteko modu ezberdinak ere. Kalkulu estatistikoetan oinarritutako beste metodo tenporal batzuk dauden arren, ohikoa da HRVa “Root Mean Square Successive Difference (RMSSD)” metodoa erabiliz kalkulatzeko. RMSSDa kalkulatzeko, sekuentzialki segidan dauden zenbait pikoren arteko denbora-diferentziak lortu behar dira. Gero, diferentzia horiek karratura berretu behar dira eta, hau egin ondoren, balio karratu guztien batez besteko balioa kalkulatu da. Azkenik, batezbesteko balio horren erro karratua kalkulatu da. 3.2 ekuazioak ezaugarria kalkulatzeko prozesu osoa laburbiltzen du.

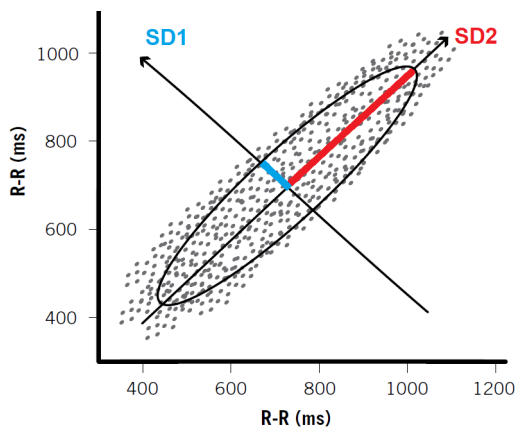
$$HRV_{RMSSD} = \sqrt{\frac{\sum_{n=1}^N \Delta t_{n,n-1}^2}{N}} \quad (3.2)$$

- **Poincareren diagrama:** HRV bistaratzeko modu interesgarri bat da. Poincareren diagrama puntu hodeien grafiko familiaria dagokio. Grafiko hau $n+1$ uneetako pikoen arteko denbora-tartea n uneko pikoen denbora-tartearen arabera irudikatzean datza. Adibidez, lau pikoren arteko denbora-tarteak $RR_{21} = 0.6s$, $RR_{32} = 0.8s$, $RR_{43} = 0.7s$ eta $R_{54} = 0.4s$ izango balira, Poincareren diagrama 3.4. Irudian bezala irudikatuko litzateke.



3.4. Irudia. Poincaré plot of the RR_{21} , RR_{32} , RR_{43} and RR_{54} intervals.

Nahiz eta 3.4. Irudiak soilik hiru puntu erakusten dituen, normalean Poincareren diagramek forma eliptikoak dituzten puntu hodeiak erakusten dituzte. Diagrama hauek oso erabilgarriak dira HRVren ez-linealtasunak deskribatzeko. Adibidez HRVaren epe motzeko eta luzeko desbideratze estandarrak SD1 eta SD2 bezala adierazten dira 3.5. Irudian, hurrenez hurren. Gainera, zenbait azterlanen arabera, grafiko horiek bihotzeko afekzio batzuk dektektatzeko erabilgarriak izan daitezke [16].



3.5. Irudia. Poincareren diagramaren itxura tipikoa. Grafiko mota honetan badira interesgarriak diren zenbait ezaugarri, SD1 eta SD2 bezalakoak.

- **HRVaren analisi frekuentziala eta maiztasun baxuko/altuko ratioa (LF/HF ratio):** halaber, Fourierren transformatua erabiliz HRVaren analisi frekuentziala egin daiteke, frekuentzia-banda desberdinei bu-


ruzko informazioa lortzeko. Maiztasun baxuak (LF) [0.04,0.15] Hz tartean daudela kontsideratzen da, eta altuak (HF) [0.15,0.4] Hz tartean daudela. LF informazioa bihotz-erritmoarekin erlazionatuta dago eta, beraz, nerbio sistema sinpatikoaren aktibazioen adierazlea da. Bestalde, HF informazioa HRVren aldakortasunarekin erlazionatzen da. Beste neurri bat ere badago, LF/HF erlazioa. Neurri honek LF eta HF banden espektro frekuentzialen dentsitateen arteko erlazioa kalkulatzeko du. Nolanahi ere, literaturan badira zalantzak neurri hauek erabiltzeko dakartzan onurei buruz [17].

3.2.2. Aktibitate elektrodermikoak (EDA)

2.2.1. Azpiatalean azaldutakoa gogoratuz, izerdi guri ekrino eta apokrinoak azalean aurkitzen dira. Guri apokrinoak hormonien ekoizpenari lotuta dauden bitartean, guri ekrinoak izerdia sortzen dute gorputzeko tenperatura erregulatzeke. Ia gorputz osoan zehar aurkitzen diren arren, kopetan, eskuetan eta oinetan guri ekrinoen kontzentrazioa handiagoa da. Bitxia bada ere, eskuen ahurretan eta oinetan dauden glandulek erlazio handiagoa dute aldaketa psikologikoekin eta emozioekin, erregulazio termikoarekin baino [18]. Ondorioz, psikologoek eta fisiologoek oso intersgarri aurkitzen dute gune horietan izerdia neurtzea. Dena den, izerdia jasotzea lan zaila da; askoz errazagoa da neurri elektrikoak larruazalean hartzea. Azalaren eroankortasuna neurtzetik lortzen den seinaleari aktibitate elektrodermikoak esaten zaio (EDA, ingelesetik: Electro-Dermal Activity).


EDA neurtzeko bi metodo ezberdin existitzen dira. Lehenengoak, metodo endosomatikoak, ez du larruazalaren gainean inolako korrante elektrikorik aplikatzea eskatzen. Bigarren metodoa, metodo exosomatikoak, azalaren eroankortasuna neurtzean datza, azal gainean kokatutako bi elektrodoen artean korrante txiki bat pasatuz. Azalaren eroankortasuna izerdi jariakinarekiko proportzionalki aldatzen da: azala zenbat eta hezeago orduan eta errazago transmitituko da elektrizitatea. Metodori hedatuena bigarren metodo hau da eta tesiaren garapenean zehar EDA biltzeko erabili dena ere bada.

Nahiz eta EDA seinalea gorputzeko edozein lekutan jaso daitekeen, gorago aipatutako arrazoia dela eta, ohikoena eskuetatik jasotzea da. Posiziorik onena falange distalak dira. Hala ere, badira beste posizio posible batzuk 3.6. Iru-dian erakusten den bezala, [5]tik aterata. Bada kontuan hartu beharreko beste ikuspegi bat, elektrodoak trebetasun gutxieneko eskuan jartzea dela normalena: ebakiak eta kailuak izateko joera gutxiago dute, eta, gainera, monitorizatutako pertsonari bere eskurik trebeena erabiltzeko aukera ematen dio.



3.6. Irudia. EDA jasotzeko elektrodoak kokatzeko posizio ezberdinak. Nahiago den kokapena 2 zenbakikoa da, falange distaletan.

ECGarekin gertatzen zen ez bezala, EDA seinaleak ez dira periodikoak. Al-diz, metatze-izaera dute, hezetasunak lurruntzeko denbora behar duelako. Hezetasun eta tenperatura aldaketei estuki lotuta dagoenez, inguruko baldintzek badute eragina seinale hauen gainean. EDA seinaleek bi osagai dituzte: Skin Conductance Level (SCL) izeneko osagai tonikoa eta Skin Conductance Response (SCR) izeneko osagai fasikoa. SCL osagaia azalaren hezetasunaren aldaketa geldoei dagokie, hau da, seinalearen oinarritzko lerroari. Bestalde, SCR osagaia NSSaren aktibazio baten ondorioz gertatzen diren bat-bateko izerdi-leherketei dagokie. Horregatik, pertsona baten arreta berenganatzen denean edo pertsona hori alerta egoeran jartzen denean, erraz ikus daiteke bere EDA seinaleak SCRz betetzen direla. Fenomeno hau 3.7. Irudiko EDA seinalean ikus daiteke: ezkerreko aldean EDA seinalea SCRrik gabe dagoen bitartean (pertsona lasaitzen ari da), seinalearen gainerako partean hainbat SCR ageri dira. Horrek esan nahi du pertsonak arreta aktiboki jartzen ari zela edo alertan jarri zela.



3.7. Irudia. Seinalearen gainerako n ez bezala, lauki batez inguratutako EDAREN ezkerreko zatiak ez du SCRrik, eta horrek, pertsona lasaitzen ari dela esan nahi du.

EDA seinalearen prozesamendua eta ezaugarrien ateratzea

EDA asko erabili da helburu anitzetarako, ez bakarrik monitorizazio medikorako, baizik eta emozioen detekziorako edo fenomeno psikologikoak deskribatzen dituzten patroifisiologikoak detektatzeko ere [19]. Esan bezala, ohikoa da EDA osagai fasikoetan eta tonikoetan deskonposatzea. Nolanahi ere, seinale fisiologiko horretatik beste ezaugarri eta azpiezaugarri batzuk atera daitezke.

- **Osagai toniko eta fasikoak (SCL and SCR):** larruazaleko konduktantzia maila (Skin Conductance Level, SCL) osagai dinamiko motelari dagokio, eta azaleko konduktantziaren erantzunak (Skin Conductance Responses, SCR) osagai fasikoei edo seinalearen aldaketa azkarragoei dagozkie. Horiek elkarren artean banandu daitezke eta, batez ere, SCRak aztertzeko egin da, SNSaren aktibazioari buruzko informazio zuzena ematen dutelako. Erraz banandu daitezke konponente biak iragazte-teknikak erabiliz, espektroaren eremu ezberdinak betetzen baitituzte [20]: SCLa [0-0,05]Hz bandan dago; SCRak, berriz, [0,05-2]Hz tartean.
- **SCL eta SCRen azpiezaugarriak:** zenbait azpiezaugarri atera daitezke SCL eta SCRen denbora-eremuko azterketatik, 3.1.. eta 3.2. Tauletan emandakoak bezalakoak, [5] eta [21] erreferentzietan proposatuak izan zirenak. Ezaugarri horiek ezaugarri-ateratze teknika morfologikoei eta estatistikoei dagozkie.

3. KAPITULUA - SEINALE FISIOLÓGIKOAK, LOGIKA LAUSOA, IKASKETA AUTOMATIKOA ETA BCI SISTEMAK

3.1. Taula. SCLtik ateratako azpiezugarriak.

Ezaugarria	Deskribapena
lehiu bateko balio maximoa malda	SCLak analisi-lehioan izandako baliorik altuena.
batezbesteko balioa leihobatean	SCLaren malda analisi-lehioan.
desbideratze estandarra	Analisi-lehiu osoan SCLak izan duen batezbesteko balioa.
	Analisi-lehioan SCLak izan duen desbideratze estandarra.

3.2. Taula. SCRetatik ateratako azpiezugarriak.

Ezaugarria	Deskribapena
SCR kopurua	Analisi-lehiu osoan zehar gertatutako SCR kopurua.
balio maximoa	SCRak analisi-lehioan izandako baliorik altuena.
batezbesteko balioa	Analisi-lehiu osoan SCRak izan duen batezbesteko balioa.
desbideratze estandarra	Analisi-lehioan SCRak izan duen desbideratze estandarra.
maldak	SCRaren zati gorakorrean eta beherakorrean izandako maldak.
latentzia	Estimulu aktibatzailearen eta SCRaren arteko denbora-aldea.
igoera denbora	SCRak balio maximora heltzeko behar duen denbora.
erdi-berreskuratze denbora	SCRa balio maximotik balio maximo horren %50ra jaisteko behar duen denbora.
batezbesteko balio totala	Seinale erregistro osoan zean SCRek izandako batezbesteko balioa.

Tesi honen edukiarekin zerikusia duten lan gehienak estresa eta emozioen detekzioaren ingurukoak direnez, zentzuzkoa da SCRetan zentratzea. Izan ere, SCRek estimulu psikologiko horiek eragindako SNS aktibazioen beharalako adierazpena ematen dute. Beraz, 3.1. eta 3.2. Taulatan ageri den bezala, EDA seinaletik ateratako ezaugarri gehienak SCRekin erlazionatuta daude.

- **Potentziaren espektro-dentsitatea (Power Spectral Density, PSD):** [22] bezalako azterketek potentziaren espektro-dentsitatea aztertzea proposatzen dute, EDA seinaleak bultzatzen dituen SNSaren jardura ikusteko. Gogora dezagun HRV seinalea aztertzeko antzeko estrategia bat ere aurkeztu zela; bihotz-sistema bai SNSak bai PNSak bultzatzen dute, eta, beraz, metodoaren erabilgarritasuna eztabaidatu egin zen. Hala ere, EDA seinale SNSak bakarrik bultzatzen duenez, metodoa hau EDARI aplikatzea askoz erabilpen sendoagoa dirudi. Gainera, subjektu ezberdinen artean asko aldatzen diren denbora-eremuko analisi-ezaugarriak ez bezala, seinalearen PSDa kalkulatzeko ikuspegia erabilgarria pertsonen

arteko desberdintasun horiek maneiatzeko erabilgarria izan daiteke.

- **Kurba azpiko gainazala (Area Under the Curve, AUC):** ikerketa batzuek AUCa analizatzea proposatzen dute, SNSaren aktibazioen intentsitatea ebaluatzeko. Hori egiten dutenen artea bi talde nagusi daude: EDA seinalearen osagaiak banatzen dutenak eta banatzen ez dutenak. Lehen taldeko ikertzaileek, lehenik eta behin, EDA seinalea SCL eta SCR osagaietan banatzen dute. Ondoren, osagai bakoitzeko AUCa analizatzen dute, bereziki SCRekin zerikusia duen AUCari erreparatuz ([23]).

Bestalde, bigarren taldeko ikertzaileek ([24], [25]) SCR jariakinen forma aprobeztatzen dute analisisa egiteko. AUC osoa kalkulatzearen ordean, SCRaren zati gorakorren AUCa besterik ez dute kalkulatu. SCRren zati gorakorren forma ia triangeluarra denez, SCRaren erdia den zati horren AUCa kalkulatzeko 3.3 formula erabiltzen dute.

$$AUC_{erdi-gorakorra} = \frac{Anplitudea_{SCR} \cdot \Delta t_{igoera}}{2} \quad (3.3)$$

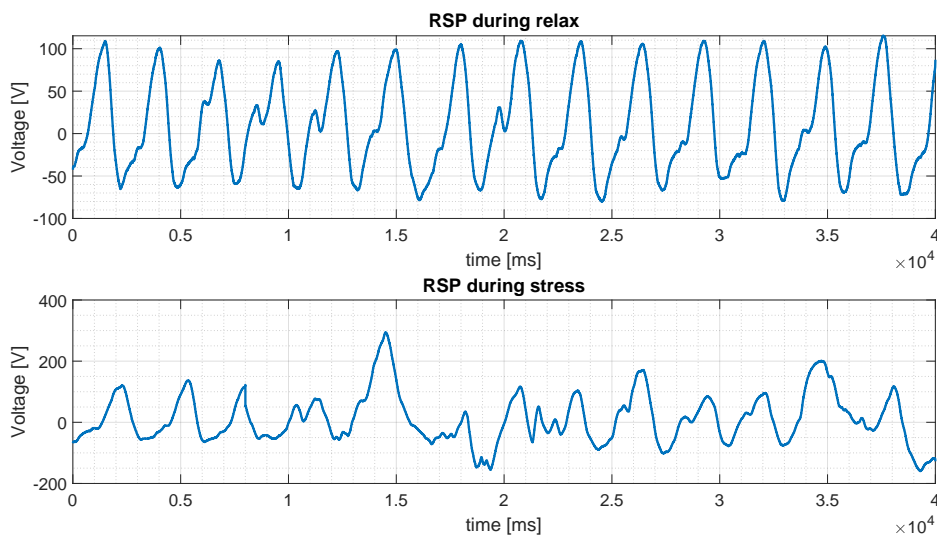
3.2.3. Arnasketa (RESP)

Arnaseko seinaleaz hitz egitean (RESP, ingeleseko “respiration” hitzetik), dokumentu honek arnas egitean toraxa zabaldu eta uzkuartzearen ondorioz sortzen den seinale elektrikoari erreferentzia egiten dio. Arnas sistematik hainbat neurri atera daitezke, espirometriak ematen dituenak bezalakoak, baina horiek aplikazio medikoekin zerikusi handiagoa dute.

Lehenago esan bezala, RESP seinalea toraxaren hedapenarekin eta uzkurduarekin lotutako seinale elektriko da. Beraz, banda bat jarri behar da pertsonaren bularraren inguruan. Banda horiek hedadura-galga simple bat izaten dute normalean, irteerako tentsioa deformazioaren arabera aldatzen duena. Beraz, bularreko bandek tentsio handiagoak ematen dituzte birrikak airez beteta daudenean, eta txikiagoak airea kanporatzen denean.

Seinaleari dagokionez, erlaxazioko RESP seinaleak nahiko harmonikoak izaten dira, airea hartzeko eta kanporatzeko erritmoak nahiko antzekoak baitira. Hala ere, gertaera estresagarrietan, arnastu eta airea kanporatzearen arteko oreka eten egiten da eta seinaleak forma harmonikoa galtzen du: anplitudeak aldatu egiten dira, arnasketa-abiadura handitu egiten da, arnasketa luzeak behinik-behin hartzen dira... Fenomeno horiei arretaz behatuz zenbait fenomeno psikologiko zehaztu daitezke, adibidez, estresa. 3.8. Irudian egoera lasaietako eta estresagarrietako seinaleen arteko desberdintasunak ikusteko adibide onak ematen dira.

3. KAPITULUA - SEINALE FISIOLÓGIKOAK, LOGIKA LAUSOA, IKASKETA AUTOMATIKOA ETA BCI SISTEMAK



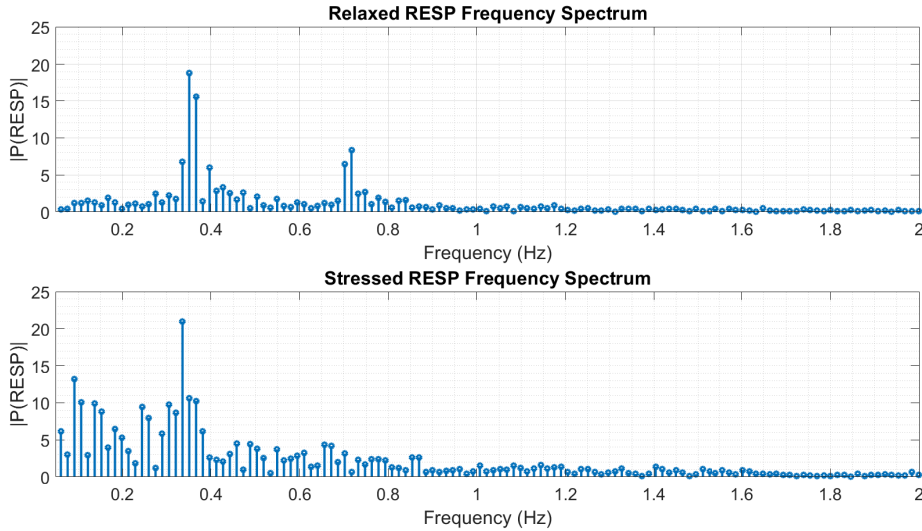
3.8. Irudia. Erlaxazioan harmonikoa izatetik gertu dagoen bitartean, RESP seinalearen forma guztiz desitxurutzen da estresatzean.

RESP seinalearen prozesamendua eta ezaugarrien ateratzea

Arnas sistema eta sistema kardiobaskularra oso lotuta daudela kontuan hartuta, normala izaten da sistema batean gertatutako aldaketak bestean islatzea. Hala ere, ECGak prozesatzean gertatzen zen ez bezala, non denbora-ezaugarriari arreta jartzea ohikoagoa den, ohikoa da RESP seinaleen prozesamendua ikuspegi frekuentzial batetik egitea.

- **Potentziaren espektro-dentsitatea (PSD):** lasaitasunean RESP seinalea harmonikoagoa delaren premisan oinarrituta, orduan seinaleran PSDari begiratzeak zentzu osoa du, seinalearen harmonikotasunaren neurri bat lortzeko. Hortaz, pertsona batek gelditasunean duen arnas erritmo normala ezagutzea baliagarria da pertsona horrek lasaitasuneko egoera batean izango duen patroi frekuentziala lortzeko. Beraz, eredu horrekiko edozein desbideratze aktibazioa ebaluatzeko erabil daiteke. 3.9. Irudiak 3.8. Irudiko seinaleen espektroak erakusten ditu: estresatutako RESP seinalearen espektroak osagai fekuentzial gehiago ditu lasaitasuneko espektroarekin konparatuta.

3.2. SEINALE FISIOLÓGIKOAK ETA EZAUGARRIEN ATERATZEA



3.9. Irudia. Estresatutako RESP seinalearen espektroak erlatiboki handiak diren osagai frekuentzial ugari ditu.

3.2.4. Elektroentzefalograma (EEG)


Hainbat metodo daude burmuinean gertatzen diren fenomenoak aztertzeko: positroien igorpen bidezko tomografia (PET), erresonantzia magnetiko funtzionala (fMRI), magnetoentzefalografia... metodo horietako bat elektroentzefalografia (EEG) da, garun-azalean gertatzen den jarduera elektrikoa jasotzean datzana. EEG aztertzea, burmuinarekin zerikusia duten beste ikerketa gai batzuekin gertatzen den bezala, diziplina berri samarra da. 20. mendearen hasieran, burmuinaren aktibitate elektrikoa soilik metodo oso inbaditzaileen bidez jaso zitekeen, hala nola orratzak garun-azalean sartuz. Oraindik, kasu batzuetan metodo zaharrenak eta inbaditzaileenak erabiltzen jarraitzen diren arren, animalak erabiltzen diren oinarritzko ikerketan bezala, gaur egun ohikoena da jarduera elektrikoa buru-azalean elektrodoak jarritz biltzea. Beraz, orain kirurgia ez da beharrezkoa datuak biltzeko.

EEGak jasotzeko metodologiari sinpleena ez bada ere, 10-20 elektrodoen kokapen-konfigurazioa nazioarteko estandar bat da eta asko erabiltzen da egoera klinikoetan. 10-20 konfigurazioak elektrodoak izendatzeko erreferentzia gisa ere balio du [26]. Beraz, erabiltzea merezi du elektrodoak non kokatu ohi diren azaltzeko. 20. urtean, lau erreferentzia-puntu nagusi daude: nasioia (sudurra eta bekokia dauden puntua), inioia (garezurraren atzealdean dagoen protuberantzia) eta belarri bakoitzaren aurikulaurreko puntuak. 10-20 konfigurazioak lau erreferentzia-puntu nagusi daude: nasioia (sudurrak eta kopetak bate egiten duten puntua), inioia (burezurra atzeko aldean dagoen protuberantzia) eta

3. KAPITULUA - SEINALE FISIOLÓGIKOAK, LOGIKA LAUSOA, IKASKETA AUTOMATIKOA ETA BCI SISTEMAK

belarri bakoitzeko puntu aurre-aurikularretan.

Gero, lau puntu horiek erreferentziatzen hartuta, burezurraren gainazala inguratzen duten irudizko bi ardatz sortzen dira (nasioitik-inioira eta ezkerreko puntu aurre-aurikularretan eskuineko puntura). Ardatz bakoitza hasierako puntutik ardatzeko luzera totalaren %10eko distantziara markatzen da. Gero, ardatzean zehar aurreratu behar da, eta ardatzaren luzera totalaren %20ko distantzia aurreratzen den bakoitzean marka berri bat jarri behar da. Markatzeko modu horrek ematen dio izena elektrodoak jartzeko metodologiari, markak ardatzeko luzera totalaren %10-20-20-20-10-ko distantziak aurreratzean jartzen baitira. Puntu honetara arte, buru-azala 9 aldiz markatuko zen. Nasioitik inioirako ardatzeko bost markak Fz, Cz, Pz puntuei (elektrodoak kokatzeko posizioei dagozkie) eta Fpz eta Oz puntuei dagozkie (ez direnak elektrodoak kokatzeko posizioak, baizik eta geroago beste elektrodo batzuk kokatzeko erabiliko diren puntuak). Bestalde, belarrien arteko ardatzean jarritako bost markak elektrodoak kokatzeko posizioei dagozkie, ezkerretik eskuinerako bidean: T3, C3, Cz, C4, T4 dira. Orain arte, 3.10. Irudian adierazten den bezala markatuko dira elektrodo-posizioak:

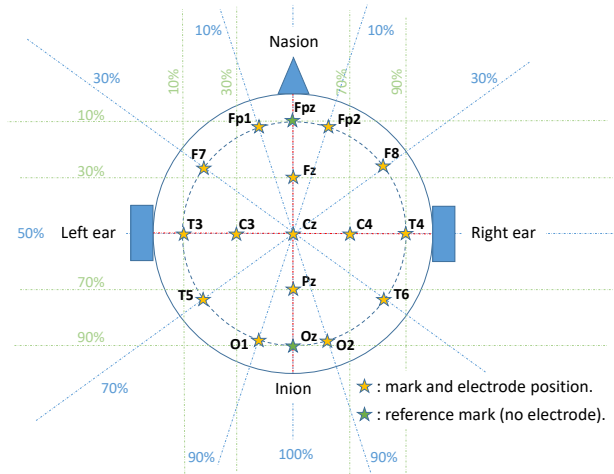


3.10. Irudia. Lehenengo erreferentzia-markak eta elektrodoak %10-20-20-20-10 ereduari jarraituz kokatuko dira ardatzetan zehar.

Elektrodoak aurkitzeko hurrengo pausoa da burua bi aldeetatik inguratzen duen Fpz-ren eta Oz-en arteko urruntze-patroia aplikatzea (10-20-20-10).


Elektrodoak kokatzeko hurrengo pausoa Fpz eta Oz artean %10-20-20-10 aldentze patroia aplikatzea da, burua bi aldeetatik inguratuz. Prozesu horretatik ateratzen diren 10 puntuak hauek dira: Fp1, F7, T3, T5 eta Oz1 ezkerrean eta Fp2, F8, T4, T5 eta Oz2 eskuinaldean (ikus 3.11. Irudia). Oharra: puntu horiek ez ezik, guztiak zenbaki bakoitiek zentzuzkoak daude ezkerrean eta zenbakiak ere erabiltzen dituzte eskuinaldean. Kontuan izan puntu horiek ez ezik, guztiak zenbaki bakoitiek zentzuzkoak daudela ezkerrean daudenean eta zenbaki bakoitiek eskuinaldean badaude.

3.2. SEINALE FISIOLÓGIKOAK ETA EZAUGARRIEN ATERATZEA



3.11. Irudia. Elektroko berrien kokapena %10-20-20-10 urruntze patroia aplikatzen lortzen da, Fpz puntutik Oz puntura.

Gero, F3 elektrodoaren kokapena kalkulatzeko, irudimenezko $\overline{Fp1}, \overline{C3}$ eta $\overline{F7}, \overline{Fz}$ segmentuen arteko elkarguneak aurkitu behar dira. F4, P3 eta P4 elektrodoak irizpide bera aplikatuz burezurreko beste hiru koadranteetan kokatu daitezke, 3.12. Irudian ageri den bezala.



3.12. Irudia. F3, F4, P3 and P4 segmentuen elkarguneak erabiliz kokatzen dira.

Azkenik, bi elektrodo bakarrik geratzen dira, A1 eta A2 erreferentziako elektrodoak. Normalean, belarrietako lobuluetan jartzen dira eta EEG kanalen neurketetatik zarata elektrikoak kentzeko erabiltzen dira. Mastoideetan ere jar daitezke (belarrien atzeko hezur-irtenguneak) helburu bererako. Hala izateko-

3. KAPITULUA - SEINALE FISIOLÓGIKOAK, LOGIKA LAUSOA, IKASKETA AUTOMATIKOA ETA BCI SISTEMAK

tan, M1 eta M2 izenak jasoko dut A1 eta A2ren ordez.

Aztertu beharreko fenomenoaren eta lortu nahi den ebazpenaren arabera, ekipamendu askok EEGak errazago jasotzea ahalbidetzen dute. Merkatuko gailurik sinpleenek EEG kanal bat edo bi bakarrik erregistratzeko aukera ematen duten bitartean, erabilera klinikoetarako gailurik aurreratuenean (eta garestie-
nek) ehun kanal baino gehiago jasotzeko aukera ematen dute. Hala ere, konputazio fisiologikoaren inguruko ikerketetan oso gutxitan erabiliko dira 16 kanal baino gehiago. Izan ere, hainbeste kanal erabiltzen dituzten aplikazioak oso gutxitan izanog dira mugikorrek edo erakargarriak erabiltzailearentzat. Adibidez, ikerketa batzuen arabera, zortzi [27] edo hamar [28] elektrodo erabiltzearekin nahiko izan beharko litzateke P300an oinarritutako burmuin-konputagailu interfaze batek emaitza onak lor ditzan (burmuin-konputagailu interfazei buruz informazio gehiago 3.5. Atalean emango da). Gainera, erabiltzeko erraztasunaren mesedetan, normalean nahiago izaten da kablerik gabeko gailuak erabiltzea, “janzgarriak” daitekenak eta elektrodo-gelik behar ez dutenak.

EEG seinalearen prozesamendua eta ezaugarrien ateratzea

- **Frekuentzia banden deskonposaketa:** EEGen propietate elektrikoei dagokienez, ikerketa gehienak [0-100]Hz banda estuan oinarritzen dira. Nolanahi ere, bandaren zatirik geldoenak eta azkarrenak, [0-7]Hz eta [30-100]Hz hurrenez hurren, ez dira oso garrantzitsuak pertsona helduentan. Hauetan, gertaera eta egoera mental garrantzitsu gehienak [8-30]Hz eremuaren barruan gertatzen dira. Aztertu beharreko fenomenoaren arabera, EEG frekuentzia-banda desberdinetan bana daiteke. Delta, Theta, Alpha, Mu, Beta eta Gamma bandak dira ohikoenak [29].
 - Delta banda: [0,5-3,5]Hz bandan gertatzen diren fenomenoek dago-
kie. Banda hau, normalean, REM ez diren lo sakoneko egoerekin erlazio-
natzatzen da, zeinetan delta aktibitateak potentziaren espektro-
dentsitate totalaren %50 baino gehiagora heldu ahal den. Esnaldian,
jaioberrietan bakarrik da nagusi, eta pertsonak zahartzen diren hei-
nean gero eta ahulagoa da. Tarte honen seinaleak anplitude altuenak
dituztenak dira eta [20-200] μ V tartean egon ohi dira.
 - Theta banda: [4-7,5]Hz bandan ematen den aktibitate elektrikoa da.
Esnaturik dauden pertsona osasuntsu helduetan (25-30 urtetik gora-
koak), theta banda oso gutxitan da indartsu, eta, hala denean, nor-
malean, gaitz baten seinale izaten da. Hala ere, umeak eta helduak
lo daudenean, banda hau burmuineko aktibitatean presente da. Hel-
duekin ari garenean, banda honen aktibitatea logurarekin, pentsa-
mendurik gabeko meditazioarekin edo sakonak ez diren lo egoerekin
erlazioatzen da. Seinale hauek buru-azaleko edozein lekutan ager
daitezke, eta, beraz, ez daude buruako eskualde espezifiko bati lotu-
ta. Banda honen seinaleen anplitudeak normalean [20-100] μ V tar-
tean egoten dira.

- Alpha banda: [8-13]Hz bandako aktibitate elektrikoari dagokio. Alfa erritmoak subjektua esna dagoenean buruaren atzealdean gertatzen dira, intentsitaterik altuenak zonalde okzipitalean ematen direlarik. Erlaxazio dagoen bitartean edo aktibitate mental oso baxuko egoeretan ematen dira erritmo hauek. Alfa erritmoak ikusteko begiak itxita egon behar dute, begiak irekita daudenean deuseztazen direlako. Alfa bandako seinaleen anplitudeak, normalean, $[0-60]\mu V$ tartean egoten dira. [30]en aurkeztutako ikerketak adierazi zuen $[20-60]\mu V$ tartean alfa erritmoen %66 aurkitzen direla eta haien anplitudeek $60\mu V$ -ak nekez gainditzen dituztela (kasuen guttien %6). Alfa uhinak forma sinusoidalak edo biribilduak izanten dituzte normalean. Hala ere, kasu batzuetan, uhinaren alde negatiboa akutua izan daiteke inolako anomalia klinikoren adirezle izan gabe.
 - Mu banda: mu banda alfa bandaren frekuentzia tartean dago ia. Hala ere, alfa banda batez ere buruaren atzealdean gertatzen den bitartean, mu banda belarri batetik bestera definitutako eremu batean gertatzen da. Frekuentzia banda hau gorputzaren mugimenduaren kontrolarekin lotuta dago eta bere uhinak atsedenean fisikoan lortzen dituzte intentsitaterik handienak. Aitzitik, mugitzean edo beste batzuek egindako ekintzak ikusten direnean mu bandako erritmoak deuseztatzen dira. Ikertzaile batzuen uste dute banda horren murrizketak detektatzea BCI sistema espezifikotarako erabil daitezkeela [31].
 - Beta banda: [14-30]Hz banda da. Beta banda EEGren asmatzaileak (Hans Berger) aurkitu zuen [32]. Banda honen aktibitatea hobeto ikusten da buruaren aurrealdean eta erdiko aldean. Talde honetako aktibitatea pentsamendu aktiboarekin eta kontzentrazioarekin lotuta dago eta oso gutxitan gaindituko ditu $30\mu V$ -ak (nahiz eta normalean anplitudea hori baino askoz txikiagoa den). Seinale hauek sendoagoak izaten dira buru-azalaren alde zentraletan.
 - Gamma banda: 30 Hz-tik gorako fenomenoek dagokie banda hau. Esaten da 30 Hz-etik gorako uhinak gamma uhinak direla, baina oraindik ez dago argi zerekin lotuta egon daitezkeen. Ikertzaile batzuek diote kontzientzia subjektiboarekin eta zentzumenen prozesakarekin zerikusia dutela [33] (batez ere ikusmenaren pertzepzioarekin). Dena den, beste ikertzaile batzuen ustez, gamma maiztasunak artefaktuekin erlazionatutako neurketa okerrengatik sortzen direla, muskuluen jarduerak eragiten dituen aktibitate elektrikoek sortzen dituztenak bezalakoak [34].
- **Patroi espazial komunak (CSP)**: patroi espazial komunak erazketarako (CSP, ingeleseko Common spatial patterns-etik), izatez ezohiko EEGren detekzioarako diseinatua izan zen arren, maiz erabiltzen da EEG seinaleetatik datu esanguratsuak lortzeko. Metodo hori aljebra linealeko kalkuluetan oinarritzen da, denboran zehar EEG kanalen multzo baten kobariantza ateratzeko, eta, beraz, oso egokia da BCI aplikazioetarako. Adibidez,

imaginazio motorreko aplikaziorik sinpleenean, EEG datuak jasotzen dira, EEGen patroiak mugimendu mota batekoak edo bestekoak diren jakiteko [35] (bi mugimendu mota besterik ez). Egoera horietan, mugimendu mota bakoitzeko EEG patroien arteko kobariantza oso lagungarria izan daiteke EEG seinaleen mugimendu mota zehazteko.

Azalpena emateko, kontsidera dezagun segundu bakoitzeko N EEG kanal dituen seinale multzo bat jasozen dela behin eta berriz. Orduan, laginketa horietako bakoitzerako, EEG kanalak $N \times L$ tamainako A matrize batean eman daitezke, kanal bakoitzerako jasotako lagin kopurua L izanik. Imaginazio motorreko i . saiakuntza bakoitzaren laginen CV kobariantza-matrizea 3.4. ekuazioa aplikatuz lortzen da.

$$CV_i = \frac{A \cdot A'}{\text{traza}(A \cdot A')} \quad (3.4)$$

Kontuan izan A' matrizea A matrizearen transposatua dela. Hortaz, $A * A'$ -k matrize karratu bat ematen du emaitza gisa. Jarraituz, emaitza horren traza lor daiteke, hau da, matrize karratu baten diagonaleko balio guztien batura. Eragiketa hori bildutako saiakuntza guztietan errepikatzen bada, kobariantza-matrize orokor bat lor daiteke, $CV_{orokorra}$, CV_i guztiak batuz eta gero saiakuntza-kopuruaz zatituz. Hori egiten bada, argi dago $CV_{orokorra}$ -k imaginazio motorreko mugimendu mota guztiei buruzko informazioa emango duela.

Algebra linealaren teoriarekin jarraituz [36], matrize bat diagonalizatu daiteke, orduan matrize hori faktorizatuta adierazi. Hau egin daiteke V_{propio} bektore propioen matrizea eta balio propioen λ matrize diagonalaren erabiliz. Hori aplikatuz gero, $CV_{orokorra}$ 3.5. ekuazioan erakusten den moduan deskonposatuta geratuko da.

$$CV_{orokorra} = V_{propio} \cdot \lambda \cdot V_{propio}' \quad (3.5)$$

Hori egin ondoren, CSPak behar bezala lortzeko, λ matrizeko balio propioak handienetik txikienera ordenatzea beharrezkoa da (aurrerago gogoratuko dugu). Orduan, 3.5. adierazpenetik abiatuta, W zurtze-matrizea lor daiteke. Matrize bat zurtzean matrize hori eraldatzen da, bere kobariantza-matrizea I identitate-matrize bat izan dadin (diagonaleko elementu guztiak 1 izango dira, eta gainerakoak 0). Hemen, zurtze-matrizea $W = \sqrt{\lambda^{-1}} \cdot V_{propio}'$ da. Honela izanda, zurtze transformazioa $CV_{orokorra}$ -ri aplikatu daiteke, haren balio propioen matrizea I_{propio} identitate-matrizea izan dadin (3.6. ekuazioa).

$$CV_{orokorra} = W \cdot I_{propio} \cdot W' \quad (3.6)$$

Hori jakinda, eta $CV_{orokorra}$ -k mota guztietako mugimenduei buruzko informazioa duela gogoratuz (gure kasuan bi mugimendu mota), ondoriozta

3.2. SEINALE FISIOLÓGIKOAK ETA EZAUGARRIEN ATERATZEA

daiteke balio propioen I_{propio} identitate-matrizea bi mugimendu-moten balio propioen matrizeen batura dela. Premisa horretan oinarrituta, bi mugimendu motetako kobariantza-matrizeak 3.7. ekuazio-sisteman bezala adieraz daitezke, $CV_{orokorra}$ -rako erabili zen W zuritze-matrize berdina erabiliz.

$$\begin{aligned} S_{mota-1} &= W \cdot CV_{mota-1} \cdot W' \\ S_{mota-2} &= W \cdot CV_{mota-2} \cdot W' \end{aligned} \quad (3.7)$$

Geroago, $CV_{orokorra}$ -rekin egindakoaren antzera, S_{mota} matrizeetako bakoitza deskonposa daiteke, 3.8. ekuazio-sistema lortuz. Transformazio bakoitzak λ_{mota} balio propio matrize berri bat emango du, identitate-matrize baten ezberdina izango dena (kontuan izan W zuritze-matrizeak soilik $CV_{orokorra}$ matrizea zuritzen duela). Hala ere, transformazio horretik ateratzen den B bektore propioen matrizea berdina izango da bi mugimendu motentzat.

$$\begin{aligned} S_{mota-1} &= B \cdot \lambda_{mota-1} \cdot B' \\ S_{mota-2} &= B \cdot \lambda_{mota-2} \cdot B' \end{aligned} \quad (3.8)$$

Hau eginez, mugimendu mota bakoitzerako transformazioen eta matrize orokorraren arteko erlazioa aurkitzea posible egiten da. Erlazio hori 3.9. ekuazioa adierazi da.

$$I_{propio} = \lambda_{mota-1} + \lambda_{mota-2} \quad (3.9)$$

Azkenik, 3.8. ekuazio-sistematik eta 3.9. ekuaziotik abiatuta, ondoriozta daiteke λ_{mota-1} balio propiorik handiena duen B matrizeko bektore propioak, λ_{mota-2} osagarritzko balio propio bat izango duela, λ_{mota-1} -eko balioarekiko ahalik eta kontrakoena izango dena. Era berean, λ_{mota-2} baliorik handienak osagarritzko λ_{mota-1} baliorik txikiena sortuko du. Orain, gogoratu behar 3.5. ekuazioaren ondoren, λ -ren balio guztiak handienetik txikienera ordenatu zirela. Beraz, B -ren bektore propioak ere ordenatuta egongo dira. Honek esan nahi du B -ren hasierako eta amaierako bektore propioak mugimendu mota biak euren artean bereizteko baliogarrienak izango direla.

Puntu honetara iristean, propietate hori aprobetxa daiteke eta imajinario motorreko saiakuntza bakoitzaren E matrizea eraldatu daiteke kanalen proiektzioak dituen Z matrize bat lortzeko. Z matrizeko proiektzio guztiak ordenatuta egongo dira mugimendu mota biak euren artean ezberdintzeko duten adierazgarritasunaren arabera. Horretarako, Q proiektzio-matrizea erabiltzen da, 3.10. ekuazioan erakusten den bezala.

$$Z = Q \cdot E \rightarrow \text{being } Q = (B' \cdot W)' \quad (3.10)$$

Q' matrizearen zutabei patroi espazial komunak (CSP) deritze, eta denboran zehar aldatzen ez direnez erabilgarriak dira EEG sarrerak bi mugimenduetan arteko bereizketa egiteko duten erabilgarritasunaren arabera antolatzeko.

Garrantzitsua da aipatzea hemen azaldutako CSP erauzte-metodoa klase bitarreko problemetarako soilik balio duela. Hala ere, CSP metodoak klase anitzeko egoeretan aplikatzeko moduak badaude, [37]n edo [38]n egiten duten bezala.

- **Ezaugarri morfologikoak eta estatistikoak:** kapitulu honetako beste seinale fisiologiko askorekin gertatzen den bezala, seinalearen morfologia-rekin lotutako ezaugarriak ateratzea normala da ere, hala nola seinalearen balio maximo eta minimoak, batezbesteko tentsioa, seinalearen potentzia, RMS balioa, seinalea zerotik pasatu den aldien kopurua eta abar.

3.3. Fuzzy-logika (logika lausoa)

Fuzzy-logika edo logika lausoa konputazio adimentsuaren barneko kontrol-estrategia bat da, eta, citerefAndujar2014n adierazten den bezala, asko erabili da identifikazio problemetarako. [39]k aurkeztu zuen lehenengo aldiz eta hainbat identifikazio problemetarako erabili da. Atal honetan, logika lausoko sistema baten zatiak aztertuko dira. Lehenengo azpiatalak, 3.3.1.k, sarrera eta irteerako menbre-sia-funtzioak nola diseinatzen diren azalduko du. Ondoren, 3.3.2. Azpiatalak sarrerak irteerako menbresia-funtzioekin lotzeko erabiltzen diren arau-sistemak azalduko ditu. Azkenik, defuzzifikazio fasea 3.3.3. Azpiatalean aurkeztuko da. Defuzzifikazio fasean, sistemak inferentzia-erregelen bidez ezarritako erlazioei irteera balio bat emango dizkie.


Logika lausoa batzuetan ulertzeko zaila den kontrol estrategia denez, ulermenaren mesedetan, atal hau azaltzeko dutxa baten logika lausoko kontrolaren adibidea erabiliko da.

3.3.1. Membresia-funtzioak

menbresia-funtzioak (MF) logika lausoko sistema zatirik garrantzitsuenetakoak dira, MFen bidez aldagaien balioak erlazionatzen baitira kontrol egoera edo estimazio maila ezberdinekin. MFek sarrerako aldagaien definizioetako anbiguotasunekin moldatzeko aukera ere ematen dute, definiziorako hizkuntza normaleko terminoak erabiliz. Adibidez, dutxako uraren tenperatura kontrolatzeko, erabiltzaile batek “34°C” tenperatura “hotza” bezala defini dezake eta “40°C” “bero” bezala. Baina zer gertatuko zen tenperatura 37°C-koa denean? Termino ezberdin biren artean egon liteke, neurri batean “epel” terminoan eta beste neurri batean “bero” terminoan. Logika lausoko MFek adibide honen antzera funtzionatzen dute, eta, ondorioz, oso indartsuak dira aldagai bat definitzeko mugak argi ez dauden kasuetan.

3.3. FUZZY-LOGIKA (LOGIKA LAUSOA)

Beraz, MFak aldagaien balioak eraldatzeko erabiltzen dira, makinek ulertzen duten domeinutik, “crisp” domeinua ingelesez, pertsonak erabiltzen dugun eremu linguistikora bihurtzeko. Bihurketa hori egiteko, beharrezkoa da “crisp” balio tarte bat definitzea, zeineri aldagai baten hizkuntza-termino zehatz bat egokituko zaion. Adibidez, aurreko adibidean, esan daiteke $[30,34]^{\circ}\text{C}$ tarte “hotz” terminoari dagokiola erabat, eta, 34°C -tik 36°C -ra, esan daiteke uraren temperatura neurri batean “hotza” dela eta bestean “epela” dela. Konbertsio horretarako MF-ek hainbat forma har ditzakete: zuzena, triangeluarra, trapezoidala, gaussiarra, etab. 3.13. Irudian ageri den bezala, aurreko temperaturren adibidea irudikatzen duena, MF-en arteko trantsizioen zakarkeria alda daiteke MF-entzat forma desberdinak hautatuz.



3.13. Irudia. MFak trapezoidalak eta triangeluarrak dira goiko aldean; beheko aldean, berriz, gaussianoak eta sigmoidalak dira.

Aldagaiak “crisp” eremutik eremu lausora edo linguistikora aldatzeko prozesu hori kontrolatu edo estimatu behar diren sistemako sarrera guztiei aplikatu behar zaie. Garrantzitsua da aipatzea membresiaren balioak normalizatu egiten direla, eta, beraz, aldagaiek izan ahal duten membresia baliorik altuena 1 dela hizkuntza-termino jakin batentzat. Dena dela, logika zehaztugabeak anbiguotasunak maneiatzeko aukera ematen duenez, baliteke aldagai bat termino batena izatea erabat, eta aldi berean beste termino batena ere bai (adibidez, 3.13. Irudian 34°C edo 38°C inguruan gertatzen den bezala). Kontuan izan, halaber, MFak sistemaren sarrerarako ez ezik, sistemaren irteerarako ere definitu behar direla.

3.3. Taula. Dutxa kontrolatzeko erregela sistema.

IF... AND IF... THEN... erregela sistema		
Ur temperatura	Ur kantitatea	Eskuleku mugimendua
Hotza	Gutxiegia	↗
Hotza	Ondo	→
Hotza	Gehiegia	↘
Epela	Gutxiegia	↑
Epela	Ondo	=
Epela	Gehiegia	↓
Beroa	Gutxiegia	↖
Beroa	Ondo	←
Beroa	Gehiegia	↙

3.3.2. Erregela sistema

Batzuetan, sistemaren sarrera eta irteeren arteko erlazioa definitzea zaila izaten da. Kasu horietan, oso erabilgarria izaten da giza ezagutzan oinarritutako erregela multzo bat definitzea [40]. Beraz, aldagai guztiak hizkuntza-eremura eraldatu ondoren, aldagaien arteko eta sistemak irteera bezala emango duen estimazio edo kontrol-ekintzaren arteko erlazioa ezartzeko momentua da. “IF... THEN...” (“BALDIN... ORDUAN...”) arauen bidez ezartzen dira erlazio horiek. Hala ere, erlazioak ezartzean, ez dago mugarik konbinatutako diren sarrerako aldagaien kopuruan. Aldagai berri bat erantsi nahi bada, baldintza kateari “OR” edo “AND” eragile logiko bat eranstearekin nahiko izango da (“EDO” eta “ETA” eragile logikoak). Batzuetan “NOT” eragile logikoak ere erabil daitezke.

Dutxa batzuek aginte eskuleku bakarra dute, temperatura eta ur-kantitateak kontrolatzen dituenak. Beraz, eskuleku posizioa bi sarrera-aldagaien arabera izango da. Honela izanda, eskulekuak balbula ireki edo itxi dezake, eta, aldi berean, ura hotzagoa edo beroagoa ateratzeko posizioetara eraman daiteke. Beraz, egoera honetarako, 3.3. Taulako erregela-sistema defini daiteke.

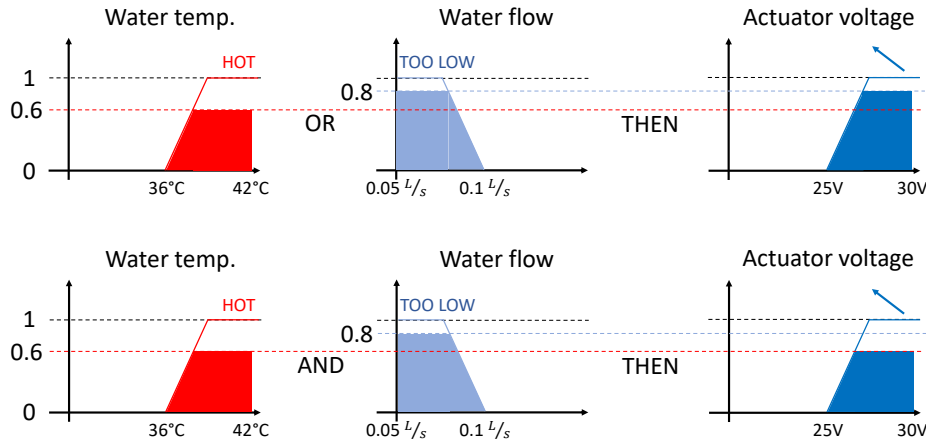
3.3. Taulako adibiderako, hau hartu da kontuan: uraren temperatura ezkerretik eskuinera handitzen da eta eskulekua gorantz mugituz ur-kantitatea handitu egiten da. Beraz, gizakiek egingo zuten kontrolaren antzekoa egin daiteke aldagaiak “IF... AND IF... THEN...” erregelen bidez erlazionatuz.

Konbinazio mota hauek aplikatzen direnean, sarrerako aldagaiek anbiguotasunak dituztenez, arau bat baino gehiago egon daitezke aktibo neurri batean. Beraz, beharrezkoa da baldintza azpimultzo bakoitzetik lortutako diren azalera banan-banan kalkulatzeko. Kalkulu horri dagokionez, erregelatik aterako diren azalaren balioek erabili diren eragilearen influentzia izango dute. Alde batetik, “AND” eragileek, baldintza katearen sarrera guztien artean, menbresia-balio

3.3. FUZZY-LOGIKA (LOGIKA LAUSOA)

minimoa duen sarrerak zehaztutako azalera emango dute emaitza bezala. Bestalde, “OR” eragileek menbresia-balio maximoko sarrerak definitutako azalera emango dute emaitza gisa.

Argiago ulertzeko, dutxako adibidean, uraren temperatura 0,6 “bero” balitz eta ur kopurua 0,8 “gutxiegi” balitz, baldintza erregelen emaitza desberdina izango litzateke erabilitako eragile logikoaren arabera. “AND” bat erabiliz gero, sortutako azaleraren balio maximoa 0,6 izango zen; ”OR”bat erabiliz gero, berriz, 0,8 izango litzateke (ikus 3.14. Irudia irudikapen grafikorako).



3.14. Irudia. Irteeraren azalerako menbresia-balioa aukeratutako eragile logikoaren arabera da.

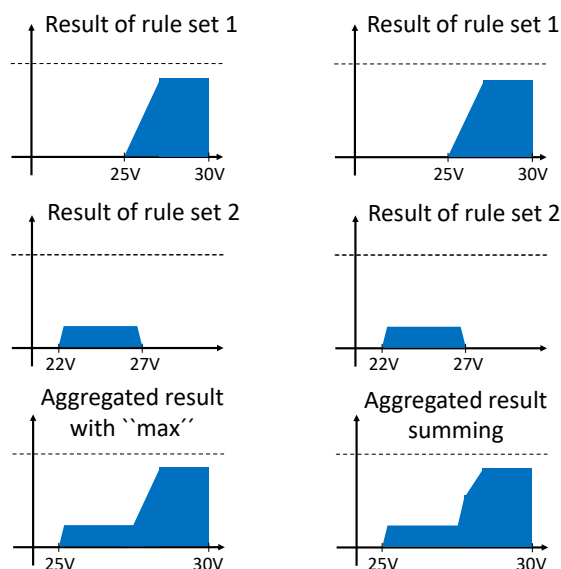
3.14. Irudian ikus daitekeenez, sarrera-aldagaiak ez dute beti %100eko menbresia. Hori gertatzen denean, seguruenik, beste erregela batzuk ere menbresia-balio txikiagoa batekin aktibatuko dira. Hori dela eta, arau desberdinek azalera desberdinak eman ditzaketenez, ezinbestekoa da azalera guztien bateraketa egitea azkenengo urratsera pasatu aurretik, defuzzifikazioa. Azkenengo bi fase hauek hurrengo 3.3.3. Azpiatalean azalduko dira.

3.3.3. Azalaren bateraketa eta defuzzifikazioa

Defuzzifikazioaren aurretik, logika lausoko sistemak bateratutako irteera orokor bat lortu behar du. Horretarako hainbat metodo daude, hala nola “max” eragilea edo batuketaren metodoa erabiltzen duen agregazioa, beste batzuen artean. Bi metodoek abiapuntu bera dute: irteera orokor bat lortzea proposatzen dute, erregela azpimultzo bakoitzak emandako azalera gainezarriz. Hala ere, amaitza biren azalera jainezartzen direnean, metodo biek modu ezberdinean jokatu dute. Alde batetik, “max” eragilearen agregazioak bakarrik menbresia-balio handieneko azalera hartuko du kontuan. Bestalde, batuketaren

3. KAPITULUA - SEINALE FISIOLÓGIKOAK, LOGIKA LAUSOA, IKASKETA AUTOMATIKOA ETA BCI SISTEMAK

metodoak gaine- zarritako azalerak gehituko ditu, eta ondorioz, azalera handiago bat lortuko du. 3.15. Irudian erakusten du nola emaitza orokorra aldatzen den erregela multzoen emaitza partzialak metodo desberdinen bidez bateratzen direnean. Ondorioz, azken emaitzeko azalera aldatzen denez, dutxaren eskulakua kontrolatzeko irteera-tentsioa ere aldatu egingo litzateke desfuzzifikazio fasean.



3.15. Irudia. Baldintza multzo bakoitzeko emaitza partzial berdinak izanda, agregazio-metodo desberdinek sistemaren emaitza orokorra aldatzen dute.

Azkenik, irteera bateratua kalkulatu ondoren, inferentzia-sistemak irteera osoa jatorrizko “crisp” domeinura bihurtu behar du berriro. Urrats horri defuzzifikazioa deritzo. Zenbait era ezberdin daude defuzzifikazioa egiteko [40], grabitate-zentroa kalkulatzekoa bezalakoa (centre of gravity, COG) edo maximoen batezbestekoa balioa (mean of the maximums, MOM) kalkulatzekoarena, besteak beste [41].


4. Kapitulan aurkeztutako lanak COG metodoa erabili zuten. Metodo hau defuzzifikazioa egiteko metodorik erabiliena, eta, bere izenak adierazten duen bezala, emaitza bateratuaren grabitate-zentroa kalkulatzeko oinarritzen da. Emaitza bateratuari 3.11. ekuazioa aplikatu behar zaio grabitate zentroa lortzeko, non μ_i -k emaitza bateratua konposatzen duten N irteera MF bakoitzak duen balio maximoa adierazten duen, eta χ_i -k, berriz, i . MFak hartutako “crisp” balioen

tartearen erdiko balioa adierazten duen.

$$irteera_{crisp} = \frac{\sum_{i=1}^N \mu_i \cdot \chi_i}{\sum_{i=1}^N \mu_i} \quad (3.11)$$

Adibidez, 3.15. Irudiko “max” eragilearen adibidearekin jarraituz eta 3.16. Irudiko balioak emanez, “crisp” irteeraren balioa 3.12. ekuazioan erakusten den moduan kalkulatu litzateke.

$$\begin{aligned} irteera_{crisp} &= \frac{\frac{30 + 25}{2} \cdot 0.8 + \frac{27 + 22}{2} \cdot 0.2}{0.8 + 0.2} = \\ &= \frac{27.5 \cdot 0.8 + 24.5 \cdot 0.2}{0.8 + 0.2} = \frac{22 + 4.9}{1} = 26.9V \end{aligned} \quad (3.12)$$



3.16. Irudia. COG defuzzifikazio metodoak 26.9V emango ditu “crisp” irteera bezala dutxaren eskulekuaren mugimendua kontrolatzeko (grabtite zentroa gorritz markatu da).

3.4. Ikasketa automatikoa

Edozein helburutarako datuak interpretatzen saiatzean, batzuetan, gizakiek ezin dituzte zentzuzko patroiak ezarri. Hala ere, datu horiek ikusteko gai ez badira ere, datu horien analistek badakite (edo, behintzat, susmatzen dute) ezkutuak badirela erlazioak eta patroia datuetatik informazio baliotsua ateratzea ahalbidetzen dutenak. Zorionez, ikaskuntza automatikoari esker, automatiko ki aurki daitezke patroi horiek, algoritmoek datuen analisisian aplika dezaketen abstrakzio-maila handiagoari esker. Alde batetik, algoritmoa eremu jarrai batean definitzen den aldagai bat aurrikusteko erabiltzen bada, algoritmoak erregresio bat egiten duela esaten da. Bestalde, problema eremu diskretu finitu bati badagokio, algoritmoa sailkatzailea dela kontsideratzen da.

Algoritmo batek datuetatik nola ikasten duenaren arabera, ikasketa automatikoko bi ikuspegi nagusi bereizten dira: gainbegiratutako ikasketa-algoritmoak

eta gainbegiratu gabeko ikasketa-algo- ritmoak. 3.4.1. eta 3.4.2. Azpiatalek bi algoritmo mota hauen paradigmarik garrantzitsuenak aurkeztuko dituzte. Ondoren, dokumentu honek 3.4.3. Azpiatalean algoritmoak balioztatzeko metodoei buruzko informazioa emango du. Azkenik, sailkatzailearen errendimenduetrika desberdinak aurkeztuko dira 3.4.4. Azpiatalean.

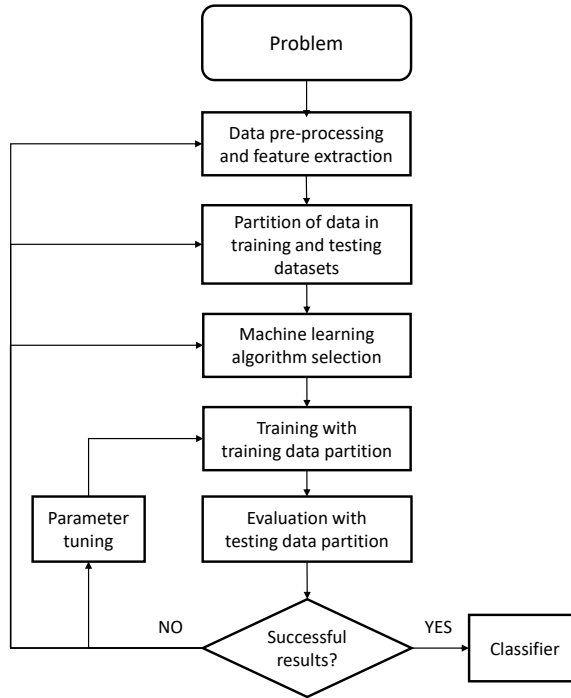
3.4.1. Gainbegiraturako ikasketa

Gainbegiraturako ikasketa-algoritmoak erregresio bat egiteko edo sailkatzen ikas-teko kanpoko laguntza behar duten algoritmoak dira. Zentzu honetan, kanpo laguntza algoritmoari ikasketako instantziak zein klaseri dagozkien esatea besterik ez da. Hori jakinda, gainbegiraturako ikaskuntza-algoritmoak funtzioak ezartzeko gai dira sarrerako datuak irteetara mapatzeko.

Beraz, gainbegiraturako ikasketa-algoritmo guztiek datuak behar dituzte entrenatzeko eta euren errendimendua hobetzeko. Algoritmo baten entrenamendua iterazio-prozesu bat da, non iterazio bakoitzean algoritmoak datu kopuru jakin bat jasotzen duen sarrera gisa. Algoritmoa elikatzeko erabiltzen diren sarrera-datu horiei instantzia deitzen zaie. Datuez elikatu ondoren, algoritmoa datuetako patroiak igartzen saiatzen da, eta instantzietako datu-patroi komunak ezagutzeko erabiltzen duen eredu matematikoa aldatzen du. Hortaz, behar adina datu izateak garrantzi handia du ikasketa automatikoa erabiltzean; nahikoa datu ez badago, algoritmoaren entrenamendua eskasa izango da eta halakoak izango dira emaitzak. Dena den, algoritmoaren gainelikadura ere negatiboa da, eta, beraz, garrantzitsua da oreka bat aurkitzea entrenamendurako erabilitako instantzien kopuruan.

Geroago, algoritmoak entrenatu ondoren, algoritmoek beste fase batetik pasatu behar dute bizitza errealeko aplikazio batean erabili aurretik: testa. Entrenamendurako datu guztiak erabiliko balira, eta algoritmoa testatzeko entrenamenduko instantzia bat erabiliko balitz, orduan emaitza ona izango zen beti algoritmoak jadanik instantzia denak ezagutuko lituzkelako. Dena den, testa fidagarria izateko, oso garrantzitsua da datuak gordetzea testan soilik erabiltzeko; izan ere, bizitza errealeko egoera ez izatearen segurtasunean, algoritmoa etorkizuneko egoera erreal batean erabiltzeko egokia dela frogatuko da. Datuen $2/3$ entrenamendurako erabiltzea eta $1/3$ entrenamendutik lortutako eredu probatzeko gordetzea, oso zabaldua dagoen planteamendua da. Gainera, test-fasean sartu aurretik, ohikoa da entrenamendu-datuen parte bat entrenaturako parametroak baliozkotzeko erabiltzea. Hala ere, datuak entrenamendurako eta testarako banatzeko beste modu batzuk daude, 3.4.3.. Azpiatalean sakonago azalduko direnak. 3.17. Irudian, ikasketa gainbegiraturako erabiliz datu-analisia problema baten oinarritzko planteamenduaren diagrama ageri da.

Literaturan badira hainbat gainbegiraturako ikasketa-algoritmo ezbedin ([42], [43]): Naive Bayes (NB) sailkatzaileak, multi-layer perceptronak (MLP), sostengu-bektoreen makina (SVM), hurbileneko K bizilagunak (K-nearest neighbours, K-NN), erabaki-zuhaitzak (DT) eta sailkatzaile-multzoak, besteak beste. Algoritmo horietako bakoitza ikuspegi matematiko ezberdin batean oinarritzen da sailkapen-lanak betetzeko.



3.17. Irudia. Datu-analisi problema baten oinarritzko planteamendua.

Naive Bayes (NB)

Sailkapen-metodo hau baldintzapeko probabilitateko Bayesen teoreman oinarritzen da. Teoremaren adierazpen matematikoa 3.13. ekuazioan aurkezten da, non $P(A | B)$ eragingaiak B baldintza izanda A gertatzeko probabilitatea adierazten duen. Gainera, $P(B | A)$ eragingaiak, B gertatzeko probabilitatea adierazten duen A baldintza gisa ezarrita. Eta bukatzeko, $P(A)$ eta $P(B)$, hurrenez hurren, A eta B gertatzeko probabilitateak dira.

$$P(A | B) = \frac{P(B | A) \cdot P(A)}{P(B)} \quad (3.13)$$

Sailkatzaile hauek, fenomeno bat gertatzeko probabilitatean eragina duten aldagaien arteko independentzia onartzean oinarritzen dira. Beraz, A fenomenoan F_1 eta F_2 aldagai independenteek eragina badute, onar daiteke $P(A | F_1, F_2) = P(A | F_1) \cdot P(A | F_2)$. dela.

Beraz, aldagaien arteko independentzia eta 3.13. ekuazioko adierazpena baliokotzat hartuta, klase jakin bateko kide izateko instantzia batek izango duen probabilitatea kalkulatzeko duen eredu estatistikoa hurrengo espresioaren bidez

adierazten da.


$$\begin{aligned}
 P(A | F_1, F_2, \dots, F_n) &= \frac{P(A) \cdot P(F_1, F_2, \dots, F_n | A)}{P(F_1, F_2, \dots, F_n)} = \\
 &= \frac{P(A) \cdot P(F_1 | A) \cdot P(F_2 | A) \cdot \dots \cdot P(F_n | A)}{P(F_1, F_2, \dots, F_n)} \rightarrow \quad (3.14) \\
 \rightarrow P(A | F_1, F_2, \dots, F_n) &= \frac{P(A)}{P(F_1, F_2, \dots, F_n)} \cdot \prod_{i=1}^n P(F_i | A)
 \end{aligned}$$

3.14. adierazpena ezagututa, instantzia batek klase bakoitzean egoteko izango dituen probabilitateak kalkulatu daitezke. Azkenik, probabilitate horiek guztiak kalkulatu, klase horren kidea izateko probabilitaterik handiena izan zuen klaseari egokituko zaio instantzia hori.

Multi-layer perceptron (MLP)


MLPak sare neuronal artifizial (artificial neural network, ANN) mota bat dira, ikasketarako atzerahedapenaren printzipioan oinarritzen dena. Sare neuronal biologikoak bezala, ANNak hainbat prozesamendu-unitatez konposatuta daude, euren artean konektatuta daudelarik. Bi neuronen arteko konexio bakoitzari pisu bat egokituko zaio. Pisu hauen balioa ANNaren entrenamenduan zehar aldatuko da, konexio horrek sailkapena edo erregresioa ondo egiteko duen garrantziaren arabera. Hala, konexioko pisuak aldatzeko entrenamendu-instantzien klasea ezagutu behar dutenez, MLPak gainbegiratutako ikasketa-algoritmoen taldean sartzen dira.

MLP bat eraikitzerakoan badira parametro batzuk erabaki behar direnak, hala nola geruza kopurua. Honela izanda ere, MLP bat eraikitzeke gutxienez hiru geruza behar dira: sarea elikatzeke erabiltzen den sarrera-geruza, sailkapenaren edo erregresioaren emaitzak ematen dituen irteera-geruza eta aurreko bi geruzak lotuko dituen geruza ezkutua bat (edo gehiago). Horrez gain, MLPak aurrera-elikadurako ANN familiari dagozkio, hau da, informazioa sarreretatik irteeretara baino ez da igarotzen, eta ez dago unitateen arteko atzerahedura-begiztarik. 3.18. Irudian, mota bakoitzeko geruza bat (sarrera, ezkutua eta irteera) duen MLP baten adibidea jaso da.



3.18. Irudia. Sarrerako, ezkutuko eta irteerako geruza bakarra dituen MLP sare neuronala.

Atzerahedapen-algoritmoek nola funtzionatzen duten jakiteko, unitate edo neurona baten barne-egitura behar bezala ulertzea beharrezkoa da. Adibidez, 3.18. Irudiko 6. neuronari erreparatuz gero, erraz ondoriozta daiteke neurona honek bere sarrera guztiak sarrerako geruzako nodoetara konektatuz lortzen dituela. Hala ere, neuronen arteko konexioak ez dira sinpleak. Horren ordez, konexioei pisu bat egokitzen zaie. Horrek esan nahi du aurreko edozein neuronaren irteera-balioa biderkatu egingo dela konexio zehatz horren pisuarekin hurrengo geruzako neuronan sartu baino lehen. Hau ikusteko 3.19. Irudian lehenago aipatutako 6. neurona horren irudikapen handitua eman da. Gainera, bada neuronaren sarrera gisa erabiltzen den beste balio bat, Θ , neuronaren alborapena deritzona (“bias”-a ingelesez). Azkenik, haztatutako sarrerak guztiak eta alborapena batu ondoren, lortutako balioa aktibazio-funtzio deritzonatan sartzen da. Aktibazio-funtzioak sarreraren guztien batura irteera-balioan transformatzen duen funtzioa da (ondoren, hurrengo geruzetako sarrera guztietarako sarrera gisa erabiliko dena). Tradizionalki, MLPek funtzio sigmoidala erabiltzen dute, ez lineala eta definizio eremu osoan diferentziagarria dena. Horri esker, MLPek problema ez-linealak ebatz ditzakete.



3.19. Irudia. 6 neuronaren barne-egitura. Aurreko geruzako neuroneki-ko loturak haztatuak dira.

Neuronen barne-egitura azaldu ondoren, orain MLParen entrenamenduan eta atzerahedapenean sakondu daiteke. Hasteko, MLParen topologia aukeratu behar da. Bigarren urratsean, berriz, ω_{ij} pisuen eta θ_j alborapenaren balioak hasieratu behar dira. Normalean, $[-1,1]$ tarteko balio aleatorio bat ematen zaie. l ikasketa-tasa ere $(0,1)$ tartean finkatu behar da. Azkenik, gainbegiratu-tako algoritmo guztiak bezala, MLPak iteratiboki entrenatu behar du.

Ulegarritasunaren mesedetan, entrenatzeko prozesua bi bloke sekuentziale-tan banatu da: sarrera balioak aurrera hedatzeko prozesua 1. Algoritmoan emango da, eta, gero, atzerahedapena 2. Algoritmoan aurkeztuko da. Algoritmo hauek geruza espezifiko batean zentratzen dira, i eta k , hurrenez hurren, analizatutako neuronarekiko, aurreko eta ondorengo geruzetako neurona baten zenbakiak dira. I eta K geruza horietako unitate edo neuronen kopurua adierazten dute. Azkenik, j eta J esanahi berdina dute, baina algoritmoa zentratzen ari den geruzarako. Formulazio matematiko konplexua duten arren, algoritmo hauen aplikazioa dirudiena baino errazagoa da. Xehetasun handiagoko azalpen batekin batera, zenbakizko adibide argigarri bat aurki daiteke [44]n.

Aipatu behar da MLPa ANNen oinarritzko forma dela. Hala ere, badira MLParen aldaera asko, arazoak beste ikuspegi batetik ebazteko, NN mota berriak sortzen dituztenak. Adibidez, MLPen oso antzekoak diren “Radial Basis Function” sareek (RBF), oinarri erradialeko funtzioak erabiltzen dituzte aktibazio-funtziorako, funtzio sigmoidala erabili beharrean [45].

Bukatzeko, erabiltzeko zailak ez diren arren, ANNek nola klasifikatzen duten ulertzea zaila da. Gainera, algoritmo hauen entrenamenduak konputazio-karga handikoak dira eta denbora asko behar dute. Izan ere, ikasketaren konbergentzia bermatuta ez dagoenez, praktika arrunta da entrenamendurako iterazio kopururako limite bat ezartzea. Hala ere, azken urteetan teknika berriak aurkitu dira sareen entrenamendua nabarmen azkartzeko, GPUak aljebra linealeko kalkuluak egiteko erabiltzea bezalakoak.

Algorithm 1 Sarrerak aurrera hedatzeko prozesua eta neuronen irteeren kalkulua.

- 1: **for** sarrera unitate bakoitzerako **do**
- 2: $Irteera_i = Sarrera_i$;
- 3: **end for**
- 4: **for** ezkutuko geruzako neurona bakoitzerako **do**
- 5: Sarreraren batukaria lortu neuronaren sarrera balioa jakiteko:

$$Sarrera_j = \Theta_j + \sum_{i=1}^I Irteera_i \cdot \omega_{ij}$$

- 6: Neuronaren irteera balioa lortu aktibazio-funtzio sigmoidala erabiliz:

$$Irteera_j = 1/(1 + e^{-Sarrera_j})$$

- 7: **end for**
 - 8: **for** irteera unitate bakoitzerako **do**
 - 9: Sarreraren batukaria lortu 5. lerroko formula bera erabiliz.
 - 10: Neuronaren irteera lortu 6. lerroko formula bera erabiliz.
 - 11: **end for**
-

Algorithm 2 Atzerahedapen algoritmoa.

- 1: **for** irteera unitate bakoitzerako **do**
- 2: Errorea kalkulatu:

$$\mathcal{E}_j = Irteera_j \cdot (1 - Irteera_j) \cdot (Class_{instance} - Irteera_j)$$


- 3: Pisuak eguneratzeko gehikuntza kalkulatu: $\Delta\omega_{ij} = l \cdot \mathcal{E}_j \cdot Irteera_i$
- 4: ω_{ij} pisuak eguneratu: $\omega_{ij-new} = \omega_{ij} + \Delta\omega_{ij}$
- 5: Neuronaren alborapena eguneratzeko gehikuntza kalkulatu: $\Delta\Theta_j = l \cdot \mathcal{E}_j$
- 6: Θ_j alborapena eguneratu: $\Theta_{j-new} = \Theta_j + \Delta\Theta_j$
- 7: **end for**
- 8: **for** ezkutuko geruzako neurona bakoitzerako **do**
- 9: Errorea kalkulatu:

$$\mathcal{E}_j = Irteera_j \cdot (1 - Irteera_j) \cdot \sum_{k=1}^K \mathcal{E}_k \cdot \omega_{jk}$$

- 10: Pisuak eguneratzeko gehikuntza kalkulatu: $\Delta\omega_{ij} = l \cdot \mathcal{E}_j \cdot Irteera_i$
 - 11: ω_{ij} pisuak eguneratu: $\omega_{ij-new} = \omega_{ij} + \Delta\omega_{ij}$
 - 12: Neuronaren alborapena eguneratzeko gehikuntza kalkulatu: $\Delta\Theta_j = l \cdot \mathcal{E}_j$
 - 13: Θ_j alborapena eguneratu: $\Theta_{j-new} = \Theta_j + \Delta\Theta_j$
 - 14: **end for**
-


Sostengu-bektoreen makina (SVM)

Sostengu-bektoreen makinaren (SVM, support vector machine ingelesez) algoritmoak printzipio erraz batean oinarritzen dira, bi klaseren arteko bereizketa marjinala maximizatzean. Azalpenarako, 3.20. Irudian adibide bat emango da bi dimentsioko espazio baterako. Hala ere, grafikoki ikustea ezinezkoa den arren, printzipio berak aplikatu ahal zaie dimentsio anitzeko kasuei.



3.20. Irudia. Kasu honetan bi klaseetako instantziak linealki bereiz daitezke.

3.20. Irudiko adibidean, oso argi dago bi klaseetako instantziak oso erraz bereiz daitezkeela. Horrelako kasuetan, SVM algoritmoek datu-multzoko klaseak hobekien bereizten dituen $n - 1$ dimentsioko hiperplanoa kalkulatu dute. Adibideko espazio bidimentsionalaren kasuan, hiperplanoaren dimentsioa $2 - 1 = 1$ izango litzateke, hau da, lerro zuzen bat (3.21. Irudian ikusten den bezala).



3.21. Irudia. Bi dimentsioko espazio batean, instantziak lerro zuzen batetik bereiz daitezke linealki. Kasu optimoan, klaseen arteko tartea maximoa da, hau da, $d1 = d2$ denean.

Badira infinitu hiperplano klaseak bereizteko erabil daitezkeenak, baina klase bateko instantzia hurbilenaren eta hiperplanoaren arteko distantzia maximiza-

tzen duen irtenbide bakarra dago. Bi dimentsioko espazio batean, hiperplanorik onena bi klaseen arteko tarte handienaren erdiko lerroa da (3.21. Irudian, $d1 = d2$ egiten duen lerroa da). Hiperplanotik hurbilen dauden instantziei “sostengu-bektore” deritze (3.21. Irudian gorriz nabarmenduta).

Analitikoki, sostengu-bektoreen arteko distantzia maximizatzen duen marjin maximoko hiperplanoa [46] defini daiteke planen Hesse forma normalaren antzeko ikuspegia erabiliz (3.15. ekuazioa).

$$\vec{\omega} \cdot \vec{x} - b = 0 \tag{3.15}$$

Geometriaren esparruko 3.15. ekuazioa gogoratuz, $\vec{\omega}$ hiperplano berriaren bektore normalari dagokio, b hiperplano horretako puntu bati eta \vec{x} instantziaren ezaugarriari. Hala ere, hemen ez dago $\vec{\omega}$ normalizatu beharrik. Hiperplano hori 3.21. Irudiko lerro jarraituari legokioke.


Formula analitiko hori erabiliz, bi hiperplano gehiago defini daitezke, jatorrizkoarekiko paraleloak direnak eta sostengu-bektoreak diren instantziek eutsiko dituztenak (3.21. Irudiko puntu lerroak). Hiperplano horiek definitzen dira, horietako baten gainetik dagoen \vec{x}_i instantzia bakoitza klase batena izan dadin (hau da, $\vec{y}_i = 1$, 3.16. ekuazioan). Era berean, beste hiperplanoaren azpian dagoen edozein instantzia \vec{x}_i beste klasekoa dela ezartzen da ($\vec{y}_i = -1$, 3.17. ekuazioa).

$$\vec{\omega} \cdot \vec{x}_i - b \geq 1 \rightarrow \vec{y}_i = 1 \tag{3.16}$$

$$\vec{\omega} \cdot \vec{x}_i - b \leq -1 \rightarrow \vec{y}_i = -1 \tag{3.17}$$


Bi hiperplano horien arteko distantzia $\frac{2}{\|\vec{\omega}\|}$ gisa defini daiteke. Beraz, $\|\vec{\omega}\|$ minimizatzeak marjinak maximoak izatea egiten du. Optimizazio-problema hori ebatzi ondoren, instantzia berri baten ezaugarriak sailkatzailean sartzen direnean, $\vec{\omega} \cdot \vec{x}_i - b$ -tik lortutako emaitzaren ikurra izango da zehaztuko duena instantzia berria klase batekoa ala bestekoa den. Zeinua positiboa bada, orduan $\vec{y}_i = 1$ eta, bestela, $\vec{y}_i = -1$.

Sailkapen-problema dimentsio handiko espazio bati dagokionean, SVMek berdin jarduten dute: klase bateko instantziak beste taldekoetatik linealki bereizten saiatzen dira. Hori esanda, kasu batzuetan klaseak ezin dira linealki banandu. Kasu horietarako, zenbait konponbide daude, hala nola ertz bigunak zehaztea edo kernela eraldatzea. Ertz bigunak aplikatzea teknika simple bat da, hiperplanoa eta marjinak definitzean nolabaiteko tolerantzia ahalbidetzen duena, kasu kopuru mugatu bat txarto sailkatzea baimenduz (ikus 3.22. Irudia).



3.22. Irudia. Ertz bigunen aplikazioak klaseak linealki banatzea ahalbidetzen du errore txiki bat izatearen truke.

Bestalde, kernel eraldaketek datuak eraldatzean datza. Honela, matematika-eragiketa batzuk erabilia, linealki banatu ahal ez diren klaseen instantziak beste espazio berri batera eramaten dira zeinean klaseak linealki banandu ahal diren (adibide grafiko bat 3.23. Irudian aurkeztu da). Instantzien distribuzioaren arabera, kernel eraldaketa ezberdinek soluzio hobeak edo okerragoak emango dituzte [47]: eraldaketa linealak, eraldaketa polinomikoak, eraldaketa erradialak...




3.23. Irudia. Kernel eraldaketei esker bi klaseen instantziak linealki bereiz daitezke.

Hurbileneko K bizilagunak (K-NN)

Algoritmo hauek instantzia batek lehenago sailkatutako instantziekiko duen hurbiltasunaren kalkuluan oinarritzen dira [48]. Antzekotasun-distantziak kalkulatu ondoren (normalean, distantzia euklidianoa), algoritmoek bozketa-prozesu bati ekiten diote. Bozketa horretan, instantzia berritik gertuen dauden klaseen artean, instantzia gehien dituen klasea hartuko da instantzia berriaren klasetzat.

Hala ere, instantzia guztiak ez dira kontuan hartzen, berritik hurbilen daudenak bakarrik. K parametroak zehazten du instantzia berritik hurbilen dauden zenbat instantzia hartuko diren kontuan bozketan. K parametro egokia aukeratzea oso garrantzitsua da, sailkapenaren emaitzean eragina izan dezakelako. Fenomeno horren adibide bat 3.24. Irudian ikus daiteke: $K = 3$ aukeratuz gero sailkapen arrakastatsua lortuko da (irudiaren ezker aldean); $K = 5$ aukeratuz gero, ordea, okerreko sailkapen emaitza lortuko da (irudiaren eskuinaldean).



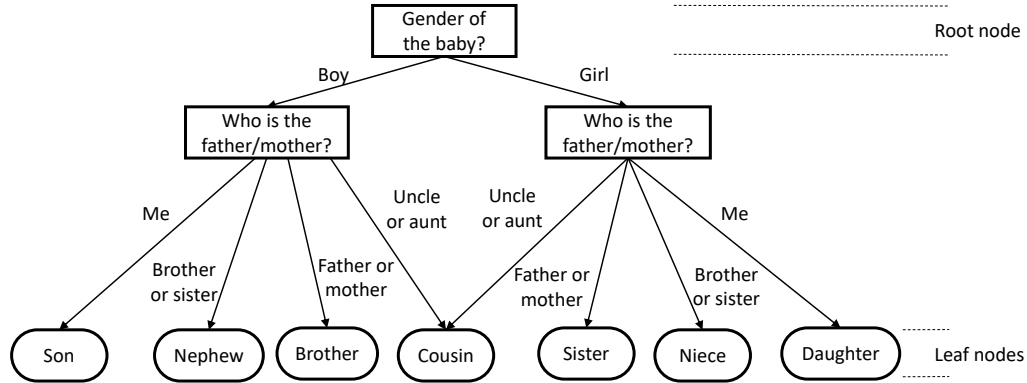
3.24. Irudia. Instantzia berriaren (izarra) klasea alda daiteke K parametroaren balioaren arabera.

Praktikotasunaren mesedetan, zenbait ikertzailek $K = \sqrt{n}$ erabiltzea proposatzen dute, non n entrenamenduko instantzia guztien kopurua den. Beste ikertzaile batzuek “saiakuntza eta errore” prozesuan baliozkotze gurutzatua erabiltzea proposatzen dute (geroago azalduko da 3.4.3. Azpiatalean). Hala ere, badaude aldaketak K -NN algoritmoan, K parametroko konfigurazio txarrek sortzen duten zaratarekiko erreaktibotasunari aurre egiten diotenak; esate baterako, pisu handiagoa ematen diete hurbilen dauden instantziei, urrunen daudenak eragin txikiagoa izan dezaten sailkapenean [49], [50].

Erabaki-zuhaitzak (DT)

DT-ak datuak sailkatzea ahalbidetzen duten fluxu-diagrama itxura duten egiturak dira. Hasierako nodotik, “erro-nodoa” deritzona, adar berriak ebaluazio-puntu batera bideratzen dira instantzien ezaugarri jakin baterako. Ezaugarriaren ebaluazioaren emaitzaren arabera, nodoa berriro adarkatuko da nodo gehiagoetara irekiz. Prozesu hau etengabe errepikatuko da azkenengo nodo batera iritsi arte. Instantziaren klasea erabakitzen duten azken nodo horiei “hosto-nodo” deitzen zaie. Sustraitik hostoetarainoko zuhaitz baten antzeko adarkatutako egitura horretik hartzen dute izena algoritmo hauek: erabaki-zuhaitzak (DT, ingelesez decision trees). Kontzeptua argitzeko, 3.25. Irudian DT simple adierazi da, familia bateko pertsona batek familia bereko haur jaioberri batekin duen ahaidetasuna zehazten duena.

3. KAPITULUA - SEINALE FISIOLÓGIKOAK, LOGIKA LAUSOA, IKASKETA AUTOMATIKOA ETA BCI SISTEMAK



3.25. Irudia. Familia bateko haur jaioberri batek familia bereko beste pertsona batekin duen ahaidetasuna zehazteko DT egitura.

DT egitura baten indukzioa prozesu iteratiboa da. Hiru sarrera behar dira horretarako [51]: instantzien D datu-multzoa, entrenamenduko instantzien C klaseak eta adar-banaketa metodoa. Ulergarritasunaren mesederako, adar-banaketa oraindik ezin da azalduko. DT bat sortzeko iterazio-prozesuak 3. Algoritmo urratsak ditu.

3. Algoritmoaren sasikodea behin eta berriz errepikatzen da, zuhaitza behar bezala adarkatuz partizio bateko instantzia guztiak klase berekoak izan arte edo instantziak deskribatzeko ezaugarririk ez dagoenera arte. Gainera, aurrekimaketa erabiltzen ez denean (aurrerago azalduko dugu), adarkatzea gelditu egiten da zatiketa-irizpide batek instantziarik gabeko partizio berri bat sortzen badu, hau da, partizio huts bat. Hori gertatzean, adar berriak baztertu egiten dira eta N nodoa aurreko zatiketaren kasu gehien zituen klasetzat etiketatuko litzateke. Adarkatze-prozesu bat gelditzen denean, algoritmoa beste adar batera joaten da eta prozesu bera errepikatzen du adarkatzeko geratzen diren datuekin.

Orain arte, DT-en eraikuntza azaldu da. Hala ere, adar-banaketa metodoa azaldu gabe dago oraindik. Adar-banaketa metodoak datu multzoa modurik homogeneoenean zatitzeko aukera ematen duen ezaugarria aurkitzen du. Aurkitu ondoren, zatiketa-punturik onena aukertzen du eta datu-multzoa azpimultzo txikiagoetan banatzen du. Metodoak aldatzen dira erabiliko den zuhaitz-motaren arabera: ID3 zuhaitzek "Information Gain" metodoa erabiltzen dute, C4.5 zuhaitzek "Gain Ratio" metodoa erabiltzen dute, CART zuhaitzek "Gini" indizea erabiltzen dute...

Azkenik, zuhaitzaren indukzioa amaitu ondoren, batzuetan adar-kopurua murriztu egin behar da, DTa sentikorregia baita zaratekiko eta anormaltasunetik. Landareen analogiarekin jarraituz, prozesu honi indukzio osteko kimaketa esaten zaio. Kimaketa normalean zuhaitzaren beheko adarretatik hasten da eta gorantz doa. Adar bat kimatu behar den edo ez erabakitze hainbat meto-

Algorithm 3 Erabaki-zuhaitzen indukzio algoritmo.

```

1: while gelditzeko_irizpidea == FALSE do
2:   N nodo berri bat sortu geratzen diren D datu multzoarekin.
3:   if D-ko instantzia denak klase berekoak dira == TRUE then
4:     N nodoa “hosto-nodo” bezala ezarri, D-ko instantzien klasekoa;
5:     gelditzeko_irizpidea = TRUE;
6:   else
7:     if instantzien ezaugarriak oraindik geratzen dira? == TRUE then
8:       Adarra banatzeko ezaugarri onena hartu eta horrekin D zatitu;
9:       Datu multzo berrietatik lehenago aukeratutako ezaugarria ezabatu;
10:      if D-tik ateratako datu multzo berriren bat hutsik dago? == TRUE
11:        then
12:          N nodoa “hosto-nodo” egin, D multzo originalean nagusi zen klasekoa;
13:          gelditzeko_irizpidea = TRUE;
14:        end if
15:      else
16:        N nodoa “hosto-nodo” egin, datuetan nagusi den klasekoa;
17:        gelditzeko_irizpidea = TRUE;
18:      end if
19:    end if

```

do daude. Adibidez, kostuen konplexutasuneko metodoek eta kimaketa-metodo ezkorrek zuhaitz originalaren errore-tasa kalkulatu dute eta adarra “hosto-nodo” batekin ordezkatuz gero lortuko zen errore-tasarekin konparatu dute. Adarrak sortzen duen errorea handiagoa balitz orduan zuhaitza kimatuko litzateke. Bestela, zuhaitza dagoen bezala utziko litzateke. Halaber, zuhaitz bat eraikitzen den heinean kimatu daiteke, adarretan behera doan instantzien kopurua esanguratsua ez denean adarkatze prozesua geldiaraziz. Kimaketa mota horri aurre-kimaketa deritzo.

Amaitzeko, DT-ak gizakientzat ulerterrazak dira eta hori oso propietate interesgarria da. Beraz, DT-ak erraz eralda daitezke arauetan oinarritutako sailkatzaile bat izateko, adibidez, (1R) arau baterko algoritmo bat izateko. Gainera, ausazko baso-sailkatzaileak (RF, random forest) sor daitezke, korrelaziorik gabeko DT multzo bat baino ez direna. Hauek, behin betiko sailkapen-emaizta orokorra ematen dute DT independente bakoitzaren irteerak erabiliz bozketa prozesu batean. Korrelaziorik gabeko DT hauek erraz entrena daitezke entrenamendu-datuak bootstrap metodoaren bidez aldatuz (hurrengo paragrafoetan azaldutako “bagging” metodoaren oso antzeko planteamendua). Horrela, DT-en desabantailetakoa bat gainditu daiteke: datuen zaratarekiko sentikortasun handia izatea.

Sailkatzaile-multzoak

Berez sailkatzaile-mota espezifiko bat ez diren arren, sailkatzaile-multzoak sortzea metodo orokorra da sailkapenen eta iragarpenen zehaztasuna hobetzeko. Sailkatzaile-multzoen metodoek proposatzen dutena sailkapena edo erregresioa egiteko hainbat eredu matematiko desberdin konbinatzea da. “Bagging” eta “boosting” metodoak aurki ditzakeg Sailkatzaile-multzoak ezagunen artean [51].

“Bagging” metodoa bigarren aditu baten iritzia lortzearen antzeko printzipioan oinarritzen da, bizitza errealean arraroa ez dena. Adibidez, osasunarekin zerikusia duten arazoetan, ohikoa da pazienteek mediku bat baino gehiagori bere iritziagatik galdetzea eta gehien errepikatzen den iritzia ontzat hartzea. Beraz, “bagging” metodoak egiten duena sailkapen-eredu bat baino gehiago sortzea, ondoren irteerarik ohikoena aukeratzeko (ikus 4. algoritmoa). “Bagging”-ak mota bereko hainbat sailkatzaile entrenatzea eskatzen du, datu multzo original “bootstrap” metodoa erabiliz eraldatuz entramendu bakoitzerako (metodo hau 3.4.3. Azpiatalean azalduko da). Behin nahi beste eredu entrenatu direla, egitike dagoen gauza bakarria eredu denak sarrera berarekin elikatzea da, geroago bozketa prozesua egiteko.

Algorithm 4 Bagging algoritmoa.

```
1:  $i=1$ ;  
2: while  $i <$  nahi diren eredu kopurua do  
3:   D datu multzo berria sortu bootstrap metodoa erabiliz;  
4:    $M_i$  ereduaren entrenatu sortutako D datu multzo berriarekin;  
5:    $i=i+1$ ;  
6: end while  
7:  $M$  eredu denak erabili sarrerako instantzia sailkatzeko eta aukeratu gehien errepikatutako emaitza.
```

“Boosting”-a problema baten emaitzak hobetzeko beste teknika bat da, zenbait eredu erabiliz. Hala ere, “bagging”-ean ez bezala, “boosting” metodoek ez diete garrantzi bera ematen sailkatzaile guztiei, bazik eta haien errendimenduen arabera haztatzen dira: sailkatzaile onenaren erabakiak pisu handiagoa du botoa ematean. Gainera, “boosting” metodoek sarrerek duten pisua ere aldatzen dute sarrera hori sailkatzeko erraztasunaren arabera. Beste era batera esanda, sarrera bat txarto sailkatzen bada, haren pisua handitu egingo da etorkizunerako. Aldiz, behar bezala sailkatu bada, sarrera instantziaren pisua murriztu egiten da. Horrela, “boosting” metodoak garrantzi handiagoa ematen die instantzia zailenei, instantzia horiek sailkatzeko errendimendua hobetu dadin.

“Boosting” metodo ezagunenetako bat Adaboost metodoa da (Adaptive Boosting esateko modu laburra) [52]. 5. algoritmoko pseudo-kodeak metodo hori laburtzen du klase bitarreko sailkapen baterako.

Algorithm 5 Adaboost boosting algoritmoa.

```

1: i=1;
2: while i < nahi diren eredu kopurua do
3:    $\omega_i$  instantzien pisuak hasieratu  $\omega_i = 1/D$  bete dadin,  $D$  datu multzoaren
   tamaina izanik;
4:    $M_i$  eredu bat entrenatu “lagindu eta ordezkatu” metodoa erabiliz;
5:    $\mathcal{E}$  errore-tasa kalkulatu: txarto sailkatutako instantzien pisue batukaria;
6:   if  $\mathcal{E} > 0.5$  then
7:      $M_i$  ereduak baztertu eta berriz hasi ereduak entrenatzen 1. pausutik;
8:   else
9:     Pisuak eguneratu:  $\omega_{i-new} = \omega_i \cdot (\mathcal{E}/(1 - \mathcal{E}))$ 
10:  end if
11:  Instantzien pisua normalizatu;
12:  i=i+1;
13: end while
14:  $M$  eredu denak erabili sarrera berriak sailkatzeko, eredu bakoitzari  $\omega_i$  pisu
   bat emanez geroko bozketan erabiltzeko,  $\omega_i = \log \frac{1 - \mathcal{E}_{M_i}}{\mathcal{E}_{M_i}}$  izanik.

```

3.4.2. Gainbegiratu gabeko ikasketa

Gainbegiraturako ikasketa-algoritmoetan ez bezala, gainbegiratu gabeko ikasketa-algoritmoek ez dute instantzien klasea ezagutu beharrik eredu bat ikasteko. Horren ordez, datuen ezaugarrietatik ikasten dute, eta, ondorioz, kanpoko laguntzarik gabe datuak taldekatzen dituzte. Beraz, datuen etiketatzea garestia edo oso motela denean bereziki erabilgarriak dira. Tesi honetan, K-means multzokatze-algoritmoa baino ez da azalduko, lan honetan erabili den gainbegiratu gabeko ikasketa-metodo bakarra izan baita.

Multzokatze-metodoen helburua datuen barruan antzekotasunak aurkitzea da, instantziak antzeko propietateak dituzten multzoetan bil daitezten, eta,aldi berean, beste multzo batzuen instantzien desberdinak diren propietateak izan ditzaten. Hala ere, algoritmoaren arabera, antzekotasuna hainbat era ezberdinetan neur daiteke. Zehazki, dokumentu honek K-means multzokatze metodoan zentratuko da.

K-means

K-means algoritmoa multzokatze-metodo bat da, distantziak erabiltzen dituen instantziak multzo ezberdinetan taldekatzeko. K-meansen kasuan, K parametroak datuak taldekatzean sortuko diren multzo kopurua adierazten du; $K = 3$ bada, datu guztiak hiru multzo handitan bilduko dira, eta $K = 5$ bada, beste bi kluster/multzo gehiago sortuko dira. Beraz, K parametro hori erabiltzaileak definitu behar du.

K-means algoritmoaren funtzionamendua sinplea da: K multzoen zentroideak mugitzen ditu, zentroide bakoitzeko taldean dauden instantzia denak eta

3. KAPITULUA - SEINALE FISIOLÓGIKOAK, LOGIKA LAUSOA, IKASKETA AUTOMATIKOA ETA BCI SISTEMAK

zentroide beraren arteko distantziak minimizatzeko. Horretarako, lehenik eta behin, algoritmoak K zentroideen kokapena hasieratuko du, datu multzoan dauden eta zoriz aukeratutako K instantzien kordenatuak erabiliz. Horren ondoren, prozesu iteratiboa hasiko da (ikus 6. algoritmoa n dimentsioko kasu baterako): lehenik, instantzia guztiak hurbilen dagoen zentroideko multzoari egokitzen zaie; gero, zentroideak birkalkulatu egiten dira, multzo horretako instantzia guztiek duten zentroiderako distantzia euklidianoaren errore karratuen batura minimizatzeko. Algoritmoaren zenbakizko adibide bat aurki daiteke [53]n. Prozesu hau errepikatu egiten da instantzia bakar bat ere ez denean multzo batetik bestera aldatzen edo algoritmoa N_{lim} iterazio egitera heldtzen denera arte.

Kontuan izan behar da K-means multzokatze-metodoaren emaitza, era nabarmen batean, zentroideen hasierako posizioaren mende dagoela. Horrela, litekeena da multzokatzearen emaitza desberdinak lortzea, hasierako zentroidearen posizioak aldatzen badira. Beraz, ohikoa da K-means algoritmoa zenbait aldiz exekutatzeko eta, emaitza denak konparatuta, errendimendu onena ematen duen bertsioa aukeratzeko. Hala ere, horrek konputazio eta denbora-kostuak handitzen ditu. Bestalde, teknika batzuk arazo horri aurre egiten saiatzen dira, hasierate-parametro onenak hautatuz [54].

Algorithm 6 K-means multzokatze algoritmoa.

- 1: K emanda, K zentroideak hasieratu zoriz aukeratutako K instantzien posizioak erabiliz;
- 2: $n_{iterazio} = 1$;
- 3: **while** gelditzeko_irizpidea == FALSE **do**
- 4: n ezaugarri dituzten i instantzien eta k zentroideen arteko distantziak kalkulatu:

$$distantzia_{ik} = \sqrt{(x_{1k} - x_{1i})^2 + (x_{2k} - x_{2i})^2 + \dots + (x_{nk} - x_{ni})^2}$$

- 5: i instantzia $distantzia_{ik}$ distantzia minimoa duen multzoari egokitu;
- 6: **if** (instantziak_taldez_aldatu == FALSE) **or** ($n_{iterazio} > N_{lim}$) **then**
- 7: gelditzeko_irizpidea = TRUE;
- 8: **break**;
- 9: **end if**
- 10: k multzoko zentroidaren koordenatu berriak kalkulatu (k multzo barruan dauden q instantzien kopuruaren arabera izango da):

$$(x_{1k}, x_{2k}, \dots, x_{nk}) = \left(\sum_{i=1}^q \frac{x_{1i}}{q}, \sum_{i=1}^q \frac{x_{2i}}{q}, \dots, \sum_{i=1}^q \frac{x_{ni}}{q} \right)$$

- 11: $n_{iterazio} = n_{iterazio} + 1$;
 - 12: **end while**
-

3.4.3. Balioztatzeko datuen zatiketa partizioetan

Sailkatzailearen portaera ebaluatu behar denean, esan bezala, garrantzitsua da entrenamenduko datuak aparte uztea eta erabili gabe mantendu diren testarako datuak soilik erabiltzea. Beraz, testaren datu multzoa izango da algoritmoen errore eta arrakasta tasak zehaztuko dituenak. Azpialt honetako datuak partizioetan zatitzeko erabiltzen diren metodoetako batzuk aurkeztuko ditu, algoritmoen portaera kalkulatzeko balio dutenak: hold-out metodoa, bootstrap aukeraketa metodoa eta K-iterazioidun baliozkotze gurutzatua.

Kanpoan utzi metodoa

Hold-out metodoa (kanpoan utzi) datuak banatzeko metodorik sinpleena da. Datuak aleatorioki bi zatitan banatzen dira, entrenatzeko eta testatzeko partizioetan. Normalean, datuen $2/3$ erdua entrenatzeko erabiltzen dira eta gainerako $1/3$ errendimendua testatzeko.

Hold-out metodoak badu aldaketa zehatz bat ausazko azpilaginketa deritzona eta zeinean hold-out prozesua k aldiz errepikatzen den. Gero, k datu-multzo ezberdin erabiltzen dira entrenamendurako eta, ondorioz, eredu horiek k aldiz testatuko dira errendimenduaren neurriak ateratzeko. Azkenik, batezbesteko errendimenduaren balioa kalkulatu da aurreko k errendimendu horien balioak erabiltzen dira.

Bootstrap aukeraketa metodoa

Bootstrap metodoa “lagindu eta ordezkatu” planteamenduan oinarritzen da. Printzipioa sinplea da; iteratiboki, datu-baseko instantzia bat hautatzen da entrenamendu-multzoa sortzeko. Hala ere, hautatutako instantzia ez da datu-multzotik ezabatzen, baizik eta hurrengo iterazioan berriro hautagaia izateko mantenduko da. Prozesua hau datu-multzoan dauden instantzia kopurua adina aldiz errepikatzeari 0.632 bootstrap aukeraketa izena ematen zaio (hurrengo bi paragrafoetan azalduko dute).

Argi dago kasu batzuk entrenamendurako partizioan errepikatuko direla eta beste batzuk, ordea, ez direla horretarako erabiliko. Instantzia guztiek entrenamendurako hautatuak izateko probabilitate bera dute beti, hau da, $P_{entrenamendu} = 1/n$, n datu-basearen tamaina izanik. Aitzitik, entrenamendurako hautatua ez izateko probabilitatea (edo, bestela esanda, testarako hautatua izateko aukera) $P_{testa} = 1 - 1/n$ da. Lehenago esan bezala, prozesua errepikatzen bada n aldiz, orduan, testako partizioan egoteko instantzia baten probabilitatea $P_{testa} = (1 - 1/n)^n$ izango da, 0.3678-ra hurbiltzen da. Eta, ondorioz, $P_{entrenamendu} = 1 - P_{testa} = 0.632$ izango da.

Azkenik, errore-tasa zehazteko beharrezkoa izango da algoritmoak izango duen entrenamenduko partizioaren probabilitateekiko alborapena konpentsatzea. Horretarako, entrenamenduaren eta testaren errore-tasak kontrako partizioare dagokion probabilitatearekin biderkatu behar dira [55]. Zenbakiz, honela irudikatuko litzateke: $\mathcal{E} = \mathcal{E}_{entrenamendu} \cdot 0.3678 + \mathcal{E}_{testa} \cdot 0.632$.

K-iterazioidun baliozkotze gurutzatua

Tesi honetan datuak banatzeko azalduko den azken metodoa K-iterazioidun baliozkotze gurutzatuko metodoa da, K-fold cross-validation deritzona. Metodo honen bidez, datu multzo bat tamaina bereko K zatietan banatzen da, instantzi bakoitza partizio bakar batean egongo direlarik esklusiboko. Gero, partizio guztietatik bat bakarrik testa egiteko gordeko da eta gainontzeko $K - 1$ partizioak ereduak entrenatzeko erabiliko dira. Prozesu hau K aldiz errepikatuko da, modu sekuentzialean testa egiteko partizioa aldatzen: lehenengo exekuzioan 1. partizioa gordeko da, bigarrenean 2. partizioa, eta horrela hurrenez hurren, amaitu arte. Azkenik, ausazko azpilaginketa egiteko egiten den bezala, errendimendua kalkulatzeko, algoritmoaren errendimenduko emaitzak K errepikapenetatik lortutako emaitza guztien batezbestekoa eginez kalkulatu da.

Normalean, K -k 10 edo hortik hurbil dagoen beste zenbaki bat (adibidez, 5 edo 20) izateko ezartzen da. Metodo hau erabiltzean, K ezartzeaz gain, datuak estratifikatzea garrantzitsua da. Horrek esan nahi du partizio guztiek antzeko instantzia kopuru bat izan behar dutela datu multzoko klase bakoitzerako. Bestela, ereduak klase baten alde joera izateko arriskua legoke. K-iterazioidun baliozkotze gurutzatuari esker, entrenamendua egiteko datuen %90 erabil daiteke. Dena den, beste metodoekin alderatuta, konputazio-kostu handiagokoa da.

Azkenik, K-fold baliozkotze gurutzatuaren konfiguraziorik muturrekoena “leave-one-out baliozkotze gurutzatua” bezala ezagutzen da. Honetan, testa egiteko instantzia bakarra gordetzen da. Konputazionalki oso garestia da, ia instantzia denak entrenamendurako erabiltzen baitira. Horregatik, baliteke oso datu-multzo handietan erabiltzea ezinezkoa izatea. Hala ere, datu-multzo txikiagoak oso eraginkorra izan daiteke.

3.4.4. Portaera ebaluatzeko neurriak

Orain arte, zatiketa-metodo batzuk azaldu dira. Azalpenetan, portaera edo errendimendua neurtzeko metrikak kalkulatzeko modua aldatu egin behar dela aipatu da. Hala ere, errendimendu-metrika horiek ez dira oraindik azaldu. Azpialt honetan, problema jakin baterako sailkatzaile desberdinek zein ongi funtzionatzen duten konparatzeko erabil daitezkeen portaera ebaluatzeko metrika erabilienak aurkeztuko dira. Errendimenduaren metrika gehienak kalkulatzeko hurrengo indize hauek erabiltzen dira, sailkapeneko klase bat erreferentziatzen hartzen dutenak:

- **Benetako positiboak (true positives, TP):** erreferentzia klaserako behar bezala sailkatu diren instantziak.
- **Positibo faltsuak (false positives, FP):** erreferentzia klasekoak balira bezala sailkatu diren instantziak dira, baina benetan beste klase batekoak direnak.

- **Benetako negatiboak (true negatives, TN):** erreferentzia klasea ez den beste klase bati zuzen egokitutako instantziak dira, hau da, erreferentzia klasekoak ez zirela ondo asmatutako kopurua.
- **Negatibo faltsuak (false negatives, FN):** erreferentzia klasekoak ez den beste klaseri oker egokitutako instantzien kopurua, horiek benetan erreferentzia klasekoak zirelako.

Zehaztasuna and errore-tasa

Errendimenduaren bi metrika hauek elkarren osagarri dira. Zehaztasunak ondo sailkatutako instantzien ehunekoa adierazten duen bitartean, errore-tasak gaizki sailkatutako kasuen ehunekoa adierazten du. Beraz, bi adierazleak [0-1] artean definitzen dira. Zehaztasunak eta errore-tasak, hurrenez hurren, 3.18. eta 3.19. adierazpenen bidez deskribatzen dira.

$$acc(\text{zehaztasuna}) = \frac{TP + TN}{TP + TN + FP + FN} = \frac{T}{T + F} \quad (3.18)$$

$$err \text{ or } \mathcal{E} = \frac{FP + FN}{TP + TN + FP + FN} = \frac{F}{T + F} = 1 - acc \quad (3.19)$$

Nahaste-matrizeak

Nahaste-matrizea taula bat da, non klase guztiak ilarako eta zutaberako goiburu gisa jartzen baitira. Han, ilara bakoitzeko klase bat harzen da erreferentziatza analisirako eta zutabeek sailkatzaileak adierazitako klasea adierazten dute. Beraz, gelaxkek erreferentziako instantzien zein kopuru zein klaseri egokitu zaizkion adierazki dute. 3.4. Taularen adibideari erreparatuz gero, konfusio-matrizeek nola funtzionatzen duten uler daiteke.

3.4. Taula. 330 instantzia dituen datu multzo baten nahaste-matrizea. 110 instantzia daude klase bakoitzeko.

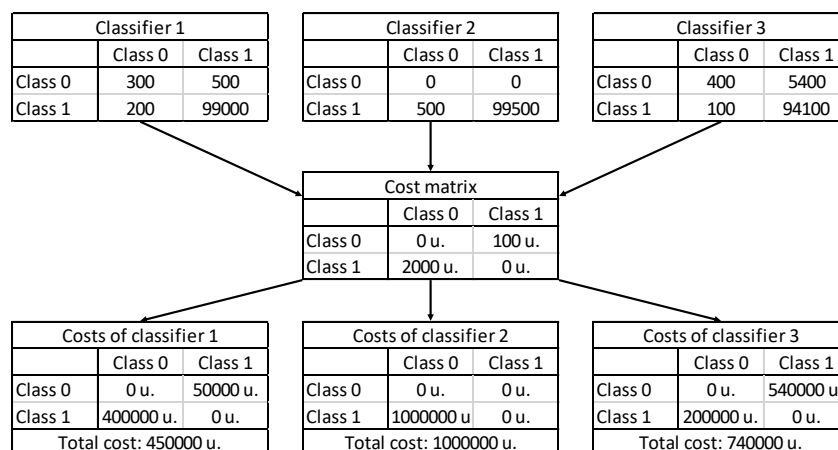
	1. klasea	2. klasea	3. klasea
1. klasea	100	10	0
2. klasea	5	85	20
3. klasea	10	20	80

3.4. Taulako nahaste-matrizeari erreparatuta, ikus daiteke erabili zen sailkatzaileak emaitzarik onenak lortu zituela lehen klaserako, 100 instantzia zuzen sailkatu baitziren eta 10 bakarrik sailkatu baitziren gaizki. Bestalde, sailkapen oker kopuru handienarekin, sailkatzailearentzat hirugarren klasea izan zen identifikatzeko klaserik zailena.

3. KAPITULUA - SEINALE FISIOLÓGIKOAK, LOGIKA LAUSOA, IKASKETA AUTOMATIKOA ETA BCI SISTEMAK

Sailkatzailearen errendimendu orokorra nolakoa izan zen ondo ikusteaz gain, nahaste-matrizeak erabilgarriak dira okerreko sailkapenek sortzen dituzten kostuekin lotuta sailkatzaile bat baino gehiagoren artean konparaketa egiteko. Bazuetan, klase bat oker klasifikatzea beste bat txarto klasifikatzea baino askoz okerragoa da [42]. Horren adibide garbia minbiziaren diagnostikoan dago, non positibo faltsu (FP) batek sortzen duen galera negatibo faltsu (FN) batek sortzen duenarekin alderatuta oso txikia den. FN batek minbizia dagoela baina ez dela detektatu adierazten du, eta horrek ondorio hilgarriak izan ditzake gaitzarentzat, detekzio azkarra kritikoa baita minbiziaren tratamendurako. Bestalde, FP batek ez luke izango horren ondorio kritikoa izango. Izan ere, FP batek pazientearen minbizia duela adierazki luke, baina ondorengo diagnosi-probek baztertu egingo lukete hipotesi faltsua. Beraz, nahiz eta bi diagnostiko-akatsak ondorio kaltegarriak dituzten, FN-ren kostu pertsonala askoz handiagoa da.

Egia esan, giza bizitza bakar baten kostua handiegia da izatez. Hala ere, aukerarik garestiena hain argia ez denean, ez dago oso argi aplikazio baterako zein sailkatzaile izango den egokiena. Kasu horietan, gaizki sailkatutako kasuen guztizkoa biderkatu egiten da sailkapen-mota bakoitzaren kostuarekin, hots, kostu txikiagoa duten erroreen sailkatzailea aukeratzeko. Hori 3.26. Irudiko diagramaren adibidean ikus daiteke. Han ikusi datieke lehenengo sailkatzailea erabiltzea aukerarik onena dela, nahiz eta bigarren sailkatzaileak baino akats gehiago egiten dituen.



3.26. Irudia. 2. sailkatzaileak akats gutxiago dituen arren, akatsari lotutako kostuek erakusten dute aukerarik onena 1. sailkatzailea erabiltzea dela.

Doitasuna, estaldura, espezifikotasuna eta F-neurriak

Azaldu berri dugunez, batzuetan garrantzitsua da egiten akatsei sakonago begiratze. Alde horretatik, zehaztasun eta errore-tasa indizeak engainagariak izan daitezke, 3.26. Irudiko adibidean gertatu zen bezala. Hori dela eta, errendimendu-adierazleen multzo berri bat diseinatu zen, bakoitza sailkapenaren zati jakin batean zentratzen delarik.

- **Doitasuna (precision, pr):** positibotzat sailkatutako instantzia guztien artean, benetako positiboen ehunekoa adierazten du.

$$pr = \frac{TP}{TP + FP} \quad (3.20)$$

- **Estaldura (recall, re):** datu-multzoan klase positiboa duten kasu guztien artean, benetako positiboen ehunekoa da. Sailkatzaileak kasu positiboak detektatzeko duen gaitasuna adierazten du.

$$re = \frac{TP}{TP + FN} \quad (3.21)$$

- **Espezifikotasuna (specificity, sp):** datu-multzoan klase negatiboa duten kasu guztien artean, benetako negatiboen ehunekoa da. Sailkatzaileak alarma faltsuak saihesteko duen gaitasuna adierazten du.

$$sp = \frac{TN}{TN + FP} \quad (3.22)$$

- **F_β -neurriak:** doitasunaren eta estalduraren arteko oreka-neurria ematen duen indizea da. Bietako bat altua bada baina bestea ez bada, F_β -neurria txikia izango da. Normalean, doitasunari eta estaldurari garrantzi bera emateko $\beta = 1$ ezartzen da, F_1 indizea lortuz. Beharren arabera alda daiteke hori: β handitzen bada, orduan doitasunak garrantzia hartzen du, eta kontrakoa gertatzen da txikiagotzen denean.

$$F_\beta = (1 + \beta^2) \cdot \frac{pr \cdot re}{(pr \cdot \beta^2) + re} \quad (3.23)$$

F neurriak bereziki erabilgarriak dira doitasunak eta estaldurak informazio nahasia eman dezaketenean. Adibidez, $pr = 1$ eta $re = 0.7$ badira, pentsa daiteke algoritmoa oso ona dela, baina $F_1 = 0.8235$ izango zen. Horrek adieraziko luke algoritmoa ez dela doitasunari begiratzekoan pentsatu ahal zen bezain ona.

3.4.5. Sarri erabilitako beste erremintak

Azpiatal honek ikasketa automatikoarekin zerikusia duten zereginetan erabili diren beste bi erreminta aurkeztuko dira, beste edozein azpiataletan guztiz sartu ezin direnak. Lehenengo tresna Wilcoxon testa da, emaitzen esanahi estatistikoa aztertzeko erabiltzen dena. Azpiatal honetan aurkeztutako bigarren teknika korrelazioan oinarritutako ezaugarrien aukeraketa metodoa da (correlation-based feature selection, ingelesez). Bigarren teknika hori ez da izatez ikaskuntza automatikoko algoritmo bat, baina askotan sailkapen-lana sinplifikatzeko erabiltzen da, sailkatzaileei beren lana egiten lagunduz.

Wilcoxon testa

Wilcoxon proba test estatistiko ez-parametrikoa bat da [56], eta baliagarria da lagin parekatuen arteko erlazioa aztertzeko. Beraz, bi sailkatzailek lortutako emaitze artean alde estatistiko adierazgarririk dagoen zehazteko erabil daiteke. Proba honen abantaila bat da, ez-parametrikoa izanik, konparatuko diren laginek ez dutela inongo distribuzio estatistikorik izan behar. Hurrengo paragrafoetan azalduko den arren, ordenagailurako aplikazio matematiko askok testa automatikoki kalkulatzeko funtzioak dituzte konparatu beharreko laginen emanda. Adibidez, “`signrank(x,y)`” funtzioa Matlab[®]-en edo “`wilcox.test(x,y,paired=TRUE)`” R-n.

D_1 eta D_2 datu-multzoen arteko Wilcoxonon testa kalkulatzeko, lehenengo bi datu-multzoen laginak binaka parekatu behar dira. Gero, lagin bikote bakoitzaren arteko diferentzia absolutua kalkulatu da kenketa honekin: $|X_{D_2i} - X_{D_1i}|$. Urrats honetan, diferentzia absolutua 0 bada, emaitza hori ematen duen bikotea baztertu egin behar da, konparatu beharreko datuen tamaina murriztu.

Hurrengo urratsa baztertu ez diren diferentzia absolutu guztiak txikitik handira ordenatzea da. Diferentzia absolutu bera ematen duen bikote bat baino gehiago badago, orduan diferentzia hori ematen duten bikote denak posizio beheren sailkatuko lirateke. Horien posizioa beteko litzuketen posizio guztien batez bestekoa izango litzateke. Adibidez, 4., 5. eta 6. posizioak izango zituzten hiru balio errepikakor baleude, horiek guztiak 5. posizioan sailkatuko lirateke. Azalpenerako, bikote bakoitzak okupatzen duen posizioari R_i deituko zaio.

Azkenik, sailkapena ezagututa, test estatistikoa kalkulatu daiteke 3.24. ekuzioa erabiliz, eta, horren ostean, p-balioak kalkulatu daitezke ere. Alde horretatik, 0,05etik beherako p-balioek adierazten dute emaitzak aleatorioak izateko %5 baino probabilitate txikiagoa dagoela. Hortaz, hau betetzean, emaitzen arteko ezberdintasunak estatistikoki esanguratsuak direla esan daiteke.

$$W = \sum_{i=1}^N \text{zeinua}(X_{D_2i} - X_{D_1i}) \cdot R_i \quad (3.24)$$

Korrelazioan oinarritutako ezaugarrien aukeraketa

Ez da arraroa datu multzoek zaratatsua edo erredundantea den informazioa izatea. Egoera hauetan ikasketa automatikoko algoritmoentzat zailagoa izaten da baliozko informazioa ateratzea. Are gehiago, datu zaratatsu eta erredundantea izateak sailkatzailearen errendimenduan eragin handia izan dezake. Erabaki-zuhaitzak honen adibide argiak dira, datuak ezaugarri esanguratsuenaren arabera zatitzen dituztelako. Hortaz, algoritmo batzuk erabiltzeko oso garrantzitsua da datuak ondo garbitzea sailkapena egin baino lehen, hau da, ezaugarri garrantzitsuenak aukeratzea. Izan ere, zaraten eta erredundantzien aurka sendoak diren algoritmoei ere laguntzen die ezaugarrien aukeraketak eta honi esker azkarrago funtzionatzea lor dezakete. Beraz, ondoriozta daiteke arazoaren dimentsioaren tamaina txikitzeak kasurik gehienetan onuragarria izaten dela.

Tesis honen lana garatu zenea, ezaugarrien aukeraketa korrelazioan oinarritutako ezaugarrien aukeraketa metodoaren bidez egiten zen (correlation-based feature selection, CFS), [57]n aurkeztua. Metodo honek S ezaugarri azpimultzoen $Meritua_s$ meritua ebaluatzen du klase baten detedktatzeko duen erabilgarritasunaren arabera. Era berean, ezaugarri horien erredundantziaren neurria ematen du ere. Ikuspegi honen arabera, $Meritua_s$ balio handiena lortuko duen ezaugarri azpimultzoa esanguratsuen izango da. $Meritua_s$ balioa 3.25. ekuaizoa erabiliz kalkulatu da, non k azpimultzoan dauden ezaugarri kopurua esan nahi duen eta r_{cf} eta r_{ff} -k, hurrenez hurren, klaseko batezbesteko eta klaseen arteko batezbesteko korrelazioak adierazten dituzten.

$$Meritua_s = \frac{k \cdot r_{cf}}{\sqrt{k + k \cdot (k - 1) \cdot r_{ff}}} \quad (3.25)$$

[57]n esan bezala, planteamendu honen aplikazioak “best-first” (onena lehenago) bilaketa estrategia heuristikoa oinarritzen da. Lehenik eta behin, metodoak hutsik dagoen S ezaugarri azpimultzo batekin hasiko da eta ezaugarri berriak banan-banan ebaluatuko eta gehituko ditu. Era honetan, garrantzitsua izaten ziurtatzea algoritmoak aukera posible denak ez dituela aztertuko. Hau egiteko, algoritmoari gelditzeko esaten zaio ikusten denean hobekuntzarik ez dela lortzen jarraian guztiz hedatutako bost azpimultzo aztertu ondoren.

3.5. Burmuin-konputagailu interfazeak (BCI)

Burmuin-konputagailu interfaze (BCI, ingelezko brain-computer interface-tik) sistemak buurmuineko aktibitate elektrikoa lagindu eta prozesatzen duten sistema horiek dira, erabiltzaileak bere ingurunearekin elkareragiteko (adibidez, ordenagailu edo eragingailu robotiko bat kontrolatzeko). Beraz, BCI aplikazioei esker erabiltzaileek muskuluak erabiltzea sahiestu dezakete azkenengo eragingailu hori kontrolatzeko, behar berezi zehatz batzuk behar dituzten erabiltzaileentzat bereziki interesgarria dena. EEG informazioa jasotzeko kaskoaz gain,

BCI sistema denek ikasketa automatiko algoritmoak erabiltzen dituzte EEG-etan ematen diren patroiak erabiltzaileak nahi duen kontrol egoeraren batekin erlazionatuta dagoen ezartzeko. Hortaz, BCI sistemak ikertzen dituen disziplina 3.4. Atalean aurkeztutako ikasketa automatikoen teknikei oso era estuan dago lotuta.

Atal honen bidez, disertazioak BCI sistemak oinarritzen diren printzipio ohi-koenetako batzuk azalduko ditu: gertaerei lotutako potentzialak (event-related potentials, ERP), bisualki eragindako potentzial egonkorak (steady-state visually evoked potentials, SSVEP) eta gertaerei lotutako desinkronizazio/sinkronizazioan oinarritutako imajinazio motorreko sistemak (event-related desynchronisation/synchronisation, ERD/ERS). Sistema mota horiek 3.5.1., 3.5.2. eta 3.5.3. Azpiataletan azalduko dira, hurrenez hurren.

3.5.1. Gertaerei lotutako potentzialak (ERP)

BCI sisteam hauek erabiltzailea gertakari zehatz bat detektatzeko kontzentratuta izatean oinarritzen dira. Gertakari hori gertatzeko zain dagoen bitartean, erabiltzailearen burmuineko aktibitatea erlatiboki egonkor mantenduko da. Dena den, bilatutako gertakaria ematen denean, gertaerari lotutako burmuineko aldeko EEG seinaleetan alterazio nabaria emango da. Adibidez, gertakaria soinu-estimulu bat bada, erabiltzaileak soinu zehatz hori entzutean alterazio bat emango da bere burmuineko entzumen-kortexean (burmuineko bi alboetara kokatzen dena). Era honetan, zenbait estimulu mota ezbedin erabili daitezke ERP-ak sortzeko: bisualak, ukimenarekin lotutakoak, entzumenezkoak, elektrikoak...


ERP-ei dagokienez, EEG-etan sortuko diren alterazioak aukeratutako estimuluaren ezaugarrien arabera izango dira. Hala izanda era, denek ezaugarri bat dute komunean: beti izango da latentzia denbora bat estimulua somatzen den momentuaren eta EEG alterazioa sortzen den momentuen artean. Honek esan nahi du denbora tarte bat egongo dela estimula somatzen denetik EEG alterazioan piko maximo edo minimoa sortzen den arte. Beraz, EEG alterazioaren morfologia ezagutzea oso garrantzitsua da estimulua somatu den zehaztuko duen ikasketa automatikoko algoritmo bat diseinatzerakoan.

ERP-ak izendatzeko badago akordio orokorra. Hasieran, “P” eta “N” letrak erabiltzen ziren EEG tentsioaren desbiderapenaren seinua positiboa edo negatiboa zen adierazteko. Letra horri lotuta, zenbaki bat erabiltzen da ere EEG alterazioa emateko behar den denbora adierazteko (milisekundutan). Adibidez, tentsio desbiderapena negatiboa bada eta 200ms behar izan baditu agertzeko, orduan ERP horren izena N200 izango zen. Dena den, denbora hauek erreferentzia moduan hartzen dira, ERP alterazioak agertzeko denborak ez direlako deterministak eta pixkat aldatu daitezkelako [58]. ERP guztien artean, P300-ak literaturan gehien aztertu direnetarikoen artean dago, letreiatzeko aplikazioan (speller application) gertatzen den bezala.

Letreiatzeko BCI aplikazioa, bere izenak adierazten duen moduan, erabiltzaileak hitzak sortzeko letrak banan-banan idaztea ahalbidetzen duen sistema da [59]. Normalean, letrak eta zenbakiak pantaila batean adierazten dira, matrize

3.5. BURMUIN-KONPUTAGAILU INTERFAZEAK (BCI)

formatu batean zeinetan matrize gelaxka bakoitzaren barrua letra edo zenbaki bakarria dagoen [60]. Orduan, aplikazioa exekutatzen den bitartean, BCI sistemak letrak eta zenbakiak nabarmenduko ditu era kontrolatuan (ikus 3.27. Irudia, [61]tik ateratakoa). Hau gertatzen den bitartean, erabiltzaileak idatzi nahi duen letra edo zenbakiari bakarrik egongo da begira. Honi esker, BCI sistemak P300 ERP bat detektatuko du erabiltzaileak nahi duen letra nabarmentzen dela somatzen duenean, eta hor detektatzean, BCI sistemak hizki hori pantailan idatziko du.



3.27. Irudia. P300 potentzialak detektatu daitezke nahi diren letrak nabarmendu direla somatzean.


3.5.2. Bisualki eragindako potentzial egonkorak (SSVEP)

Erabiltzaileak etengabe dir-dir egiten duen argi iturri bati begiratzen dionean burmuinean potentzial elektrikoak eragiten dira ere. Hau gertatzean, ikusmenari lotutako kortexeko eremuetan posible da erresonantzia bat detektatzea argiak dir-dir egiten duen frekuentziako aktibitate elektrikoan, kortex okzipitalean eta kortex parietaleko atzekaldean [62], alegia. Erresonantzia hau egonkor egongo da (teknikaren izenak adierazten duen moduan) erabiltzaileak dir-dir egiten duen argiari begiratzeari uzten dionera arte. Hortaz, pantaila bateko alde ezberdinetan frekuentzia ezberdinetan dir-dir egiten duten puntuak jartzen badira, orduan EEG erresonantzia ezberdinak sor daitezke eta hauen detekzioa erabil daiteke erabiltzaileak nahi dituen agindu komandoak bidaltzeko. 3.28. Irudian ikusi daiteke nola dir-dir egiten duen frekuentziak potentzial ezberdinak eragiten dituen EEG kanal ezberdinetan (irudia [63]etik atera da).

Sistema mota hauen alderik onenetariko bat da erresonantziak erraz detekta daitezkeela Fourierren transformatua erabiliz eta geroago potentzia espektroko dentsitatea kalkulatu. Ere, erabiltzaileak agindu komando asko izatea per-

3. KAPITULUA - SEINALE FISIOLÓGIKOAK, LOGIKA LAUSOA, IKASKETA AUTOMATIKOA ETA BCI SISTEMAK

mititzen dute sistema hauek. Azken finean, frekuentzia ezberdin asko detekta daitezke, [64]n egin zen bezala, 12 klase ezberdin detektatu zirela. Bestalde, EEG kaskoa eramatea inbaditzailea ez dela kontsideratzen den arren, dir-dir egiten duen argi bati begiratzeari nahiko metodo oldarkorra da eta erabiltzailea erraz nekatu daiteke.



3.28. Irudia. Gorriaz markatutako 12.5Hz-ko frekuentzia dir-dir egiten duen estimuluaren frekuentziari dagokio.

3.5.3. ERD/ERS imajinazio motorreko sistemak

Tesi honetan azalduko den azkenengo BCI metodo edo aplikazioa gertaerei lotutako desinkronizazioan (event-related desynchronisation, ERD) eta gertaerei lotutako sinkronizazioan (event-related synchronisation, ERS) oinarritutako imajinazio motorreko sistemak dira. ERD/ERS parametroak adierazten du frekuentzia banda batean ematen den potentzialen handipena edo murrizketa gertakari jakin bat somatzean [58], [65]. ERD/ERS imajinazio motorreko BCI sistemen kasuan, aldatzen direnak β eta μ bandak dira. 3.2.4. Azpiatalean azaldu den bezala, bi banda hauek deusetzen dira gorputzeko atal bat mugitzean [66]. Dena den, hau ez da soilik gorputze atal bat mugitzean, baizik eta atal bat mugitzeari buruz pentsatzen denean ere. Hori dela eta, BCI sistema mota honek izen hori hartzen du.

Fenomeno honi esker, ikasketa automatikoko algoritmoak gorputzeko atal zehatz baten mugimenduari lotutako EEG patroiak detektatzeko gai dira. Beraz, burmuineko zonalde zehatzetan gorputzeko zein ataleko mugimendua kontrola-

3.5. BURMUIN-KONPUTAGAILU INTERFAZEAK (BCI)

tzen den jakitea oso garrantzitsua da. Adibidez, C3 kanala (ezker hemisferioan) nabarmen deuseztatzen da eskuineko besoa mugitu nahi dela pentsatzean. Bestalde, C3 egonokor mantentzen den arren, eskuineko hemisferioko C4 kanala deuseztatuko da ezkerreko besoa mugitzeari buruz pentsatzean. Hortaz, gorputzaren alde bateko gorputzadarrak burmuineko kontrako aldean kontrolatzen dira. Dena dela, eskuei eta besoei lotutako patroiak detektatzea erraza den arren, aipatu behar da gauza berdina hankekin egitea askoz zailagoa dela. Hau honela da hanka bakoitza kontrolatzen duen kortexen eremuak elkarrekiko oso gertu daudelako eta, hori dela eta, jasotako EEG seinaleak oso antzerakoak dira eta zaila da bien artean ezberdintzea.

BCI metodologia mota honen erabilera oso interesgarria da, ERP eta SSVEP sistemetan ez bezala, ez dagoelako kanpoko estimuluen beharrik; erabiltzailea bera da EEG patroiak sortzen dituen irudimena erabiliz. Ordea, entrenamendu denbora luzeak eskatzen ditu, ez bakarrik ikasketa automatikoko sistema entrenatzeko baizi eta erabiltzailea bera entrenatzeko ere (gorputzadar bat mugitzeari buruz pentsatzea ez da oso gauza normala). Hortaz, sistemaren portaera erabiltzailearen esperientziaren eraginpean egongo da. Dagoeneko, BCI sistema mota hauek neuror-errehabilitazio aplikazioetan erabiltzen dira, 3.29. Irudian erakusten den bezala ([1]tik atera dena), non apoplexia bat izan zuen paziente bat bere gorputzadarraren kontrola berreskuratzeko errehabilitazioa egiten ari den.



3.29. Irudia. ERD/ERS imajinazio motorreko BCI sistemak neuro-errehabilitaziorako erabili ahal dira galdutako gorputzadarren gaineko kontrola berreskuratzeko.

Tesi honek BCI sistema mota hauen inguruko informazioa 6. Kapitulan sakonduko du. Bertan, tesi honek egindako imajinazio motorrari lotutako ekarpena aurkeztuko da.

3. KAPITULUA - SEINALE FISIOLÓGIKOAK, LOGIKA LAUSOA,
IKASKETA AUTOMATIKOA ETA BCI SISTEMAK

III. Atala
Ekarpenak

4. Kapituluia

Estres-maila era jarraian zenbatesteko ekarpenak

4.1. Sarrera

Gaur egungo gizarteav sentimenduetan, emozioetan eta, orokorrean, ongizate psikologikoan gero eta interesatuago dago. Ondorioz, emozioak eta fenomeno psikologiko zehatz batzuen detekzioa, sailkapena eta ebaluazioa aztertzen duten ikerketen kopurua nabarmen hazi da azkenengo hamarkadetan. Honi lotuta, kapitulu honek seinale fisiologikoen prozesamenduaren bitarteko estres-mailaren estimazioari egindako ekarpena aurkeztuko du.

Hasiera puntu bezala, ikerketa taldeak, lehenago, estresaren adierazgarriak diren bat-bateko aldaketa fisiologikoen detekzioaren eta neurketaren inguruan lan egin zuen [67]. Dena den, lehenengo lan honetan, Euskal Herriko Unibertsitateko (UPV/EHU) Aldapa eta GICI ikerketa taldeen arteko kolaborazioan egin zena, solik bat-bateko aldaketak aztertzen ziren. Hortaz, taldeak pentsatu zuen interesgarria izango zela soluzio teknologiko bat diseinatzea, konputazio-adimentsuko teknikak erabiliz, era jarraitu batean estresaren mailako estimazioa emateko. Kapitulu honetan aurkeztuko den lana, tesi honen hasierako faseari dagokionez, GICI ikerketa taldeko Irigoyen dokotorearen gidaritzapean egin zen. GICI eta Aldapa ikerketa taldeen arteko kolaborazio honi esker, tesi honen idazlea Aldapa taldeko kide izatera heldu zen.

Kapituluaaren egiturari dagokionez, 4.2. Atalak ikerketaren testuinguruari eta ekarpenarekin zerikusia duten literaturako lanei buruzko berrikustea emango dio irakurleari. Ondoren, 4.3. Atalak seinale fisiologikoak jasotzeko jarraitu zen protokolo esperimentalak aurkeztuko du. Horren ostean, 4.4. Atalak geroago logika lausoko sisteman sarrera bezala erabili ziren ezaugarriak erazteko erabili ziren seinale-prozesamendu teknikak azalduko ditu, eta, jarraian, 4.5. Atalak estres-maila neurtzeko erabili zen logika lausoko sistema azalduko du. Bukatzeke, 4.6. Atalak lanaren emaitzak aurkeztuko ditu eta laburpen orokor bat emango da 4.7. Atalean.

4.2. Testuingurua eta erlazionatutako lanak

Konputazio afektiboa interdisziplinarioa den adarra da, konputazio zientzien, psikologiaren eta zientzia kognitiboen teknikak eta azterketak konbinatzen dituena. Psikologoek antzeko ikerketetan lan egin zuten arren, konputazio afektiboaren ikuskerak modernoa [68]tik sortu zen. Konputazio afektiboak barne hartzen duen eremua oso zabala da, emozioen eta sentimenduen neurketa ikertzen duen atala izanik tesi honetarako intersgarria dena.

Emozioen eta sentimenduen ikerketa ez da berria den ikerketa adarra. Dena den, oraindik ere ikerlarien arreta harrapatzen jarraitzen du, giza-adimenaren inguruan oraindik alderdi asko baitaude argitzeke. Honela izanda, badira ikerketa asko eguneroko bizitzan emozioek duten eragina aztertzen dutenak. Ikerketa batzuk giza-jarreraren azterketan zentratzen dira [69]. Beste batzuek emozioak nola induzitu ahal diren ikertzen dute [70]. Hala ere, badago adar bat, “borroka edo ihesa” (“fight or flight”) teoriatik abiatuta [71], arreta aldaketa fisiologikoen eta estresa sentitzearen arteko erlazioetan jarri duena [72, 73]. Azkenengo adar honi dagokio tesi honek aurkezten duen lehenengo ekarpena.

2. Kapituluaren azaldu den bezala, “borroka edo ihesa” egoerek Nerbio Sistema Autonomaren (SNS, ingeleseko Sympathetic Nervous System hitzetatik) aktibazioak eragiten dituzte eta hauek gorputzaren erreakzioak sortzen dituzte: arnasketa erritmoa azeleratzen da oxigeno gehiago muskuluetara heltzeko, izerdiaren jariaketa handitzen da, begi-niniak zabaldu egiten dira [74, 75]... Ondorioz, aldaketa hauek sentsoreen bidez neurtu ahal direnez, ikerketa askok arreta jarri dute aldaketa fisiologiko hauetan. Ikerketa horien helburua aldaketa fisiologiko horiek emozio, sentimendu eta sentsazioak sentitzearekin duten lotura aztertzeko, adibidez, estresaren sentitzearekin duten lotura. Ikertzaile batzuek sentsore intrusiboak erabiltzen dituzten bitartean, begi-ninien tamaina edo aupegiko espresioak jasotzeko kamerak bezala [76], beste ikertzaile batzuek arropan integratu ahal diren sentsore ez hain intrusiboak erabiltzen saitzen dira (edo batere intrusiboak ez direnak) [77, 78].

Ongizate fisikoa, fisiologikoa eta psikologikoa erlazionatuta daudela argi dagoen arren, erlazio hau nola funtzionatzen den ez dago guztiz argi oraindik [79]. Beraz, ikertzaile askok konputazio-adimentsuko teknika ezberdinak erabili dituzte aldaketa fisiologikoaren eta estresaren arteko erlazioa ezartzen laguntzeko, ikasketa automatikoa edo logika lausoa bezalakoak [80–83]. Ikerketa lerro honi jarraituz, kapitulu honetan azaldutako lanak estres-mailaren estimazio jarraitua emateko [84]n aurkeztutako logika lausoko sistemaren hobekuntza aurkezten du, bihotz-erritmoa (HR) eta aktibitate elektrodermikoa (EDA) sistemaren sarre-ratzat zituena. Sistemaren hobekuntzak, gehien bat, [84]en erabilitako seinale fisiologikoen prozesamendu tekniken hobekuntzetatik eta sistemari sarrera seinale berriak gehitzetik dator: ECG-ko R pikoen detekzioa [85–88], EDA seinalearen deskonposaketa, arnasketa-seinaleran (RESP) eransketa, beste batzuen artean.

4.3. Protokolo esperimental

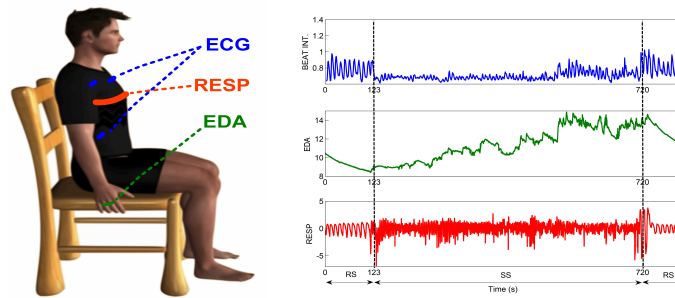
Gizakiak parte izango diren protokolo esperimental baten diseinua egiteko zenbait alderdi hartu behar dira kontuan, ikuspegi legal, etiko eta teknikoei lotutakoak. Aspektu legalei eta etikoei dagokienez, partaideen pribatasun eskubideak errespetatzen direla ziurtatzea guztiz beharrezkoa da. Hortaz, gizakiak esperimenturen parte direnean, partaideen identitatea anonimoa izango dela ziurtatuko duen moduan gordetzea praktika orokorra da [89]. Gainera, partaideak esperimentuaren prozedimentuari buruz informatuak izan behar dira eta horren ostean dokumentu bat bete behar dute zeinean esperimentuan parte hartzea onartu dutela adierazten duten. Esperimentu honetan 166 pertsonak parte hartu zuten, denak Euskal Herriko Unibertsitatik etorriak (125 gizonetakoak eta 41 emakumetakoak). Esperimentuko populazioaren adinak 19 eta 45 urteen bitartekoak ziren, batezbesteko adina 22,8 urtekoa eta desbiderapen estandarra 3,1 urtekoa izanik.

Legalak aparte, ikertzaileek kontuan hartu beharreko aspektu teknikoak beste eratako arazoekin lotuta dago, sentsoreen kokapen egokia aukeratzearekin, esperimentuaren faseen orden egokia aukeratzearekin edo nahi diren partaideen erreakzioak sortzeko erabiltzen diren jardueren aukeraketarekin, adibidez. Literaturan egoera psikologiko eta emozional zehatza indultzeko diseinu esperimentalaren inguruko zenbait lan aurki daitezke, [90] edo [91] modukoak.

Lehenago, [67] -n, ikerketa taldeak atal honetan aurkeztutako protokolo esperimental erabili zuen. Protokoloaren helburua partaideengan estresa indultzzea da eta horretarako 3D egurrezko puzzle bat 10 minututan egiteko eskatu zitzaion. Gainera, partaideek 2 minutuko bideo erlaxagarria ikusi zuten puzzlea egiten hasi baino lehen eta puzzlea egiteko denboraren ostean. Partaideak egoera basal batera eramateko erabili zen bideo hau, partaideen aldagai fisiologikoen balioak tarte normal batean izan zitezten geroago kontrolerako informazio gisa erabiltzeko. Puntu honetatik aurrera hurrengo nomenklatura motza erabiliko da hiru fase horiei erreferentzia egiteko: RS (“relaxing state” hitz ingelesetik) bideo erlaxagarrien faseei esango zaie eta SS (“stressful state”) deituko zaio puzzlea eraikitze faseari.


Esperimentu osoan zehar partaideen EDA, ECG eta RESP seinaleak jaso ziren Biopac MP36[®] ekipamendua erabiliz, 1000Hz-tan lagintzen. Puzzlea eraikitzeak eskuen trebezia eskatzen duenez, EDA jasotzeko sentsoreak partaidearen trebetasun gutxienerako eskuan kokatu ziren, erdiko hatzamarrean eta hatz erakuslean. Era honetan, EDA jasotzeko sentsoreek ez zuten era nabari batean partaideen errendimenduan eraginik izango eta, era berean, elektrodoek molestia txiki batzuk sortuko zituzten estresa sortzeko lagungarriak izango zirenak. Bestalde, ECG sentsoreak partaidearen bularrean kokatu ziren eta RESP seinalea bularrean kokaturiko banda batekin jaso zen. 4.1. Irudiak sentsore bakoitzaren kokapenaren diagrama erakusten du (ezkerraldean) eta, era berean, jasotako seinaleen adibideak irudikatzen ditu fase bakoitzeko hasiera eta amaieraren markak emanez (eskuinaldean).

4. KAPITULUA - ESTRES-MAILAREN ZENBATESPEN JARRAITUA



4.1. Irudia. Sentsoreen kokapenaren eskema eta jasotako seinaleen adibideak.

Konpondu beharreko beste arazo tekniko bat seinaleetan artefaktuak agertzea da. 3D puzzlea eraikitzeak partaidea mugitzea eskatzen duenez, jasotako seinaleak ziurrenik artefaktuak izango dituzte, mugimenduekin elektrodoek azalarkin kontaktua galdu ahal dutelako. Gainera, elektrodoen gela denborarekin lehertu egiten da eta horrek sentsorea eta azalaren arteko konduktibitatean eragina du. Honen ondorioz, batzuetan ECG-en anplitudea murriztu egiten da eta R pikoen detekzioa zailagoa egiten da, seinalearen eta zarataren arteko erratioa txikitzen baita. Fenomeno hauen adibide batzuk 4.2. Irudian aurkeztu dira, esperimuntuan jasotako seinaleak irudikatuz. 4.4. Atalean proposatutako prozesamendu teknikek arazo hauei soluzioa emango diete.



4.2. Irudia. Zarata eta artefaktuak ager daitezke ECG seinaleetan.

4.4. Seinale fisiologikoen prozesamendua

Esandako moduan, proposatutako estres-maila estimatzeko metodoak ECG, EDA eta RESP seinaleetatik ateratako ezaugarriak erabiltzen ditu. Atal honetik horiek erazteko erabili diren prozesamendu teknikak aurkeztuko ditu.


Lehenik eta behin, 4.4.1. Azpiatalak ECG seinalearen prozesamendua aurkeztuko du, 4.2. Irudikoen moduko zaraten eragina ekiditzeko R pikoen detekzio metodo hobetuaren ekarpena aurkeztuz. Geroago, RESP seinalearen tratamendua azalduko da 4.4.2. Azpiatalean, non analisi frekuentzialaren eta estatistikoen konbinazioa egitea proposatzen den. Bukatzeko, EDA-tik ateratako ezaugarrien erazketa 4.4.3. Azpiatalean azalduko da.

4.4.1. ECG-a prozesatzen: R pikoen detekzio hobetua

Medianako iragazkia

Base-lerro mugikorra duen seinalea izatea normala da ECG-ak jasotzean. Arazo hau konpontzeko zenbait irizpide daude, “high-pass” iragazkiak erabiltzea modukoak. Dena den, iragazki eraginkorrek diseinatzea konputazio kostu handiak ditu edo seinalearen fasea aldatzen da. Horregatik, aplikatzeko oso erreza den iragazki ez lineala izanda, [85]n medianako iragazkia erabiltzea proposatu zen base-lerroen desbiderapenak ezabatzeko.

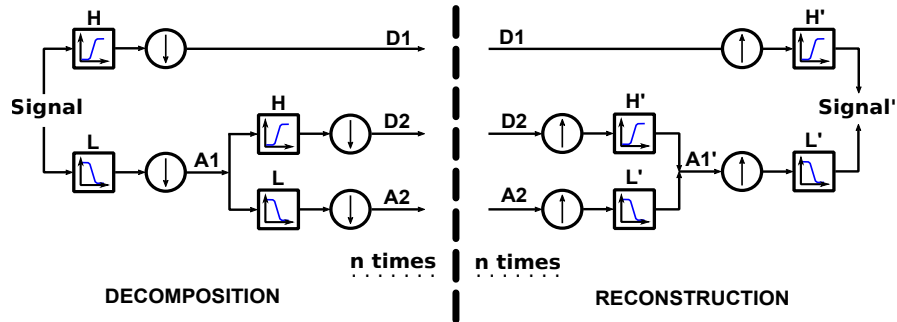
Jasotako seinaleen analisi enpirikoa egin ondore, taldeak 100ms-ko medianako fitroa erabiltzea erabaki zuen. Iragazki honen tamaina egokia da base-lerroaren desbiderapenak kentzeko, hauek normalean denbora hori baino gutxiago irauten dutelako. Honen adibidea 4.3. Irudian ikusi daiteke, zeinean seinale originala eta filtratua bata bestearen gainean grafikatu diren.



4.3. Irudia. Base-lerroko desbiderapenak ongi ezabatu dira 100ms-ko mediana iragazkia erabiliz.

Wavelet iragazketa

Base-lerroko desbideraketaz gain, ohikoa da zarata elektrikoa biltzea bio-seinaleak jasotzen direnean. Adibidez, gailu komertzialek 50Hz-eko hozka-iragazkia erabiltzeko aukera ematen dute sare elektrikitik datorren edozein zarata kentzeko. Hala ere, elektrodoen eta azalaren arteko kontaktua oso ona ez bada, baliteke sentsoreek jasotzen duten zarata maiztasun-banda jakin batean kontzentratu ez egotea. Iragazte tradizionalak huts egiten duenean, wavelet analisi diskretua zarata kentzeko hautagai egokia dela dirudi [92]. 4.4. Irudian, wavelet-etan oinarritutako deskonposaketa eta berreraikuntza nola egiten diren azaltzen duen diagrama ageri da.



4.4. Irudia. Wavelet deskonposaketaren and berreraikuntzaren eskema.

Wavelet deskonposaketa 4.4. Irudiko ezker aldean ageri da, eta, ikus daitekeenez, seinalea bi maiztasun-bandatan banatzean datza, bata goi-maiztasuneko informazioari dagokiona eta bestea behe-maiztasuneko informazioari dagokiona. Bi maiztasun-bandetan banaketa H eta L deskonposizio-iragazkiak erabiliz lortzen da (H goi-maiztasunetarako, L behe-maiztasunetarako). Horren ondoren, ondoriozko seinale horiek jatorrizko laginketa-maiztasunaren erdira azpiolagindu behar dira. Azpilaginketa-etapa horretan lortzen dira A eta D koefizienteak: A koefizienteek seinalearen $[0, F_s/2]$ tarteko informazioa daramate, eta D koefizienteek $[F_s/2, F_s]$ bandako informazioa daramate. Uhinen deskonposaketa nahi adina aldiz errepika daiteke, eta, horri esker, jatorrizko seinalearen informazio guztia tamaina konprimituko datu-multzo txikiagoetan lor daiteke.

Bestalde, wavelet berreraikuntza diskretua deskonposizioa alderantzizkatzea eta kontrako norabidean itzultzea bezain simplea da. Hala, azpilaginketa egin beharrean, A eta D koefizienteen lagin kopurua bikoiztu behar da, sortu berri diren laginen balioak zero izanik. Ondoren, lortutako seinaleek H' eta L' berreraikitze-iragazkietatik igaro behar dute. Iragazki horiek zero balio berri horiek tratatuko dituzte. Azkenik, hurrengo deskonposizio-mailaren A koefizienteak lortzeko H' eta L'-ren irteerak gehitu behar dira.


Hala, wavelet deskonposizio diskretua seinaleak prozesatzeko oso tresna indartsua da, ikertzaileei informazio-banda egokian soilik arreta jartzeko aukera

4.4. SEINALE FISIOLÓGIKOEN PROZESAMENDUA

ematen baitie. Hori erraz egin daiteke A edo D koefiziente jakin batzuen balio guztiei zero balioa emanez. Hori egiten bada, orduan, seinalea berreraikitzean koefiziente horietako informazio guztia ez da kontuan hartuko, eta, horren ondorioz, askoz ere seinale garbiagoa lortuko da. Gainera, propietate horri esker, wavelet-ak asko erabili dira konpresio-soluzio gisa datu handiak gordetzeko.

Hala ere, puntu honetara iritsita, oraindik ez dago argi nola H, L, H' eta L' iragazkiak ezartzen diren. Galdera horren erantzuna ez da hutsala, iragazki horien inplementazioa analisirako aukeratu den wavelet-aren arabera baita. Wavelet-familia bat baino gehiago daude, eta ez da harritzekoa wavelet desberdinek lana behar bezala egiteko gai izatea. Zentzu horretan, seinale bat wavelet batekin deskonposatzen bada eta, geroago, wavelet bera erabiliz guztiz berreraiki badaiteke, wavelet hori lan horretarako egokitzat har daiteke. Gainera, gutxi gorabeherako beste arau on bat da informazio garrantzitsuarekin ikusizko antzekotasuna duen wavelet bat aukeratzea.

Horrekin jarraitez, Coiflet familiako wavelet-ak [93] QRS konplexuen nahiko antzekoak dira, eta, beraz, berreraikuntza inolako galerarik gabe egin daitekeela egiaztatzen ondoren, zarata iragazteko hautatu zen. Beraz, base-lerroko desbiderapenik gabeko ECG seinaleak Coiflet wavelet-ak erabiliz deskonposatu ziren. Ondoren, berreraikuntzarako D koefizienteei kasurik ez egitea erabaki zen, zarata gutxiagoko ECGaren hurbilketa lortzeko. Kontuan hartu behar da prozesu horrek informazio pixka baten galera eragiten duela. Hala ere, EKGaren morfologia nahiko ondo mantentzen da eta seinalearen eta zarataren arteko erlazioa jatorrizko seinalearena baino hobea da. Horren adibide bat 4.5. Irudian ageri da, non seinalea sei aldiz deskonposatu eta A koefizienteak soilik erabiliz berreraiki zen.

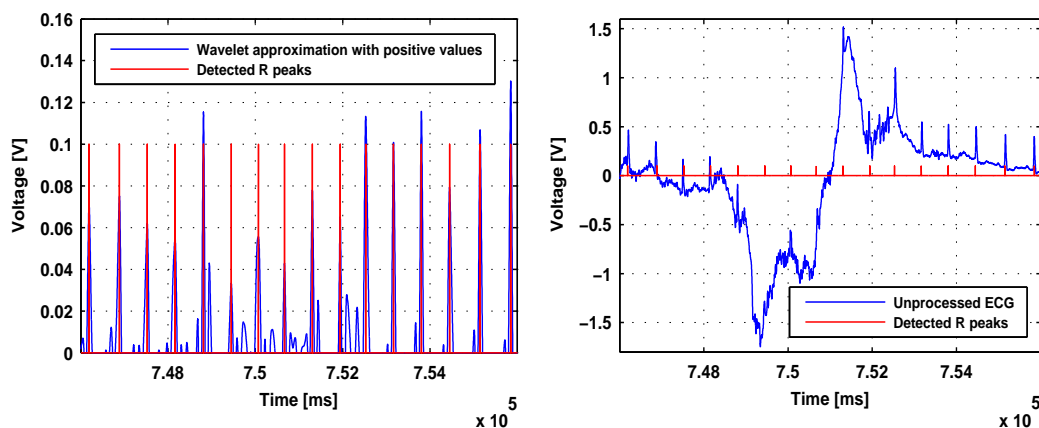


4.5. Irudia. Zarataren iragazketa wavelet-en 6. mailako hurbilketarekin.

Pikoen detekzioa

Zarata kendu ondoren, HR kalkulatzeko hurrengo urratsa R pikoak detektatzea da. Horretarako, ECG uhinaren hurbilketaren balio negatibo guztiak ezabatzea proposatzen da (edo R gailurrak negatiboak diren ezohiko kasu horietan soilik zati negatiboa).


Horren ondoren, R piko nabarmenenak bilatu besterik ez da egin behar eta, hori egiteko, seinalea ekortu behar da. ECG seinalea oso dinamikoa ez denez, lan honek aurreko hiru RR tarteen batezbesteko denbora kalkulatzeko proposatzen du. Gero, batezbesteko balio hori hurrengo R pikoaren posizioa estimatzeko erabil daiteke. Orduan, pikoa detektatzea erraza da RR tartearen %20-an aurrera eta atzera seinalea ekortuz pikorik handiena bilatzen. Hau egitean komeni da prozesua behar bezala osatu dela egiaztatzea, wavelet hurbilketan detektatutako R pikoen posizioak eta jatorrizko ECG seinalearenak bata bestearen gainean jarri prozesua behar bezala burutu dela egiaztatzeko (ikus Irudia: 4.6. Irudia).



4.6. Irudia. Detektatutako R pikoen posizioak wavelet hurbilketaren eta ECG seinale originalaren R pikoen pozioekin bat datoz.

Azkenik, R pikoen detekzioa behar bezala egin bada, oso erraza da HR seinalea kalkulatzeko 3.1. ekuazioa aplikatuz. Lortzen den HR seinale hori metodo tradizionalagoekin kalkulaturakoak baino sendoagoa izango da. Adibidez, 4.2. Irudiko seinalerako, proposatutako algoritmoak HR kalkulu sendoagoa ematen du esperimentuan bioseinaleak jasotzeko erabilitako Biopac MP36[®] gailuak emandakoarekin alderatuz gero (ikus 4.7. Irudia).

4.4. SEINALE FISIOLGIKOEN PROZESAMENDUA



4.7. Irudia. Ekipamendu komertzialak artefaktuen eragin nabaria izan dezaketen bitartean, proposatutako algoritmoak HR seinalearen kalkulu sendoa ematen du.

4.4.2. RESP seinalearen prozesamendua

3.2.3. Azpialdean adierazten den bezala, pertsona erlaxatu baten RESP seinalea estresatua sentitzen den pertsona batena baino harmonikoagoa izatea espero daiteke. SNS-a aktibatzen denean birrikak azkarrago mugiarazten ditu, oxigenoa odolera transferitzean organismoak behar dituen kantitateak ase daitezten. Beraz, pertsona baten estres-maila ebaluatzeko informazioa lor daiteke RESP seinaleari prozesamendu-teknika egokiak aplikatuz. Lan honek frekuentzia-analisiaren teknikak eta kalkulu estatistikoak konbinatzea proposatzen du, informazio hori 4.5. Atalean geroago aurkeztuko den logika lausoko sisteman sarrera-ezaugarri gisa erabiltzeko.


RESP seinaleen frekuentzia-analisisa

Normalean, Fourier transformatuak seinale baten maiztasun-espektroa ikusteko erabiltzen dira. Horrela, seinale bat zein harmonikoa den egiazta daiteke. Hala ere, askotan erresoluzio handia lortzeko lagin asko hartu behar dira, eta hori nahiko garestia izan daiteke konputazionalki. Gainera, Fourier-en ohi-ko eraldaketek $[0, F_s/2]$ Hz-eko maiztasun-tartean ematen dute informazioa, eta, seinale fisiologikoen kasuan, normalean $F_s/2$ maiztasun horren ingurutik informazio gutxi atera daiteke.

Beraz, lan honek proposatzen du RESP-aren maiztasun-kontzentrazioa aztertzea, hau da, seinalea zein harmonikoa den, maiztasun desberdinetako uhin sinusoidal hutsekin korrelazioan jartzea. Hori egitean, arreta guztia maiztasun-banda interesgarrian soilik jar daiteke. Beraz, subjektu bakoitzarentzat, behin bakarrik kalkulatu behar da seinalearen espektroa fenomeno fisiologiko gehienak dauden maiztasun-bandaren mugak jakiteko. Horren adibide bat 4.8. Irudian

4. KAPITULUA - ESTRES-MAILAREN ZENBATESPEN JARRAITUA


ikus daiteke.



4.8. Irudia. RESP seinale bate frekuentzia-espektoa.

Zenbait esperimentuko partaideren RESP seinaleen espektoak analizatu ondoren, ondoriozta daiteke $[0-0,5]$ Hz maiztasun-tarteak bai RESP seinale erlaxatuen zein estresatuen informazioa duela. Horregatik erabaki zen korrelazioa lortzea RESP seinaleen eta uhin guztiz sinusoidalen artean, 0,01Hz-etik 0,5Hz-etara doazenak, 0,01Hz-eko aldakuntza pausua erabiliz. Korrelazio horiek kalkulatzeko, hainbat leiho-tamaina erabili ziren., estresari buruzko informazioa ateratzeko leiho-tamainarik egokiena zein den jakiteko. Aztertu ziren leihoen tamainak 20s, 40s eta 60s izan ziren, guztientan 10s-ko mugimendu pausua erabiliz. Korrelazio horien emaitza 4.9. Irudian ikus daiteke. Irudi horretan, goiko aldean RESP seinalearen adibide bat marraztu da, eta, horren azpian, kolore-mapa bat erabili da leiho-tamaina desberdinetarako.

4.4. SEINALE FISIOLÓGIKOEN PROZESAMENDUA



4.9. Irudia. RESP seinalaren eta guztiz sinusoidalak diren seinaleen arteko korrelazioen emaitzak 20s, 40s eta 60s-ko lehio tamainak erabiliz.

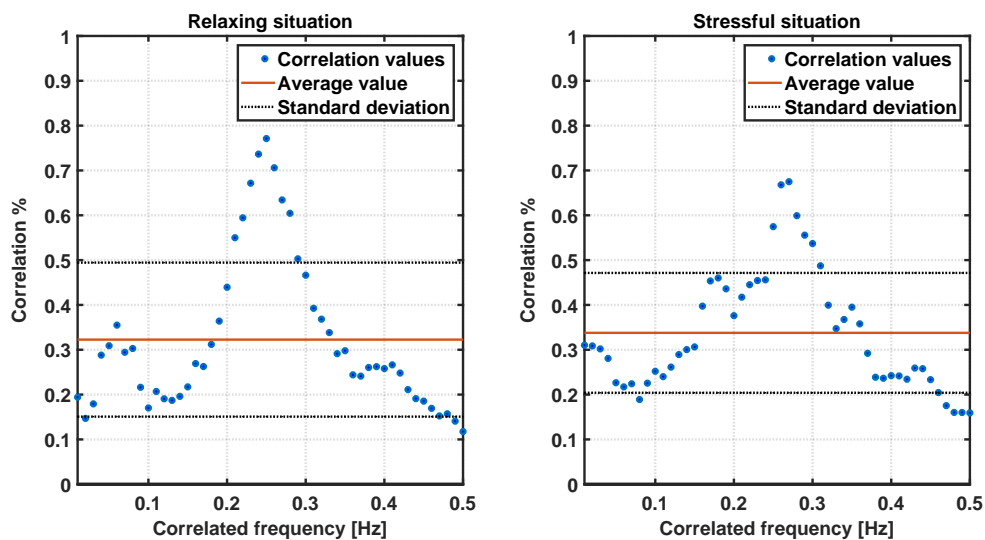
Analisi estatistikoa eta seinalearen leunketa

4.9. Irudian ikusten denez, RESP-aren maiztasun-kontzentrazioa aldatu egiten da egoera erlaxagarria izatetik estresante izatera pasatzen denean. Kapitulu honetan aurkeztutako lanak proposatu zuen maiztasun-korrelazioaren balioen desbideratze estandarra erabiltzea estres-maila era jarraituan ebaluatzen duen logika lausoko sistemaren sarrera-ezaugarri gisa.

Ikuspegi horri jarraituz, desbideratze estandarra kalkulatzeko proposatu zen

4. KAPITULUA - ESTRES-MAILAREN ZENBATESPEN JARRAITUA


leiho mugikorreko estrategiari jarraituz. Hau egitean, korrelazio-balioen desbideratze estandarra handiagoa izan zen subjektua erlaxatuta sentitzen zenean. Horrek zentzua du; izan ere, erlaxatuta sentitzan, begiratutako maiztasun guztietarako korrelazio-balioak oso txikiak dira, maiztasun nagusi batean izan ezik, oso korrelazionatuta dagoena. Hala izanda, batezbesteko balioa puntu horietako gehienetatik nahiko urrun egongo da. Bestalde, egoera estresagarrietan, korrelazio-balioak uniformeago banatzen dira, eta, horregatik, balio horiek batez- besteko baliotik hurbilago egongo. Hortaz, desbideratze estandarra txikiagoa da erlaxazio-egoerekin alderatuta. Kontuan hartuta nahiko arraro dirudiela, 4.10. Irudiak pertsona beraren bi kasuen adibide bat irudikatzen du grafikoki.



4.10. Irudia. RESP seinalearen eta uhin sinusoidalen arteko korrelazio-balioak eta horien parametro estatistikoak, bi egoeretako analisi lehi batean.


Kontzeptu hori ulertu ondoren, RESP eta seinalee sinusoidalen arteko korrelazio-balioen desbideratze estandarraren bilakaera ere marraztu daiteke. 4.11. Irudian ikus daitekeenez, desbideratze estandarrak balio handiagoak lortzen ditu esperimentuaren zati erlaxagarrietan. Gainera, ikus daiteke desbiderapen estandarra txikiagoa dela esperimentuaren erdian (estres-zatian).

4.4. SEINALE FISIOLÓGIKOEN PROZESAMENDUA



4.11. Irudia. Goiko zatia: parte-hartzaile baten RESP seinalea. Beheko zatia: korrelazio-balioen desbideratze estandarra.

Zati erlaxagarrien eta estresagarrien arteko ezberdintasunak begi bistaz argia diruditen arren, seinale horrek logika lausoko sistema detekzio faltsu batera eramango luke sarrera gisa erabiliko balitz. Izan ere, zatia estresagarriko puntu batzuek nahiko desbirapen estandar balio handiak dituzte (adibidez, 400s inguru 4.11. Irudian). Beraz, seinale hori leundu egin behar da estresaren eta erlaxazioaren arteko aldeak handitu daitezzen. Lan honetan, desbiderapen estandarreko seinalea leuntzeko, desbiderapen estandarreko seinale bera RR denborartearen seinalearen RMS balioarekin biderkatzea proposatzen da (horren formula 3.2 ekuazioan aurkeztu zen). Biderketa horren ondorioz, egoera lasaigarrien eta estresagarrien arteko aldeak handitu egin dira (ikus 4.12. Irudia). eta horrela, bada posible logika lausoaren sistemarako sarrera gisa erabiltzea.



4.12. Irudia. Biderketaren ostean, lortutako seinale leunduak gero eta alde handiagoak ditu zati erlaxagarrietako pikoen eta zati estresagarrien arteko pikoen artean.

4.4.3. EDA prozesatzen

EDAr dagokionez, prozesatzen errazagoa da. Bi parametrotan banatu zen: batezbesteko balioa eta seinalearen aldakuntza 20s-ko analisi-leiho batean. Horrela, batezbesteko baliori garrantzi gutxiago ematen ahal zaio analisi-leiho barruko seinaleak duen aldakuntzarekin konparatuta. Ikuspegi hau ohikoa da literaturan; izan ere, larruazalearen izerdiaren adierazgarria izanda, EDA seinalea seinale metagarria da, eta, beraz, seinalaren base-lerroa ez da errez murriztuko. Bestalde, aldakuntzak ez daude batezbesteko balioaren mende eta esan daiteke SNSaren aktibazioen adierazgarriagoa dela EDAREN batez besteko balioarekin alderatuta.

4.5. Estres-maila zenbatesteko logika lausoko sistema


Atal honetan, estres-maila etengabe ebaluatzeko diseinatu zen logika lausoko sistema aurkezten da. Horretarako, lehenago azaldutako lau sarrera-ezaugarriak erabiltzen ditu: HR seinale hobetua, RESP seinalearen eta uhin sinusoidal puruen arteko korrelazioen desbideratze estandar leundua eta EDAREN batezbesteko eta aldakuntza-balioak. menbresia-funtzioen diseinuak (MF) [84]ko plantillak erauzteko proposamenaren ikuspegiarekin jarraitu zuen, baina funtzio tarteko estres-mailetarako funtzio berri bat gehituz. Atal honetako lana egiteko Matlab[®]-en “fuzzy logic toolbox” erabili zen.

Lehenik, 4.5.1. Azpiatalak menbresia-funtzioak eta EDA seinalea deskonposatzearen arrazoa aurkeztuko ditu, eta, geroago, 4.5.2. Azpiatalean erregela-sistemarako jarraitutako estrategia azalduko da.

4.5.1. Logika lausoko menbresia-funtzioen diseinua


Hasieran, ikerketa taldea [94]ren logika lausoaren sistema diseinatzen hasi zenean, sarrerako MF-en diseinua [84]ren plantillen erauzketaren ikuspegian oinarritu zen. Ikuspegi horrek RS eta SS faseen seinale fisiologikoak banan-banan hartzea proposazen du. Ondoren, esperimenduaren seinale eta fase bakoitzerako, MF gaussiano bat definitu behar da, fase bakoitzeko seinalearen batezbesteko eta desbideratze estandarreko balioak erabiliz. Dena den, egoera batzuetan, HR seinaleak aldakortasun handia du eta HRaren desbideratze estandarra oso handia izatea eragiten du. Fenomeno hori 4.13. Irudiko HR seinalean ikus daiteke, non parte-hartzailearen HR-a asko aldatzen den esperimenduaren hasierako zatian.

4.5. ESTRES-MAILA ZENBATESTEN LOGIKA LAUSOKO SISTEMA



4.13. Irudia. HR-aren aldaketak handiak izan ziren esperimentuaren lehenengo RS fasean.

Fenomeno horren ondorioz, sarrerako MFak gainezar daitezke. Hori arazo bat da, izan ere, ziurgabetasun-egoera asko sortu ahal direlako HR sarreraren balioak RS eta SS egoereta neurri berean badagozkie. Egoera hauek kudeatzeko, erlaxazioaren eta estresaren arteko trantsizioetarako tarteko MF bat erabiltzea proposatzen du lan honek. Bitarteko funtzioaren terminoa "estres maila ertaina" izan zen (MS, medium-stress ingelesez). Gainera, RS eta SS faseentzat MF forma trapezoidalak erabiltzea proposatu zen eta MS mailarako forma gaussiar bat soilik erabiltzea. 4.14. Irudian ageri den moduan, estrategia honek gainjarritako plantillen arazoa gertzea eragozten du (irudiaren eskuinaldea); forma gaussiarrak soilik erabiltzean, berriz, MF-ak gainjarri izan daitezke. Gainera, hiru MF-ak erabiltzeko proposamenak balio oso baxuak eta oso handiak kudeatzen laguntzen du, beste era batean ziurgabetasun gisa hartuko liratekeenak.



4.14. Irudia. HR-ko MF-ak gainjartzea saihestu ahal da erlaxazioaren eta estresaren arteko trantsizioetarako hirugarren MF bat erabiliz.

Koherentziari eusteko, estrategia bera erabili da sarrerako beste MF-entzat, RS, MS eta SS MF-ak definituz sarrera guztietarako. Alde batetik, RS eta SS

4. KAPITULUA - ESTRES-MAILAREN ZENBATESPEN JARRAITUA

4.1. Taula. menbresia-funtzioen definizioa.

Algaia	Definizioa	Egoerak	Forma	Formako erpinak
Sarrera:		RS	Trapezoidala	Aldakorra
Bihotz-erritmoa (HR)	Aldakorra	MS	Gaussiarra	Aldakorra
		SS	Trapezoidala	Aldakorra
Sarrera:		RS	Trapezoidala	Aldakorra
Batazbest.EDA	Aldakorra	MS	Gaussiarra	Aldakorra
		SS	Trapezoidal	Aldakorra
Sarrera:		RS	Trapezoidala	[-2,-2,-0.75,0]
Δ EDA	[-2,2]	MS	Triangeluarra	[-0.5,0,0.5]
		SS	Trapezoidala	[0,0.75,2,2]
Sarrera:		RS	Trapezoidala	Aldakorra
RMS_{RR}	Variable	MS	Gaussiarra	Aldakorra
$\cdot CORR_{RESP}$		SS	Trapezoidala	Aldakorra
Sarrera:		RS	Trapezoidala	[0,0,0.275,0.475]
Estres-maila	[0,1]	MS	Triangeluarra	[0.25,0.5,0.75]
		SS	Trapezoidala	[0.525,0.725,1,1]

guztiak funtzio trapezoidal gisa definitu dira. Bestalde, aldagai guztiek ez dute forma bera MS-rentzat: HR-rako eta batezbesteko EDA seinalerako forma gaussiarrak erabili ziren bitartean, funtzio triangeluarrak definitu ziren EDAREN aldakuntzetarako eta RESP seinalearen korrelazio eta RR tartean RMS balioaren arteko biderketa leundurako. Sistemaren irteerari dagokionez, hiru MF-ak hasieratik definitu ziren. Irteera [0,1] “crisp” tartean egoteko diseinatu zen estres-mailaren zenbatespena normalizatua izateko. 4.1. Taulan, MF guztien definizioaren laburpena ageri da. Taulako balio batzuk aurredefinituak eta estandarrak izan daitezke subjektu guztientzat, baina ezin da berdina egin besteentzat, jasotako seinale fisiologikoaren tentsio tartearen arabekoak baitira.

4.5.2. Erregela-sistema

Erregela-sistemaren diseinua egiteko, “IF... AND IF... THEN...” erregelak erabili ziren, “max” agregazio-metodoa erabiliz. Hortaz, sarrerako aldagaiak binaka erlazionatu ziren. Gainera, 3.3.3. Azpiatalean aipatu bezala, COG metodoaren bidez egin zen defuzifikazioa. Hala ere, erregeletan definitutako erlazioak aldatuz joan ziren 4.4.2. Azpiatalean azaldu diren seinale fisiologikak prozesatzeko teknikak garatzen ziren heinean.

Erregelen diseinuaren hasierako etapetan, bi MF definitu ziren sarrerako aldagaientzat (RS eta SS) eta hiru estresaren zenbatespenaren irteerarentzat (RS, MS eta SS). Egoera horretan, erregelak zehaztu ziren MS irteera soilik aktibatzeke erregeletako lehenengo eta bigarren sarreren klaseak bat ez zetozenean.

4.6. EMAITZA ESPERIMENTALAK

Hau da, 1 sarrera RS egoeran eta 2 sarrera SS egoeran zeudenean eta alde-rantziz. Bestela, bi sarrerak menbrescia berdina izatean, erregelaren ondorioa sarrerekin bat etorriko zen egoerako irteera aktibatzea izango zen. Ikuspegi hori modu laburtuan adierazten da 4.2. Taulan.

4.2. Taula. Hasierako erregela-sistema.

1. sarreako egoera	2. sarreako egoera	Ondorioa
SS	SS	SS
SS	RS	MS
RS	SS	MS
RS	RS	RS

Geroago, proba batzuk egin ondoren, estrategia aldatzea erabaki zen, sistemaren irteerak oso aldaketa dinamikoak izaten zituelako errazki. Beraz, sarrera-aldagaien hirugarren MF gisa MS egoera gehitzea erabaki zen, eta, hala, tarteko egoera horiek erabiltzea estresa trantsizio zenbatespen leunagoak lortzeko. Ondoren, erregela-sistema aldatu egin behar izan zen sarrera guztiei MF berri bat gehitzearen ondorioz. Alde horretatik, sistema sinpleagoa lortzeko erregelak aldatu egin ziren: 1 eta 2 sarrerak RS baziren, irteera RS izango litzateke, eta irizpide bera erabiliko litzateke MS eta SS kasuetan. 4.3. Taulan ageri da planteamendu berri hori.

4.3. Taula. Sarrera-aldagaien arteko erlazioak.

1. sarreako egoera	2. sarreako egoera	Ondorioa
SS	SS	SS
MS	MS	MS
RS	RS	RS

Erregelen diseinua amaitzeko, 4.3. Taulako erregela-multzei pisu desberdinak eman zitzaizkien, erregela bakoitza elikatzen ari ziren aldagai fisiologikoen arabera. Izan ere, sistemaren sarrera guztiek ez dute garrantzi bera estresa ebaluatzeko. Adibidez, HR-aren eta EDA-ren aldakuntzaren arteko erlazioa fidagarriagoa da HR-ak EDA-ren batezbesteko balioarekin duen erlazioa baino (seinalearen izaera metagarria dela eta). Sistemaren arau guztiak 4.4. Taulan jaso dira, non konbinazio bakoitzaren pisua ere adierazi den. Gainera, EDA-tik ateratako bi sarreren arteko erlazioa ez zen kontuan hartu, EDA osoan sarrera gisa erabiltzea bezalakoa izango zelako.

4.6. Emaita esperimentalak

Estresa ebaluatzeko sistema diseinatzeko azken urratsa proba-etapa batera eramatea izan zen. Helburua [84]ren proposamenaren, hasierako etapetako garape-

4. KAPITULUA - ESTRES-MAILAREN ZENBATESPEN JARRAITUA


4.4. Taula. Proposatutako erregela-sistema.

1. sarrera: algaiaren egoera	2. sarrera: algaiaren egoera	Ondorioa	Pisua
HR-RS	Δ EDA-RS	RS	1
HR-MS	Δ EDA-MS	MS	1
HR-SS	Δ EDA-SS	SS	1
HR-RS	$RMS_{RR} \cdot CORR_{RESP}$ -RS	RS	0.75
HR-MS	$RMS_{RR} \cdot CORR_{RESP}$ -RS	MS	0.75
HR-SS	$RMS_{RR} \cdot CORR_{RESP}$ -RS	SS	0.75
Δ EDA-RS	$RMS_{RR} \cdot CORR_{RESP}$ -RS	RS	0.6
Δ EDA-MS	$RMS_{RR} \cdot CORR_{RESP}$ -RS	MS	0.6
Δ EDA-SS	$RMS_{RR} \cdot CORR_{RESP}$ -RS	SS	0.6
HR-RS	Batazbest.EDA-RS	RS	0.5
HR-MS	Batazbest.EDA-MS	MS	0.5
HR-SS	Batazbest.EDA-SS	SS	0.5
Batazbest.EDA-RS	$RMS_{RR} \cdot CORR_{RESP}$ -RS	RS	0.3
Batazbest.EDA-MS	$RMS_{RR} \cdot CORR_{RESP}$ -RS	MS	0.3
Batazbest.EDA-SS	$RMS_{RR} \cdot CORR_{RESP}$ -RS	SS	0.3

naren [94] eta amaierako sistemaren [95] arteko analisi konparatiboa egitea iezan zen. Konparazioa egiteko, lehen aipatutako hiru sistemak sarrera-seinale berekin elikatu ziren (esperimentuan jasotakoak). Konparazioa errazteko, hiru sistemen estresaren zenbatespenarekin batera (beheko grafikoa), sarrera-seinale guztiak 4.15. Irudian (lehenengo lau grafikoa) irudikatu dira beheranzko orden honetan: HR, EDA-ren batezbesteko balioa, EDA-ren aldakuntzak eta sinu puruko uhinen eta RESP seinaleran arteko korrelazioen desbideratze estandar leundua. Estres-erantzunek oso dinamika azkarrak ez dituztenez, sarrera-seinaleen balioak 20s-ko leiho-tamaina erabiliz sisteman sartu ziren, 10s-ko urrats irrista-korrarekin.

Puzlea eraikitzeke fasearen hasieraren eta amaieraren inguruan ($t=120s$ eta $t=720s$), 4.15. Irudiak erakusten du MS egoerarako MF berri bat gehitzeko estrategiak aukera ematen diola proposatutako sistemari leunago erreakzionatzeko, [84]n proposatutako sistemarekin eta lanaren hasierako etapen sistemarekin alderatuta [94]. Gainera, $t=250s$ -tik $t=300s$ -ra, RESP seinalearen eta sinuen arteko korrelazioen desbiderapen estandarreko seinaleak balazta baten funtzioa betetzen du, EDA hazten ari denean estresaren gehiegizko zenbatespena ez gertatzeko.

Beraz, esan daiteke proposatutako sistema berria egonkorragoa dela estresmaileko eremu osoan, eta ez dela hain bortitza sarrera-seinaleetako batean bat-bateko aldaketei erreakzionatzen. Gainera, ikus daiteke proposamatutako sistemak ematen dituen estres-mailaren zenbatespenak, orokorrean, beste bi sistemek ematen dituztenen nahiko antzekoak direla. Nolanahi ere, zaila da esatea balio horiek zer zehaztasunez adierazten duten errealitatea: estresaren sentsa-



4.15. Irudia. HR, batezbesteko EDA, EDA aldakuntzak eta leundutako RESP seinaleko desbideratze estandar sarrerek eta estres-mailaren zenbatespena konparatutako hiru metodoak erabilia.

zioa subjektiboa da eta hori kuantifikatzeko modu bakarra parte-hartzaileek esperimentuaren amaieran egindako inkestak dira (Lang-ek [96]n proposatutako “Self-Assessment Manikin”, adibidez). Alde horretatik, arazo nagusia da inkestek ez dutela estresaren adierazpen jarraitua ematen, baizik eta subjektuek esperimentuan sentitu zuten moduaren inpresio orokorra.

4.7. Laburpena

Herritarren ongizatea lortzeko, gero eta interes handiagoa dago seinale fisiologikoen prozesamenduaren inguruan. Zenbait gertaera fisiologiko automatikoki detektatzea tresna erabilgarria izan daiteke zenbait gaixotasun psikologiko detektatzeko, hala nola estresa, eta horiei tratamendu azkarra emateko. Hala ere, prozesamendu fisiologikoko teknikek artefaktu asko dituzten denbora-serie oso aldakorrekin moldatu behar dute.

Kapitulu honen ekarpenak prozesamendu-teknikak aurkeztu ditu seinale fisiologikoak jasotzean sortzen diren zenbait arazori (R gailur hobetuaren detekzioa) errazago aurre egiteko. Gainera, estresa detektatzeko balio dezaketen ezaugarri berriak proposatu ditu (RESP seinlearen korrelazioen desbideratze estandar leundua). Horrela, estresa detektatzeko sistema batek detekzio faltsu-

4. KAPITULUA - ESTRES-MAILAREN ZENBATESPEN JARRAITUA

rik izan ez ditzan prozesamendu-teknika sendoak erabiltzeak duen garrantzia azpimarratu du.

Horretaz gain, logika lausoko sistema baten aldaketa bat aurkeztu du, estres psikologikoaren maila detektatzeko sisteman lau sarrera-ezaugarri erabiliz: HR, EDA-ren batezbesteko balioa, EDA-ren aldakuntzak eta RESP seinalearen korrelazioen desbideratze estandar leundua. Gainera, sarrerako aldagaien arteko erlazioak definitzeko modua erraztu egin da, sistemaren sarreraren menbresia-funtzioei erdiko estres-mailarentzan MF berri bat gehituz. Azkenik, proposatutako sistema beste bi sistema ezberdinekin konparatu da, proposamenak estres-maila desberdinen arteko trantsizioak leunago zenbatesten zituela erakutsiz.

Mugak eta etorkizunerako ildoak

Aurkeztutako ekarpenek estresa hautematearekin zerikusia duten hainbat eremutan hobekuntzak izan arren, ahulgune batzuk aipatu behar dira. Lehenik eta behin, lan honek ez du metodorik eman R pikoak detektatzeko algoritmoa hasieratzeko. Alde horretatik, hasieratzea eskuz egin zen, metodoaren ahulgune nagusietako bat delarik. Hala ere, ahulgune horrek beste ikerketa-ildo bat ireki zuen eta proposatutako teknikak hobetzera eraman zuen taldea. Ondorioz, horrelako problemak [97]en ebatzi ziren.

Limitazioekin jarraituz, bada beste puntu ahul bat nahiko arrunta dena arlo psikologikoari lotutako gertakarien detekzioarekin zerikusia duten ikerketean: etiketatzea eta etiketak baliozkotzea. Gai hauen inguruan ikertzen denean, oso konplexua da gertaerak etiketatzea eta fenomeno psikologikoak gertatzen ari diren indarraren kuantifikazioa egitea. Alderdi horiei buruzko informazioa galdeketen eta elkarrizken bidez soilik jaso daiteke eta normalean subjektuek esperimentu osoan sentitu ziren moduaren adierazpen orokorra ematen dute. Dena den, elkarrizketa horiek ez dute ia informaziorik ematen bat-bateko fenomenoei buruz, eta, nahiz eta ikertzaileek esperimentuetan zehar etiketak har ditzaketen, etiketa horiek baliozkotzea zaila da. Zalantzarik gabe, esperimentuko parte-hartzaileen jokaera bidez grabatzeak muga horiek gainditzen lagun dezake, baina aparteko zailtasuna eranstean dio esperimentuak prestatzeari. Azken finean, muga etiko eta legalak oztopo handiak jartzen dituzte.

Azkenik, proposatutako logika lausoko sistemari dagokionez, ahulezia handiena da erabiltzailearen parametro fisiologikoen balio normalen buruzko informazioa alde aurretik jakin behar dela. menbresia-funtzioak plantillak ateratzean oinarritzen direnez, ezinezkoa da sistema doitzea erabiltzailearen aldagai fisiologikoak zein tartetan izaten diren jakiten ez bada. [84] bezalako ikerketatalde batzuek sare neuronalak erabiltzea proposatzen dute menbresiako-funtzioen egokitzapenaren arazo hori gainditzeko. Nahiz eta proposamena egitea posiblea den, datuak ondo etiketatzeke zailtasunak direla eta, proposamen hori inplementatzea nahiko zaila da.

5. Chapter

Contributions to detection of responses towards relaxation

5.1. Introduction

In the recent years, there has been a change in both medicine and psychology towards considering mental and physical well-being as a key tool for preventing diseases rather than focusing on treating their symptoms [98–101]. Following this tendency, psychologists and clinicians have started to use biofeedback techniques to determine the mental state of patients by monitoring their physiological signals. These techniques, for instance, can be used to determine how deeply a patient has gone into relaxation [102–104]. This is an interesting approach as it helps determine which are the best working relaxation techniques for each patient. Consequently, it helps them to prevent psychological disorders such as stress or anxiety, or else, recover from them. However, collecting and interpreting physiological signals is far from easy and requires expertise. Therefore, only professionals can use these techniques. That is why developing techniques for the automatic detection of psycho-physiological phenomena can be especially useful.

In spite of many studies focusing on stress, very few pay attention to the physiological phenomena linked to relaxation (most of them belonging to the field of psychology). In this sense, the team considered interesting to research around the automatic detection of relaxation for two main reasons. First, because the technical literature concerning relaxation is almost non-existent and, second, because it is a research line highly connected to the previous work done by the team around stress. Accordingly, the contributions presented in this chapter will be centred in the design of a strategy to enable the automatic detection of physiological drifts towards relaxation.

5. KAPITULUA - DETECTION OF RESPONSES TOWARDS RELAXATION

The work developed for this contribution covered areas of different disciplines of medicine and psychology, apart from computer sciences. Therefore, as most of the steps of this work required verification from experts of both medical and psychological disciplines, this work was carried out with the collaboration of the Department of Neurology of the Cruces University Hospital [105] and of the Instituto Burmuin centre of psychology [106].

Regarding the structure of the chapter, first, Section 5.2. will review the context from which this study derived and will present relevant literature related to the study of relaxation. Second, Section 5.3. will present the experimental setup that enabled to collect, analyse and prepare the data for a later study using machine learning techniques. Although more signals had been collected, only the EDA was finally used for the detection of changes towards relaxation. Accordingly, this section will also cover the extraction of the two features of the EDA, which contribute making it easier to detect physiological changes towards relaxation. After that, Section 5.4., will present the application of machine learning done for automatically detecting those physiological changes indicative of a change towards relaxation. This section also present the results obtained from applying these techniques, especially focusing on decision trees as they were the selected algorithm for taking the development some steps further. Finally, Section 5.5. will summarise the contributions done and will discuss the limitations of the work as well as the future lines derived from this study.

5.2. Context and related work

The World Health Organization states that health is beyond the absence of diseases or infirmity: health implies physical, psychical and social well-being [3]. Currently, evidence has pointed out the importance of how having good mental health acts as an efficient preventive measure for avoiding some everyday diseases from appearing [107]. In this sense, achieving relaxation can be very useful for preventing and recovering from some common diseases of the field of clinical psychology, such as anxiety disorders or depression [108–110]. Related to that, using relaxation techniques is a simple but effective way to get to that mental well-being [111–113].

This way, relaxing using relaxation techniques is a good practise that can be used in a dairy manner, even when no psychologically bothersome symptoms are felt. Focusing on relaxation techniques, it is evident that the effects they produce on the organism do not only stop in the psychological domain. Instead, relaxation techniques have also a beneficial impact on the operation of the body [114], [115]. These beneficial effects get reflected in the physiological changes that occur in the organism; this type of reactions were named “Relaxation Responses” (RResps hereinafter) by Benson in [116]. These reactions of the body are due to the parasympathetic nervous system (PNS) getting active. As already mentioned in Section 2.2., the sympathetic nervous system (SNS) and the parasympathetic nervous system (PNS) react complementarily to each other. Whereas the SNS activates while stressed, it is the PNS that operates

when stress stops or when feeling relaxed [5, 72, 117–119].

As said, these activations of the PNS have impact in many physiological variables, such as the reduction of the heart-rate and breathing pace or the reduction of the opening of eye pupils. Nevertheless, unlike most of those variables that are linked to both the SNS and PNS, the activation of the eccrine sweat glands is only regulated by the PNS. This phenomenon postulates the EDA signal as a good indicator for detecting relaxation: eccrine sweating only occurs when the SNS is active, or, in other words, if sweating is not taking place it means that the parasympathetic part of the nervous system is active.

Finally, concerning technical literature, some studies analyse relaxation from a perspective of emotional recognition. Some others study the states of relaxation using biological signals [78], [120]. Apart from those, some studies focus on stress and compare the patterns that take place during stress against those considered to be basal that can be seen when a person is relaxed [76, 121–125]. However, the team had been unable to find any study focusing on the automatic detection of the physiological shifts indicative of RReps taking place and, so, decided that it would be interesting to research on it and fill that gap in the literature.

5.3. Experimental setup and data analysis

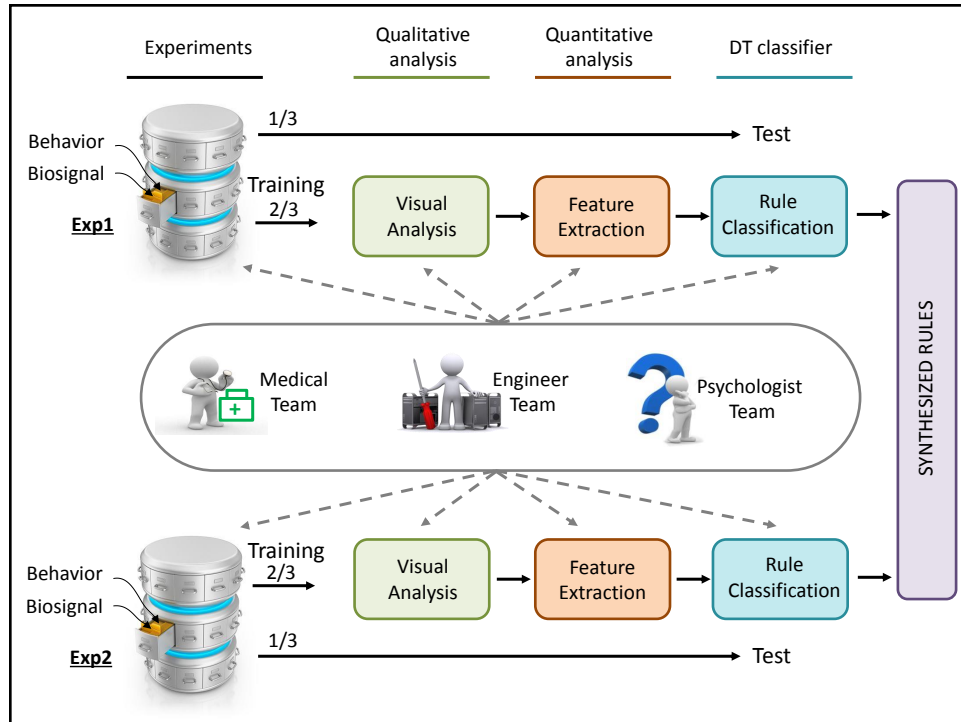
As it normally happens in most of the studies implying the analysis of physiological signals, data is collected by means of an experimental stage. In this study, the signals were collected from two experiments, both involving relaxation events. Whereas the first experiment focused on producing both stress and relaxation, the second targeted only relaxation. After collecting the signals from both of them, these data underwent a qualitative and a quantitative analysis so that the features that were more indicative for relaxation could be extracted. This whole process from collecting the data until it was taken into the final classification stage is summarised by the diagram of Figure 5.1..

This section explains all the work done regarding data collection and preparation: Subsection 5.3.1. will present the populations and experimental protocols of the two experiments, as well as how data was partitioned for the later analysis; Subsection 5.3.2. will explain the qualitative analysis and labelling process of the data and Subsection 5.3.3. will explain the quantitative analysis that was done to extract the most relevant features of the EDA.

5.3.1. Data collection and preparation

As already explained, the data used in this study were collected from two different experiments. The main objective of collecting the signals from different experiments was to get information meaningful of the different types of situations in which relaxation occurs. For example, relaxation may take place in the middle of a stressful situation when a person tries not to get overwhelmed. In other cases, relaxation happens under less aggressive environments, as it

5. KAPITULUA - DETECTION OF RESPONSES TOWARDS RELAXATION



5.1. Figure. The data of the two experiments underwent through different analyses before applying machine learning techniques to detect the RResps.

happens listening to relaxing music laying down in the sofa. Based on these concepts, the first experiment involved RReps inside stressful situations and the second experiment aimed to produce deeper relaxation with the application of relaxation techniques in calm environments.

Experiment 1

The first experiment corresponds to the experiment of the 3D puzzle presented in Section 4.3. and it will be named Exp 1 from now on. As explained in the previous chapter, this experiment aimed to produce stress on the participants. Anyway, during these experiments there were many events of relaxation, as, for example, when participants took deep breaths to get calm. Therefore, Experiment 1 provides data full of information regarding RResps taking place in the middle of stressful situations.

Apart from the physiological signals, the researchers also took record of the feelings and impressions of the participants during the experiment. This was done by asking participants to fill the SAM questionnaire presented in

[126]. Furthermore, marks were taken during the experiment, noting down those moments in which the researchers saw that the participants were taking breaks or long deep breaths to relax. Other important events were also marked, such as the finishing of the puzzle or a piece of the puzzle falling from their hands. Later, participants would be asked about these marked events for corroborating that the notes were correct and subsequently build a behavioural database for labelling the data for the application of machine learning of Section 5.4..

Experiment 2

The second experiment (named Exp 2 from this point) from which data was collected was intended to produce deeper and longer RResps. To do so, in collaboration with Instituto Burmuin, the team designed an experiment in which participants achieved relaxation using different relaxation techniques. The literature covers many ways to induce relaxation: listening to music [127, 128], watching images and videos [129, 130], taking deep and controlled breath [131], meditating [104, 114] and using mind-fullness techniques [103]...

For this experiment, attentional breathing and muscular relaxation techniques were selected. First of all, as done in Exp 1, participants were taken to a basal state for having it as a reference. Then, the experiment was divided into three stages more. In the first stage, participants had to breath in a controlled manner at a rhythm that was indicated in a screen. Then, during the second stage, they would go through an attentional breathing period. To end the experiment, during the third stage they would close their eyes and practise muscular relaxation. The sessions had an average length of 12 minutes and, both before and after the experiment, the psychologist took track of the emotional states of the participants for building the behavioural database of Exp 2.

All the volunteers participated individually in the experiment and all of those sessions took place in a room inside Instituto Burmuin. The total population of the experiment consisted of 18 patients of Instituto Burmuin (4 men and 14 women) participating voluntarily. Therefore, compared to Exp 1, the population of this experiment covers a different age span: they were aged between 32 and 56, being 40.22 years old the average age with a standard of 9.14 years. As done in Exp 1, to fulfil all the legal and ethical requirements, all participants were explained the experiment and asked to fill their respective consent form (CEISH-UPV/EHU, BOPV 32 (M10_2016_189)).

Concerning the collection of the biosignals, for the sake of consistency, the same signals of Exp 1 were in the sessions of Exp 2: the EDA and ECG. Nevertheless, the equipment used to collect those signals was different. In this case, the team collected the signals using a sampling rate of 256Hz with the ProComp Infiniti System hardware and the BioGraph Software - T7500M equipment. Also, as the equipment also provides the possibility to obtain it, the HRV signal was collected during these experiments.

Data preparation

Before starting the analysis of the data and applying machine learning techniques, it is necessary to arrange it so that every data chunk fulfils certain criteria so that how data is presented does not affect any of the later processes. For instance, it is vital to ensure that training and testing data partitions are independent. But sometimes it is necessary to satisfy some other conditions as explained in the following paragraphs.

First of all, the data chunks or instances that are going to be used in the machine learning algorithms must have the same size. This may also affect the data labelling process. In the case of this study, the data collected does not have any label. However, this work was intended for classifying physiological signal chunks to determine whether an RResp is taking place or not. Accordingly, when the team of experts were asked to label the signals, they would have to do it by looking at signal chunks of consistent size throughout the whole duration of the experiments. Thus, following the line of previous work done related to stress, the team decided to divide the signals in 20s instance using a 20s sliding window moving every 5s. However, as the signals had been sampled at 1000Hz in Exp 1 and at 256Hz in Exp, the team had to subsample all of them down to 1Hz before doing the 20s windowing. The labelling process and window selection will be further explained in the following Subsection 5.3.2..

Apart from data chunk size, when machine learning algorithms are involved the datasets used for both training and testing the algorithms must be balanced. In the two experiments, there were different phases in which the subjects were doing different things. Therefore, to have balanced datasets, the researchers had to make sure that the training and testing partitions included data chunks or instances from all the stages of the experiments.

To do so, the team decided to create smaller data segments that would be independent of each other. For creating independence between segments, the team left unused those data windows that overlapped in contiguous segments, achieving this way segment disjunction. Finally, the team opted to employ 2/3 of each smaller segment for training the machine learning algorithms and the remaining 1/3 for testing. It is important to bear in mind that the smaller data segments had different durations depending on the experiment that was analysed. Whereas the duration of the longer experiment, Exp 1, lasted for 115s, the segments of Exp 2 had a duration of 95s.

5.3.2. Qualitative analysis


Accomplished the data preparation and having windowed the physiological signals, the team could then pay attention to the qualitative properties of the EDA signals. In this sense, before getting to numerical details, it was important to analyse the EDA qualitatively and to detect the RReps patterns so that they could be related to specific psychological states.

As explained in Subsection 3.2.2., the EDA is a signal that has an accumulative nature and that it is common to decompose it into two main compo-

nents [132]: the Skin Conductance Level (SCL), which corresponds to the slow variations and the Skin Conductance Responses (SCRs), that correspond to the fast variations produced by sweat burst. It was also explained that eccrine sweating only happens when the SNS is active and stimulates the sweat glands. Therefore, as SCRs correspond to the sweat burst, the presence of SCRs in the EDA can be used as a descriptor of SNS getting active. Moreover, some works state that the size of the SCRs is proportional to the magnitude of the SNS activations [133, 134], i.e, the bigger the SNS activation the greater the SCRs.

Taking this phenomenon as a premise, the study presented in this contribution suggested looking at the problem from another perspective and to use the absence of SCRs as an indicator of the SNS not being active. At the same time, these absences also indicate that it is the parasympathetic part of the ANS that is active [116]. Subsequently, it can be concluded that an EDA signal whose SCL component is decreasing is meaningful for relaxation taking place. Nevertheless, unlike it happens with the HR value (increasing or decreasing with SNS and PNS activations), the EDA baseline value is not meaningful for the state of neither the SNS nor the PNS. Hence, a researcher should not be disguised by the baseline value of the EDA as it is not indicative for relaxation. Instead, it is the decreasing tendency of the EDA baseline who reflects that relaxation is taking place.

Accordingly, depending on the shape of the EDA signal, it is possible to identify two types of situations. The first situation is when the SCL component is decreasing in a very linear manner with no sudden bursts. In these situations, it can be said that very deep RResp are taking place. However, there is another type of situations in which although many SCRs occur, the SCL decreases slightly for shorter periods. These type of situations correspond to the second scenario in which RResps happen: when a person tries to relax in the middle of a stressful situation (see Figure 5.2.).

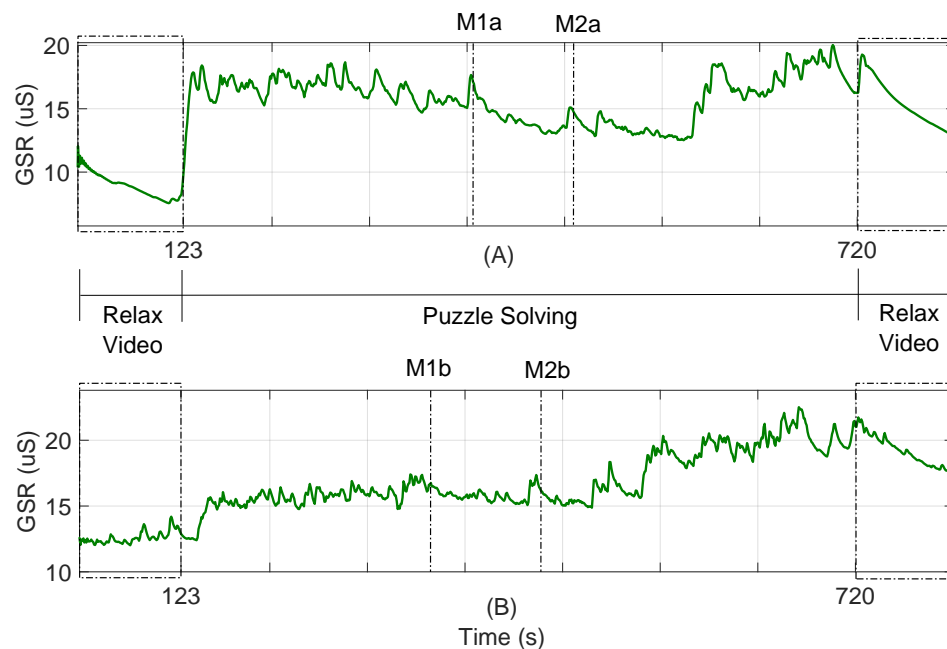


5.2. Figure. The presence and absences of SCRs in the EDA signal can be used as indicators of SNS and PNS activations, respectively.

Once these two patterns of the different types of RResps had been identified,

5. KAPITULUA - DETECTION OF RESPONSES TOWARDS RELAXATION

the team could analyse the collected databases and see if those patterns had been mirrored in the EDA signals collected in the experiments. By looking at the signals, the researchers could see that indeed a majority of the collected signals showed some of these patterns. For example, Figure 5.3. shows that different phenomena took place in two of the registers collected during Exp 1. Subject A showed very deep RResps at both the beginning and ending of Exp 1 (upper graph of Figure 5.3.). On the contrary, subject B could not relax at the beginning and, despite he managed to do it at the end of the experiment, the presence of SCRs evidence that the relaxation achieved was not as deep as the subject A's. Seeing these phenomena in the signals, the team checked what each participant's replies to the interviews they had done at the end of the sessions. All the events in the EDA strongly correlated to their answer to the interview, in which subject A had found the initial and final videos to be very relaxing. Concerning subject B, he answered that he was very nervous at the beginning of the experiment and that he had hardly been able to concentrate on the initial video. However, once the puzzle-solving phase had finished, he said that it had been possible for him to relax a bit during the final video.



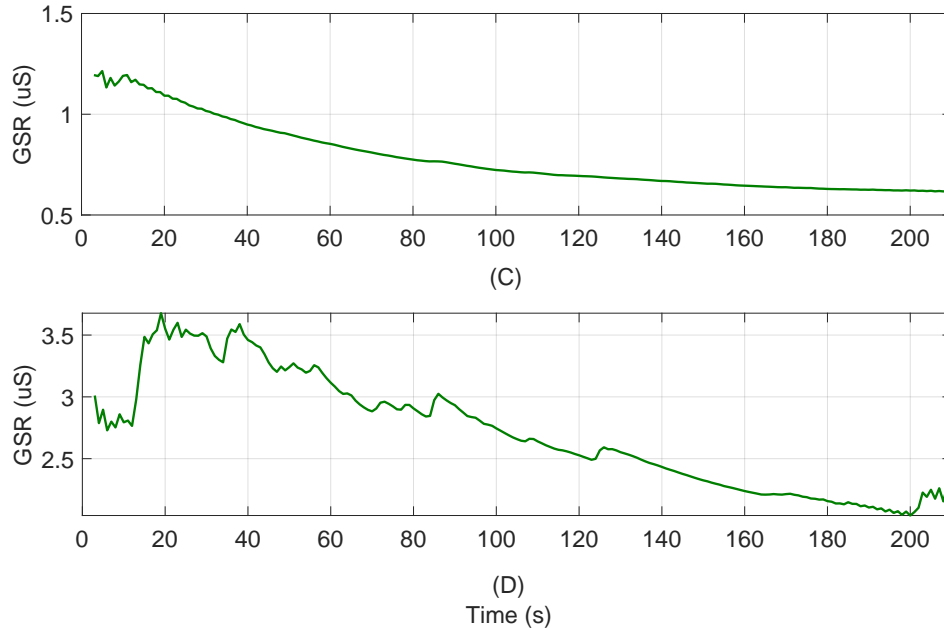
5.3. Figure. During the videos, subject A could relax better than subject B. The EDA of subject B was affected by several SCRs during the videos.

Apart from those overall impressions, the team also analysed the events that had been noted down by the researchers. Following with the example of Figure 5.3., during the experiment of subject A, the researchers had marked down

events M1a and M2a as events related to relaxation. For instance, an RResp had been marked at M1a, when subject A stopped, took a deep breath and tried to relax. Something similar happened at M2a, when the participant stopped for a while and started to consider giving up solving the puzzle. Hence, it is evident that there is lots of relevant information in the behavioural database built from the interviews and the notes taken by the researchers during the experiment. Consequently, the importance of collecting such a database is confirmed as there is a strong link between stress/relaxation and how people feel.

Regarding the registers of Exp 2, the collected signals also showed various types of patterns. Two registers have been plotted in Figure 5.4., corresponding to subject C (top graph) and D (bottom graph). In this case, subject C experienced a very linear and unaltered EDA decrease and, subsequently, it can be concluded that the volunteer achieved great relaxation. This got corroborated by the interview done to subject C at the end of Exp 2, who found the session to be very relaxing. On the other hand, subject D stated that it had been difficult to relax at the beginning and that it was not until the second half of the session that she could get relaxed. Analysing subject D's EDA, her declarations matched closely what happened in the EDA: in the first quarter the EDA suffered many SNS activations due to the nervousness; then, in the second quarter the SCL started to reduce but with many smaller SCRs happening; finally, after 90s, the EDA of subject D started to decrease in a very linear manner.

5. KAPITULUA - DETECTION OF RESPONSES TOWARDS RELAXATION



5.4. Figure. Although subject C relaxed deeply, subject D could not relax until the end of the session and, accordingly, the EDA only decreases linearly in the second half of the session.

In the next stage of the qualitative analysis, with the help of the psychologists and clinicians, the team created the labelling system to define the intensities of the RResps. The labelling system consisted of four different labels. The first label, LRResp (Low RResp), corresponds to those cases in which the RResp is not very deep but still there is a physiological change towards relaxation. Then, medium intensity physiological changes were given the MRResp label (Medium RResp). Accordingly, the deepest relaxation responses were labelled as HRResps (High RResp). Last, label NRResp (No RResp) was created for the situations in which no RResps were happening (when the subject is in neutral psychological states or stressing). This approach of using three intensity levels for the RResps is also consistent with the labelling used for assessing stress (recall Chapter 4).

Finally, the last step of qualitative analysis was to label the registers for the application of the supervised learning algorithms of Section 5.4.. To do so, a member of the team who had knowledge on both physiology and psychology analysed all the windows and labelled them according to her opinion on the intensity of the RResp happening in the window (if there was any). To avoid biasing her opinion, she was given all the windows in a random order. Furthermore, although only the windows of the EDA signals would be labelled, the member of the team was also given the HRV signal for having a clearer idea of

what happening in each window. Later, after she had finished, the rest of the team gathered with the expert neurophysiologists of Cruces Hospital and psychologists of Instituto Burmuin and analysed that window labels. As they had already collaborated with the research team in [67], those experts were accustomed to window approach analyses. Thanks to the experts, the team could get a second opinion on the labelling and corrected the labels in which the experts disagreed with the team member.

5.3.3. Quantitative analysis


The qualitative analysis and the data labelling led the team to the next step of the EDA analysis, the quantitative analysis. This analysis helped the team decide which were the best two features to extract from the EDA for identifying RResps, being one of the features one of the main contributions of this work. Besides, it is in the quantitative analysis that the values of those features were related to the different intensity RResp levels defined in the labels.

The analysis of the signals was done using a 20s sliding window approach, moving every 5s. Other types of signals, such as the periodical signals, can be easily analysed using frequency domain analysis. However, the EDA is a non-stationary and non-periodical signal, which makes it complicated to use frequency-based strategies. On the contrary, time-domain strategies as the sliding window are very suitable for signals with these properties and so, it is common to find its use in the literature [78, 84].

The operation principles of the sliding windows have already been explained in Chapter 4. Anyway, as the contribution presented in this chapter only used the EDA, it is interesting to determine which windows size is the best for the recognition of RResps. Checking the literature, the team could find that the time windows vary widely from 3s short window to the longest 300s windows [78, 84, 135, 136]. Therefore, after reading in [21] that “*features extracted from the tonic component express the sympathetic tone and are often computed within time windows of 20s, since the upper cut-off frequency of the tonic component is about 0.05 Hz*”, the team decided to use 20s windows and to be consistent with what done in [67]. This way, the team could study both phasic and tonic components (SCRs and the SCL) with a window size big enough to contain information and that is not very computationally costly.

Later, having chosen a proper window size, the team extracted different features from the EDA and ended up only using two of them: the slope of the EDA within an analysis window (sEDA) and, the innovative feature, the area enclosed between the instant EDA and the linear regression of the EDA within the window (aEDA). As the EDA is a largely varying signal, these features were normalised inside the boundaries of the analysis window. Thanks to it, the same threshold values could be used in all the analysed windows. As the descriptive name of aEDA might lead the reader to certain confusion, the graphical representation of the two has been depicted in the below Figure 5.5..

5. KAPITULUA - DETECTION OF RESPONSES TOWARDS RELAXATION



5.5. Figure. The selected features are the slope of the EDA within the analysis window and the surface enclosed between the linear regression of the EDA and its instant value.

Paying attention to the first feature, *sEDA*, it seems evident that a positive slope of the EDA means that the person is getting stressed and so, that no relax is taking place. Therefore, *sEDA* necessarily has to be negative within the analysis window if an *RResp* is happening. Concerning *aEDA*, taking into account the physiological relationship between the absence of SCRs and PNS activations, it seems clear that the EDA signal will decrease in a very linear manner, without SCRs, when the PNS activation is maintained in time. Subsequently, if the EDA decreases linearly then (due to the absence of SCRs), then the shape of the EDA will be very close to its linear regression within that analysis window. Consequently, the *aEDA* feature results in very small values when the PNS activation is intense and long in time. On the contrary, if sudden SCRs altered a PNS activation, they would make the EDA signal to bounce around the linear regression, producing higher *aEDA* values. Thus, the smaller *aEDA* the deeper the *RResp*.

Many works in the literature extract features from the EDA for both emotional recognition and stress detection [21, 137, 138]. *sEDA* is a clear example of it being used since the middle of the 20th century. Apart from the slope, it is possible to find features belonging to other types of analysis: statistical parameters, increments, nonnegative convolutions, areas, etc. ([78, 121–123, 133]). If the proposed *aEDA* feature should be classified in one of these categories, it would fit in the ones related to extraction of areas. However, most of the area type features that are extracted from the EDA require the signal to be decomposed into the tonic and the phasic components. Later, most studies working with areas extract the areas under the curve and other area related features from the separated phasic and tonic components [23, 139]. Also, some research avoid decomposing them and focus on the morphological properties of SCRs, such as rising times and amplitudes of the first half of SCRs [24, 25]. Nevertheless, to the

extent of the authors' knowledge, the proposed aEDA feature is innovative and merges the strategies of these works only taking the most beneficial parts. Not implying component decoupling, the aEDA has information from both tonic and phasic components and, simultaneously, it is not computationally costly because the linear regression calculation is an easy procedure.

5.4. Application of machine learning

This section is divided into two subsections. The first subsection, Subsection 5.4.1. will explain the data classification done with machine learning techniques. In this process, the team used different supervised learning algorithms to classify the windows as belonging to one of the four aforementioned labels: NRResp, LRResp, MRResp and HRResp. Subsection 5.4.1. will also present the results of those classifications, which were used to select the best performing type of algorithm for classifying RReps. For the simulations and performance calculations of the two experiments, the team used the same partitioning strategy: 2/3 of the data were used for training and 1/3 for testing the algorithms.

After doing this process for the two experiments' datasets (Exp 1 and Exp 2), the team saw that decision trees (DT) obtained good results in both of them. Accordingly, they decided to merge both DTs and create a synthesized rule system for general use in any of the experiments. The process via which the team designed this rule system will be explained in Subsection 5.4.2..

5.4.1. Selection of the best classifying algorithm

There are many machine learning algorithms and depending on the application and on the databases to classify, their performance might vary considerably. Therefore, when looking for an algorithm to classify data it is always interesting to do a comparison between various algorithms so that the best performing one can be selected. For the case of this study, the team decided to use only supervised learning algorithms; as the signal windows had already been labelled there was no point in using clustering algorithms.

To do this comparison between algorithms the team opted for using Weka's implementation of 12 algorithms with their default algorithm settings [140]. The team decided to use the default parameters because fine-tuning an algorithm requires time and sometimes optimising the classifier performance for a class may worsen its performance for the others. Therefore, the team thought that using default would be good as, instead favouring any algorithm in detriment of the others, it would rather indicate the suitability of each algorithm under fair-play conditions.

The team selected 12 algorithms considering them to be state of the art algorithms within the algorithm families that base on the same type of paradigm (refer to Section 3.4. for more information). The 12 supervised learning algorithms that were chosen are 1R rule, Decision Tree (DT), k-NN (1-NN and 5-NN), Naive Bayes (NB), Radial-Basis Network (RBF), Support Vector Machine

5. KAPITULUA - DETECTION OF RESPONSES TOWARDS RELAXATION

(SVM), Logistic Regression (LR), Ada Boost (AdaB, combining 10 decision trees), Bagging (Bag, combining 10 decision trees), Random Forest (RF) and Multi-Layer Perceptron (MLP). The results of this comparison for the data of the two experiments can be checked in Table 5.1., where the given performance indicators correspond to the presented in Subsection 3.4.4..

5.1. Table. Results of the performance of the 12 classifiers.

Classifier	Exp 1			Exp 2		
	P	R	F1	P	R	F1
1R	0.649	0.682	0.665	0.773	0.797	0.785
DT	0.990	0.990	0.990	0.992	0.992	0.992
1-NN	0.978	0.978	0.978	0.969	0.969	0.969
5-NN	0.978	0.977	0.978	0.966	0.965	0.965
NB	0.822	0.797	0.809	0.859	0.823	0.840
RBF	0.955	0.955	0.955	0.953	0.953	0.953
SVM	0.913	0.912	0.913	0.814	0.739	0.740
LR	0.888	0.888	0.888	0.952	0.951	0.951
AdaB	0.989	0.989	0.989	0.992	0.992	0.922
Bag	0.990	0.989	0.989	0.992	0.992	0.992
RF	0.991	0.992	0.991	0.992	0.992	0.992
MLP	0.952	0.951	0.952	0.892	0.864	0.878

The results of Table 5.1. show that DTs, RF and the ensembles of classifiers (AdaB and Bag using 10 DTs) were the best classifiers, obtaining very similar results. Thus, seeing those results, the team chose to continue working on the DTs because the other algorithms do not have the same explanatory capacity as DTs. Being very easy to understand makes DTs to be perfect for users without any computer science background. Moreover, DTs are very simple and the branch splitting criteria can be easily modified. This was very useful for the work presented in the next subsection, where the DTs specifically designed for each of the experiments were merged into a single synthesized rule system useful for both databases. The DTs produced during the comparison of the algorithms corresponds to Weka's J48 pruned tree algorithm (Weka's default DT setting), which corresponds to Quinlan's C4.5 algorithm [141].

5.4.2. The synthesized rule system

Being selected as the best algorithm for having one of the best performances and being easily understandable, the team considered that it was worth taking the DTs to a higher level of analysis. To do so, the team wanted to see and compare the rules of the DTs generated for Exp 1 and Exp 2, which can be seen in Figures 5.6. and 5.7. respectively. There, the main splitting points have been marked with colour boxes (those marks will be used later on this subsection).

J48 pruned tree Experiment 1

```

-----
aEDA <= 0.069998
|   sEDA <= 0.000021
|   |   sEDA <= -0.04861: -3 (1494.0)
|   |   sEDA > -0.04861
|   |   |   aEDA <= 0.039991: -3 (361.0/45.0)
|   |   |   aEDA > 0.039991: 0 (92.0)
|   |   sEDA > 0.000021: 0 (295.0)
aEDA > 0.069998
|   sEDA <= -0.050193
|   |   aEDA <= 0.199712: -2 (1846.0/16.0)
|   |   |   aEDA > 0.199712
|   |   |   |   sEDA <= -0.300083: -1 (689.0/13.0)
|   |   |   |   sEDA > -0.300083
|   |   |   |   |   sEDA <= -0.289222
|   |   |   |   |   |   sEDA <= -0.294407: 0 (11.0/2.0)
|   |   |   |   |   |   sEDA > -0.294407
|   |   |   |   |   |   |   sEDA <= -0.292119: -1 (4.0)
|   |   |   |   |   |   |   sEDA > -0.292119
|   |   |   |   |   |   |   |   sEDA <= -0.291568: 0 (2.0)
|   |   |   |   |   |   |   |   sEDA > -0.291568: -1 (3.0/1.0)
|   |   |   |   |   |   sEDA > -0.289222: 0 (539.0/6.0)
|   sEDA > -0.050193: 0 (3374.0)

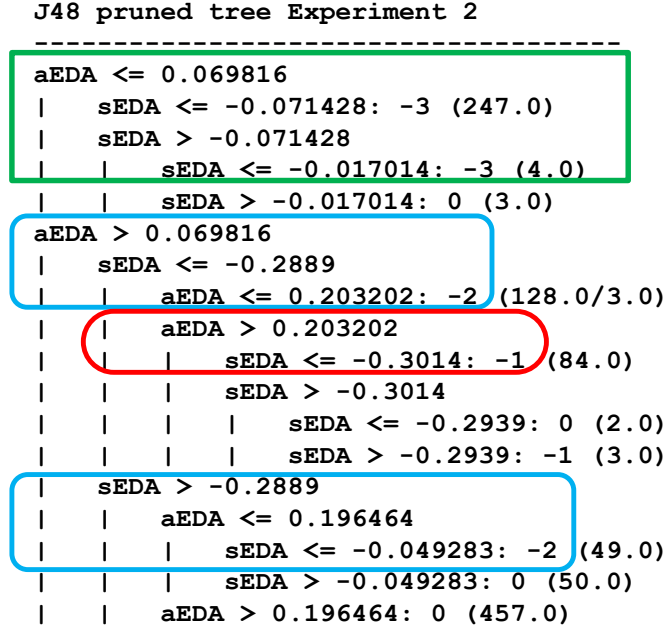
```

5.6. Figure. The rules of the DT for Exp 1.

Knowing how these DTs operate, the team wanted to study their performance with a higher degree of detail by seeing how good they were, not at a general level, but a class-specific level. The classification results of each DT for each class have been presented in Table 5.2.. The first two columns of Table 5.2. indicate the labels for the different RReps levels and the number of instances that had been catalogued by the experts for each RResps level. Then, the performance metrics of Subsection 3.4.4. are presented from the third to the eighth columns. Please note that there are two rows for which only the precision (P), recall (R) and F-1 score have been given. These two rows correspond to the average results for the data of the whole datasets of Exp 1 and Exp 2. Accordingly, the labels of those rows have a total of instances equal to the sum of the quantities belonging to the four RResp levels in each experiment.

Additionally, as the main rules shown in Figures 5.6. and 5.7. had similar thresholds, the team also decided to cross the DTs. This means that they used the DT created for Exp 1 with the data of Exp 2 and, consequently, they did the same in the opposite direction. The results of the classification of the crossed systems are also given below in Table 5.2., from the ninth column to the

5. KAPITULUA - DETECTION OF RESPONSES TOWARDS RELAXATION



5.7. Figure. The rules of the DT for Exp 2.

5.2. Table. The performance indicators of each classifier using them with the original dataset with which they were designed and with other experiment's dataset.

State	Manual label	DT						Crossed DT					
		TP	FN	FP	P	R	F1	TP	FN	FP	P	R	F1
<i>Exp1</i>	4354				0.990	0.990	0.990				0.965	0.965	0.965
NRResp	2177	2153	24	6	0.997	0.989	0.993	2140	36	95	0.957	0.983	0.970
LRResp	349	342	7	15	0.958	0.980	0.969	335	14	11	0.968	0.960	0.964
MRResp	923	909	14	4	0.996	0.985	0.990	901	22	14	0.985	0.976	0.980
HRResp	905	905	0	20	0.978	1.000	0.989	824	81	34	0.960	0.910	0.935
<i>Exp2</i>	513				0.992	0.992	0.992				0.992	0.992	0.992
NRResp	257	256	1	1	0.996	0.996	0.996	256	1	1	0.996	0.996	0.996
LRResp	44	43	1	1	0.977	0.977	0.977	43	1	2	0.956	0.977	0.966
MRResp	87	85	2	1	0.988	0.977	0.983	85	2	1	0.988	0.977	0.983
HRResp	125	125	0	1	0.992	1.000	0.996	125	0	0	1.000	1.000	1.000

fourteenth.

The results given in Table 5.2. show that when crossed, the classifiers performed very good, almost at the same level as when they were used with their original dataset. This confirmed the suspicions of the researchers, who thought this might happen as a consequence of the rules marked in Figures 5.6. and 5.7. were very similar. Consequently, the team considered that merging both classifiers into a unified classifier would be interesting.

To calculate the new classifier the team took the rules of the original DTs and calculated new splitting criteria. These new points were obtained by calculating the average value of the splitting points of the two DTs. Then, for the avoiding rare numbers, the values were rounded keeping only two decimals. For instance, taking the splitting criteria of Figures 5.6. and 5.7. for the LRResp class (the ones inside red boxes), the splitting points of the new classifier would be calculated as done in Equations 5.1 and 5.2.

$$\begin{aligned} aEDA &= (aEDA_{Exp1} + aEDA_{Exp2})/2 \\ &= (0.1997 + 0.2032)/2 = 0.2014 \approx 0.2 \end{aligned} \tag{5.1}$$

$$\begin{aligned} sEDA &= (sEDA_{Exp1} + sEDA_{Exp2})/2 \\ &= -(0.3000 + 0.3014)/2 = -0.3007 \approx -0.3 \end{aligned} \tag{5.2}$$

However, there is an exception to the calculations of the splitting criteria of label HRResps. If attention is paid to Figure 5.6. and 5.7., the reader will realise that the DT of Exp 1 has a case that has not been considered in the other DT: when $sEDA < -0.04861$ and $aEDA \leq 0.03999$. Consequently, leaving these cases out of consideration of the new synthesized rule system would worsen considerably its performance. Therefore, to avoid false detections, the team opted to add this rule using a logic OR to the splitting criterion calculated with the method already explained. Consequently, after calculating all the splitting criteria, the team obtained the new synthesized rule system that is presented in Table 5.3..

5.3. Table. The decision rules the new synthesized rule system.

State	Synthesized/unified rules
LRResp	(sGSR<-0.3) AND (aGSR>0.2)
MRResp	(sGSR<-0.05) AND (0.07<aGSR<0.2)
HRResp	((-0.05<sGSR<0) AND (aGSR<0.04)) OR ((sGSR<-0.06) AND (aGSR<0.07))
NRResp	Any other situation

The new system was then taken into test, obtaining the results presented in Table 5.4.. These results show that the new system has a very good performance, which in the case of Exp 1 obtained better results than the DTs designed expressly for it ($F1_{SYNTHESIZED}=0.994$ vs $F1_{DT-Exp 1}=0.990$).


5. KAPITULUA - DETECTION OF RESPONSES TOWARDS RELAXATION

5.4. Table. Performance indicators of the unified classification system.


State	Manual label	Unified rules					
		TP	FN	FP	P	R	F1
<i>Exp1</i>	4354				0.994	0.994	0.994
NRR esp	2177	2176	1	9	0.996	1.000	0.998
LR Resp	349	339	10	12	0.969	0.969	0.969
MR Resp	923	909	14	4	0.996	0.985	0.990
HR Resp	905	905	0	0	1.000	1.000	1.000
<i>Exp2</i>	513				0.992	0.992	0.992
NRR esp	257	257	0	2	0.992	1.000	0.996
LR Resp	44	42	2	1	0.977	0.955	0.966
MR Resp	87	85	2	1	0.988	0.977	0.983
HR Resp	125	125	0	0	1.000	1.000	1.000

Finally, the team considered interesting to verify empirically that the new algorithm performed correctly over time. To do so, they decided to input the EDA signals of the experiments into the algorithm and see if the outputs given over time were correct. For the sake of consistency, the following Figures 5.8. and 5.9. respectively show the new algorithm's outputs of for the EDA signals of subjects A and B from Exp 1 and C and D from Exp 2. For these simulations the RResp levels have been represented numerically, ranging from 0 to -3: 0 corresponds to NRResp, -1 to LRResp, -2 to MRResp and -3 to HRResp.

5.4. APPLICATION OF MACHINE LEARNING



5.8. Figure. During the videos, the RResps measured for subject A have much higher intensity than subject B's.



5.9. Figure. Subject C achieved much deeper RResps compared to subject D.

5. KAPITULUA - DETECTION OF RESPONSES TOWARDS RELAXATION

In Figures 5.8. and 5.9. the EDA signals have been plotted in the green at the top part of the graphs of each user. Below them, the synthesized systems RResp level output has been depicted in blue and it updates its value every 5s according to the sliding window approach. In Figure 5.8. it can be seen that during the relaxing videos of Exp 1, compared to subject B, the algorithm gave much higher RResp outputs for subject A's EDA. This estimation is coherent to what the subjects stated in their interviews. Besides, the algorithm also gave medium intensity RResps for the events marked as M1a, M1b, M2a and M2b. The good performance also gets reflected for the cases of Exp 2 shown in Figure 5.9.. There, subject C got high levels of relaxation during the whole session, but, on the contrary, the algorithm's outputs did not indicate that maintained RResps until the second half of the session.

5.5. Summary

New paradigms of medicine and psychology pose relaxation as a key tool for preventing and helping to heal certain diseases from the clinical psychology discipline, such as stress, anxiety disorders or depression. Thus, getting to know how and when patients get relaxed would be helpful for professionals when assessing patients. Moreover, as relaxation produces no side effects but only benefits to the organism, creating affordable technological solutions for helping users understand how relaxation takes place in their organism would be very helpful for the public health of a fast-living society like ours.

Nevertheless, there is not much technical literature in the field of computer sciences that study relaxation, and when they do so, most of them analyse it transversally and focus on stress. Apart from these works, some others study relaxation within an emotional recognition approach, which is also different from detecting stress from the perspective of physiological computing. Therefore, considering there is a gap in the literature, the team decided to study the physiological changes that relaxation produces in the organism, the RResps, and to subsequently design an automatic system capable of detecting and classifying those RResps.

The study analysed RResps from two different points of view. First, the team collected the signals from an experiment (Exp 1) that produced RResps during a stressful situation. Second, the team also collected signals from an experiment (Exp 2) especially aimed to produce relaxation in the participants. Analysing these data with the help of experts in physiology and psychology the team could detect and define the boundaries in the EDA signal that reflect different levels of RResps, cataloguing them with four labels: NRResp (0), LRResp (-1), MRResp (-2) and HRResp (-3).

As said, the patterns that permitted to detect those four levels of RResps were found thanks to the thorough analysis of the EDA signal of sweating. More certainly, the patterns were found in the two features that were extracted from the signal: the slope and the area created by the instant EDA signal and its linear regression. Although the first has been used in the literature since

decades, the second feature is an innovative feature that gives a little twist to the feature extraction related to the areas produced by the EDA curve, which normally tend to analyse the phasic and tonic components separately.

Finally, having detected the EDA features and patterns that indicative of the RResps, the team tried different supervised learning algorithms to find the best performing algorithm for detecting the RResps taking place in the signals collected in Exp 1 and Exp 2. Despite different algorithms obtained similarly good performances for the two experiments, the group opted to choose DTs as unlike the others, they have explanatory properties. Later, the two DTs created for signals of the experiments were further studied. During this final study, the team saw that the rules of both DTs were similar and that they also performed well with the dataset of the experiment with which they had not been trained. Therefore, as a last step of the study, the team merged the most relevant rules of the two DTs to build a simpler yet similarly effective synthesized rule system.

Limitations and future lines

This work has shown that it is possible (and also interesting) to detect physiological responses towards relaxation applying machine learning algorithms to just two features coming from a single physiological variable: the EDA. Nevertheless, it is a matter that has not been sufficiently covered by the literature and so, there is still a lot to research. For instance, as the number of participants in Exp 2 was relatively reduced, the population that took part in this study mostly consisted of students of a very specific age range. Therefore, it would be convenient to expand the study to different ages and a wider population in general and, then, see if the extracted features and the classifiers perform as well as they did with the collected data from the experiments.

Apart from that, as also commented in Subsection 4.7., one of the most complicated problems in this type of experiments is the labelling of data. As they imply subjective concepts such as stress and relaxation, it is complex to determine whether the labels given to the registers are trustworthy. Most of the times, the labels given to the instances rely solely on the answer that the participants give to interviews and questionnaires at the end of the data collection experiments. Nevertheless, what stated in these interviews reflects only a general impression and leaves out what happening in eventual situations. This is the major weak point of most of the studies that involve impressions and feelings.

However, being a weak point, the problem arising from data labelling may also be the most relevant open line to research in the future. For the writer of this thesis, automatic detection tools and strategies as the one presented in this contribution can result very helpful for online labelling of the signals collected in future experiments. This way, if this detection algorithm (or any other depending on the experiment) was run while the signals are being collected, then it would be possible for the researchers to have all the signals labelled even before interviewing the participants. This way, the researchers would get

5. KAPITULUA - DETECTION OF RESPONSES TOWARDS RELAXATION

the possibility to ask the participants about eventual situations in which the algorithms reacted very remarkably and could directly contrast both the labels and the veracity of the detection algorithm itself.

Besides, it would be very interesting to implement the solution in a portable hardware platform. Whereas most of the solutions to problems found in the literature of physiological computing imply collecting various signals, the proposed system only uses one signal and, so, it should be relatively easy to implement (if compared to others).

Finally, in this study, the team saw that RResps produced by relaxation techniques are normally more intense than those produced during a stressful situation. However, it might be possible to find certain patterns hidden in the physiological reactions that indicate to which type of situation does the detected RResp belong to. Consequently, the team considers that it would be interesting to give an extra twist to the algorithm to see if is possible to differentiate between these two types of RResps.

6. Chapter

Contributions to ERD/ERS Brain-Computer Interfaces

6.1. Introduction

The first human electroencephalogram was collected in 1924 by Hans Berger [142]. Nevertheless, it was not until the decade of 1970 that brain activity caught the attention of the researchers of engineering disciplines. It was in those years that the first Brain-Computer Interfaces (BCI hereinafter) were produced. Those BCI systems mostly focused on helping people restore the auditive, vision or limb moving capabilities they had previously lost. Therefore, it was only in clinical environments that BCI systems were used.

However, the fast development in electronics of the last decades have made affordable computer devices with high computational capabilities. Related to that, the number of studies around machine learning has grown proportionally to the power of CPUs. At the same time, the number of technological methods to capture the activity of the brain has also increased [143], and so, the same has happened with the number of companies producing EEG headsets. The technical and economical synergy produced between disciplines has made much easier to collect, detect and classify brain activity patterns using computer devices. Consequently, the use of BCI systems has expanded from the medical environments to many other applications, such as videogames, caregiving applications for elderly people, domotics or even the military.

Although there are some differences in the implementation, all BCI systems have the same basic structure [144, 145]. First, EEG signals are collected using electrodes, which can be either wet (if they require using contact gel) or dry. Then, the signals are processed by the computer device in search of specific signal patterns. Finally, the computing unit will send a command to an end-effector in those cases that a known pattern is detected. As explained in Subsection 3.5., there various types of BCI which differ from each other in the way they produce the desired brain activity patterns: event-related potentials (ERPs),

steady-state visually evoked potentials (SSVEP), ERD/ERS motor imagery...

This work presents the contribution done to the state of the art of ERD/ERS motor imagery BCI, proposing to combine supervised and unsupervised learning algorithms in a hierarchical classification system for a 5 class motor imagery classification problem. The chapter will develop in a similar manner to Chapter 4. and 5.: the context and literature related to the work will be explained in Section 6.2.; then Section 6.3. will present BCI Competition III dataset IIIa and the modification done to expand it from being a 4-class problem to a 5-class problem. Later, the analysis done using only supervised learning algorithms will be given in Section 6.4. and, as the results were not satisfactory, a new solution will be presented in Section 6.5., were the team proposes to combine the K-means unsupervised learning algorithm with SVMs in a hierarchical classification system. Finally, the experimental results will be presented in Section 6.6. and the work will be summarised in Section 6.7. along with the limitations of the work and the future lines.

6.2. Context and related work

Apart from the study of mental states of the previous two contributions, researching about brain-activity is also among the interests of the research team. Concerning this area, the team considered interesting to apply their experience to tackle the classification problems related to brain-computer interfaces (BCI). However, collecting electroencephalograms (EEGs) is a far from simple task, and so, instead of creating their experimental design, the team opted for using an already existing dataset for the study. Therefore, as they had already worked with it [146], the team chose to use dataset IIIa from the BCI Competition III database, which is a competition referenced very often in the literature. In it, participants were given a set of EEG signals and they have to perform the best classification possible for a specific motor imagery problem.

As already explained, there are different types of BCI systems. However, having chosen to use dataset IIIa from BCI Competition III [147], the type of the BCI system for this study already was selected: it was an ERD/ERS motor imagery BCI. These systems are among the most commonly studied in the literature [148–151]. They base on detecting variations of the brain potentials that are produced when the user moves or thinks of moving a part of the body [152, 153]. To train these systems, users are told to think about moving a part of the body after seeing or hearing a specific signal. Therefore, it can be said that these systems work synchronously, being time-locked to specific cues.

Normally, motor imagery systems intend to discriminate between various classes of brain activity patterns. The simplest systems only try to determine whether it is the right hand or the left hand that wants to be moved. Some others get more complex and try to detect movement intentionality of various parts of the body. Nevertheless, sometimes researchers focus too much on identifying brain patterns related to intentional movements and forget that human brains do not continuously send commands to the limbs. Being like that, detecting the

absence of intentional control states (non-intentional control, NC) can be said to be as important as correctly classifying the different intentional control states (IC). If not, the system would detect many false positives and produce several undesired end-effector actuation, resulting in user discomfort and discarding the BCI system as an adequate technological solution [154, 155].

Considering this, some studies have catalogued motor imagery as NC pattern rejection problem in which the unrejected IC patterns have to be correctly differentiated. This can be done either by classification [156] or by setting thresholds for EEG signals below which brain activity is ignored [154, 157, 158]. Therefore, it can be said that the problem can be divided into two classification levels: first, NC and IC patterns have to be separated and, later, differentiate the classes of the instances labelled as IC. Whereas the first classification tries to keep the false positive rate (FPR, $FPR = FP/(FP + TN)$) as low as possible for not being refused by the user (scoring over 10% is considered not to be good enough [156, 159, 160]), the second classification searches to maximise the accuracy classifying ICs.

Following this line, the contribution work explained in this chapter looks to give a solution to the ERD/ERS motor imagery problem presented in the BCI Competition, but adding a new NC class for representing the situations in which no movement is intended. Consequently, the addition of the NC class also increases the difficulty of the problem, as the FPR of the system has to be kept below 10%. The proposal presented in this chapter uses a two-level hierarchical system. First, it uses the K-means unsupervised learning algorithm for the initial NC-IC classification, keeping the FPR under 10%. And then, in the second level classification, it uses a Support Vector Machine (SVM) to determine the exact class of the instances classified as IC by the K-means algorithm.

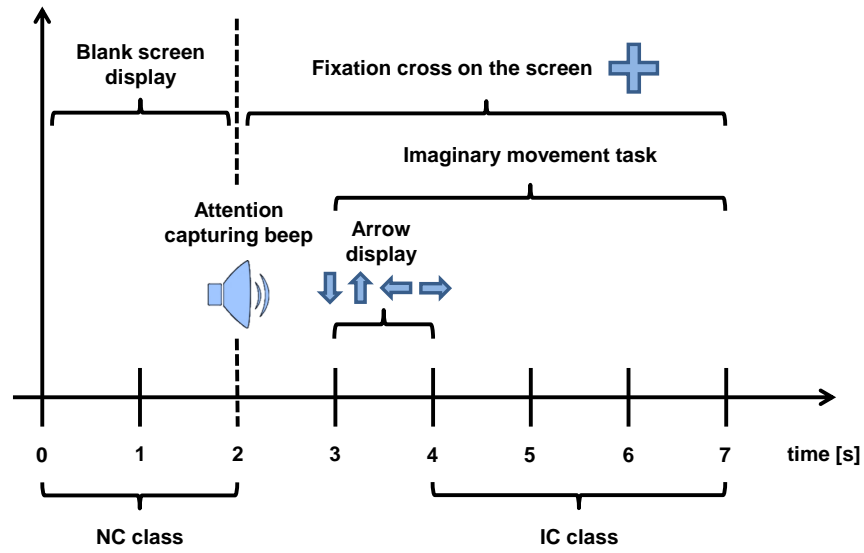
6.3. Data and experimental methodology

6.3.1. The original dataset

As explained in the previous sections, the team decided to start the research using the IIIa dataset from the BCI Competition III database. This dataset has already been used several times in the literature and so it is a perfect dataset for comparing the results of the proposal against other references in the literature. Furthermore, being easily accessible, using this dataset helps other researchers reproducing the work presented in this chapter.

BCI Competition III dataset IIIa contains EEG activity from 3 volunteers (named K3b, K6b and L1b) participating in a motor imagery data collection experiment. For the experiment, the researchers of [147] placed 60 electrodes along the scalp of the volunteers to collect the EEG signals. These experimental sessions consisted of several trials in which the participants had to think of moving a specific part of their body when a PC screen gave them a signal indicating to do so. Depending on the given signal they had to think of moving the right hand, the left hand, the tongue or the feet. Each motor imagery

trial followed the same experimental protocol, which is depicted in Figure 6.1.. For the moment the reader will be asked to ignore the “IC” and “NC” class annotations of Figure 6.1., they will be clarified later on.



6.1. Figure. Structure of an imaginary movement trials.

As shown in Figure 6.1., each trial lasted for 7s during which different events took place. In the first 2s the screen remained blank and at $t=2$ s a beeping sound was reproduced to capture the volunteer’s attention. Since then, the screen showed a fixation cross “+” that would remain displayed until the end of the trial. After the beep, during the [2-3]s interval, the screen would solely show the cross and, at $t=3$ s, an arrow would appear for 1s (i.e., until $t=4$ s). These arrows point to one direction, indicating the body part to think of moving of. If the arrow point up it meant that the volunteers had to think of moving their tongue; when pointing down it meant thinking of moving the feet, and, lastly, left and right-pointing arrows indicated the imaginary movement of the left and right hands respectively. Although the arrows were only displayed from $t=3$ s to $t=4$ s, the volunteers were asked to keep on thinking of moving the part of the body since the apparition of the arrow until the end of the trial, which is from $t=3$ s to $t=7$ s. Finally, after the 7s trial, the participants were given a 2s break to rest before starting the next signal collection trial.

To finish with the presentation of the original dataset, the signals were sampled with a 250Hz sampling rate and after being collected they were band filtered in the [1-50]Hz range and notch filtered at 50Hz for removing any noise coming from the power-line. After the three subjects’ sessions had finished, the dataset

consisted of 840 instances: 360 cases for subject K3b, 240 for K6b and 240 for L1b. During their sessions, each participant had the same number of trials for each part of the body. Hence, the classes inside the dataset are balanced, which prevents classification biasing towards any class.

6.3.2. Expansion and preprocessing of the original dataset

Expanding the original dataset

So far, this document has only explained the original dataset, which only considers intentional movement control states (IC) for given parts of the body. Nevertheless, as explained in section 6.2., a BCI system needs to be capable of recognising the absence of movement as it prevents the system from triggering undesired end-effector actuations. Being aware of this problem, the team decided to make the problem closer to real-life application and to expand the original dataset creating a new one that included non-intentional control states (NC).

For the expansion of the dataset, the team opted for taking the first seconds of the trials and label them as belonging to the NC class. Initially, as they had done in their previous approach to this dataset [146], the team considered taking the EEG signals until $t=3s$. The reason to do so was because it was not until then that the participants were told which limb to move imaginatively (recall Figure 6.1.). Nevertheless, they discarded this idea because the beeps of $t=2s$ would most probably alter the brain potentials and bias the classification. Instead, to avoid the problem, the team only catalogued the EEG signals from $t=0s$ to $t=2s$ as belonging to NC. On the contrary, there was no such a problem for the IC instances, because Blankertz's team had been cautious and prevented the influence of the arrows appearing and disappearing by only using the [4-7]s signals intervals for building the dataset. The annotations of the bottom part of Figure 6.1. give a graphical indication of the trial time intervals that were used for creating the 4 types of IC and the NC class instances.

After completing the expansion process the newly created dataset included a total of 1400 instances. From those 1400 cases 600 came from subject K3b, having 360 IC instances and 240 NC instances and, the other 800, came from subjects K6b and L1b (400 for each subject: 240IC and 160NC).

Preprocessing and feature extraction

Once the team got the new dataset, they had to do some preprocessing and preparation work over it before approaching the classification problem. First of all, as using 60 EEG signals was too much, the team thought simplifying the problem would result in favour of a better classification. Consequently, following the work of [161], the team applied the multi-class common spatial pattern (CSP) method to extract the 5 most meaningful projections for each class (please refer to Subsection 3.2.4. for the explanation of CSP). So, having 4 IC classes and 1 NC class, this process was applied 5 times (once per class).

Having kept only the most meaningful projections the team thought that it would also be good to filter out the information of brain activity bands not related to movement. Accordingly, the 5 most significant projections of each class were band filtered, keeping only 3 frequency bands: 8-12Hz, 12-20Hz and 20-30Hz. Recalling what explained in Subsection 3.2.4., the first division of these bands is related to Alpha and Mu rhythms, which are highly related to movement and take place within the 8-13Hz range. Besides, lying in the 14-30Hz, the Beta band is related to concentration. Thus, it is also interesting to analyse this band as it is prompt to vary during motor imagery sessions. Anyway, it is a very wide frequency band and so it made sense dividing it into two smaller bands.

The last step before creating the partitions for the classifier training and testing was to extract the features of the information that had been kept after the filtering. As the team wanted to focus the interest of the contribution on classification, they decided to continue with AlZoubi's approach [161] and extract the following seven features: the minimum and maximum voltage values, mean voltage, voltage range, average power of the signals, rate of zero voltage crossings and rate of samples above zero volts. The mathematical formulae with which these features were calculated can be consulted in Table 6.1..

6.1. Table. Mathematical descriptions of the extracted 7 features.

Extracted features	
Minimum voltage	$V_{\min} = \min(X_n)$
Maximum voltage	$V_{\max} = \max(X_n)$
Mean voltage	$V_{\text{mean}} = \frac{1}{N} \cdot \sum_{n=1}^N X_n$
Voltage range	$V_{\text{range}} = V_{\max} - V_{\min}$
Average signal power	$P_{\text{signal}} = \frac{1}{N} \cdot \sum_{n=1}^N X_n^2$
Rate 0 voltage crossings	$R_{0\text{-cross}} = \frac{1}{N-1} \cdot \sum_{n=1}^N [\text{sign}(X_{n-1}) \neq \text{sign}(X_n)]$
Rate of samples above 0 volts	$R_{\text{positive}} = \frac{1}{N} \cdot \sum_{n=1}^N (X_n \geq 0)$

Dataset partitioning and feature selection

As the problem analysed in the new dataset is a classification problem, it was necessary to partition the datasets for training and testing the algorithms that would be used. Being considered a two-level classification problem, the expanded dataset had to be divided into three smaller datasets. Two of the partitions, TrainingSet1 and TrainingSet2, would be used for respectively training the classifiers of the first and second levels. Then, the third partition, named TestSet, would be used for testing the whole system.

On the one side, for subject K3b, TrainingSet1 and TestSet had both 240

instances, from which 120 were NC and the other 120 belonged to the IC classes (30 instances for each class). Concerning TrainingSet2, it was smaller than the other partitions as the second level classifier only had to distinguish among the four IC classes. Therefore, TrainingSet2 consisted of 30 instances for each IC class (left hand, right hand, tongue and feet), i.e., a total of 120 instances. On the other side, subjects K6b and L1b had less data and so, their partitions followed a similar distribution but with less data in each partition: TrainingSet1 and TestSet contained 160 instances (80 NC and the other 80 equally distributing the IC classes) and TrainingSet2 consisted of 80 IC instances (20 cases for each class).

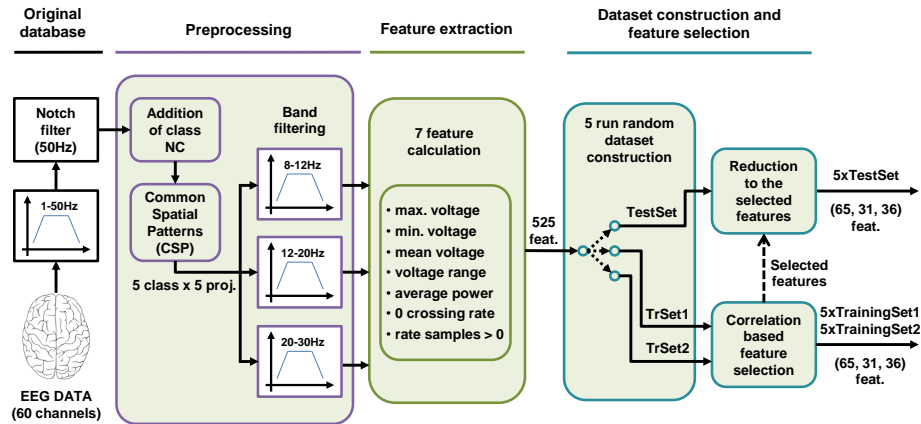
As the researchers wanted the results of their analysis to be rigorous, the dataset partitioning process separated the instances randomly into each subjects training and testing dataset. Furthermore, the process was repeated 5 times so that the training and testing of the algorithms could be thoroughly analysed. Also, the training of both the first level and the second level classifiers were trained using a 10-fold cross-validation approach (10-fold CV from now on). Consequently, the results of the training process presented in the following section will correspond to the average scores of the 50 trainings that resulted from this 5-run 10-fold CV process. On the contrary, the testing of the whole system did not follow a cross-validation methodology and so, the results given for the system tests will represent the average result of the algorithms over 5 runs. Also, as 5 training and testing runs were done, the scores given for both the two trainings and the testing will include the standard deviation over those 5 runs.

Finishing this section and before going onto the classification, the team had 5 variations of the dataset partitions in which each instance had 525 features: 5 projections were selected each class (1 NC and 4 IC) from the CSP processing, each projection was divided into 3 frequency bands and 7 features were extracted from each band ($5 \times 5 \times 3 \times 7 = 525$). This might result in overfitting the classifiers and so, to avoid the curse of dimensionality, the team decided to dismiss the useless or redundant information using the correlation-based feature selection method (see Subsection 3.4.5.) on Weka platform. This was done by creating an empty feature set and then adding features under the best first greedy searching approach. After applying it to the training partitions of the 5 runs, the number of instance features was considerably reduced, having an averaged number of 65, 31 and 36 features respectively for subjects K3b, L1b and K6b. Concerning TestSet partitions, it is important to bear in mind that there was no need to apply the feature selection to them. Instead, the same features of the training would be selected for the testing partitions. This was done because the testing process is done to assess an algorithm already trained using some specific features and, subsequently, the instances used for both purposes must have the same features.

Overview of the initial steps

As the team proceed many steps until reaching the point that training and testing partitions were ready, it has been considered useful to summarise all

these steps with a fast overview of what done in Section 6.3.. For the sake of an easier comprehension, the whole process has been graphically represented in Figure 6.2..



6.2. Figure. Diagram of the whole construction process of the new datasets.

First of all, it is important to remember that the original EEG signals were taken from dataset IIIa of BCI Competition III [147]. Those 60 EEG signals had been collected with a 250Hz sampling rate and then notch filtered to remove noises coming from the grid, i.e., at 50Hz. Then, the team modified the dataset by using the first 2s of the signals as belonging to NC control states. Later, the instances were taken through CSP processing, repeating the process once per class (hence, 5 times) to get the most meaningful projections of the signals for each of the classes. After the CSP, the 25 projections were band filtered, getting as result 3 frequency bands for each projection: 8-12Hz, 12-20Hz and 20-30Hz.

Finished the preprocessing, the seven features of Table 6.1. were extracted from each projection's three frequency bands. In the following step, the data coming from the different subjects went 5 times under random partitioning, obtaining three smaller datasets: TrainingSet1 and TrainingSet2 for training the first and second-level classifiers respectively and TestSet for testing the whole system. Finally, to avoid the curse of dimensionality, the best features for training the classifiers were chosen using the correlation-based feature selection method (those same features would be used for the TestSet partitions).

6.4. Previous approaches of the classification

This section will present the two supervised learning-based approaches that the team tried for the classification problem proposed with the newly expanded database. As stated in Section 6.2., for a system to be admitted as usable, the

first level NC vs. IC classification's FPR has to remain below 10%. As it will be shown, any of these approaches fail to fulfil this restriction and shows how solely using supervised learning methods limits the usability of the BCI systems, justifying the use of unsupervised learning proposed in Section 6.5..

This section has been divided into two subsections. First, Subsection 6.4.1. will present the most basic approach which is no other than trying to tackle the problem using a single supervised learning classifier to distinguish between the five classes. Second, Subsection 6.4.2. will give a proposal based on dividing them into two levels: the first for separating NC and IC class instances and the second for determining to which of the four IC classes belonged the instances considered as IC in the first level. Consequently, this two-level hierarchical system will consist of two classifiers, one for each level, coming both from the supervised learning algorithm family.

6.4.1. One-level system based on supervised learning

As an initial approach to solve the motor imagery proposed in the dataset, it made sense to try a single level solution. So far, many different supervised learning algorithms have been used for BCI systems [162,163]. For this initial single-level approach the team considered interesting to try 11 different algorithms that can be considered to represent the state of the art of the different machine learning paradigms (see Subsection 3.4.1. for more information). The chosen algorithms and their paradigms are listed below:

- **Tree-based:** decision trees (DTs), random forests (RFs).
- **Ensembles of classifiers:** 10 decision tree combinations of Ada boost (AdaB) and bagging (Bag) algorithms.
- **Function-based:** support vector machines (SVMs) and radial basis function (RBF) network.
- **Distance-based:** 1-NN and 5-NN versions of k-nearest neighbours.
- **Rule-based:** 1R rule.
- **Probabilistic:** naïve Bayes (NB) and logistic regression (LR).

Initially, the team tried to optimise the parameters of each of the classifiers to get the best possible result. However, after some trials, the team saw that optimising the classifier towards improving the accuracy for one class resulted in worsening the performance for the other classes. Thus, in the end, Weka platform's default structure and parameter settings were used for all the classifiers. Being a single level system, the classifiers had to differentiate between the 5 classes, i.e., 1 NC class and the 4 different IC classes (left hand, right hand, tongue and feet).

For this experimentation, the team decided to compare the performance of the classifier using part of the training datasets and, then, only taking the best

6. KAPITULUA - ERD/ERS BRAIN-COMPUTER INTERFACES

performing onto the testing phase (with TestSet). The reason not to use the whole TrainingSet1 and TrainingSet2 datasets was to avoid biasing the classifiers towards any of the classes. Therefore, those datasets were reduced to 300 cases for subject K3b (60 instances of each class) and to 200 cases for the other two subjects (40 instances of each class). The average accuracy and FPR values (with the standard deviation) were the selected performance indicators for these comparisons. These indicators were obtained over 5 runs, and for the training, using the 10-fold CV methodology. The results obtained from the comparison of the 11 classifiers are the ones presented in Table 6.2..

6.2. Table. Accuracies and FPRs of the classifiers of the one-level system over 5-runs, with 10-fold CV for the training.

		Estimation of the best classifier											Test
		1R	DT	1-NN	5-NN	NB	RBF	SVM	LR	AdaB	Bag	RF	SVM
K3b	Accuracy (%)	39.1	64.8	72.2	75.6	75.7	77.0	81.6*	67.7	75.8	71.9	73.0	77.5±3.7
	FPR (%)	75.0	52.0	48.3	48.7	35.7	33.0	31.6	42.3	37.3	44.0	47.0	29.2±4.9
L1b	Accuracy (%)	45.8	62.6	62.8	70.3	70.3	70.5	73.5*	60.3	69.3	68.7	68.4	74.4±3.2
	FPR (%)	79.0	50.5	48.5	41.5	45.0	37.0	34.0	42.5	42.0	41.5	45.5	27.5±7.2
K6b	Accuracy (%)	35.5	47.7	49.9	52.8	51.3	57.1	57.3*	48.5	56.2	56.1	55.4	55.6±3.9
	FPR (%)	55.0	55.0	51.0	55.0	45.0	41.0	44.5	53.0	41.5	38.5	39.0	36.2±10.0
Aver.	Accuracy (%)	40.0	59.3	63.1	67.6	67.2	69.5	72.3*	60.1	68.3	66.5	66.6	70.4±3.6
	FPR (%)	70.4	52.4	49.1	48.4	41.0	36.4	36.0	45.4	39.9	41.7	44.3	30.7±7.0

As shown in Table 6.2., SVMs were the best performing classifiers of the training. However, the team wanted to check if the performance differences were statistically significant before choosing them as the best classifier. Consequently, the results were compared employing a 95% significance Wilcoxon non-parametric test (explained in Subsection 3.4.5.). The results from these test proved SVMs to be significantly better, obtaining p-values below 0.02. Thus, the SVMs were finally tested using TestSet (see the last column of Table 6.2., obtaining an average accuracy of 70.4% using the three subjects' testing datasets. Despite it seems a relatively good result, the average FPR was 30.7%. This FPR is far above the maximum value of 10% and so, the practical use of such a system would not be viable.

6.4.2. Two-level system based on supervised learning

Once the team saw that single level solutions using only supervised learning strategies could not score an FPR lower than 10%, they decided to try to separate the whole problem and divide it into two tasks. Whereas the first task would correspond to the initial NC-IC class separation, the second task would be determining the specific class of the instances previously classified as IC.

For the first classification level, the team decided to use the same 11 classifiers

6.4. PREVIOUS APPROACHES OF THE CLASSIFICATION

used in the previous Subsection 6.4.1.. In this case, it was only TrainingSet1 that was used to train the first level system and TrainingSet2 was kept for training the second level classifier. The results obtained from the training of the first level have been presented in Table 6.3.. These results show how although the FPRs values had improved in general, they were still above the allowable maximum of 10%: the best average results over the 5-run 10-fold CV process was obtained by the 5-NN algorithm (82.4% accuracy and 16.4% FPR).

6.3. Table. Estimated performances over 5-runs with 10-fold CV for the first level classifiers of the supervised learning two-level system: accuracy and FPR.

		1R	DT	1-NN	5-NN	NB	RBF	SVM	LR	AdaB	Bag	RF
K3b	Accuracy (%)	66.9	71.9	79.6	84.0*	78.3	80.2	81.8	73.7	79.7	78.7	78.4
	FPR (%)	34.0	28.5	22.5	12.8	26.2	19.5	17.5	25.7	21.3	20.3	24.8
L1b	Accuracy (%)	71.4	75.5	79.9	82.5	77.1	79.9	81.1	80.5	81.3	80.4	83.1*
	FPR (%)	30.8	24.3	18.8	17.0	38.8	31.5	25.5	18.8	19.5	22.3	22.8
K6b	Accuracy (%)	76.6	75.5	76.9	80.0	79.4	81.5	82.1	76.5	81.0	82.4*	81.8
	FPR (%)	20.3	24.8	25.5	21.0	22.5	15.3	18.3	24.5	18.0	16.8	20.3
Aver.	Accuracy (%)	71.0	74.0	78.9	82.4*	78.3	80.5	81.7	76.4	80.5	80.2	80.7
	FPR (%)	29.1	26.2	22.3	16.4	28.7	21.7	20.0	23.4	19.9	19.9	22.9

Despite the team had already seen that the FPR values obtained in the first level were unacceptable, they still wanted to see how good would the second level classifier perform using those 11 algorithms. Therefore, those classifiers were trained using TrainingSet2, getting the results presented in Table 6.4.. During this process, the SVM proved to be the best algorithm for determining the specific class of IC instances (left hand, right hand, tongue and feet), scoring an accuracy of 78.2%.

6.4. Table. Estimated accuracies over 5-runs with 10-fold CV for the second level classifiers of the supervised learning two-level system.

Accuracy (%)	1R	DT	1-NN	5-NN	NB	RBF	SVM	LR	AdaB	Bag	RF
K3b	46.5	69.0	79.2	83.5	81.2	81.2	88.3*	69.7	79.2	75.8	81.5
L1b	54.8	68.5	66.3	70.3	74.5	71.3	80.8*	69.8	75.5	73.3	73.5
K6b	35.8	57.5	51.0	57.5	54.5	55.5	60.3*	49.8	59.0	57.8	56.5
Average	45.8	65.6	67.4	72.3	71.7	71.0	78.2*	64.0	72.4	69.9	72.1

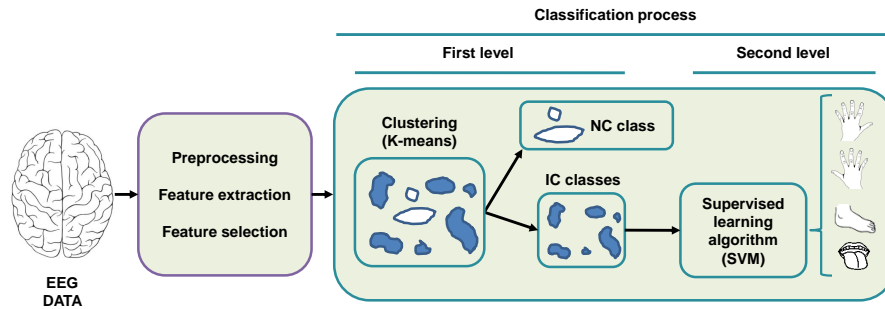
Finally, to be consistent with the methodology, the classifier results of both levels were analysed using the 95% significance Wilcoxon non-parametric test. On the one hand, the test showed that the results of the 5-NN algorithm of the first level were not significantly different from a statistic perspective. On the

other hand, the test concluded that the results of the SVM were significantly better compared to the other classifiers' (scoring p-values below 0.02).

Consequently, after the whole analytic process, the team concluded that it was not possible to have FPR values below 10% using Weka's default values. Anyway, the team decided to fine-tune the 5-NN classifier of the first level to see if it was possible to obtain permissible FPRs. When they adjusted the thresholds to determine if an instance corresponded to the IC class, they were able to take the FPR below 10%. However, the overall accuracy of the system decreased considerably. Thus, the team opted for trying the new approach of using the K-means unsupervised learning clustering algorithm for the first level classification. This way, as it will be presented in the next Section 6.5., the team could define the minimum proportion of IC belonging instances inside a cluster for labelling the whole cluster as IC, obtaining acceptable FPRs with a good overall performance accuracy.

6.5. Two-level hierarchical classification system using unsupervised learning

As done in Subsection 6.4.2., for the proposal of this contribution the team decided to divide the problem into two levels. However, in the proposal of this section, the team decided to attempt the first level classification using unsupervised learning clustering techniques while maintaining supervised learning techniques for the second level to determine whether the instances labelled as IC corresponded to moving either the left or right hands, the feet or the tongue. The proposal has been graphically summarized in Figure 6.3..



6.3. Figure. Structural diagram of the proposal: it uses clustering and supervised learning algorithms for the first and second levels respectively.

6.5.1. First level: detection of movement intentionality

Not having obtained an acceptable FPR without affecting the overall system performance, the team considered interesting to vary the strategy and to use an unsupervised learning algorithm for the first level classification (IC vs. NC class). Concretely, the algorithm selected for this task was K-means, which again, was applied using Weka's default settings. However, the team decided to tackle the problem as done in [164], setting a minimum number of IC instances in a cluster as the threshold to exceed for considering the whole cluster as belonging to the IC class (called the IC-threshold). This way it is possible to get FPR scores below 10%, as setting threshold conservatively to avoid undesired end-effector actuation produced by false positive detections.

After having chosen the new approach to the problem, the team tried different K parameter settings for the K-means algorithm and estimated the performance of the different variations using TrainingSet1 with a 5-run 10-fold CV methodology. These trials were done for 12 different K parameter values, starting at K=5 and increasing the value in increments of 5 until K=60. Moreover, the performance estimations of the algorithm variations were also calculated with different IC-thresholds for considering a whole cluster as being labelled as IC. The results of this experimentation can be found in Table 6.5. of page 136.

Looking at Table 6.5. it is possible to see how the algorithm performed with the datasets of each subject averaged from the 5-run 10-fold CV experimentation. Table 6.5. gives the average accuracy and FPR values for all the K parameter and IC-threshold settings. From all, the best performing setting is K=35 combined with an IC-threshold of 80%, which scored 73.5% of accuracy and 7.4% of FPR. It has been considered that setting IC-threshold to 80% is the best option as it produces the highest accuracies among all the settings that have FPRs of less than 10%. Having defined IC-threshold as 80%, the team decided that K=35 was the best setting as, using the three subjects' results, it is the one getting the best average accuracy.

Finally, as it was also done with the two systems presented in Section 6.4., the significance of the results was statistically analysed with the 95% significance Wilcoxon test. The comparative analysis showed that setting IC-threshold to 80% produced significant differences with the other IC-threshold values. On the other side, concerning the K parameter, the test concluded that setting K inside the [20,40] range did not produce significant differences in the results. Anyway, the settings inside this range were proven to give statistically significant differences compared to the values of K out of this range (p-values<0.02).

6.5.2. Second level: intentional movement classification

Once the classifier of the first level had been tuned up it was time to select a classifier for the second level classification. Seeing the experimentation of Subsection 6.4.2. where the SVM obtained the best performance classifying the IC instances (their average accuracy was 78.2%, see Table 6.4.), the team opted for directly using again this type of algorithm for the second level.

6. KAPITULUA - ERD/ERS BRAIN-COMPUTER INTERFACES

Therefore, as a summary, having chosen to use SVMs for the second-level classifier, the proposed two-level hierarchical classification BCI system consisted in combining a thresholded K-means algorithm for the first level and an SVM algorithm for the second level classification. By doing this, the FPR of the system can be kept under 10% while at the same time maintaining the second level IC classification performance. The following Section 6.6. will present evidence of this, presenting the results of the system during the test as well as comparing them with other research focused on the same problem.

6.5. Table. Estimation of the K value and IC threshold: accuracy and FPR depending on the value of the K parameter and the IC threshold.

IC-threshold	5-run / 10-CV	K value													
		5	10	15	20	25	30	35	40	45	50	55	60		
90%	K3b	Accuracy (%)	52.0	62.6	65.8	68.2	67.5	67.1	68.3	68.5	71.1	72.3*	71.2	70.7	
		FPR (%)	1.0	2.5	2.8	3.7	4.0	4.3	4.2	3.8	4.7	5.3	6.8	6.7	
	L1b	Accuracy (%)	51.1	57.0	59.5	64.8	64.8	64.8	67.1	68.8*	67.9	68.4	67.8	68.2	
		FPR (%)	2.0	3.5	3.5	5.0	5.8	5.8	5.5	6.3	7.8	8.0	9.3	9.8	
	K6b	Accuracy (%)	53.0	63.9	64.5	66.3	65.3	67.6	68.6	68.6	69.1	69.4*	69.1	69.2	
		FPR (%)	1.0	2.8	6.0	6.5	5.3	7.0	6.8	8.5	9.3	8.8	9.3	10.8	
	Aver.	Accuracy (%)	52.0	61.4	63.6	66.6	66.1	66.6	68.1	68.6	69.6	70.3*	69.7	69.5	
		FPR (%)	1.3	2.9	3.9	4.9	4.9	5.5	5.3	5.9	6.9	7.1	8.2	8.8	
	80%	K3b	Accuracy (%)	58.9	70.8	71.9	73.2	74.7	74.3	75.8	76.3	76.3	76.6*	74.7	71.9
			FPR (%)	6.5	7.5	6.0	6.7	7.3	7.7	7.2	6.7	6.5	7.7	8.0	7.8
		L1b	Accuracy (%)	54.3	62.8	64.8	69.9	71.9	70.1	71.4	71.5*	69.6	70.3	72.0	72.8
			FPR (%)	3.0	7.8	6.8	8.8	7.3	7.8	6.8	8.5	9.5	9.8	10.0	10.5
K6b		Accuracy (%)	65.5	71.5	71.1	73.3	71.6	72.6*	72.3	70.6	71.0	71.1	72.5	71.8	
		FPR (%)	6.5	5.8	8.8	9.0	8.8	8.3	8.3	9.5	11.0	10.0	10.0	11.0	
Aver.		Accuracy (%)	59.5	68.7	69.6	72.3	73.0	72.6	73.5*	73.3	72.6	73.2	73.3	72.1	
		FPR (%)	5.5	7.1	7.0	7.9	7.7	7.9	7.4	8.0	8.6	8.9	9.1	9.5	
70%		K3b	Accuracy (%)	70.8	74.9	76.4	76.9	76.4	76.7	76.9	79.7*	78.3	78.1	77.2	77.1
			FPR (%)	17.5	13.5	8.5	9.0	10.8	12.0	11.8	9.8	9.8	10.7	12.3	11.5
		L1b	Accuracy (%)	61.3	70.1	73.9	74.8	75.8	74.0	75.1	75.6	73.8	73.5	74.6	76.1
			FPR (%)	14.8	18.3	15.0	13.0	12.8	13.8	14.3	15.0	14.8	15.5	15.5	13.5
	K6b	Accuracy (%)	75.4	76.8	75.3	75.4	74.6	75.8	74.9	74.5	74.1	73.6	74.4	74.0	
		FPR (%)	15.5	10.5	13.5	13.5	13.0	13.5	12.8	14.0	15.5	16.3	16.3	16.3	
	Aver.	Accuracy (%)	69.4	74.1	75.4	75.9	75.7	75.6	75.8	77.0	75.8	75.5	75.7	75.9	
		FPR (%)	16.1	14.0	11.8	11.4	12.0	12.9	12.8	12.5	12.9	13.6	14.4	13.5	
	60%	K3b	Accuracy (%)	73.8	76.9	78.8	78.7	77.8	77.5	77.5	80.7	79.4	79.0	78.3	78.4
			FPR (%)	21.7	15.5	14.5	11.7	14.0	15.5	15.7	13.3	13.3	14.0	16.0	15.2
		L1b	Accuracy (%)	68.8	73.6	76.5	77.0	76.8	74.9	76.9	77.0	74.6	74.6	73.6	77.0
			FPR (%)	34.8	24.8	21.3	16.5	18.0	20.0	19.0	19.0	20.5	21.0	20.0	19.0
K6b		Accuracy (%)	77.5	77.6	76.3	75.6	75.6	76.8	75.4	75.6	75.6	76.1	76.1	75.0	
		FPR (%)	20.0	13.5	15.5	16.8	18.0	17.5	17.3	18.3	18.8	18.3	20.1	20.0	
Aver.		Accuracy (%)	73.4	76.2	77.4	77.3	76.9	76.5	76.7	78.2	77.0	76.9	76.3	77.0	
		FPR (%)	24.9	17.6	16.7	14.5	16.3	17.4	17.1	16.4	16.9	17.2	18.2	17.6	

Note: FPRs below 10% have been shaded in grey; asterisks “*” indicate the highest accuracy for a subject with an specific IC-threshold and the results of the best performing option have been underlined. The bold box encloses the cases without statistically significant differences in accuracy.

6.6. Experimental results

6.6.1. Testing the hierarchical two level system

Testing the first-level classifier

So far the proposed two-level hierarchical classifying BCI system has been designed. However, as explained in Section 3.4., every machine learning solution has to be tested with data that has remained unused for this purpose. In this case, TestSet dataset was the data partition that was created for the testing, which was built five times for all the subjects for getting reliable results from 5-runs. Hence, first of all, it was the first level classifier that was tested to check that the system obtained good FPR results. The results of this test are presented in Table 6.6., where IC-NC confusion matrix has been given along with the average accuracy and FPR over the 5-runs.

6.6. Table. Confusion matrix, accuracy and FPR of the first level classifier using TestSet.

(K-means, K=35) (IC-threshold 80%)	Confusion Matrix			FPR (%)	Accuracy (%)
K3b		IC-estimated	NC-estimated	7.2±4.1	73.5±2.9
	IC-real	65	55		
	NC-real	9	111		
L1b		IC-estimated	NC-estimated	8.5±3.6	74.3±5.8
	IC-real	46	34		
	NC-real	7	73		
K6b		IC-estimated	NC-estimated	9.5±4.2	70.5±2.9
	IC-real	40	40		
	NC-real	8	72		
Average				8.2±3.9	72.9±3.7

The results of Table 6.6. show that the FPR constraint was successfully satisfied as the FPR for the three subjects' were lower than 10%, being 8.2% the average FPR for them. Whereas the best FPR was obtained for subject K3b (FPR of 7.2%, 9 misclassified NC instances), it was slightly worse for the other two: 8.5% for L1b (7 misclassified instances) and 9.5% for K6b (8 misclassified instances). Concerning the instances correctly estimated as IC, 65, 46 and 40 cases that would be passed onto the second level classifier for subjects K3b, L1b and K6b respectively.

Testing the second-level classifier

After testing the first classification level it was time to do the same for second-level classifier. For that purpose, the SVM algorithm was used to determine the specific class IC class of the correctly classified IC instance. As shown in the confusion matrix of Table 6.7., the four classes between which the algorithm had to differentiate are left hand, right hand, tongue and feet. The average accuracy of the SVMs for each of the subjects over the 5-runs has also been given in Table 6.8., along with its standard deviation from all the runs.

6.7. Table. Classification performance for the second level with the TestSet dataset.

		Confusion Matrix				Accuracy (%)
K3b		Left-estimated	Right-estimated	Tongue-estimated	Foot-estimated	89.2±2.0
	Left-real	11	3	0	0	
	Right-real	2	21	0	0	
	Tongue-real	0	0	12	1	
	Foot-real	0	0	1	14	
L1b		Left-estimated	Right-estimated	Tongue-estimated	Foot-estimated	78.3±1.4
	Left-real	9	1	0	0	
	Right-real	2	12	0	0	
	Tongue-real	1	1	5	3	
	Foot-real	0	0	2	10	
K6b		Left-estimated	Right-estimated	Tongue-estimated	Foot-estimated	57.5±8.5
	Left-real	6	5	0	0	
	Right-real	4	7	0	0	
	Tongue-real	2	3	2	0	
	Foot-real	1	1	1	8	

The values of Table 6.7. show relatively good accuracies for K3b and L1b (89.2% and 78.3% respectively) and worse results for K6b, getting only an accuracy of 57.5%. Concerning the classes, from an overall perspective, the most difficult task for the classifier was to distinguish between the left and right hands. However, in the particular case of K6b, it was the tongue moving class that was the most difficult to classify.

Overall performance analysis

The last step of the test phase was to obtain the general performance of the BCI system, involving in the performance indicator calculations the numbers from both classification levels. Therefore, considering the classification of the 5 classes (1 NC and 4 IC), the team calculated the system's overall performance indicators (FPR and accuracy) of Table 6.8..

6.8. Table. Classification performance for the proposed system with TestSet dataset over 5-runs.

	K3b	L1b	K6b	Average
FPR (%)	7.2±4.1	8.5±3.6	9.5±4.2	8.2±3.9
Accuracy (%)	70.4±2.2	68.1±2.0	59.4±3.7	66.6±2.6

Analysing the values given in Table 6.8. it can be seen that the average accuracy obtained for K3b and L1b (70.4% and 68.1% respectively) differ considerably from the poorer result obtained for K6b (59.4%). Thus, the average accuracy of the system taking into account all the subjects was 66.6% with an average FPR of 8.2%. Reading in the literature the team found that a similar situation happened in [165]. Further reading [161], the differences in the performance between participants got justified as the system performance is very influenced by the expertise of the subjects using the system. Accordingly, having some previous experience with motor imagery, K3b and L1b were considerably better creating clear motor imagery patterns compared to K6b, who was a beginner in the matter.

6.6.2. Comparison of the results in the literature

Having tested the system the team considered interesting to compare their results against the obtained by other research teams. Although they might not be equal, the work presented in this chapter is very similar to other works found in the literature and so, the team considered that it was possible to establish some comparisons. Table 6.9. gives a summary of the results of the similar works found in the state of the art, giving for each of those research the following information: the number of classes considered in the classification problem, the FPR false positive rate and accuracy scores of their solution and type of algorithm they used for the classification. Concerning the number of classes considered by the works, Table 6.9. considers that IC classes are different to the NC class and so, if the work took into account the NC class then it will be marked as “(+1)” in the table.

6.9. Table. Comparative table of the research found in the literature.

Reference	Number of classes (+ NC class)	FPR (%)	Accuracy (%)	Algorithm employed
[161]	4 (+0)	—	74.2	Support Vector Machine
[166]	4 (+0)	—	64.4	Hierarchical Support Vector Machine
[37]	4 (+0)	—	77.6	Multi-class CSP + Fuzzy System
[156]	2 (+1)	10	83.4	Support Vector Machine
[154]	2 (+1)	26.7 / 28.3	73 / 75	ROC Curve Analysis
[155]	1 (+1)	17	72	Support Vector Machine
[159]	3 (+1)	19	84.3	Mahalanobis Linear Distance Classifier
[167]	2 (+1)	21.7	73.5	Correlation-Based
[168]	2 (+1)	1	54	k-Nearest Neighbour + Linear Discriminant Analysis
Our approach	4 (+1)	8.2	66.6	K-means + Support Vector Machine

Looking at Table 6.9. three main blocks can be differentiated. The results of the works that did not consider the NC class occupy the first three lines of the table. As the NC class was not taken into account, these results will also lack the score for the FPR. Then, there is a second block that contains six works that did consider the NC class. Finally, the system proposed in this chapter takes the space of the last block for the sake of making easier the comparison.

Concerning the first block (the ones not considering the NC class), the researchers of [37] applied their solution to the original IIIa dataset of BCI Competition III and they achieved an accuracy of 77.6% combing a fuzzy system with a multi-class CSP algorithm. The work presented in [161] also used this dataset getting an overall accuracy of 74.2%. Finally, a different dataset was used in [166], dataset IIa from BCI Competition IV. To solve the problem of the dataset, which also included 4 IC classes, they used a hierarchical SVM classifier and they obtained an accuracy of 64.4%. Comparing these results to the obtained in the work presented, it can be seen that the accuracy of [166] is worse. Then, the systems of [37] and [161] obtained better accuracies than the system proposed in this chapter. However, none of these works took into account the problem of keeping the FPR low, which affects considerably the performance of the solutions for motor imagery problems.

About the second block, they analysed a two IC lass (left and right hands) motor imagery problem in [154], respectively achieving an accuracy of 73%

and 75% for the left and right-hand movements. Anyway, having such good accuracies, the FPRs of their solution were far above 10%: 26.7% for the left hand and 28.3% for the right hand. Similar results were obtained [167], an accuracy of 73.5% and an FPR of 21.7%, for the hand or foot motor imagery classification problem they chose to analyse. Then, the team of [155] considered a single class problem for detecting the intention of moving the arm in the signals of 6 volunteers. They compared the performance of seven different algorithms, among which SVMs were found to be the best (72% accuracy). However, keeping the FPR low was the biggest problem for them, which was above 17% and in some cases even reached a value of 75%. They stated that these FPR values were a problem as they would trigger actions when the user wanted to remain at rest. Something similar was mentioned in [159], where they got better accuracy results (84.3%) and 19% for the FPR) but still did not satisfy the restriction for the FPR (they obtained an FPR of 19%).

So far, none of the works referenced so far obtained an acceptable FPR value. However, in [156] they scored an FPR of 10% and an accuracy of 83.4%. In that work, they used an SVM to face a motor imagery problem in which they had to recognise the intentions of moving either hand. Apart from that work, they also achieved a successful FPR (1%) in [168]. In this work their team merged the k-NN algorithm with linear discriminant analysis (LDA), scoring accuracy of 54%. However, in both cases, it is a two IC class problem that is being analysed and so the difficulty of the classification can be considered to be lower compared to the problem chosen for this contribution.

Therefore, the comparative analysis of the results of this systems proves that the proposed hierarchical system could be a feasible solution for multiple class BCI applications, such as controlling a wheelchair, using a prosthetic limb or controlling a pointer, among others [151, 159, 169].

6.6.3. Other results

Finally, the team did some final extra research around the proposed classification system. Thus, closing this section, this thesis will present the analysis of the times required for the implementation of the system as well as some further results that were obtained from slightly varying the classifiers of the system.

Timing results for an on-line implementation

Beyond analysing the performance of the system, the team also considered interesting to check whether it would be feasible to implement this system in an on-line application. Thus, it was important to verify that the system was able to give a classification response in the time between two epochs.

Accordingly, the team calculated the times to train and test the proposed hierarchical system, presented in the following Table 6.10.. Regarding the training, Table 6.10. provides the time required for training just an instance and for training the whole model, including preprocessing, feature extraction and selection steps. Besides, Table 6.10. also shows the times needed to classify an

instance during the testing phase. The times given in Table 6.10. correspond to the average time calculated from using all the available data for training and testing the BCI system for the three subjects. These results were obtained using a machine running Windows 7 (64 bit) with an Intel Core i7-3770, 3.4 GHz processor.

6.10. Table. Average training and testing times needed by the system.

Average (K3b / L1b / K6b)	Training Model	Training Instance	Test Instance
CSP	65.006	0.108	< 0.001
Feature extraction	5.246	0.009	0.009
Feature selection	13.337	0.022	-
K-means	1.047	< 0.001	< 0.001
SVM	0.929	< 0.001	< 0.001
Total time (s)	84.636	< 0.140	< 0.012

The time values presented in Table 6.10. show that it would be possible to implement this system in a real-life on-line application as only 12ms are needed for classifying a test instance. This time is much lower than what needed in other references of the literature [154], [155] and [159], which use sliding windows that require times between 0.5s and 2s. Apart from that, the total training time is less than 2 minutes, especially if the training of the K-means and SVM are done in parallel.

Further tuning of the system

To finish with this section the team decided to do a last modification of the hierarchical system, adding the NC class to the 4 IC classes to the second level classifier. The intention to do this was to try to improve the overall performance by giving the system the chance to recover from the NC instances incorrectly classified as IC. Additionally, this would allow to be less conservative in when setting the IC-threshold to keep the FPR under 10%.

By doing this it was possible to see that the overall accuracy can be increased by setting sub-optimal K parameter and IC-threshold values. Different tests were done using the 5-runs of TestSet with the modified system, setting IC-threshold to 70% and K to 20, 25 and 35. The performance obtained from these tests are reflected in Table 6.11., where it is shown that the average accuracy of the system increased at the cost of worsening the FPR (especially for K6b, going from 9.5% to 15%). However, the improvement of the accuracy of the system is clear, even increasing by more than 3 points when K=35 and IC-threshold=70%. Consequently, depending on the case, this type of approach might be feasible, specially when an experienced person used the system.

6.11. Table. Classification performance for the system with a 5-class classifier in the second level.

		K3b	L1b	K6b	Average
K=20	FPR (%)	8.5±2.6	8.5±4.2	14.5±7.4	10.2±4.4
IC-threshold=70%	Accuracy (%)	73.9±3.4	69.1±3.6	61.1±5.3	68.9±4.0
K=25	FPR (%)	9.5±4.5	8.0±3.5	13.5±4.5	10.2±4.2
IC-threshold=70%	Accuracy (%)	74.5±4.0	70.3±3.4	60.1±3.4	69.2±3.7
K=35	FPR (%)	10.5±5.9	7.5±3.9	15.0±5.4	10.9±5.2
IC-threshold=70%	Accuracy (%)	74.9±2.6	70.6±3.6	61.1±3.7	69.8±3.2

6.7. Summary

Among the different types of BCI systems, ERD/ERS motor imagery is one of the most studied in the literature. This type of systems base on detecting brain activity potential changes happening in specific frequency bands of EEGs when the user tries to move or thinks of moving a given part of the body. If different types of potential variations are detected, the BCI system can give specific commands to any end effector or interface, permitting user interaction with the environment without needing any muscular activity. Thus, apart from detecting movement intentionality, it is also vital for the system to recognise when the user wants to be inactive and so, avoid false tripping end-effector activity. These type of applications are starting to be used in the area of neural rehabilitation for helping people regain control over their limbs. Nevertheless, the applications of motor imagery are expanding to new horizons, such as the video-game industry, caregiving or domotics.

Along this contribution chapter, this thesis presented a BCI system that differentiates non-intentional (NC) and intentional movement control states (IC), being also able to classify four different types of intentional movement IC patterns: right hand, left hand, tongue and feet. To do so, the system divides the EEG signal classification problem into two levels. The first determines whether the instance entering the system corresponds to the NC or the IC class to subsequently pass those classified as IC to the second-level classifier. Then, the second classifier determines the specific class of the instance among the four possible IC patterns. Concerning the types of algorithm, whereas the first level of classification employs an unsupervised learning clustering algorithm, a thresholded K-means, the second level classifier is a supervised learning support vector machine (SVM).

Regarding the training and testing of the system, the researchers used an already existing dataset that has been often referenced in many works related to BCI systems: BCI Competition III dataset IIIa. This dataset contains 60 EEG signals for three different subjects repeating several motor imagery trials. However, the original data did not include instances of the NC type and so, the team had to expand the dataset by adding new instances that were created from

the initials seconds of the EEG signals acquired during the experiments of the original dataset. After that, the was sequentially taken to pre-processing and feature extraction stages, and later, three partitions were created: two for training (TrainingSet1 and TrainingSet2) and one for testing the system (TestSet). The partitioning process took care of creating class-balanced smaller datasets so that the classifiers would not get biased. Furthermore, the process was repeated 5 times to later apply the 5-run 10-fold cross-validation methodology to the experimentation.

Once several classifier had been estimated with the training partitions, the team chose the combination of the K-means and the SVM classifiers as the best option and tested it using TestSet. The system obtained an overall average accuracy of 66% for the three subjects. Also, concerning the minimisation of the false positive detections of the NC class, the system was able to keep the false positive rate (FPR) below 10% (the maximum acceptable), getting 8.2% as the average FPR for the tree subjects. Therefore, it can be considered that the intentionality control state detection is robust enough for being used in a real-life application out of the laboratory.

Once the system's performance had been tested, the team did a comparison of their results against other studies found in the state of the art. First, they compared the results of the system against other solutions that used 4-class and 5-class classifiers. These systems presented different degrees of accuracy, some of them better and some of them worse than the proposed solution. However, none of the ones with better accuracy could fulfil the restriction of keeping the FPR under 10%. Even more, in spite of its importance, some of those works did not take the problem into account. After that, the proposed solution was compared to some other systems that kept the FPR low, but they either got worse accuracy or they analysed a classification problem with less classes (a simpler and easier problem). Therefore, the comparative analysis reinforced the positive opinion towards the utility of the system.

Finally, some further analysis was done, checking the times for implementation of the system. These times were short enough to be applied in an online solution. Besides, the team did extra tuning of the classifiers to improve the accuracy of the system, taking the FPR values closer to the limit marked by the 10%. This approach might be valid only for those users with experience in motor imagery systems.

Limitations and future lines

The study presented in this section analysed a motor imagery problem that works in synchronously to given cues indicated on a PC screen. Therefore, any possible real-life application would be strongly limited to having a screen always in front of the user. This limitation opens a new study line in which the system could be applied to non-segmented data and, so, work in a self-paced manner as the systems presented in [170] and [171].

Apart from this line, the team also sees interesting applying automatic EEG

channel selection techniques as done [172] and [173]. By doing this it would be possible to reduce even more the dimensionality of the system, resulting in a simpler problem that permits the use of simpler and faster classifiers.

Another important future line for the team focuses on the training and feedback of the BCI system users [174]. As seen in the experimentation, the performance of the system is highly influenced by the expertise of the users. Consequently, creating a software platform to train users on the proposed motor imagery BCI system would be useful for increasing its accuracy and designing other aspects concerning the usability of the solution.

IV. Part
Konklusioak

7. Chapter

Conclusions

This thesis dissertation presents contributions to improve both psychological state detection strategies from the field of physiological computing and ERD/ERS motor imagery BCI systems using machine learning techniques.

In the field of physiological computing, this thesis has been focused on two main areas. The first area corresponds to the continuous assessment of the mental stress level, studying pre-processing and new feature extraction techniques as well as redefining a fuzzy logic stress level estimation system. The data for this study was collected from volunteers taking part in a dexterity experiment expressly designed to produce stress.

Concerning the second area, this study was focused on the detection of the physiological changes that are related to the opposite psychological state to stress, the physiological responses towards relaxation. In these regards, the study was focused on detecting which are the EDA features that are most indicative for the activations of the parasympathetic nervous system. The physiological signals were collected from two experiments, one designed for studying relaxation inside a longer stressful situation and the other for analysing the relaxation produced by relaxation techniques. Besides, this part of the work also studied the use of different supervised machine learning algorithms for the detection of those physiological responses towards relaxation.

Finally, the third research line presented in this thesis diverged from the physiological computing area to focus on Brain-Computer Interfaces. This contribution focused on applying both unsupervised and supervised learning algorithms to a motor imagery problem that is well-known in the literature, which is getting good accuracy classifying the classes of the intended imaginary movements while keeping the false positive rate (FPR) below 10% for the cases in which no intentional movement is desired.

The contributions related to physiological computing and motor imagery BCI systems prove the importance of using intelligent control and machine learning strategies to create new human-signal processing systems or to improve the performance of the already existing human-machine and human-computer interfaces. The coming sections 7.1. and 7.2. will present the main conclusions

obtained from the studies related these two areas. Later, the main future work lines will be presented in Section 7.3. and, finally, the reference bibliography that supports this thesis will be presented in Section 7.4..

7.1. Physiological computing

7.1.1. Continuous estimation of stress

The analysis of different physiological signals (EDA, ECG and RESP) showed that the activations of the sympathetic nervous system (SNS) can be detected on the changes in the dynamics of physiological signals. Concerning signal processing and feature extraction, the contribution presented a methodology to extract a heart-rate signal robust to artefacts by combining median filtering, wavelet analysis and a window sweeping r-peak detection algorithm. Besides, to prevent the accumulative nature of the EDA from biasing the stress estimation of the later fuzzy logic analysis, the EDA was decomposed into two components: the average value and the increment of the signal, both within the signal analysis window of 20s.

Apart from processing well-known EDA and ECG signals, it was proven that respiration signals also carry this type of information. The information was extracted by applying a frequential correlation analysis less costly than traditional Fourier analysis. However, although the correlation value of the most highly correlated frequency provides this information, the work showed how to increase the difference between the values that are obtained during stressful and non-stressful situations. This was done by multiplying the correlation value of the most highly correlated frequency with the RMS value of the heart-rate variability signal.

Finally, all those features were used to get a continuous stress level estimation using a fuzzy-logic system. Basing on a previous design in the literature, the team designed a new system that used the previously mentioned four features of the physiological signals already mentioned. To asses the influence of these signals, a new intermediate medium-stress (MS) membership function was added to the system for getting softer transitions between highly stressful and non-stressful situations. Also, the inference rules were weighted according to the meaningfulness of the input features related to the degree of activation of the SNS.

The results of the system was tested using the signals collected during the experimental stage, in which participants had to solve a 3D wooden puzzle within 10 minutes. When compared to other systems in the literature, the results of the assessment showed softer transitions between different situations as well as lower reactivity to sudden changes in the physiological signals. Therefore, having fulfilled these two objectives of the work, the results of the comparison seem promising to the team.

7.1.2. Detection of physiological changes towards relaxation

As a continuation of the study done related to stress assessment, the team designed a system to detect eventual physiological changes produced towards relaxation (called RResps, Relaxation Responses). In this contribution, the team used the signal database collected for the previous study related to stress to see the physiological changes that take place in the body when a person relaxes or tries to do so in the middle of a mentally demanding or stressful situation. Also, the team collected the EDA and HR of different volunteers in a second experiment, which was specially targeted to see the effects of different relaxation techniques in the physiology. During both experiments, the team collected the impressions of the participants through interviews and questionnaires, as well as marked the registers of the signals in the instants in which a relevant event took place.

In collaboration with a team of psychologists and neuro-physiologists, the researchers carried out both qualitative and quantitative analyses of the collected EDA signals. During these analyses, the team reached different conclusions. First, as the eccrine sweat glands are only innervated by the SNS, the team concluded that it is possible to detect RResps solely looking at the EDA signal. When the SNS activates it produces the so-called skin-conductance responses (SCRs), which get represented as a sudden burst of sweat in the EDA signal. Consequently, the team concluded that if no SCRs take place, it means that is the SNS is not but the parasympathetic nervous system (PNS), which is the one responsible for the “rest and digest” type of reactions in the organism.

Second, taking into account the answers of the participants to the interviews, the team concluded that it was possible to label the EDA signal within 20s analysis windows using four different labels: NRResp for the absence of RResps in the signal, LRResp for low-intensity RResps, and MRResp and HRResps for respectively indicating medium and high-intensity RResps. Consequently, the team gathered with the psychologists and physiologists and labelled the EDA signals collected from both experiments every 20s. In order not to bias their opinions, they were randomly given each EDA analysis window.

The last conclusion concerns feature extraction from the EDA signal. After thoroughly analysing the EDA signal with the physiologists, the team decided that two EDA features were indicative for detecting RReps. The first feature is the slope of the EDA within the 20 analysis window, which is indicative or relaxation as an increasing EDA denotes that the SNS is active and that no relaxation is taking place. The second feature, which is innovative to the team’s knowledge, corresponds to the surface area contained between the linear regression of the EDA and the EDA instant signal, both of them within the 20s analysis window. The way to understand this feature is as follows: when the EDA decreases very linearly without any SCR, then the linear regression and the instant signal will be almost the same producing a negligible area meaningful of an intense and pronounced RResp. On the contrary, if the EDA decreases but it suffers sudden SCRs, then resulting area would be bigger and so the RREsp

less intense.

Finally, the team extracted these two features for all the subjects of the experiments and took those features to classification. They trained and tested 11 different supervised learning algorithms, among which decision trees (DT) showed themselves as the best option for having very good results and being their decision self-explanatory. Later, the most relevant rules of DTs designed expressly for each of the experiments were selected and merged to build a synthesized rule system valid for the two cases and scoring similar or better results than the experiment specific DTs ($F1_{\text{SYNTHESIZED}}=0.994$ vs $F1_{\text{DT-EXP1}}=0.990$ and $F1_{\text{DT-EXP2}}=0.992$).

In summary, in view that the system obtained good performance results using solely two features extracted from the EDA, the team believes that the results obtained during this work are satisfying.

7.2. Motor imagery BCI systems

During the period in which this thesis focused on BCI systems, the research team focused on solving the ERD/ERS motor imagery problem presented in BCI Competition III dataset IIIa. The problem consisted in correctly classifying 4 classes of intentional movement control states (IC) having 60 EEG channels: moving the right hand, left hand, tongue and feet. Nevertheless, the original dataset did not cover the control states in which no intentional movement is thought about (NC states). Therefore, they built an expanded dataset including the initial seconds of the motor imagery signal collection trials as belonging to the NC class. The expansion of the database added an extra level of difficulty to the classification task, as an extra constraint was added to the problem along with the addition of the NC class instances: the false positive ratio of the NC class instances had to be kept under 10% to avoid undesired actuator activity that would lead to user frustration.

After expanding the database, the team applied the CSP methodology to get the most relevant 5 projections for each of the 5 classes (1 NC, 4 IC) out of the 60 EEG channels. Then, the chosen projections were band filtered into three bands and subsequently, the three bands of each projections were used to extract 7 features. After that, the whole preprocessed dataset was partitioned over 5 runs to get three different smaller data subsets: two for training classifiers and one for testing the system estimated to be the best during the training. Finally, for the training partitions of each of the 5-runs, the most meaningful features for each class were selected using the correlation-based feature selection method.

Once all the data subsets had been prepared, the team used them to train different types of machine learning solutions to solve the classification problem. First, they tried solving the 5 class problem using a single classifier based on supervised learning algorithms. Besides, the team also tried to divide the problem and to use a two-level hierarchical classification system based solely on supervised learning methods: the first level was used to differentiate between NC and IC classes in general and the second level was used to differentiate among

the four different IC classes. Although eleven different types of algorithms were tried for these solutions, none of them succeed fulfilling the constraint of keeping the FPR under 10%.

Therefore, seeing the failure of the systems based on supervised learning, the team opted for using a hybrid two-level hierarchical classifier that combined the K-means unsupervised learning algorithm for the initial classification and support vector machines (SVM, a supervised learning algorithm) for the secondary classification inside the IC classes. Moreover, for keeping the FPR low, the team modified the K-means method setting a minimum threshold percentage for the first level classifier. The objective of this threshold was to ensure that all clusters labelled as corresponding to IC type instances at least had a minimum percentage of instances belonging to any of the IC classes. The proposed hybrid hierarchical succeed where the previous two approached had failed: it scored a 66.6% accuracy and an 8.2% FPR on average for the three subjects' signals included in the dataset.

In light of these promising results, the performance of the system was compared to other references in the literature facing the same problem. This comparison showed that proposed system performed better than the others in most of the cases, and, when it did not, it was because the other systems were facing a simpler problem with less classes or not taking NC states into account. Furthermore, the times required to train and test the system were also tested, proving that they are small enough to permit an online implementation of the system for a real-life motor imagery application.

7.3. Future lines

The works presented in the contribution chapters has left the gates opened to further work to be done in each of the three subjects.

In the context of the stress estimation system, the team left a gap in the R-peak detection algorithm as they did not define how to initialise it. Therefore, this had to be done manually, which is far from being useful in a real online implementation. This issue has already been solved by the GICI research team in [97]. However, the team continued improving the R peak detection algorithm making it more robust to noises as well as very computationally efficient [175].

Apart from that, the team saw a weakness in the fuzzy-logic system, which is requiring knowledge about the normal physiological parameters of the user. This is an important flaw of the system as it makes it requires the user to learn to program the solution. Therefore, it would be interesting to create automatically adapting templates using some type of machine learning method, as the use of neural network proposed in [84].

Concerning the line related to the detection the physiological patterns of relaxation, it is important remark that the study was limited to population age and so, it would be interesting to expand the study widening the studied population. It is important to bear in mind that the studies focusing on the automatic detection of the physiological variations indicative for relaxation

7. KAPITULUA - CONCLUSIONS

are practically non-existent. Therefore, expanding the study to a much bigger population would be useful to corroborate what concluded in this work.

Besides, the team finds interesting to further tune the detection system to make it capable of differentiating between those relaxation responses that take place in hostile situations and those that happen in calm situations. Also, it would be interesting to implement the proposal in a hardware platform because it should be relatively easy to do it as it only uses single physiological variable. Note that, in the end, the final objective of designing these types of solutions is that they can be used in the real-life.

With regard to the two lines commented so far, the author of this thesis would like to make mention a future line that concerns both of them. This future lines is related to the difficulties underlying signal labelling. The sense of stress and relaxation is a very subjective matter and despite the users can give certain indications about it, these are collected via interviews and questionnaires, which give a rather general impression instead of detailed information. Therefore, the author considers that it would be very interesting to use the proposed systems during new data collection experiments. If this was done, then it would be possible to get automatic marks of the most relevant events happening in the physiology of the participants during the experimental stage, and so, making it possible for the researchers to ask the participants about these events to get a better labelling. This future line would be interesting for all researchers that work towards detecting emotions, feelings and other human phenomena that are subjective and difficult to quantise.

Finally, some future lines also opened from the line analysing the motor imagery classification problem. First of all, the studied system was based on collecting EEG patterns time locked to specific indications on a PC screen. Requiring to have a PC screen in front of the user can be a serious limitation, because it might create a sensation on the user as he/she was marked and that catches too much the attention of the people around. Therefore, it would be very important for these systems to work asynchronously, not requiring external stimuli. This could be done by approaching the problem using sliding analysis windows, as proposed in [170] and [171].

The last future line derived from this contribution is related to building training platform so that users can practise using motor imagery systems. As it was shown, the performance of BCI systems is very influenced by how experienced the user is. Therefore, such a platform would be useful to get better accuracy and FPR values while at the same time making the training less tiring. Accordingly, the team started developing a car fetching pc game. The intention of the team is to integrate the proposed BCI system to the game and this way build a motor imagery training system.

7.4. Related publications

This thesis dissertation will finish with the presentation of the different journal and conference articles that were published during this period of thesis concerning the presented three main contributions. The publications are presented below, listed according to their category.

International journals:

- A. Salazar-Ramirez, E. Irigoyen, R. Martinez, and U. Zalabarria, “An enhanced fuzzy algorithm based on advanced signal processing for identification of stress,” *Neurocomputing*, vol. 271, pp. 48 – 57, 2018.
- R. Martinez, A. Salazar-Ramirez, A. Arruti, E. Irigoyen, J. I. Martin, and J. Muguerza, “A self-paced relaxation response detection system based on galvanic skin response analysis,” *IEEE Access*, vol. 7, pp. 43730–43741, 2019.
- A. Salazar-Ramirez, J. I. Martin, R. Martinez, A. Arruti, J. Muguerza, and B. Sierra, “A hierarchical architecture for recognising intentionality in mental tasks on a brain-computer interface,” *PLOS ONE*, vol. 14, pp. 1–18, 06 2019.

International conferences:

- A. Salazar-Ramirez, E. Irigoyen, and R. Martinez, “Enhancements for a robust fuzzy detection of stress,” in *International Joint Conference SOCO’14-CISIS’14-ICEUTE’14*, pp. 229–238, Springer, 2014.
- U. Zalabarria, E. Irigoyen, R. Martínez, and A. Salazar-Ramirez, “Detection of stress level and phases by advanced physiological signal processing based on fuzzy logic,” in *International Joint Conference SOCO’16-CISIS’16-ICEUTE’16* (M. Graña, J. M. López-Guede, O. Etxaniz, Á. Hertero, H. Quintián, and E. Corchado, eds.), (Cham), pp. 301–312, Springer International Publishing, 2017.
- A. Salazar-Ramirez., R. Martinez., A. Arruti., E. Irigoyen., J. I. Martin., and J. Muguerza., “A preliminary system for the automatic detection of emotions based on the autonomic nervous system response,” in *Proceedings of the 6th International Congress on Neurotechnology, Electronics and Informatics - Volume 1: NEUROTECHNIX*, pp. 46–52, INSTICC, SciTePress, 2018.
- M. Perez-Frutos, A. Salazar-Ramirez, M. L. Alvarez, R. Martinez, J. I. Martin, and A. Arruti, “Influence of the environmental hostility level in an hci system,” in *Proceedings of the XX International Conference on Human Computer Interaction, Interacción ’19*, (New York, NY, USA), Association for Computing Machinery, 2019.

7. KAPITULUA - CONCLUSIONS

National conferences:

- U. Zalabarria, E. Irigoyen, A. Salazar-Ramirez, and R. Martinez, “Procesamiento robusto para el análisis avanzado de señales electrocardiográficas afectadas por perturbaciones,” in *Actas de las XXXVI Jornadas de Automática*, Comité Español de Automática de la IFAC (CEA-IFAC), Sept. 2015.

Bibliography

- [1] D. C. Irimia, R. Ortner, M. S. Poboroniuc, B. E. Ignat, and C. Guger, “High classification accuracy of a motor imagery based brain-computer interface for stroke rehabilitation training,” *Frontiers in Robotics and AI*, vol. 5, no. 130, 2018.
- [2] J. Preece, Y. Rogers, and H. Sharp, *Interaction Design: Beyond Human-Computer Interaction*. New York, NY, USA: John Wiley & Sons, 2001.
- [3] World Health Organization, “Preamble to the constitution of the world health organization,” in *Constitution of the World Health Organization* (W. H. Organization, ed.), pp. 1–2, World Health Organization, 1948.
- [4] OpenStax, *Anatomy & Physiology*. OpenStax CNX, Feb. 2016. Accessed: 25.09.2019. <https://openstax.org/books/anatomy-and-physiology/pages/1-introduction>.
- [5] J. T. Cacioppo, L. G. Tassinary, and G. G. Berntson, *Handbook of Psychophysiology*. Cambridge Univ. Press, third ed., 2007.
- [6] W. B. Cannon, *Bodily changes in pain, hunger, fear, and rage: An account of recent researches into the function of emotional excitement*. D. Appleton & Company, 1915.
- [7] Harvard Medical School, “Understanding the stress response: Chronic activation of this survival mechanism impairs health.” Harvard Health Publishing, 2018. Accessed: 26.09.2019. <https://www.health.harvard.edu/staying-healthy/understanding-the-stress-response>.
- [8] L. Lanteaume, S. Khalifa, J. Régis, P. Marquis, P. Chauvel, and F. Bartolomei, “Emotion induction after direct intracerebral stimulations of human amygdala,” *Cerebral Cortex*, vol. 17, pp. 1307–1313, 07 2006.
- [9] H. Gray and W. H. Lewis, *Anatomy of the Human Body*. Lea & Febiger, Philadelphia, 1918.
- [10] B. Cornell, “Blood composition,” 2018. Accessed: 30.09.2019. <https://ib.bioninja.com.au/standard-level/topic-6-human-physiology/62-the-blood-system/blood-composition.html>.

BIBLIOGRAPHY

- [11] Blausen.com staff [Internet], “Medical gallery of blausen medical 2014: Thoracic cavity.” WikiJournal of Medicine 1(2): 10., 2014. Accessed: 26.09.2019. https://en.wikiversity.org/wiki/WikiJournal_of_Medicine/Medical_gallery_of_Blausen_Medical_2014.
- [12] M. Cadogan, “Ecg lead positioning.” Life in the fast lane [Blog], 2019. Accessed: 12.11.2019. <https://litfl.com/ecg-lead-positioning/>.
- [13] S. C. Segerstrom and L. S. Nes, “Heart rate variability reflects self-regulatory strength, effort, and fatigue,” *Psychological Science*, vol. 18, no. 3, pp. 275–281, 2007.
- [14] A. L. Hansen, B. H. Johnsen, and J. F. Thayer, “Relationship between heart rate variability and cognitive function during threat of shock,” *Anxiety, Stress, & Coping*, vol. 22, no. 1, pp. 77–89, 2009.
- [15] M. Malik, “Heart rate variability: Standards of measurement, physiological interpretation, and clinical use,” *Circulation*, vol. 93, pp. 1043–1065, 03 1996.
- [16] M. A. Woo, W. G. Stevenson, D. K. Moser, R. B. Trelease, and R. M. Harper, “Patterns of beat-to-beat heart rate variability in advanced heart failure,” *American Heart Journal*, vol. 123, no. 3, pp. 704–710, 1992.
- [17] M. S. Houle and G. E. Billman, “Low-frequency component of the heart rate variability spectrum: a poor marker of sympathetic activity,” *American Journal of Physiology-Heart and Circulatory Physiology*, vol. 276, no. 1, pp. 215–223, 1999.
- [18] R. Edelberg, “Electrical activity of the skin,” in *Handbook of psychophysiology* (N. S. G. . R. A. Sternbach, ed.), pp. 367–418, New York: Holt, Rinehart & Winston., 1972.
- [19] G. H. Zimny and E. W. Weidenfeller, “Effects of music upon gsr and heart-rate,” *The American Journal of Psychology*, vol. 76, no. 2, pp. 311–314, 1963.
- [20] A. N. Ishchenko and P. P. Shev’ev, “Automated complex for multiparameter analysis of the galvanic skin response signal,” *Biomedical Engineering*, vol. 23, pp. 113–117, May 1989.
- [21] A. Greco, G. Valenza, and E. P. Scilingo, *Advances in Electrodermal Activity Processing with Applications for Mental Health*, ch. Feature extraction, pp. 31–33. Springer International Publishing, first ed., 2007.
- [22] H. F. Posada-Quintero, J. P. Florian, A. D. Orjuela-Cañón, T. Aljama-Corrales, S. Charleston-Villalobos, and K. H. Chon, “Power spectral density analysis of electrodermal activity for sympathetic function assessment,” *Annals of Biomedical Engineering*, vol. 44, pp. 3124–3135, Oct 2016.

-
- [23] A. Greco, G. Valenza, A. Lanata, G. Rota, and E. P. Scilingo, “Electrodermal activity in bipolar patients during affective elicitation,” *IEEE Journal of Biomedical and Health Informatics*, vol. 18, pp. 1865–1873, Nov 2014.
- [24] N. Nourbakhsh, F. Chen, Y. Wang, and R. A. Calvo, “Detecting users’ cognitive load by galvanic skin response with affective interference,” *ACM Trans. Interact. Intell. Syst.*, vol. 7, pp. 12:1–12:20, Sept. 2017.
- [25] A. Barreto, J. Zhai, and M. Adjouadi, “Non-intrusive physiological monitoring for automated stress detection in human-computer interaction,” in *ICCV-HCI*, Oct. 2007.
- [26] A. Morley, L. Hill, and A. G. E. Kaditis, “10-20 system eeg placement,” 2016. Accessed: 08.10.2019. <https://www.ers-education.org/lrmedia/2016/pdf/298830.pdf>.
- [27] U. Hoffmann, J.-M. Vesin, T. Ebrahimi, and K. Diserens, “An efficient p300-based brain-computer interface for disabled subjects,” *Journal of Neuroscience Methods*, vol. 167, no. 1, pp. 115–125, 2008. Brain-Computer Interfaces (BCIs).
- [28] M. Kaper, P. Meinicke, U. Grossekhoefer, T. Lingner, and H. Ritter, “Bci competition 2003-data set iib: support vector machines for the p300 speller paradigm,” *IEEE Transactions on Biomedical Engineering*, vol. 51, pp. 1073–1076, June 2004.
- [29] D. L. Schomer and F. H. Lopes da Silva, *Niedermeyer’s Electroencephalography: Basic Principles, Clinical Applications, and Related Fields*. Philadelphia, PA, USA: Lippincott Williams & Wilkins, 6th ed., 2016.
- [30] O. Simonova, B. Roth, and J. Stein, “Eeg studies of healthy population—normal rhythms of resting recording,” *Acta Universitatis Carolinae. Medica (Praha)*, vol. 13, no. 7, pp. 543–551, 1967.
- [31] G. Pfurtscheller and C. Neuper, “Eeg-based brain-computer interfaces,” in *Niedermeyer’s Electroencephalography: Basic Principles, Clinical Applications, and Related Fields* (D. L. Schomer and F. H. Lopes da Silva, eds.), pp. 1227–1236, Philadelphia, Pa.: Lippincott Williams & Wilkins, 2010.
- [32] H. Berger, “Über das Elektrenkephalogramm des Menschen. Zweite Mitteilung (2nd report),” *Journal of Psychology and Neurology (Leipzig)*, 1930.
- [33] N. S. Kort, P. Cuesta, J. F. Houde, and S. S. Nagarajan, “Bihemispheric network dynamics coordinating vocal feedback control,” *Human brain mapping*, vol. 37, pp. 1474–1485, April 2016.

BIBLIOGRAPHY

- [34] E. M. Whitham, K. J. Pope, S. P. Fitzgibbon, T. Lewis, C. R. Clark, S. Loveless, M. Broberg, A. Wallace, D. DeLosAngeles, P. Lillie, A. Hardy, R. Fronsco, A. Pulbrook, and J. O. Willoughby, "Scalp electrical recording during paralysis: Quantitative evidence that eeg frequencies above 20hz are contaminated by emg," *Clinical Neurophysiology*, vol. 118, no. 8, pp. 1877–1888, 2007.
- [35] H. Ramoser, J. Muller-Gerking, and G. Pfurtscheller, "Optimal spatial filtering of single trial EEG during imagined hand movement," *IEEE Trans Rehabil Eng*, vol. 8, pp. 441–446, Dec. 2000.
- [36] D. Bruff, "Chapter 5 eigenvalues and eigenvectors," 2005. [Math 20 - Introduction to Linear Algebra and Multivariable Calculus lecture slides]. Accessed: 07.11.2019. http://www.math.harvard.edu/archive/20_spring_05/handouts/ch05_notes.pdf.
- [37] T. Nguyen, I. Hettiarachchi, A. Khatami, L. Gordon-Brown, C. P. Lim, and S. Nahavandi, "Classification of multi-class bci data by common spatial pattern and fuzzy system," *IEEE Access*, vol. 6, pp. 27873–27884, 2018.
- [38] M. Grosse-Wentrup and M. Buss, "Multiclass common spatial patterns and information theoretic feature extraction," *IEEE Transactions on Biomedical Engineering*, vol. 55, pp. 1991–2000, Aug 2008.
- [39] L. Zadeh, "Fuzzy sets," *Information and Control*, vol. 8, no. 3, pp. 338 – 353, 1965.
- [40] Y. Bai, H. Zhuang, and D. Wang, eds., *Advanced Fuzzy Logic Technologies in Industrial Applications*. Springer, Sept. 2006.
- [41] W. V. Leekwijck and E. E. Kerre, "Defuzzification: criteria and classification," *Fuzzy Sets and Systems*, vol. 108, no. 2, pp. 159 –178, 1999.
- [42] C. Bielza and P. Larrañaga, "Supervised pattern classification," June 2018. [Advanced Statistics and Data Mining Summer school (ASDM) lecture slides].
- [43] F. Osisanwo, J. Akinsola, O. Awodele, J. Hinmikaiye, O. Olakanmi, and J. Akinjobi, "Supervised machine learning algorithms: Classification and comparison," *International Journal of Computer Trends and Technology (IJCTT)*, vol. 48, pp. 128–138, June 2017.
- [44] J. Han and M. Kamber, *Data Mining Concepts and Techniques (2nd Edition)*, ch. Classification by Backpropagation, pp. 327–336. Morgan Kaufmann, Jan. 2006.
- [45] D. S. Broomhead and D. Lowe, "Multivariable functional interpolation and adaptive networks," *Complex Systems*, vol. 2, 1988.

-
- [46] M. A. Hearst, S. T. Dumais, E. Osuna, J. Platt, and B. Scholkopf, "Support vector machines," *IEEE Intelligent Systems and their Applications*, vol. 13, pp. 18–28, July 1998.
- [47] S. Amari and S. Wu, "Improving support vector machine classifiers by modifying kernel functions," *Neural Networks*, vol. 12, no. 6, pp. 783–789, 1999.
- [48] T. Cover and P. Hart, "Nearest neighbor pattern classification," *IEEE Transactions on Information Theory*, vol. 13, pp. 21–27, January 1967.
- [49] T. Bailey and A. K. Jain, "A note on distance-weighted k-nearest neighbor rules," *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 8, pp. 311–313, April 1978.
- [50] S. Dhanabal and S. Chandramathi, "A review of various k-nearest neighbor query processing techniques," *International Journal of Computers and Applications*, vol. 31, pp. 14–22, Oct. 2011.
- [51] J. Han and M. Kamber, *Data Mining Concepts and Techniques (2nd Edition)*, ch. Classification by Decision Tree Induction, pp. 291–310. Morgan Kaufmann, Jan. 2006.
- [52] J. Haebichan, "Adaboost for dummies: Breaking down the math (and its equations) into simple terms." Accessed: 02.11.2019. <https://towardsdatascience.com/adaboost-for-dummies-breaking-down-the-math-and-its-equations-into-simple-terms-87f439757dcf>.
- [53] K. Teknomo, "Numerical example if k-means clustering," 2017. Accessed: 07.11.2019. <https://people.revoledu.com/kardi/tutorial/kMean/NumericalExample.htm>.
- [54] G. Hamerly and C. Elkan, "Alternatives to the k-means algorithm that find better clusterings," in *Proceedings of the Eleventh International Conference on Information and Knowledge Management, CIKM '02*, (New York, NY, USA), pp. 600–607, ACM, 2002.
- [55] I. H. Witten and E. Frank, *Data Mining: Practical Machine Learning Tools and Techniques*. Morgan Kaufmann, 2016.
- [56] F. Wilcoxon, "Individual comparisons by ranking methods," *Biometrics Bulletin*, vol. 1, no. 6, pp. 80–83, 1945.
- [57] M. A. Hall, "Correlation-based feature selection for discrete and numeric class machine learning," in *Proc Int Conf Mach Learn*, pp. 359–366, Morgan Kaufmann, 2000.
- [58] J. Kropotov, *Quantitative EEG, Event-Related Potentials and Neurotherapy*. Philadelphia, PA, USA: Academic Press (Elsevier), 1st ed., 2009.

BIBLIOGRAPHY

- [59] L. Farwell and E. Donchin, “Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials,” *Electroencephalography and Clinical Neurophysiology*, vol. 70, no. 6, pp. 510 – 523, 1988.
- [60] B. Z. Allison and J. A. Pineda, “Erps evoked by different matrix sizes: implications for a brain computer interface (bci) system,” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 11, pp. 110–113, June 2003.
- [61] Nazarbayev University, “School of engineering and digital sciences,” 2019. Accessed: 11.12.2019. <https://nu.edu.kz/faculty/berdakh-abibullaev>.
- [62] X. Xing, Y. Wang, W. Pei, X. Guo, Z. Liu, F. Wang, G. Ming, H. Zhao, Q. Gui, and H. Chen, “A high-speed ssvep-based bci using dry eeg electrodes,” *Scientific Reports*, vol. 8, Oct. 2018.
- [63] Y. Zhang, P. Xu, Y. Huang, K. Cheng, and D. Yao, “Ssvep response is related to functional brain network topology entrained by the flickering stimulus,” *PLOS ONE*, vol. 8, pp. 1–11, 09 2013.
- [64] M. Nakanishi, Y. Wang, Y.-T. Wang, and T.-P. Jung, “A comparison study of canonical correlation analysis based methods for detecting steady-state visual evoked potentials,” *PLOS ONE*, vol. 10, pp. 1–18, 10 2015.
- [65] G. Pfurtscheller and F. L. da Silva, “Event-related eeg/meg synchronization and desynchronization: basic principles,” *Clinical Neurophysiology*, vol. 110, no. 11, pp. 1842–1857, 1999.
- [66] E. Thomas, J. Fruitet, and M. Clerc, “Investigating brief motor imagery for an erd/ers based bci,” in *2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp. 2929–2932, Aug 2012.
- [67] R. Martinez, E. Irigoyen, A. Arruti, J. Martin, and J. Muguerza, “A real-time stress classification system based on arousal analysis of the nervous system by an f-state machine,” *Computer Methods and Programs in Biomedicine*, vol. 148, pp. 81–90, Sept. 2017.
- [68] R. Picard, “Affective computing,” Tech. Rep. 321, M.I.T. Media Laboratory Perceptual Computing, 1995.
- [69] D. R. López, A. F. Neto, and T. F. Bastos, “On line recognition of human actions based on patterns of rwe windows applied in dynamic moment invariants,” *RIAI*, vol. 11, no. 2, pp. 202–211, 2014.
- [70] W. Sato, M. Noguchi, and S. Yoshikawa, “Emotion elicitation effect of films in a japanese sample,” *Social Behavior and Personality: an international journal*, vol. 35, no. 7, pp. 863–874, 2007.

-
- [71] W. B. Cannon, "Stresses and strains of homeostasis," *The American Journal of the Medical Sciences*, vol. 189, no. 1, pp. 13–14, 1935.
- [72] S. W. Porges, "The polyvagal theory: phylogenetic substrates of a social nervous system," *International Journal of Psychophysiology*, vol. 42, no. 2, pp. 123–146, 2001.
- [73] S. Kreibig, "Autonomic nervous system activity in emotion: A review," *Biological psychology*, vol. 84, no. 3, pp. 394–421, 2010.
- [74] C.-S. Poon and M. S. Siniaia, "Plasticity of cardiorespiratory neural processing: classification and computational functions," *Respiration physiology*, vol. 122, no. 2, pp. 83–109, 2000.
- [75] X. Navarro, "Fisiología del sistema nervioso autónomo," *Revista Neurológica*, vol. 35, pp. 553–562, 2002.
- [76] P. Ren, A. Barreto, J. Huang, Y. Gao, F. R. Ortega, and M. Adjouadi, "Off-line and on-line stress detection through processing of the pupil diameter signal," *Annals of biomedical engineering*, vol. 42, no. 1, pp. 162–176, 2014.
- [77] K. Subramanya, V. B. Vishnuprasada, and S. Kamath, "A wearable device for monitoring galvanic skin response to accurately predict changes in blood pressure indexes and cardiovascular dynamics," in *INDICON 2013*, pp. 1–4, IEEE, 2013.
- [78] J. Healey, R. W. Picard, *et al.*, "Detecting stress during real-world driving tasks using physiological sensors," *Intelligent Transportation Systems, IEEE Transactions on*, vol. 6, no. 2, pp. 156–166, 2005.
- [79] H. Helson and L. Quantius, "Changes in skin temperature following intense stimulation," *Journal of Experimental Psychology*, vol. 17, no. 1, pp. 20–35, 1934.
- [80] C. K. Lee, S. Yoo, Y. J. Park, N. H. Kim, K. S. Jeong, and B. Lee, "Using neural network to recognize human emotions from heart rate variability and skin resistance," in *IEEE-EMBS 2005.*, pp. 5523–5525, IEEE, 2006.
- [81] G. E. Sakr, I. H. Elhajj, and H. A.-S. Huijjer, "Support vector machines to define and detect agitation transition," *Affective Computing, IEEE Transactions on*, vol. 1, no. 2, pp. 98–108, 2010.
- [82] G.-J. De Vries, S. Pauws, and M. Biehl, "Insightful stress detection from physiology modalities using learning vector quantization," *Neurocomputing*, vol. 151, pp. 873–882, 03 2015.
- [83] N. Sharma and T. Gedeon, "Artificial neural network classification models for stress in reading," in *Neural Information Processing*, pp. 388–395, Springer, 2012.

BIBLIOGRAPHY

- [84] A. de Santos Sierra, C. S. Ávila, J. G. Casanova, and G. B. D. Pozo, “A stress-detection system based on physiological signals and fuzzy logic,” *Industrial Electronics, IEEE Transactions on*, vol. 58, no. 10, pp. 4857–4865, 2011.
- [85] P. Sasikala and R. Wahidabanu, “Robust r peak and qrs detection in electrocardiogram using wavelet transform,” *International Journal of Advanced Computer Science and Applications-IJACSA*, vol. 1, no. 6, pp. 48–53, 2010.
- [86] M. Talbi, A. Aouinet, L. Salhi, and A. Cherif, “New method of r-wave detection by continuous wavelet transform,” *Signal Processing: An International Journal (SPIJ)*, vol. 5, no. 4, p. 165, 2011.
- [87] G. de Lannoy, A. De Decker, and M. Verleysen, “A supervised wavelet transform algorithm for r spike detection in noisy ecgs,” in *Biomedical Engineering Systems and Technologies*, pp. 256–264, Springer, 2009.
- [88] R. J. Martis, C. Chakraborty, and A. K. Ray, “Wavelet-based machine learning techniques for ecg signal analysis,” in *Machine Learning in Healthcare Informatics*, pp. 25–45, Springer, 2014.
- [89] A. Ezeiza, N. Garay, K. L. de Ipiña, and A. Soraluze, “Ethical issues on the design of assistive technology for people with mental disabilities,” in *ICEHVE*, Mar. 2008.
- [90] J. J. Gross and R. W. Levenson, “Emotion elicitation using films,” *Cognition & emotion*, vol. 9, no. 1, pp. 87–108, 1995.
- [91] CSEA-NIMH, “The international affective picture system: Digitalized photographs,” *Center of Research in Psychophysiology*, 1999.
- [92] Z. Hong-tu and Y. Jing, “The wavelet decomposition and reconstruction based on the matlab,” in *Proc. of the Third Int. Symposium on Electronic Commerce and Security Workshops (ISECS 2010), China*, 2010.
- [93] D. Wei, *Coiflet-type wavelets: theory, design and applications*. PhD thesis, The University of Texas, 1998.
- [94] A. Salazar-Ramirez, E. Irigoyen, and R. Martinez, “Enhancements for a robust fuzzy detection of stress,” in *International Joint Conference SOCO’14-CISIS’14-ICEUTE’14*, pp. 229–238, Springer, 2014.
- [95] A. Salazar-Ramirez, E. Irigoyen, R. Martinez, and U. Zalabarria, “An enhanced fuzzy algorithm based on advanced signal processing for identification of stress,” *Neurocomputing*, vol. 271, pp. 48 – 57, 2018.
- [96] P. J. Lang, “Behavioral treatment and bio-behavioral assessment: Computer applications,” *Technology in Mental Health and Delivery Systems*, pp. 119–137, 1980.

-
- [97] U. Zalabarria, E. Irigoyen, A. Salazar-Ramirez, and R. Martinez, "Procesamiento robusto para el análisis avanzado de señales electrocardiográficas afectadas por perturbaciones," in *Actas de las XXXVI Jornadas de Automática*, Comité Español de Automática de la IFAC (CEA-IFAC), Sept. 2015.
- [98] M. E. P. Seligman and M. Csikszentmihalyi, "Positive psychology: An introduction," *American Psychologist*, vol. 55, no. 1, pp. 5–14, 2000.
- [99] H. Cuadra and R. Florenzano, "Subjective well-being: Towards a positive psychology," *Revista de Psicología de la Universidad de Chile*, vol. 12, no. 1, pp. 83–96, 2003.
- [100] D. K. Simonton and R. Baumeister, "Positive psychology at the summit," *Review of General Psychology*, vol. 9, pp. 99–102, 06 2005.
- [101] P. V. Cappellen, E. L. Rice, L. I. Catalino, and B. L. Fredrickson, "Positive affective processes underlie positive health behaviour change," *Psychology & Health*, vol. 33, no. 1, pp. 77–97, 2018. PMID: 28498722.
- [102] R. J. Fehring, "Effects of biofeedback-aided relaxation on the psychological stress symptoms of college students.," *Nursing research*, vol. 32, no. 6, pp. 362–366, 1983.
- [103] J. van der Zwan, W. de Vente, A. Huizink, S. Bögels, and E. de Bruin, "The effects of physical activity, mindfulness meditation, or heart rate variability biofeedback on executive functioning, worrying, and mindfulness," *Biological Psychology*, vol. 129, pp. 383 – 384, Oct. 2017.
- [104] J. A. P. H. Perera, P. M. C. Perera, L. M. Rathnarajah, and H. B. Ekanayake, "Biofeedback based computational approach for working stress reduction through meditation technique," in *2016 Sixteenth International Conference on Advances in ICT for Emerging Regions (ICTer)*, pp. 132–140, Sep. 2016.
- [105] M. Díez-Cirarda, N. Ojeda, J. Peña, A. Cabrera-Zubizarreta, M. n. Gómez-Beldarrain, J. C. Gómez-Esteban, and N. Ibarretxe-Bilbao, "Neuroanatomical correlates of theory of mind deficit in parkinson's disease: A multimodal imaging study," *PLOS ONE*, vol. 10, pp. 1–16, 11 2015.
- [106] Instituto Burmuin, "Equipo de profesionales," Oct. 2018.
- [107] M. E. P. Seligman, *Florecer. La Nueva Psicología Positiva y la Búsqueda del Bienestar*. Oceano, 2016.
- [108] A. Conrad and W. T. Roth, "Muscle relaxation therapy for anxiety disorders: It works but how?," *Journal of Anxiety Disorders*, vol. 21, no. 3, pp. 243 – 264, 2007.

BIBLIOGRAPHY

- [109] E. Donegan and M. Dugas, “Generalized anxiety disorder: A comparison of symptom change in adults receiving cognitive-behavioral therapy or applied relaxation,” *Journal of consulting and clinical psychology*, vol. 80, pp. 490–6, 04 2012.
- [110] J. Hoyer, K. Beesdo, A. T. Gloster, J. Runge, M. Höfler, and E. S. Becker, “Worry exposure versus applied relaxation in the treatment of generalized anxiety disorder.,” *Psychotherapy and psychosomatics*, vol. 78, pp. 106–115, 2009.
- [111] C. Blanco, F. J. Estupiñá, F. J. Labrador, I. Fernández-Arias, M. Bernaldo-de Quirós, and L. Gómez, “El uso de las técnicas de relajación en la práctica de una clínica de psicología,” *Anales Psicología*, vol. 30, no. 2, pp. 403–411, 2014.
- [112] F. Pagnini, G. M. Manzoni, G. Castelnuovo, and E. Molinari, “The efficacy of relaxation training in treating anxiety,” *International Journal of Behavioral Consultation and Therapy*, vol. 5, no. 3-4, pp. 264–269, 2010.
- [113] S. E. Stevens, M. T. Hynan, M. Allen, M. M. Braun, and M. R. McCart, “Are complex psychotherapies more effective than biofeedback, progressive muscle relaxation, or both? a meta-analysis.,” *Psychological reports*, vol. 100, pp. 303–324, Feb. 2007.
- [114] K. S. Carter and R. Carter, “Breath-based meditation: A mechanism to restore the physiological and cognitive reserves for optimal human performance.,” *World journal of clinical cases*, vol. 4, pp. 99–102, Apr. 2016.
- [115] H. Benson, S. Alexander, and C. L. Feldman, “Decreased premature ventricular contractions through use of the relaxation response in patients with stable ischaemic heart-disease.,” *Lancet (London, England)*, vol. 2, pp. 380–382, Aug. 1975.
- [116] H. Benson, J. F. Beary, and M. P. Carol, “The relaxation response,” *Psychiatry*, vol. 37, no. 1, pp. 37–46, 1974. PMID: 27764631.
- [117] J. N. Morey, I. A. Boggero, A. B. Scott, and S. C. Segerstrom, “Current directions in stress and human immune function,” *Current Opinion in Psychology*, vol. 5, pp. 13–17, Oct. 2015. Health behavior.
- [118] J. J. Kim and D. M. Diamond, “The stressed hippocampus, synaptic plasticity and lost memories.,” *Nature reviews. Neuroscience*, vol. 3, pp. 453–462, July 2002.
- [119] P. A. Low and E. E. Benarroch, *Clinical Autonomic Disorders*. Lippincott Williams and Wilkins, third ed., 2008.
- [120] H. Sandler, U. Fendel, E. Peters, M. Rose, R. Boesel, and B. Klapp, “Subjective experience of relaxation – induced by vibroacoustic stimulation by

- a body monochord or cd music – a randomised, controlled study in patients with psychosomatic disorders,” *Nordic Journal of Music Therapy*, pp. 1–20, 10 2015.
- [121] N. Sharma and T. Gedeon, “Modeling a stress signal,” *Applied Soft Computing*, vol. 14, pp. 53–61, 01 2014.
- [122] K. Palanisamy, M. Murugappan, and S. Yaacob, “Multiple physiological signal-based human stress identification using non-linear classifiers,” *Elektronika ir Elektrotechnika*, vol. 19, pp. 80–85, Jan. 2013.
- [123] C. Lin, J. King, J. Fan, A. Appaji, and M. Prasad, “The influence of acute stress on brain dynamics during task switching activities,” *IEEE Access*, vol. 6, pp. 3249–3255, 2017.
- [124] J. Choi and R. Gutierrez-Osuna, “Using heart rate monitors to detect mental stress,” in *Proceedings - 2009 6th International Workshop on Wearable and Implantable Body Sensor Networks, BSN 2009*, pp. 219–223, 06 2009.
- [125] J.-S. Wang, C.-W. Lin, and Y.-T. C. Yang, “A k-nearest-neighbor classifier with heart rate variability feature-based transformation algorithm for driving stress recognition,” *Neurocomputing*, vol. 116, pp. 136–143, 2013. *Advanced Theory and Methodology in Intelligent Computing*.
- [126] M. M. Bradley and P. J. Lang, “Measuring emotion: the self-assessment manikin and the semantic differential,” *Journal of behavior therapy and experimental psychiatry*, vol. 25, no. 1, pp. 49–59, 1994.
- [127] Y. Z. Tan, S. Ozdemir, A. Temiz, and F. Celik, “The effect of relaxing music on heart rate and heart rate variability during ecg gated-myocardial perfusion scintigraphy,” *Complementary Therapies in Clinical Practice*, vol. 21, no. 2, pp. 137–140, 2015.
- [128] A. Goshvarpour, A. Abbasi, and A. Goshvarpour, “Evaluating autonomic parameters: the role of sleep duration in emotional responses to music,” *Iranian journal of psychiatry*, vol. 11, pp. 59–63, Feb. 2016.
- [129] P. J. Lang, M. M. Bradley, and B. N. Cuthbert, “International affective picture system (iaps): Technical manual and affective ratings,” *NIMH Center Study Emotion Attention*, pp. 39–57, 1997.
- [130] C. A. Gabert-Quillen, E. E. Bartolini, B. T. Abravanel, and C. A. Sanislow, “Ratings for emotion film clips,” *Behavior Research Methods*, vol. 47, no. 3, pp. 773–787, 2015.
- [131] M. Matsumoto and J. C. Smith, “Progressive muscle relaxation, breathing exercises, and abc relaxation theory,” *Journal of Clinical Psychology*, vol. 57, no. 12, pp. 1551–1557, 2001.

BIBLIOGRAPHY

- [132] Y. Nagai, h. Critchley, E. Featherstone, M. Trimble, and D. R...J., "Activity in ventromedial prefrontal cortex covaries with sympathetic skin conductance level: a physiological account of a "default mode" of brain function," *NeuroImage*, vol. 22, no. 1, pp. 243–251, 2004.
- [133] M. Benedek and C. Kaernbach, "Decomposition of skin conductance data by means of nonnegative deconvolution," *Psychophysiology*, vol. 47, pp. 647–658, Mar. 2010.
- [134] J. Sugenoya, S. Iwase, T. Mano, and T. Ogawa, "Identification of sudomotor activity in cutaneous sympathetic nerves using sweat expulsion as the effector response," *European Journal of Applied Physiology and Occupational Physiology*, vol. 61, no. 3–4, pp. 302–308, 1990.
- [135] M. Merino Monge, I. M. Gomez Gonzalez, A. Cantero, and K. Guzman, "Assessment of biosignals for managing a virtual keyboard," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 2012, pp. 331–337, 07 2012.
- [136] M. Saidi, H. Hassanpoor, and A. Azizi Lari, "Proposed new signal for real-time stress monitoring: Combination of physiological measures," *AUT Journal of Electrical Engineering*, vol. 49, no. 1, pp. 11–18, 2017.
- [137] S. Jerritta, M. Murugappan, R. Nagarajan, and W. Khairunizam, "Physiological signals based human emotion recognition: a review," *Proceedings - 2011 IEEE 7th International Colloquium on Signal Processing and Its Applications, CSPA 2011*, pp. 410–415, Mar. 2011.
- [138] K. H. Kim, S. W. Bang, and S. R. Kim, "Emotion recognition system using short-term monitoring of physiological signals," *Medical and Biological Engineering and Computing*, vol. 42, pp. 419–427, May 2004.
- [139] D. R. Bach, K. J. Friston, and R. J. Dolan, "Analytic measures for quantification of arousal from spontaneous skin conductance fluctuations," *International Journal of Psychophysiology*, vol. 76, no. 1, pp. 52–55, 2010.
- [140] A. R. Subhani, W. Mumtaz, M. N. B. M. Saad, N. Kamel, and A. S. Malik, "Machine learning framework for the detection of mental stress at multiple levels," *IEEE Access*, vol. 5, pp. 13545–13556, 2017.
- [141] J. R. Quinlan, "Induction of decision trees," *Machine Learning*, vol. 1, pp. 81–106, Mar 1986.
- [142] J. W. Britton, L. C. Frey, J. Hopp, P. Korb, M. Koubeissi, W. Lievens, E. Pestana-Knight, and E. L. St, *Electroencephalography (EEG): An introductory text and atlas of normal and abnormal findings in adults, children, and infants*. American Epilepsy Society, Chicago, 2016.

-
- [143] I. Choi, I. Rhiu, Y. Lee, M. H. Yun, and C. S. Nam, "A systematic review of hybrid brain-computer interfaces: Taxonomy and usability perspectives," *PLoS one*, vol. 12, no. 4, p. e0176674, 2017.
- [144] C. Guger, B. Z. Allison, and G. Edlinger, *Brain-Computer Interface Research: A state-of-the-art summary*. Springer, 2014.
- [145] J. R. Wolpaw, "The bci endeavor and the mission of this new journal," *Brain-Computer Interfaces*, vol. 1, pp. 2–4, 2014.
- [146] J. Abascal, A. Arruti, J. I. Martin, and J. Muguerza, "A hierarchical bci system able to discriminate between non intentional control state and four intentional control activities." Proceedings of the International Conference on Physiological Computing Systems, 2014.
- [147] B. Blankertz, K. R. Muller, D. J. Krusienski, G. Schalk, J. R. Wolpaw, A. Schlogl, G. Pfurtscheller, J. D. R. Millan, M. Schroder, and N. Birbaumer, "The bci competition iii: Validating alternative approaches to actual bci problems," *IEEE Trans Neural Syst Rehabil Eng*, vol. 14, pp. 153–159, 2006.
- [148] P. J. García-Laencina, G. Rodríguez-Bermudez, and J. Roca-Dorda, "Exploring dimensionality reduction of eeg features in motor imagery task classification," *Expert Syst Appl*, vol. 41, pp. 5285–5295, 2014.
- [149] W.-Y. Hsu, "Fuzzy hopfield neural network clustering for single-trial motor imagery eeg classification," *Expert Syst Appl*, vol. 39, pp. 1055–1061, 2012.
- [150] L. F. Nicolas-Alonso and J. Gomez-Gil, "Brain computer interfaces, a review.," *Sensors (Basel, Switzerland)*, vol. 12, pp. 1211–1279, 2012.
- [151] T. Shi, H. Wang, and C. Zhang, "Brain computer interface system based on indoor semi-autonomous navigation and motor imagery for unmanned aerial vehicle control," *Expert Syst Appl*, vol. 42, pp. 4196–4206, 2015.
- [152] G. Pfurtscheller and C. Neuper, "Motor imagery and direct brain-computer communication," *Proc IEEE*, vol. 89, pp. 1123–1134, July 2001.
- [153] L. Cao, B. Xia, O. Maysam, J. Li, H. Xie, and N. Birbaumer, "A synchronous motor imagery based neural physiological paradigm for brain computer interface speller.," *Front Hum Neurosci*, vol. 11, p. 274, 2017.
- [154] G. Townsend, B. Graimann, and G. Pfurtscheller, "Continuous EEG classification during motor imagery-simulation of an asynchronous bci," *IEEE Trans Neural Syst Rehabil Eng*, vol. 12, pp. 258–265, June 2004.
- [155] D. Planelles, E. Hortal, A. Costa, A. Ubeda, E. Iáez, and J. M. Azorín, "Evaluating classifiers to detect arm movement intention from eeg signals.," *Sensors (Basel, Switzerland)*, vol. 14, pp. 18172–18186, Sept. 2014.

BIBLIOGRAPHY

- [156] F. Lotte, H. Mouchere, and A. Lecuyer, "Pattern rejection strategies for the design of self-paced EEG-based brain-computer interfaces," in *Proc. 19th IEEE Int Conf Pattern Recognit*, pp. 1–5, Dec. 2008.
- [157] R. Leeb, D. Friedman, G. R. Müller-Putz, R. Scherer, M. Slater, and G. Pfurtscheller, "Self-paced (asynchronous) bci control of a wheelchair in virtual environments: a case study with a tetraplegic.," *Comput Intell Neurosci*, p. 79642, 2007.
- [158] J. Pan, Y. Li, R. Zhang, Z. Gu, and F. Li, "Discrimination between control and idle states in asynchronous ssvep-based brain switches: A pseudo-key-based approach," *IEEE Trans Neural Syst Rehabil Eng*, vol. 21, pp. 435–443, May 2013.
- [159] D. Huang, K. Qian, D.-Y. Fei, W. Jia, X. Chen, and O. Bai, "Electroencephalography (eeg)-based brain-computer interface (bci): a 2-d virtual wheelchair control based on event-related desynchronization/synchronization and state control.," *IEEE Trans Neural Syst Rehabil Eng*, vol. 20, pp. 379–388, May 2012.
- [160] R. Scherer, F. Lee, A. Schlogl, R. Leeb, H. Bischof, and G. Pfurtscheller, "Toward self-paced brain-computer communication: navigation through virtual worlds.," *IEEE Trans Biomed Eng*, vol. 55, pp. 675–682, Feb. 2008.
- [161] O. AlZoubi, I. Koprinska, and R. A. Calvo, "Classification of brain-computer interface data," in *Proc 7th Australasian Data Mining Conf*, vol. 87 of *AusDM '08*, (Darlinghurst, Australia, Australia), pp. 123–131, Australian Computer Society, Inc., 2008.
- [162] H. Bashashati, R. K. Ward, G. E. Birch, and A. Bashashati, "Comparing different classifiers in sensory motor brain computer interfaces.," *PloS one*, vol. 10, p. e0129435, 2015.
- [163] A. Celecia, R. Gonzalez, M. Vellasco, and P. Vellasco, "Ensemble of classifiers applied to motor imagery task classification for bci applications." *Int Jt Conf Neural Netw*, 2017.
- [164] A. Bashashati, S. G. Mason, J. F. Borisoff, R. K. Ward, and G. E. Birch, "A comparative study on generating training-data for self-paced brain interfaces," *IEEE Trans Neural Syst Rehabil Eng*, vol. 15, pp. 59–66, Mar. 2007.
- [165] F. Y.-T. Lee, R. Scherer, R. Leeb, C. Neuper, H. Bischof, and G. Pfurtscheller, "A comparative analysis of multi-class eeg classification for brain-computer interface." *10th Computer Vision Winter Workshop (CVWW)*, 2006.

-
- [166] E. Dong, C. Li, L. Li, S. Du, A. N. Belkacem, and C. Chen, "Classification of multi-class motor imagery with a novel hierarchical svm algorithm for brain-computer interfaces.," *Med Biol Eng Comput*, vol. 55, pp. 1809–1818, Oct. 2017.
- [167] S. Aliakbaryhosseinabadi, N. Jiang, A. Vuckovic, R. Lontis, K. Dremstrup, D. Farina, and N. Mrachacz-Kersting, *Replace, Repair, Restore, Relieve-Bridging Clinical and Engineering Solutions in Neurorehabilitation*, vol. 7, ch. Detection of Movement Intention from Movement-Related Cortical Potentials with Different Paradigms., pp. 237–244. Springer, Jan. 2014.
- [168] A. Bashashati, R. K. Ward, and G. E. Birch, "Towards development of a 3-state self-paced brain-computer interface.," *Comput Intell Neurosci*, p. 84386, 2007.
- [169] F. Nijboer, "Technology transfer of brain-computer interfaces as assistive technology: barriers and opportunities.," *Ann Phys Rehabil Med*, vol. 58, pp. 35–38, Feb. 2015.
- [170] Y. Yu, Z. Zhou, E. Yin, J. Jiang, J. Tang, Y. Liu, and D. Hu, "Toward brain-actuated car applications: Self-paced control with a motor imagery-based brain-computer interface," *Comput Biol Med*, vol. 77, pp. 148–155, Oct. 2016.
- [171] F. Melinscak, L. Montesano, and J. Minguez, "Asynchronous detection of kinesthetic attention during mobilization of lower limbs using eeg measurements.," *J Neural Eng*, vol. 13, p. 016018, Feb. 2016.
- [172] T. Alotaiby, F. E. A. El-Samie, S. A. Alshebeili, and I. Ahmad, "A review of channel selection algorithms for eeg signal processing," *EURASIP J Adv Signal Process*, vol. 2015, 2015.
- [173] A. Astigarraga, A. Arruti, J. Muguerza, R. Santana, J. I. Martin, and B. Sierra, "User adapted motor-imaginary brain-computer interface by means of eeg channel selection based on estimation of distributed algorithms," *Math Probl Eng*, vol. 2016, pp. 1–12, 2016.
- [174] M. Alimardani, S. Nishio, and H. Ishiguro, "The importance of visual feedback design in bcis; from embodiment to motor imagery learning.," *PloS one*, vol. 11, p. e0161945, 2016.
- [175] U. Zalabarria, E. Irigoyen, R. Martinez, and A. Lowe, "Online robust r-peaks detection in noisy electrocardiograms using a novel iterative smart processing algorithm," *Applied Mathematics and Computation*, vol. 369, p. 124839, 2020.