



الجمهورية العربية السورية
وزارة التعليم العالي والبحث العلمي

جامعة دمشق

كلية الهندسة الميكانيكية والكهربائية

قسم هندسة الحواسيب والأتمتة

تحسين المعالجة الأولية للإشارات الحيوية للتحكم بذراع روبوتية

رسالة مقدمة لنيل درجة الماجستير في هندسة الروبوت وبرمجته

إعداد:

م. حذيفة مرهج

المشرف المشارك: د. أكرم مسوح

مدرس في قسم الحواسيب والأتمتة

المشرف: أ.م.د. أغيد القطعان

أستاذ مساعد في قسم الحواسيب والأتمتة

العام

2023

لجنة الحكم

لجنة الحكم المشكلة بناءً على قرار مجلس البحث العلمي والدراسات العليا في جامعة دمشق رقم /966/ المتخذ خلال الجلسة رقم /6/ بتاريخ 12/12/2022 لمناقشة رسالة الماجستير في كلية الهندسة الميكانيكية والكهربائية قسم الحواسيب والأتمتة التي أعدها الطالب حذيفة مرهج بعنوان:

"تحسين المعالجة الأولية للإشارات الحيوية للتحكم بذراع روبوتية"

د. رؤوف حمدان

عضواً

المدرس في قسم الحواسيب والأتمتة

إبصار حاسوبية ومعالجة الصور

.....

د. رافة خازم

عضواً

المدرسة في قسم الحواسيب والأتمتة

هندسة القيادة والقياس عن بعد (نظم تشغيل)

.....

أ.م.د. أغيد القطعان

عضواً مشرفاً

أستاذ مساعد في قسم الحواسيب والأتمتة

اختصاص علوم الحاسبات

.....

تصريح خطي

أنا الموقع أدناه أصرح بعملتي الكامل وقبولي:

١. أن كل ماينتج عن البحث والأطروحة هو ملكية فردية ومالية بالتشارك مع جامعة دمشق، وأنني ألتزم بأخذ موافقة الجامعة في حال رغبتني بنشر البحث أو الأطروحة أو جزء منها نصاً أو مضموناً خارج إطار الجامعة (من دور نشر أو مكتبات أو مواقع الكترونية وغيرها من وسائل النشر).

٢. أنه لا يوجد أي جزء من هذه الأطروحة تم اقتباسه من عمل علمي آخر أو أنجز للحصول على شهادة أخرى في جامعة دمشق أو معهد تعليمي داخل أو خارج الجمهورية العربية السورية.

الإهداء

إلى جسرٍ متينٍ يحمل أعباء المنزل دون كللٍ أو ملل، وإلى من تعطي أضعاف قدرتها من دون أي مقابل وتفني حياتها لكي ترى أبناءها يصلُّون إلى ما يصبون إليه، إلى من ذكرهم الله عزَّ وجل في كتابه العزيز بقوله تعالى:

بسم الله الرحمن الرحيم

{ واخْفِضْ لَهُمَا جَنَاحَ الذُّلِّ مِنَ الرَّحْمَةِ وَقُلْ رَبِّ ارْحَمْهُمَا كَمَا رَبَّيْنِي صَغِيرًا }

أبي وأمي

إلى مصدر إلهامي ومثلي الأعلى، إلى من هم سندي على مر الأيام الصَّعاب

إخوتي

إلى من كانوا العون ومن قدموا يد المساعدة في أيام السَّراء والضَّراء وإلى من اتسموا بطيب المعشر وحسن الخُلق، إلى إخوةٍ ليسوا من أبي وأمي

أصدقائي وأقاربي

شكر وتقدير

أنقدم بخالص كلمات الشكر والامتنان لمن كانوا القدوة والمنازة التي ترشدنا وتصحح وتصوب مسارنا، إلى من لهم الفضل في وصولنا إلى هنا، إلى منبع العلم ومنهل الأخلاق

الدكتور أغيد القطعان

الدكتور أكرم مسوح

إلى جميع أعضاء الهيئة التدريسية في قسم الحواسيب والأتمتة ممثلين برئيس القسم

الدكتور رؤوف حمدان

إلى جميع أعضاء لجنة الحكم من أساتذة مشرفين ومشاركين

الدكتور رؤوف حمدان

الدكتور أغيد القطعان

الدكتورة رافة خازم

الملخص

تعد عملية التواصل بين الدماغ البشري والحاسوب أمراً مهماً في عصرنا هذا لأسبابٍ شتى، بحيث أصبح بإمكان الإنسان إصدار الأوامر للأجهزة الالكترونية عبر قراءة إشارات الدماغ الكهربائية وترجمتها إلى أوامر برمجية يفهمها الحاسوب ويفسرها، حيث تعتبر تقنية أو نظام واجهة الدماغ-حاسوب (BCI) من أفضل التقنيات بهذا المجال، حيث يتم أخذ إشارات الدماغ (EEG) كمدخلات لهذا النظام ويتم ترجمتها إلى أوامر على جهاز الحاسوب، و لم تعد الأبحاث العلمية في مجال الذكاء الاصطناعي وتعلم الآلة وخاصة ما يسمى واجهات الدماغ -حاسوب موجهة فقط لذوي العجز الحركي بل أصبحت موجهة للاستخدام العام لأجل تحسين تجربة استخدامنا للحواسيب وتواصل الانسان مع الحاسب بشكل أفضل.

ومن هنا وفي هذه الدراسة استخدمت بيانات الإشارات الحركية (EEG-MI) لأجل عملية تصنيف تلك الإشارات إلى حركات يد يمينى، وحركات يد يسرى، وذلك باستخدام خوارزميات وطرق متعددة منها: خوارزمية تحليل المكوّن أو العنصر المستقل (ICA) لأجل تصفية تلك الإشارات وإزالة آثار الضجيج الناتج عن تأثير بعض الإشارات الحيوية الأخرى، كإشارات العضلات، والقلب، والتنفس، وحركة العين....إلخ، وبعد ذلك استخدم الترشيح المكاني بواسطة مرشح النمط المكاني المشترك (CSP)، وبعد ذلك استخراج السمات لأجل عملية التصنيف وذلك باستخدام خوارزميات تعلّم الآلة بالاعتماد على آلة دعم القرار (SVM)، حيث فُصل بين الصنفين وتم الحصول على نتائج جيدة بدقة 89.2%.

الكلمات المفتاحية: إشارات الدماغ الحركية EEG-MI، تحليل العنصر المستقل ICA، مرشح النمط المكاني المشترك CSP، تعلّم الآلة ML، آلة دعم القرار SVM

فهرس المحتويات

الإهداء	IV
شكر وتقدير	V
الملخص	VI
1-1 المقدمة:	2
2_1 مشكلة البحث:	5
3_1 أهمية البحث:	5
الأهمية العلمية:	5
الأهمية التطبيقية:	5
4-1 الهدف من البحث:	6
5-1 محتوى الرسالة:	6
6-1 الخاتمة:	7
1-2 المقدمة:	8
2-2 الدراسات المرجعية التي اهتمت بموضوع معالجة الإشارات الدماغية:	8
1-2-2 تصنيف إشارات EEG بناءً على التعرف على الأنماط:	8
2-2-2 نموذج التعلم العميق لتصنيف EEG-MI المتعلقة بـ BCIs:	10
3-2-2 نظام BCI للصور أو التخيلات الحركية يعتمد على شبكات التعلم العميق وتطبيقاته:	11
4-2-2 BCI المستندة إلى EEG باستخدام الصور الحركية، التقنيات والتحديات:	12
5-2-2 التعرف على إشارة الصور الحركية EEG باستخدام الشبكة العصبية الالتفافية العميقة:	13
6-2-2 الاستدلال الربيع والدقيق متعدد الطبقات لـ MI-BCIs باستخدام السمات الطيفية والزمنية واسعة النطاق:	14
3-2 الخاتمة:	16
1-3 المقدمة:	18
2-3 البناء العام للجهاز العصبي General Design of the Nervous System:	18
1-2-3 البنية التشريحية للجهاز العصبي Anatomic Structure of the Nervous System:	18

18	:Central Nervous System الجهاز العصبي المركزي 1-1-2-3
23	:Peripheral nervous system الجهاز العصبي المحيطي 2-1-2-3
23	:Physiological structure of the nervous system البنية الفيزيولوجية للجهاز العصبي 2-2-3
23	:Neuron structure بنية العصبون 1-2-2-3
23	:الوظائف المتكاملة للمراكز العصبية: 2-2-2-3
23	:BCI تعريف 3-3
23	:التعريف التقليدي: 1-3-3
26	:التعريف الحديث: 2-3-3
27	:BCI تاريخ نظام 3-3-3
27	:تطبيقات نظام BCI المختلفة: 4-3-3
27	:التطبيقات الطبية: 1-4-3-3
27	:التطبيقات التعليمية: 2-4-3-3
28	:التطبيقات الأمنية: 3-4-3-3
28	:التطبيقات الترفيهية: 4-4-3-3
28	:كيف يعمل نظام BCI: 5-3-3
28	:1-5-3-3 قياس النشاط الدماغي (بدون جراحة):
29	:Electroencephalography للدماغ 2-5-3-3
29	:الأهداف العامة من تخطيط الدماغ: 3-5-3-3
30	:Electrode Placement System لمواقع الإلكترودات 4-5-3-3
32	:Way of Measurement تحميل إشارات الدماغ 5-5-3-3
32	:6-5-3-3 قياس النشاط الدماغي (مع جراحة):
33	:الخاتمة: 4-3
35	:المقدمة: 1-4
35	:الأموال الدماغية: 2-4
36	:أنواع الأموال الدماغية: 1-2-4
38	:EEG Processing معالجة إشارات الدماغ 3-4

39	4-4 الأدوات المستخدمة في عملية معالجة إشارات الدماغ:
41	4-5 المعالجة الأولية لإشارات الدماغ EEG Preprocessing:
43	4-6 الخاتمة:
45	5-1 المقدمة:
45	5-2 تحويل فورييه Fourier Transformation:
46	5-3 تحويل فورييه القصير زمنياً Short Time Fourier Transformation:
48	5-4 التحويل المويجي Wavelet Transformation:
50	5-4-1 الموجبة الأم:
52	5-5 التحويل المويجي المنقطع Discrete wavelet transform:
54	5-6 تحليل كثافة طيف الطاقة للإشارة الدماغية Power Spectrum Density:
55	5-7 المرشح المكاني المشترك Common Spatial Pattern:
56	5-8 المصنف Support Vector Machine:
62	5-9 الخاتمة:
64	6_1 مقدمة:
64	6-2 كيفية استخلاص الإشارات والحصول عليها:
65	6-2-1 تسجيل الإشارات Data recording:
68	6-3 خطوات المعالجة الأولية Preprocessing Steps:
77	6-4 عملية استخراج السمات Features Extraction:
83	6-5 التصنيف Classification:
87	6-6 المحاكاة Simulation:
90	6-7 مناقشة النتائج والآفاق المستقبلية:
91	المراجع:
94	الملحق:

فهرس الأشكال

3	الشكل (1,1) جهاز قراءة إشارات الدماغ EEG وأول تجربة بهذا المجال كانت على قرد
4	الشكل (2,1) مواقع الإلكترودات التي تتموضع على الرأس
4	الشكل (3,1) أصناف وحزم إشارات الدماغ
5	الشكل (4,1) آلية العمل من بداية قراءة الإشارات الدماغية وصولاً للخروج
9	الشكل (2-1) مخطط مقترح لاستخراج السمات وتصنيف إشارات ال EEG
10	الشكل (1-2) البنية المفاهيمية لشبكة CNN
11	الشكل (3-2) المقارنة بين أداء كل من GRNN و LSTM
12	الشكل (4-2) يوضح عملية استخراج واختيار السمات FE
12	الشكل (5-2) يوضح (a) مقارنة بين أداء ودقة الخوارزميات من أجل استخراج السمات، بينما (b) يظهر الوقت التقريبي لكل خوارزمية من أجل عملية استخراج السمات
13	الشكل (6-2) بنية نظام التعرف على التصورات أو التخييلات الحركية MI
13	الشكل (7-2) تأثير فحص الالتفاف على نتائج تحديد الهوية
14	الشكل (8-2) المخطط المتبع في عملية معالجة وتصنيف إشارات الدماغ
19	الشكل (1-3) أهم الشقوق والتلافيف الموجودة على الدماغ
21	الشكل (2-3) أهم الفصوص المكونة للمخ
22	الشكل (3-3) تقسيم سطح قشرة المخ إلى مناطق تبعاً للتخصص الوظيفي للخلايا العصبية
25	الشكل (4-3) تجاوز نظام BCI الطرق التقليدية في التواصل
26	الشكل (5-3) نظام ربط واجهة الدماغ حاسوب
26	الشكل (6-3) نظام الربط والتنبيؤ
29	الشكل (7-3) التخطيط الكهربائي للدماغ باستخدام الإلكترودات
30	الشكل (8-3) نظام تثبيت المجسات 20-10
31	الشكل (9-3) توزيع الإلكترودات في نظام 20-10 على فروة الرأس
32	الشكل (10-3) طرق تحميل إشارات الدماغ
33	الشكل (11-3) طرق تسجيل الإشارات الدماغية
36	الشكل (1-4) موجة دلتا
37	الشكل (2-4) موجة ثيتا
37	الشكل (3-4) موجة ألفا
38	الشكل (4-4) موجة بيتا
38	الشكل (5-4) موجة غاما
42	الشكل (6-6) مخطط عام لكيفية المعالجة الأولية لإشارات الدماغ واستخراج السمات والتصنيف
43	الشكل (7-4) مخطط تفصيلي لعملية المعالجة الأولية للإشارات الدماغية
45	الشكل (1-5) تحويل فورييه بترددات مختلفة
46	الشكل (2-5) تحويل STFT
47	الشكل (3-5) تحويل فورييه القصير زمنياً عند ترددات مختلف
48	الشكل (4-5) التحويل المويجي
49	الشكل (5-5) التحويل المويجي عند تدرجات مختلفة
50	الشكل (6-5) التحويل المويجي
51	الشكل (7-5) Haar Wavelet
51	الشكل (8-5) Mexican Hat Wavelet
56	الشكل (9-5) خطوط الفصل ضمن خوارزمية SVM
57	الشكل (10-5) الاختبار الأول لخطوط الفصل
58	الشكل (11-5) الاختبار الثاني لخطوط الفصل

59.....	الشكل (5-12) الاختبار الثالث لخطوط الفصل
60.....	الشكل (5-13) النقاط الشاذة الغير مصنفة
61.....	الشكل (5-14) عملية المقابلة بين فضاء الدخل وفضاء المميزات
61.....	الشكل (5-15) يمثل أشهر التوابع الأساس المستخدمة من قبل المصنف SVM والتي تمثل نواة عملية الفصل
64.....	الشكل (6-1) مخطط يوضح عملة قراءة ومعالجة وتصنيف إشارات الدماغ الحركية لليد اليمنى واليسرى
65.....	الشكل (6-2) المخطط الزمني لجلسة واحدة
65.....	الشكل (6-3) المخطط الزمني للنموذج ككل
66.....	الشكل (6-4) يبين مكان تموضع الإلكترودات على فروة الرأس بالإضافة لموضع الإلكترودات العينية
66.....	الشكل (6-5) قائمة بأنواع الأحداث التي تم تسجيلها
69.....	الشكل (6-6) الإشارات قبل عملية الترشيح
69.....	الشكل (6-7) الإشارات بعد عملية الترشيح
70.....	الشكل (6-8) يبين التشوهات المرافقة للإشارات الدماغية في صف بيانات ال EEG
71.....	الشكل (6-9) مصادر الضجيج المؤثر على الإشارات الدماغية
71.....	الشكل (6-10) تأثير كل إشارة على الإشارة الدماغية الصافية Pure EEG
72.....	الشكل (6-11) عملية فصل المصادر وهي الأصوات في حفلة Cocktail-Party
72.....	الشكل (6-12) استخدام خوارزمية ICA لفصل المصادر وتخمينها
73.....	الشكل (6-13) يمثل عملية التمرکز التي تحصل على البيانات
74.....	الشكل (6-14) يمثل عملية تبيض البيانات Whitening
75.....	الشكل (6-15) كيفية التخلص من المكونات الغير مرغوبة باستخدام خوارزمية ICA
76.....	الشكل (6-16) الاختلاف بين خوارزميتي ICA و PCA بطريقة الحصول على المكونات
76.....	الشكل (6-17) الاختلاف بين خوارزميتي ICA و PCA من حيث آلية العمل
84.....	الشكل (6-18) دقة التصنيف لبيانات التدريب لكل شخص
84.....	الشكل (6-19) دقة التصنيف لبيانات الاختبار لكل شخص
85.....	الشكل (6-20) المخطط المتبع من قبل البحث الذي تتم المقارنة معه
87.....	الشكل (6-21) مصفوفة الالتباس Confusion Matrix
88.....	الشكل (6-22) واجهة البرنامج المستخدم في عملية المحاكاة
89.....	الشكل (6-23) حركة تمثل انتقال الذراع نحو اليمين
89.....	الشكل (6-24) حركة تمثل انتقال الذراع نحو اليسار

فهرس الجداول

الجدول(1_2) نتائج معاملات التقارب عند تردد(0-3.90) للمهام المعرفة.....	9
الجدول(2_2) نتائج معاملات التقارب عند تردد(3.90-7.81) للمهام المعرفة.....	10
الجدول(3-2) يبين النتائج النهائية لتصنيف أربعة أصناف.....	11
الجدول(4-2) يبين نتائج التصنيف باستخدام SVM.....	15
الجدول(5-2) يبين مقارنة بين الدراسات المرجعية المذكورة سابقاً.....	15
الجدول(1-4) يبين أنواع أمواج الإشارات الدماغية وتردد كل منها والحال التي تنشط عندها تلك الموجات.....	39
الجدول(1-6) تفاصيل قاعدة البيانات المستخدمة في البحث.....	67
الجدول(2-6) عدد العينات لكل شخص.....	68
الجدول(3-6) يبين التقسيم الحاصل لكل صنف عند جميع الأشخاص.....	78
الجدول(4-6) عدد ال trials لكل صنف خلال عملية التدريب.....	78
الجدول(5-6) عدد ال trials لكل صنف خلال عملية الاختبار.....	79
الجدول(6-6) يمثل شعاع المميزات لكل حركة في الخرج.....	82
الجدول(7-6) يبين مقاييس معايير الدقة لتقرير التصنيف.....	85
الجدول(8-6) مقارنة النتائج بين البحث الأساسي والبحث الذي جرت المقارنة معه.....	86
الجدول(9-6) نتائج بارامترات ومعايير التصنيف.....	87

جدول المصطلحات

الاختصار	المعنى باللغة الإنكليزية	المعنى باللغة العربية
A-BP	Average Band Power	متوسط طاقة النطاق
AUC	Area under curve	المنطقة تحت المنحني
AR	Auto Regression	الانحدار التلقائي
BPF	Band Pass Filter	مرشح تمرير حزمة
BCI	Brain-Computer Interface	واجهة دماغ حاسوب
CSP	Common Spatial Pattern	مرشح ذو النمط المكاني المشترك
CNN	Convolutional Neural Network	الشبكة العصبونية الالتفافية
DWT	Discrete Wavelet Transform	تحويل الموجات المتقطع
EMG	Electromyography	التخطيط الكهربى للعضلات
EEG	Electroencephalogram	التخطيط الكهربى للدماغ
EOG	Electrooculogram	التخطيط الكهربى لعضلات العين
ECG	Electrocardiogram	التخطيط الكهربى لعضلة القلب
ECoG	Electrocochleography	تخطيط كهربى يستخدم لمعرفة نسبة ضغط السائل على القوقعة
EVD	Eigen Value Decomposition	تحليل القيمة الذاتية
ERD	Event-Related Desynchronization	عدم التزامن المرتبط بالحدث
ERS	Event-Related Synchronization	التزامن المرتبط بالحدث
FE	Features Extraction	استخراج السمات
FT	Fourier transform	تحويل فورييه
FFT	Fast Fourier transform	تحويل فورييه السريع
FIR	Finite Impulse Response	استجابة النبضة المحددة
FS	sampling frequency or sampling rate	معدل التقطيع

FBCSP	Filter Bank CSP	بنك الترشيح ذو النمط المكاني المشترك
GRNN	General Regression Neural Network	الشبكة العصبونية للانحدار العام
ICA	Independent Component Analysis	تحليل المكونات المستقلة
KNN	K-Nearest Neighbors	خوارزمية أقرب جار في التصنيف
LSTM	Long Short-Term Memory	ذاكرة طويلة-قصيرة المدى
ML	Machine learning	تعلم الآلة
MLP	Multilayer perceptron	شبكة بيرسيبترون متعددة الطبقات
MI	Motor Imagery	تخيل الحركة
MNE	Minimum Norm Estimates	الحد الأدنى من التقديرات المعيارية
PCA	Principal Component Analysis	تحليل العناصر الرئيسية
PSD	Power Spectrum Density	كثافة طيف الطاقة
RBF	Radial Basis Function	تابع القاعدة الشعاعية
SNR	Signal to Noise Ratio	نسبة الإشارة إلى الضجيج
SVM	Support Vector Machines	آلة دعم القرار
S-BP	Selective Band Power	طاقة النطاق الانتقائية
SM	Statistical Moments	اللحظات الإحصائية
STFT	Short-Time Fourier Transform	تحويل فورييه قصير المدى
SOS	Second Order Statistics	المتغيرات الإحصائية من الدرجة الثانية
TM	Template Matching	مطابقة النموذج

الفصل الأول

المقدمة

Introduction



1-1 المقدمة:

تعد السكتة الدماغية والحوادث المرورية واحدة من الأسباب الرئيسية التي تجعل حياة عدد كبير من الأشخاص مأساوية، بسبب تعرضهم لشلل نصفي أو عجز حاد، والذي يجلب عبئاً ثقيلاً على المريض و أسرته في أثناء الرعاية الصحية به، لاسيما أيضاً تزايد أعداد المصابين بشكل كبير جراء الحرب الأخيرة على بلدنا وبالأخص الأشخاص الذين تعرضوا لبتز بإحد الأطراف، حيث لا يوجد إحصائيات واضحة لعددهم حتى اليوم، لذلك طرحت فكرة البحث بهدف التوصل لأطراف صناعية حيّة مقادة عن طريق الإشارات الدماغية لتعويض المصابين عن أطرافهم.

خلال العقدين السابقين لم تعد الأبحاث العلمية في مجال الذكاء الاصطناعي وتعلم الآلة وخاصة فيما يسمى واجهات الدماغ والحاسب (BCI) موجهة فقط لذوي العجز الحركي، بل أصبحت موجهة أيضاً للاستخدام العام لأجل تحسين تجربة استخدامنا للحواسيب وتواصل الإنسان مع الحاسب بشكل أفضل .

واجهات الدماغ _ حاسوب: هي تقنية للتواصل المباشر بين الدماغ البشري والحاسب الآلي، بحيث يمكن للإنسان إصدار الأوامر للأجهزة الالكترونية عبر قراءة إشارات الدماغ الكهربائية وترجمتها إلى أوامر برمجية يفهمها الحاسب، بحيث يأخذ النظام المدخلات من الدماغ عبر جهاز ال (EEG) ويترجمها إلى أوامر على جهاز الحاسب .

هذه التقنية الواعدة هي التقنية الوحيدة اليوم التي يمكن أن تسمح للملايين من البشر الذين يعانون من الشلل التام أو النصفي بالتواصل والحركة من جديد. مع العلم أن هذه التقنية قد جربت في البداية على قرد وكانت النتائج جيدة .


وقد أثبتت علوم الأعصاب وجود (100) مليار خلية عصبية في دماغ الإنسان، والتي تتميز الخاصية الكهروكيميائية والتي يمكن قياسها ووصفها عن طرق أشكال إشارات أو موجات الدماغ (Delta, Theta, Alpha, Beta, Gamma) وهذه الموجات تصف نشاطات الدماغ المختلفة (نوم، خمول، حركة، تفكير وتركيز عميق إلخ)

وعلى سبيل المثال يمكن ملاحظة تغير نشاط موجات إلفا من حيث التردد الأعظمي ومطال الموجة بالإضافة إلى المجال الترددي الذي تعمل ضمنه هذه الموجة كاستجابة لفتح وإغلاق العين [2,1]. تمنح قناة التوصل بين الدماغ والحاسوب إمكانية نقل المعلومات من وإلى الدماغ على أشكال إشارات كهربائية، حيث يعتمد المبدأ العام في قراءة إشارات الدماغ على قراءة النشاطات الكهربائية عن سطح الرأس بحيث توضع أقطاب كهربائية (Electrodes) على الجمجمة الرأس وهذا النوع يدعى (Non_Invasive BCI) أي غير جراحي ويوجد طريقة أخرى للقراءة وهي عن طريق وضع الأقطاب الكهربائية على سطح القشرة الدماغية مباشرةً. وهنا نكون بحاجة لعمل جراحي ويدعى هذا النوع (Invasive BCI) [3]، ولكن تكون الإشارة في هذه الطريقة معرضة للتشويش بشكل أكبر وكمونها عالٍ لقربها المباشر من الدماغ. وهذا يساعد على إمكانية الحصول على معلومات مفيدة قادرة على إيضاح طبيعة الموجات،

تصنيفها وتحليلها، ومن ثم استثمارها للحصول على أمر تحكم يقوم بتحريك ذراع آلي بهدف إطلاق أمر إجراء مؤقت، أو تنفيذ أطراف صناعية حية لتعويض المصابين أو أصحاب الإعاقات الخاصة عن أطرافهم المفقودة [5,4]. وعلى الرغم من وجود العديد من الطرق لمساعدة أصحاب الإعاقات على سبيل المثال (التحكم الصوتي، استخدام الإيماءات، استخدام حركة العين أو استخدام جويستيك.... إلخ) ولكن لا يمكن أن يستخدمها مرضى السكتة الدماغية أو المرضى المصابين بالشلل، لذلك كانت تقنية BCI هي الأفضل، فقام الباحثان Geethu Suresh, S.Shanmugaraju في عام (2016) بتصميم نظام تحكم لاسلكي لكرسي متحرك مقاد عن طريق موجات الدماغ وباستخدام حساسات (Mindware Mobile) ويمكن للكرسي الحركة للأمام والخلف تبعاً لقوة ومضة العين، كما يمكنه أن يتحرك باتجاه عقارب الساعة عن طريق شدة الانتباه، وقد زود الكرسي بحساس أمواج فوق صوتية بهدف تجاوز العقبات [6].


قام الباحثون Marwan Nafea et al في عام 2018 بتصميم نظام تحكم بمنزل ذكي بهدف مساعدة أصحاب الإعاقات وكبار السن بأداء الوظائف اليومية، يسمح النظام للمستخدم بتشغيل وإطفاء أربعة أجهزة عن طريق ومضة العين وشدة التركيز ولكن لاحظ الباحثون وجود أوامر غير مقصودة بسبب حركة العضلات والضجيج الناتج عن قراءات غير دقيقة [7].

وقام الباحثون Tharani.k et al أيضاً في عام 2019 بطرح فكرة ثورية وهي إمكانية استخدام الواقع الافتراضي في صناعة أمر التحكم في تقنية BCI الأمر الذي يوفر إمكانيات أكبر في المعالجة وتوفير الطاقة، حيث يصبح الجهاز المحمول قادراً على القيام بعمليات أقل. تم إجراء البحث بالاعتماد على قراءة إشارات الدماغ وتحليل هذه الإشارات ودراسة إمكانية استنباط أمر تحكم يعتمد على تمييز الإشارة عنج صدور أمر تحكم من الدماغ.




الشكل (1,1) جهاز قراءة إشارات الدماغ EEG وأول تجربة بهذا المجال كانت على قرد

وفيما يأتي شكل يوضح مواقع الإلكترودات وكيفية تموضعها على الرأس:



الشكل (1-2) مواقع الإلكترودات التي تتموضع على الرأس

كما يبين الشكل الآتي الإشارات الدماغية وتردد كل حزمة من تلك الإشارات:



الشكل (1-3) أصناف وحزم إشارات الدماغ

2_1 مشكلة البحث:

تكمن المشكلة في أن إشارات الدماغ من أكثر الإشارات صعوبة في الدراسة وذلك لكثرة الضجيج فيها وقرب المراكز العصبية الحسية_الحركية من بعضها البعض وبالتالي التأثير المتبادل الذي يؤثر على دقة التصنيف وتعقيد عملية المعالجة، وهذا يحتاج إلى معالجة قد تأخذ وقتاً طويلاً بالإضافة إلى أن ذلك الضجيج يؤثر على السمات والمميزات المأخوذة من تلك الإشارات فبدون المعالجة لا يمكننا أخذ واستحصال السمات المهمة والمناسبة وذات الفائدة والكفاءة المطلوبة في البحث.

3_1 أهمية البحث:


الأهمية العلمية:

- تقديم دراسة وتحليل لطرق التواصل بين الدماغ البشري و الحاسب .
- تقديم دراسة تحليلية وعرض وتفسير الإشارات العصبية للدماغ وطرق معالجتها.

الأهمية التطبيقية:

- استخدام ذراع روبوتية تشبه اليد البشرية يمكن أن يستخدمها المعاقون والمصابون بشلل في إحدى الأطراف العلوية لمساعدتهم في القيام باحتياجاتهم اليومية.

يبين الشكل التالي تطبيق عملي لآلية قراءة إشارات الدماغ واستخدامها للتحكم في ذراع روبوتية:



الشكل (4-1) آلية العمل من بداية قراءة الإشارات الدماغية وصولاً للخروج

1-4 الهدف من البحث:

استخدام ذراع روبوت شبيهة باليد البشرية و التحكم بها عن طريق معالجة الإشارات العصبية الحركية للدماغ، والتمكن من مساعدة الأشخاص المعاقين والمصابين بشلل بإحدى الأطراف العلوية . وهذا الأمر غاية في الأهمية لما له من فائدة طبية وطنية وخصوصاً بعد تعرض العديد من المواطنين السوريين لقطع أو بتر.

1-5 محتوى الرسالة:

تتألف الرسالة من ستة فصول كما يأتي:

الفصل الأول:

عُرض في هذا الفصل مقدمة عامة للبحث وعن إشارات الدماغ وكيفية تطور دراستها عبر العقود الماضية ومدى تأثيرها في الواقع العلمي والعملية، كما عُرضت مشكلة وأهمية البحث وما هو الهدف منه، كما عُرض أيضاً ملخص لمحتوى الرسالة لكل فصل بشكل بسيط.

الفصل الثاني:

عُرض في هذا الفصل بعض الدراسات المرجعية المتعلقة بموضوع البحث، حيث قام بعض الباحثين بالاهتمام بالجزء الذي يعني بتحسين آلية معالجة الإشارات الدماغية وبعضهم الآخر بتحسين دقة تصنيف تلك الإشارات من خلال استخدام أكثر من طريقة لأخذ العينات واستخدام أكثر من مصنف للتصنيف، حيث عُرضت النتائج التي توصلوا إليها خلال الفترة الأخيرة من العقد الماضي.

الفصل الثالث:

كان لابد من الحديث عن بنية الدماغ وكيفية عمله ومكوناته من أجل فهم عملية نشوء الإشارة العصبية وانتقالها عبر الأعصاب وصولاً للوجه الحركية المطلوبة، لأن بما أن البحث يقوم على إشارات الدماغ ومعالجتها وتم التطرق في هذا الفصل لنظام واجهة الدماغ حاسوب وهو من أوائل الأنظمة وأشهرها وأفضلها للتعامل مع إشارات الدماغ، حيث يعتبر هذا النظام وكأنه قناة ربط بين الدماغ البشري والحاسوب، كما تحدثت عن كيفية وطرق استخلاص الإشارات الدماغية عن سطح فرة الرأس أو عن سطح القشرة الدماغية مباشرة وماهي الأجهزة والأدوات المطلوبة للقيام بذلك.

الفصل الرابع:

في هذا الفصل تحدثت بشكل مفصل عن إشارات الدماغ وأنواعها والحيّز أو المجال الترددي الخاص بها، لأن هناك أكثر من حزمة ترددية للأمواج الدماغية (Delta, Theta, Alpha, Beta, Gamma) وفي كل حزمة يكون لدينا نشاط محدد يعبر عن حالة الدماغ ومايقوم به الشخص، كما تم التطرق أيضاً لطرق معالجة تلك الإشارات وتحسينها) الترشيح، رفع نسبة الإشارة للضجيج SNR، خفض معدل التقطيع DownSampling، استخدام الخوارزمية ICA من أجل فصل المصادر وإزالة الضجيج والشوائب Artifacts والإشارات الحيوية الأخرى التي تؤثر على الإشارة.... إلخ (حيث عُرضت الخوارزميات والطرق المتبعة في هذه العملية بشكل عام وأيضاً بشكل خاص بالبحث.

الفصل الخامس:

في هذا الفصل تحدثت عن عملية مهمة جداً فبعد معالجة الإشارات الدماغية وهي الجزء الأهم في الدراسة تأتي عملية استخراج السمات التي لا تقل أهمية عن سابقتها، حيث عرضت الخوارزميات التي تنشط في هذا المجال وكيفية تأثيرها على دقة النتائج بعد التصنيف، فهناك العديد من السمات التي يمكن الحصول عليها من إشارات الدماغ فمنها سمات (زمانية وترددية وزمنية-ترددية ومكانية.... إلخ)، ثم تطرقت بعد ذلك لعملية التصنيف وهي العملية النهائية بعد استخراج السمات حيث اعتمدتُ على المصنف SVM وأعطى نتائج جيدة.

الفصل السادس:

وضحتُ في هذا الفصل أهم النتائج التي تم التوصل إليها ومقارنتها مع نتائج سابقة تعتمد على نفس البيانات المدروسة، ثم عرضت الآفاق المستقبلية والخلاصة.

1-6 الخاتمة:

عرضت في هذا الفصل المراحل الأساسية التي يمر بها نظام معالجة إشارات الدماغ مع شرح موجز لكل مرحلة، كما سلّط الضوء على أغلب الأعمال التي أنجزت ضمن هذه الرسالة مع توضيح كلاً من مشكلة وأهمية والهدف من البحث. وأخيراً قدمت شرحاً موجزاً لمحتوى فصول الرسالة

الفصل الثاني

الدراسات المرجعية

Reference studies

1-2 المقدمة:


نالت دراسة إشارات الدماغ وتطبيقاتها المختلفة اهتمام العديد من الباحثين وعالجت العديد من الزوايا وسلطت الضوء للنقاط المهمة في هذا المجال، وعملت على تطوير هذا المجال وخاصة في العقد الأخير، فمنهم من اهتم لعملية المعالجة الأولية لتلك الإشارات، وبعضهم عمل على تحسين دقة التصنيف وكيفية استخراج السمات. وفيما يأتي مجموعة من الدراسات التي اهتمت بموضوع البحث نفسه:

2-2 الدراسات المرجعية التي اهتمت بموضوع معالجة الإشارات الدماغية:

1-2-2 تصنيف إشارات EEG بناءً على التعرف على الأنماط:

البحث بعنوان Classification of EEG Signals Based on Pattern Recognition Approach حيث نُشر في مجلة Frontiers in Computational Neuroscience [7] بتاريخ 2017.

قام الباحثون Hafeez Ullah Amin, Wajid Mumtaz, Ahmad Rauf Subhani, Mohamad Naufal
Mohamad Saad and Aamir Saeed Malik باستخدام بعض خوارزميات تعلم الآلة ML وخوارزميات ضغط أو تقليل الأبعاد مثل خوارزمية PCA وكانت المخطط المتبع في عمليات المعالجة والتصنيف كالآتي:



الشكل (1-2) مخطط مقترح لاستخراج السمات وتصنيف إشارات ال EEG

وكانت النتائج كما يأتي:

الجدول (1_2) نتائج معاملات التقارب عند تردد (0-3.90) للمهام المعرفة

Classifier	Accuracy (%)	Sensitivity (%)	Specificity (%)	AUC	Precision (%)	Kappa Statistic
KNN, $k = 3$	98.21	96.88	99.63	0.98	99.64	0.96
SVM, RBF	99.11	99.28	98.93	0.99	98.93	0.97
MLP, $N = 5$	97.14	96.48	97.83	0.98	97.86	0.94
Naïve	89.63	88.24	90.77	0.94	91.07	0.78


الجدول (2_2) نتائج معاملات التقارب عند تردد (3.90-7.81) للمهام المعرفة

Classifier	Accuracy (%)	Sensitivity (%)	Specificity (%)	AUC	Precision (%)	Kappa statistic
KNN, $k = 3$	82.50	80.95	84.21	0.85	85	0.84
SVM, RBF	86.67	87.93	85.48	0.89	85	0.87
MLP, $N = 5$	89.17	89.83	88.52	0.90	88.33	0.89
Naïve	78.33	77.42	79.31	0.79	80	0.77

2-2-2 نموذج التعلم العميق لتصنيف EEG-MI المتعلقة بـ BCIs:

البحث بعنوان A Deep Learning MI-EEG Classification Model for BCIs [8] ونُشر في مجلة 2018 26th European Signal Processing Conference (EUSIPCO).

قام فريق من الباحثين من الجامعة التقنية في الدنمارك وجامعة غوبنهاغن وهم Hauke Dose, Jakob S. Møller, Sadasivan Puthusserypady and Helle K. Iversen باستخدام تقنيات التعلم العميق من أجل تصنيف التخيلات الحركية لإشارات الدماغ وقاموا باستخدام الترشيح المكاني باستخدام CSP وكان المخطط التوضيحي للعملية على الشكل الآتي:



الشكل (2-2) البنية المفاهيمية لشبكة CNN

وكانت النتائج كما يأتي:

الجدول (3-2) يبين النتائج النهائية لتصنيف أربعة أصناف


		predicted				recall
		L	R	0	F	
actual	L	325	16	100	42	0.672
	R	15	287	120	61	0.594
	0	28	46	358	51	0.741
	F	39	16	96	332	0.687
precision		0.799	0.786	0.531	0.683	

تبين النتائج الدقة لكل صنف من حركة اليد اليسرى L واليد اليمنى R وحالة الراحة 0 وأخيراً حركة الأقدام F.

3-2-2 نظام BCI للصور أو التخييلات الحركية يعتمد على شبكات التعلم العميق وتطبيقاته:

البحث بعنوان A Motor-Imagery BCI System Based on Deep Learning Networks and Its Applications [9] نُشر في مجلة IntechOpen في عام 2018.


قام الباحثان Jzau-Sheng Lin and Ray Shihb باستخدام تقنيات التعلم العميق DL وكانت النتائج كما يأتي:



الشكل (3-2) المقارنة بين أداء كل من LSTM و GRNN


2-2-4 BCI المستندة إلى EEG باستخدام الصور الحركية، التقنيات والتحديات:

البحث بعنوان EEG-Based Brain-Computer Interfaces Using Motor-Imagery: Techniques and Challenges [10] ونُشر في مجلة Sensors في عام 2019. قام الباحثون Natasha Padfield, Jaime Zabalza, Huimin Zhao, Valentin Masero and Jinchang Ren واعتمدوا على المخطط الآتي في عملية المعالجة الأولية واستخراج السمات والتصنيف:



الشكل (2-4) يوضح عملية استخراج واختيار السمات FE

وكانت النتائج كما يأتي:




الشكل (2-5) يوضح (a) مقارنة بين أداء ودقة الخوارزميات من أجل استخراج السمات، بينما (b) يظهر الوقت التقريبي لكل خوارزمية من أجل عملية استخراج السمات

5-2-2 التعرف على إشارة الصور الحركية EEG باستخدام الشبكة العصبية الالتفافية العميقة:


البحث بعنوان Motor Imagery EEG Signal Recognition Using Deep Convolution Neural Network [11] ونُشر في مجلة Frontiers in Neuroscience بتاريخ 2021.

قام الباحثان Xiongliang Xiao and Yuee Fang بالتعرف على إشارات الدماغ الحركية وتصنيفها باستخدام الشبكات العصبونية الالتفافية CNN حيث استخدم المخطط الآتي في عمليات استخلاص الإشارات ومعالجتها ومن ثم استخراج المميزات والتصنيف وصولاً للخروج المطلوب:



الشكل (2-6) بنية نظام التعرف على التصورات أو التخيلات الحركية MI


وكانت النتائج على النحو الآتي:



الشكل (2-7) تأثير فحص الالتفاف على نتائج تحديد الهوية

6-2-2 الاستدلال الربيع والدقيق متعدد الطبقات لـ MI-BCIs باستخدام السمات الطيفية والزمنية واسعة النطاق:

البحث بعنوان Fast and Accurate Multiclass Inference for MI-BCIs Using Large Multiscale Temporal and Spectral Features [21] ونُشر في IEEE (EUSIPCO) بتاريخ 2018. قام الباحثون Cavigelli, Luca Michael Hersche, Tino Rellstab, Pasquale Davide Schiavone, Lukas Benini and Abbas Rahimi بقراءة إشارات الدماغ وتصنيفها بالاعتماد على المميزات الطيفية والزمنية واستخدموا مصنف آلة دعم القرار SVM من أجل تصنيف الحركات الناتجة عن الإشارات الدماغية باتباع المخطط الآتي :



الشكل (8-2) المخطط المتبع في عملية معالجة وتصنيف إشارات الدماغ

ولكن الباحثين لم يقوموا بعمليات معالجة أولية على الإشارات للحصول على بيانات جاهزة لمرحلة استخراج السمات، وبذلك يتم التأثير على الدقة ويبين الجدول الآتي الدقة التي توصل إليها الباحثون ومن هنا انطلق هذا البحث بالتعديل على هذا المخطط واستخدام بعض خوارزميات معالجة الإشارة واستخراج المميزات للحصول على دقة تصنيف أعلى.

الجدول (2-4) يبين نتائج التصنيف باستخدام SVM

No. features	11352	11352
SVM kernel	linear	rbf
Riemannian kernel	N/A	N/A
Spectral bands	b_1-b_{43}	b_1-b_{43}
Temporal windows	T_1-T_{11}	T_1-T_{11}
Subject 1	86.83	85.41
Subject 2	57.24	57.24
Subject 3	86.45	80.95
Subject 4	61.40	62.28
Subject 5	61.23	67.03
Subject 6	50.70	50.23
Subject 7	92.42	86.28
Subject 8	87.82	87.45
Subject 9	79.17	85.98
Avg. accuracy	73.70±15.9	73.65±14.5

الجدول (2-5) يبين مقارنة بين الدراسات المرجعية المذكورة سابقاً

اسم البحث	تاريخ النشر	مكان النشر	منهج الدراسة	المشاكل	الدقة
[1] A Deep Learning MI-EEG Classification Model for BCIs	2018	EUSIPCO	CNN	تم استخدام الشبكات العصبونية ولكن لم يتم أخذ السمات المهمة لعملية التصنيف خلال التردد المناسب	78.6%
[2] Fast and Accurate Multiclass Inference for MI-BCIs Using Large Multiscale Temporal and Spectral Features	2018	IEEE (EUSIPCO)	ML	تم استخدام قاعدة بيانات معيارية مناسبة للدراسة وكافية للتدريب والاختبار ولكن لم يتم إجراء عمليات المعالجة الأولية المناسبة والهامة	73.70%
[3] EEG-Based Brain-Computer Interfaces Using Motor-Imagery: Techniques and Challenges	2019	Sensors	ML	لم يتم استخدام بيانات كافية لعملية التدريب وتم أخذ السمات من عملية تحويل فورييه التي أعطت دقة مقبولة ولكن أخذت وقت أطول من بقية العمليات	70.3%
[4] Motor Imagery EEG Signal Recognition Using Deep Convolution Neural Network	2021	Frontiers in Neuroscience	CNN	أعطت هذه الدراسة دقة عالية ولكن بسبب قلة البيانات اللازمة لعملية التدريب، والمشكلة الأخرى في هذا البحث أنه لم يتم بعملية معالجة أولية للبيانات المدروسة	~91%
[5] A Motor-Imagery BCI System Based on Deep Learning Networks and Its Applications	2018	Intech Open	DL	استغرق زمن تصنيف كبير جداً وقاعدة البيانات غير مناسبة نسبياً للبحث	~92%
[6] Classification of EEG Signals Based on Pattern Recognition Approach	2017	Frontiers in Computational Neuroscience	ML-PCA-DWT	دقة عالية ولكن زمن المعالجة الأولية كبير وزمن التصنيف كبير أيضاً وقاعدة البيانات حجمها صغير نحتاج لقاعدة بيانات معيارية يكون فيها حجم بيانات التدريب مناسب للبحث	99.11%

3-2 الخاتمة:


عرضت في هذا الفصل بعضاً من أهم الدراسات المرجعية المتعلقة بالبحث ومجالات معالجة إشارات الدماغ، مع بيان المنهج الذي اتبعته دراسة كل باحث من الباحثين مستعرضاً النتائج التي توصلوا إليها في كل مجال.

الفصل الثالث

الجهاز العصبي تشريحياً وفيزيولوجياً

ونظام واجهة الدماغ حاسوب

**Nervous system anatomical and
physiological and BCI System**



1-3 المقدمة:

يعتبر الجهاز العصبي مع جهاز الغدد الصم المسؤول الرئيسي عن تأمين معظم وظائف التحكم والتنظيم في الجسم، حيث يحتوي الدماغ على المراكز التي تتحكم في العمليات الذهنية والانفعالية والحسية في جسم الإنسان، ويتميز الجهاز العصبي عن بقية الأجهزة بدقة وتعقيد الأعمال التي يستطيع إنجازها، فهو يتلقى المعلومات الواردة إليه من الأعضاء الحسية المختلفة، ثم يقوم بمعالجة هذه المعلومات بشكل مناسب بحيث تحدث استجابات حركية مناسبة.

2-3 البناء العام للجهاز العصبي :General Design of the Nervous System

وسنتحدث عنه تشريحياً وفيزيولوجياً :

1-2-3 البنية التشريحية للجهاز العصبي Anatomic Structure of the Nervous System

تشريحياً يُقسّم الجهاز العصبي على:

1-1-2-3 الجهاز العصبي المركزي :Central Nervous System

يتكون الجهاز العصبي المركزي في جسم الإنسان من الدماغ (Brain) والنخاع الشوكي أو الحبل الشوكي (Spinal Cord)

ويتكون الدماغ من :


- المخ (Cerebrum)
- جذع المخ (Brain Stem) والذي يتضمن : الدماغ الأوسط (Midbrain) والجسر (Pons) والنخاع المستطيل (Medulla Oblongata)
- المخيخ (Cerebellum)

وتتحكم كل منطقة أو جزء من هذه الأجزاء في أنشطة فيزيولوجية منفصلة، وعلى الرغم من ذلك فإنّ تضافر جهود هذه الأجزاء وليس استقلاليتها في العمل هو الذي يضفي على الدماغ تلك الكفاءة العالية والفريدة التي تميز نشاطه الفيزيولوجي.

يقسم الشق الطولاني الإنسي الداخلي (Medial Longitudinal Fissure) المخ على نصفين غير منفصلين تماماً عن بعضهما بعضاً وهما نصف الكرة المخي الأيمن (Right Cerebral Hemisphere) ونصف الكرة المخي الأيسر (Left Cerebral Hemisphere)

أما نصف الكرة الأيمن فيتحكم بالحانب الأيسر من الجسم وعلى العكس منه نصف الكرة الأيسر يتحكم بالجانب الأيمن من الجسم وأحدهما يكون نصف الكرة المخي المسيطر (Cerebral Dominant Hemisphere) فالأشخاص الين يستعملون اليد اليمنى يكون نصف الكرة المخي الأيسر هو المسيطر أكثر والعكس صحيح.

ويتكون كل من نصفي كرة المخ من قشرة خارجية (Cerebral Cortex)، تحتوي على ثنيات تسمى تلافيف المخ (Gyri)، يوجد فيها العديد من الشقوق (Sulci) والشكل يوضح التلافيف والشقوق المهمة منها ووظائفها.



الشكل (1-3) أهم الشقوق والتلافيف الموجودة على الدماغ

وتقسم قشرة المخ في كل نصف كرة مخية على أربعة فصوص:

■ الفص الجبهي Frontal Lobe:

وهو مركز الوظائف العقلية مثل: الإدراك والوعي والحكم والتخطيط، وبه مراكز تتحكم في تنسيق حركات الجسم وحركات الشفتين واللسان واليدين.

وهو المسؤول عن التحكم بالعواطف والانفعالات لدى الإنسان وكذلك مهم لتعلم وممارسة المهارات الحسية الحركية المعقدة، فالأشخاص الذين لديهم تلف في هذا الفص لايقدرّون المواقف الاجتماعية وكيفية التصرف الملائم لهذه

المواقف، ولا يتحكمون بعواطفهم فتراهم يضحكون تارةً ويبكون تارةً أخرى وأي شيء يخطر على بالهم يقومون به دون تقييمه ما إذا كان فعلاً مناسباً في الموقف أم لا.

كذلك يحتوي التلفيف الجبهي السفلي في الجزء الخلفي منه في نصف الكرة المخي المسيطر على منطقة بروكا (Broca's Area) وهي المنطقة المسؤولة عن التكلم وتلفها يؤدي إلى الحبسة الحركية (Motor Aphasia) حيث إن الشخص المصاب يعرف ما يريد أن يقوله، ولكن لا يستطيع أن يتكلم أو يكون كلامه بطيئاً وغير مفهوم على الرغم من عدم وجود شلل في عضلات اللسان والحلق والحنجرة.

التلفيف أمام الشق المركزي (Precentral Gyrus) وجدار الشق المركزي الأمامي (Central Sulcus) يحتويان على القشرة الحركية (Motor Cortex) المسؤولة عن حركة العضلات الإرادية في الجانب المعاكس من الجسم أي القشرة الحركية في نصف الكرة المخي الأيمن مسؤولة عن حركة عضلات الجانب الأيسر من الجسم وعلى العكس فالقشرة الحركية في نصف الكرة المخي الأيسر مسؤولة عن حركة العضلات في الجانب الأيمن من الجسم وتلف هذه المنطقة يؤدي إلى شلل في الجانب المعاكس من الجسم.

في القشرة الحركية تكون أعضاء الجسم ممثلة بالمقلوب أي الجزء السفلي من القشرة الحركية يتحكم في اللسان والحنجرة ومن ثم الوجه وهكذا وفي الأعلى تكون منطقة التحكم بعضلات القدم.

■ الفص الجداري Parietal Lobe:

يتخصص في الإحساس، حيث تصل إليه معلومات من مستقبلات اللمس والتذوق والألم والحرارة والضغط ويتحكم كذلك في إفراز اللعاب.


ويحتوي التلفيف خلف المركزي (Postcentral Gyrus) وهذا التلفيف مع الجدار الخلفي للشق المركزي يحتويان على القشرة الحسية (Sensory Cortex) المسؤولة عن الإحساس في الجانب المعاكس من الجسم. وتلف هذه المنطقة يؤدي إلى فقدان الإحساس في الجانب المعاكس من الجسم وتكون أعضاء الجسم ممثلة بالمقلوب كما هو في القشرة الحركية.

■ الفص الصدغي Temporal Lobe:

وهو المسؤول عن عملية السمع حيث يستقبل الإشارات السمعية حيث يحتوي التلفيف الصدغي العلوي (Superior Temporal Gyrus) على مناطق السمع، وكذلك يحتوي على التلفيف الهامشي الفوقي (Supramarginal Gyrus) والتلفيف الزاوي (Marginal Gyrus) وهما يحتويان على الذاكرة الخاصة بالكلمات المقروءة والمكتوبة وتلف هذه المنطقة يؤدي إلى خلل في القراءة أو تعلمها (Dyslexia).

■ الفص القفوي (القدالي الحففي) Occipital Lobe :

يقع في مؤخرة المخ ويحتوي على مركز الإبصار وتلف هذه المنطقة يؤدي إلى العمى، والشكل يوضح الفصوص المكونة للمخ.



الشكل (2-3) أهم الفصوص المكونة للمخ


ويوجد داخل كل فص من هذه الفصوص الأربعة مناطق متخصصة في تأدية وظيفة معينة وبصفة عامة يمكن تقسيم هذه المناطق داخل كل فص إلى ثلاث مجموعات رئيسية:

❖ القشرة الحركية: وهي المسؤولة عن تنبيه نشاط العضلات.

ومنها نوعان:

- القشرة الحركية الرئيسية Primary Motor Cortex: وهي موجودة في القمم وتلافيف نصفي كرة المخ والخلايا العصبية الموجودة في هذه المنطقة تتحكم في النشاط العضلي الإرادي ومن المثير للانتباه أن الخلايا العصبية تكون مرتبة تبعاً للجزء العضلي من الجسم الذي تتحكم فيه هذه الخلايا، فمثلاً نجد الخلايا العصبية المتحكم في عضلات الركبة تتركز في المنطقة العليا من القشرة يليها الخلايا المتحكم في عضلات الفخذ، ثم الخلايا المتحكم في عضلات اليد وهكذا.

- القشرة الحركية الثانوية Premotor Cortex: وتتحكم في الحركات العضلية الناتجة عن عمليات التدريب من أي نوع مثل تدريب الأصابع على آلة موسيقية أو الكتابة على الحاسوب وهكذا.
 - ❖ القشرة الحسية الرئيسية: وتمثل المكان الذي تنتهي عنده الإشارات العصبية القادمة إلى المخ وبالمثل فإن كل جزء من أجزاء الجسم يقابله جزء من أجزاء القشرة الحسية والخلايا العصبية تكون مرتبة تبعاً للجزء من الجسم الذي يصل منه الإحساس.
 - ❖ القشرة المنسقة Association Cortex: وهي عبارة عن مساحة كبيرة من أنسجة المخ تقع بين مناطق القشرة الحركية والقشرة الحسية وتحدث فيها عملية التكامل والتناسق بين الإحساس والاستجابة كما توجد في فص مقدمة الجبهة منطقة من القشرة المنسقة تقع فيها كل النشاطات الفكرية المعقدة مثل التخطيط والابتكار والسلوك والذاكرة ويوجد في القشرة المنسقة كذلك مناطق تخزين المشاعر وتفسير معاني الكلمات وما تتضمنه من تشبيهات أو معاني مبهمه.
- والشكل يوضح المناطق سابقة الذكر والتي تمثل القشر الحركية والحسية والمنسقة



الشكل (3-3) تقسيم سطح قشرة المخ إلى مناطق تبعاً للتخصص الوظيفي للخلايا العصبية

3-2-1-2 الجهاز العصبي المحيطي Peripheral nervous system:

يتألف الجهاز العصبي المحيطي من الأعصاب القحفية والأعصاب الشوكية وهي تقوم بنقل المعلومات من وإلى الجملة العصبية المركزية وهذه المعلومات تنتقل من داخل الجسم أو من خارجه، وبدورها تقسم الجملة العصبية المحيطية على قسم وارد، وقسم صادر.

3-2-2-2 البنية الفيزيولوجية للجهاز العصبي Physiological structure of the nervous system:

يقسم الجهاز العصبي وظيفياً فيزيولوجياً إلى ثلاثة أقسام:

- القسم الحسي.
- مراكز الدمج.
- القسم الحركي.

قبل دراسة وفهم الجملة العصبية من الناحية الفيزيولوجية لابد من فهم بنية العصبون الذي يشكل الوحدة التشريحية الأساسية للجهاز العصبي ويحتوي على مايقارب 111 مليار عصبون، يموت منها ما بين 111-1 ألف خلية كل يوم يتم التخلص منها عن طريق الخلايا الدعامية وتتكدس أجسام معظم الخلايا العصبية في قشرة المخ حيث تحتوي على مايقارب 6 ملايين خلية عصبية في كل سنتيمتر مكعب.

3-2-2-1 بنية العصبون Neuron structure:

يتألف العصبون من ثلاثة أقسام رئيسية:

- جسم العصبون The Soma:

ويشكل الجزء الأساسي من العصبون ويحتوي على النواة وجهاز غولجي والمكونات الأخرى الموجودة في باقي خلايا الجسم.

- المحور الإسطوانى The Axon:

وهو استطالة هيولية طويلة ومجموع المحاور الإسطوانية يشكل الأعصاب ويمتاز المحور الإسطوانى بقدرته على نقل كمون العمل إلى نهايته المحيطية وهناك يمكن تحرر نواقل تكون مخزنة في حويصلات.

- الاستطالات السيتوبلاسمية The Dendrites:

يمتد عدد من التفرعات الهيولية خارج جسم العصبون ويختلف عددها من عصبون لآخر، ويصل طولها إلى 1 ملم في بعض الأحيان وعددها كبير جداً وتصنف العصبونات بحسب وظيفتها إلى حسية وحركية وبينية.

3-2-2-2 الوظائف المتكاملة للمراكز العصبية:

إن الوظيفة الرئيسية للجهاز العصبي هي معالجة المعلومات الواردة إليه بطريقة تسمح بحدوث استجابة حركية مناسبة. إن أكثر من 99% من المعلومات الحسية يتم نبذها وإهمالها من الدماغ لأنها غير هامة، فعلى سبيل المثال لا ينتبه الإنسان في الحالة السوية لتماس جسمه مع ملابسه ولا لضغط المقعد أثناء الجلوس ..إلخ. بعد أن يختار الدماغ المعلومات الحسية المهمة تنتقل هذه المعلومات إلى المناطق الحركية المناسبة من الدماغ لتعطي الارتكاسات (ردات الفعل) المطلوبة. تدعى عملية إدخال المعلومات في مسارها بالوظيفة التكاملية للجملة العصبية، وبناءً على ذلك إذا وضع شخص ما يده على موقد حار فإن الاستجابة المرغوبة هي إبعاد اليد عن الموقد، كما يشارك هذا الارتكاس ارتكاسات أخرى ثانوية مثل تحريك الجسم بكامله بعيداً عن الموقد والصراخ بسبب الألم.

3-3 تعريف BCI:


إن الطريقة الطبيعية للتواصل أو التحكم تعتمد عادةً على الأعصاب والعضلات، تبدأ العملية من نية الشخص بالقيام ما، تحفز هذه النية عمليات معقدة في أماكن يتم تنشيطها في الدماغ، وهكذا بدوره يولد إشارة كهربائية تنتقل عبر الجهاز العصبي الطرفي إلى العضلات الموافقة لتقوم بالحركة المناسبة.

إن نظام BCI يقدم بديلاً عن هذه الطريقة، إذ يقوم بقراءة النشاط الدماغي المرتبطة بنية الشخص مباشرةً من الدماغ ويترجمه إلى إشارات كهربائية للتحكم بتطبيقات BCI المختلفة.

أي يسمح بفتح قناة اتصال بين الدماغ والحاسوب تقوم بما يأتي:

- دماغ_حاسب: تتم عن طريق قراءة إشارات الدماغ وترجمتها إلى أوامر يستطيع أن يفهمها الحاسوب.
- حاسوب_دماغ: يقوم الحاسوب بإرسال معلومات (مشاعر، بيانات) عن طريق تحفيز مناطق معينة في الدماغ بإرسال إشارات كهربائية ضعيفة تكون بنفس الكهرباء التي تنتجها خلايا الجسم العصبية.


ويبين الشكل تجاوز الطريقة التقليدية في التواصل.



الشكل (3-4) تجاوز نظام BCI الطرق التقليدية في التواصل

3-3-1 التعريف التقليدي:

الهدف من نظام الواجهة هو إعطاء الأشخاص المصابين بإعاقة شديدة طريقة أخرى للتواصل (لا تعتمد على العضلات) ويبين الشكل نظام واجهة الدماغ حاسوب:



الشكل (3-5) نظام ربط واجهة الدماغ حاسوب

2-3-3 التعريف الحديث:

نظام يستلم إشارات حيوية مقروءة من المستخدم ويتنبأ بشكل مباشر بالأمر أو الفكرة التي يحاول المستخدم التفكير فيها كما يبين الشكل:



الشكل (3-6) نظام الربط والتنبؤ

3-3-3 تاريخ نظام BCI:

- عمل Hans Berger عام 1929 على جهاز أصبح لاحقاً يعرف باسم Electroencephalogram (EEG)، يستطيع هذا الجهاز تسجيل الإشارات الكهربائية الناتجة عن النشاط الدماغي باستخدام الكترودات، وكان هناك توقعات بإمكانية التحكم بالأجهزة المختلفة من خلال هذه الإشارات، ولكنها بقيت مجرد تكهنات لفترة طويلة.
- في عام 1964 قام الطبيب Grey Walter بوصل إلكترودات بشكل مباشر إلى الباحة الحركية لدماغ مريض (كان المريض يخضع لعملية لأسباب أخرى) وطلب من المريض أن يضغط على زر لتقليب شرائح يتم عرضها على جهاز إسقاط، وقام بتسجيل النشاط الدماغي الناتج عن هذه الحركة، ثم قام بوصل النظام إلى جهاز إسقاط، ففوجئ بأن الشرائح تم تقليبها بمجرد تفكير المريض بكبس الزر (دون كبسه فعلياً) وهنا كانت بداية وجود نظام BCI، لم يقوم الطبيب بنشر الحادثة، ولكنه أخبر بها مجموعة تدعى مجموعة Ostler في لندن.
- بقيت الأبحاث حول نظام BCI تتطور ببطء لعدة سنوات لاحقة، ولم يكن هناك سوى مختبرين يقومان بأبحاث جدية حول هذا النظام حتى نهاية القرن الماضي.
- تطورت بعدها أبحاث BCI بسرعة وخاصة في السنوات القليلة الماضية، ففي كل سنة تُنشر العديد من الأوراق البحثية والمقالات وتُعقد المؤتمرات، فالיום يوجد أكثر من 100 مجموعة بحثية تعمل على تطوير هذه التقنية وهذا العدد في تزايد مستمر.

3-3-4 تطبيقات نظام BCI المختلفة:

3-3-4-1 التطبيقات الطبية:

- إمكانية التواصل مع المرضى المصابين بمتلازمة المنحبس Locked-in Syndrome (الحالة المرضية التي يكون فيها المريض في حالة استيقاظ ووعي، ولكنه غير قادر على التواصل الشفهي مع الآخرين لكونه في حالة شلل كامل لكل عضلاته الإرادية عدا عضلات العينين).
- تسمح للمعوق أن يتحكم في الكرسي المتحرك (أو أي جهاز آخر) عن طريق التفكير.
- التحكم بأطراف الاصطناعية القابلة للتحكم عوضاً عن الأطراف الاصطناعية الثابتة.
- استعادة بعض الحواس المفقودة كالسمع والبصر.

3-3-4-2 التطبيقات التعليمية:

- مشاركة الخبرات (تجربة تناقل الخبرات بين جردين أحدهما في البرازيل والآخر في أمريكا).
- توظيف أكثر من دماغ في الوقت نفسه لحل مشكلة ما.

3-4-3-3 التطبيقات الأمنية:

- إمكانية استخراج المعلومات من المستخدم مثل الأرقام السرية، تاريخ الميلاد، مكان السكن، المعرفة بشخصية ما.
- استجواب المتهمين وإمكانية استخدامه كجهاز كاشف للكذب.
- استخدامه كجدار أمني (كلمة مرور، فتح خزانة، تشفير ملفات) عن طريق قراءة نشاطات الدماغ الناتجة عند عرض صور مختلفة.

4-4-3-3 التطبيقات الترفيهية:


- إمكانية التحكم بمختلف الأجهزة عن طريق التفكير مثل التحكم بـ (التلفاز، درجة حرارة المنزل، ألعاب الفيديو، مؤشر الحاسوب، الأجهزة الذكية.... إلخ).
- قراءة الأحلام.

5-3-3 كيف يعمل نظام BCI:

يقوم نظام BCI بقياس النشاط الدماغي، يعالجه، ويولد الإشارات التحكمية التي تعكس قصد المستخدم. ولفهم كيفية عمل النظام يجب علينا أولاً أن نفهم كيفية قياس النشاط الدماغي، وماهي الإشارات الدماغ المستخدمة.

1-5-3-3 قياس النشاط الدماغي (بدون جراحة):

إن النشاط الدماغي هو عبارة عن نشاط كهربائي ونشاط مغناطيسي، والحساسات المتوفرة يمكنها كشف أنواع مختلفة من التغيرات في هذه الأنشطة، أي في أوقات مختلفة ومناطق مختلفة من الدماغ، ولكن معظم نظم BCI تعتمد على القياسات الكهربائية للنشاط الدماغي، وذلك باستخدام حساسات توضع على الرأس لقياس هذا النشاط. كما هو مبين في الشكل الآتي:



الشكل (7-3) التخطيط الكهربائي للدماغ باستخدام الإلكترودات

3-5-3-2 التخطيط الكهربائي للدماغ :Electroencephalography

يستخدم مصطلح التخطيط الكهربائي للدماغ EEG للدلالة على عملية تسجيل النشاط الكهربائي من فروة الرأس Scalp باستخدام تقنيات الاقتباس والتضخيم (Electrodes)، وتسمى الإشارة المقتبسة بإشارة التخطيط الكهربائي للدماغ.

إن إشارات الدماغ حساسة كثيراً لما يسمى بـ (Artifacts) وهي إشارات كهربائية أخرى مثل الإشارات الحيوية الناتجة عن حركة العين EOG والإشارات الناتجة عن حركة العضلات EMG وإشارات أخرى كإشارات القلب ECG أيضاً مع المصادر المغناطيسية مثل خطوط الطاقة، حيث يمكن أن تؤثر بشكل سلبي على إشارة الدماغ وجميع هذه الإشارات يجب التخلص منها لأنها تشوش وتشوه إشارات الدماغ مما يؤثر على دقتها.


3-5-3-3 الأهداف العامة من تخطيط الدماغ:

- تشخيص حالات الأرق وموت الدماغ الغيبوبة.

- تحديد مناطق الدماغ المصابة بسبب حادث معين أو ورم.
- اختبار المسالك العصبية.
- تطبيقات التغذية العصبية الخلفية.
- التحكم بدرجة التخدير في بعض الحالات.
- تشخيص أمراض الصرع.
- مراقبة تطور دماغ الإنسان والحيوان.
- تحديد التأثيرات العصبية لبعض العقاقير.


3-3-4 النظام العالمي لمواقع الإلكترودات :Electrode Placement System

استخدمت أنظمة مختلفة لتسجيل إشارة ال EEG من فروة الرأس البشري أهمها ما أوصى بها الاتحاد الدولي لجمعيات تخطيط كهربائية الدماغ العصبية السريرية IFSECN وهو نظام فريد من نوعه لتحديد أماكن الإلكترودات، ويعرف باسم بنظام (10-20) System Ten-Twenty وقد سمي بهذا الاسم لأن المسافة بين أي الكترودين متجاورين تساوي 10% أو 20% من المسافة الكلية بين نقطتين مرجعيتين، واستُخدمت نسب لتحديد المسافات بين الإلكترودات وليس مسافات ثابتة بسبب تغير حجم الجمجمة مئة شخص لآخر، ويبين الشكل كيفية تثبيت المجسات في النظام.



الشكل (3-8) نظام تثبيت المجسات 10-20

وفقاً للنظام العالمي يوجد لكل إلكترود اسم محدد بحرف يعبر عن اسم المنطقة التي يوضع عليها الإلكترود وبرقم خاص أيضاً. فمثلاً يعبر عن الإلكترودات التي توضع على المنطقة الجبهية Frontal Lobe بحرف F بينما يعبر عن الإلكترودات الممتدة على طول المنطقة العليا في الرأس Midcoronal Plane بحرف C وتأخذ الإلكترودات المتوضعة على المنطقة الجدارية Parietal Lobe بحرف P بينما الإلكترودات التي تتوضع على المنطقة القفوية Occipital Lobe فيرمز لها بالحرف O وهناك الإلكترودات التي تكون متوضعة على الفص الصدغي Temporal Lobe فيرمز لها بحرف T وهناك إلكترودات تتوضع على القطر الطولي الدماغى فيرمز لها بحرف Zero(Z) كرمز صغير يضاف لجوار الحرف الأساسي الذي يعبر عن موضع الإلكترود، مثال على كذلك الإلكترودات Cz-Pz. بحيث تأخذ الإلكترودات أرقام صغيرة تضاف إلى جوار الحرف الأساسي، تعبر الأرقام الزوجية منها إلى أن الإلكترودات واقعة في النصف الأيمن للدماغ، بينما الأرقام الفردية تعبر عن الإلكترودات الواقعة في النصف الأيسر من الدماغ، ويبين الشكل توزيع الإلكترودات في نظام 10-20 على فروة الرأس.




الشكل (3-9) توزيع الإلكترودات في نظام 10-20 على فروة الرأس

3-3-5-5 Way of Measurement :تحميل إشارات الدماغ

تُؤخذ إشارة الدماغ عادة بواسطة عدة أزواج مختلفة من الإلكتروودات بهدف الحصول على عدة إشارات مختلفة من إشارات الدماغ، وبالتالي الحصول على فكرة عامة عن كامل إشارات الدماغ وليس لمنطقة محددة فقط، وهناك طريقتنا لاقتباس إشارة الدماغ وهما:

- الطريقة أحادية القطبية: يوصل مدخل واحد من المضخم إلى إلكترود مرجعي متوضع على شحمة الأذن، بينما المدخل الثاني إلى الإلكترود العادي.
- الطريقة ثنائية القطبية: توصل أزواج من الإلكتروودات السطحية إلى مداخل المضخمات في ترتيب متناسق، وعادة توصل نصف هذه المداخل إلى إلكترودات من جانب واحد من الرأس، وبذلك نتمكن من مقارنة الفعالية الكهربائية للمناطق المتناظرة من الدماغ بمقارنة إشارة إلكترود مع إلكترود آخر.

يبين الشكل شرحاً لطرق تحميل إشارات الدماغ حيث الشكل A يبين الطريقة ثنائية القطبية والشكل B يبين الطريقة أحادية القطبية.




الشكل (3-10) طرق تحميل إشارات الدماغ

3-3-5-6 قياس النشاط الدماغي (مع جراحة):

إن التقنية التي عُرضت مسبقاً تدعي بطريقة التسجيل الغير اجتياحية، أي لاحتياج إلى أي عمل جراحي أو حتى اختراق للجلد، أما طرق التسجيل الاجتياحية فتتطلب إجراء عمل جراحي لزرع (غرس) الحساسات، وهذا العمل الجراحي يتضمن

فتح الجمجمة، وقطع الأغشية التي تغطي الدماغ، ومن ثم زرع الإلكترودات فإذا وضعت الإلكترودات على القشرة المخية (تحت الجمجمة وفوق القشرة مباشرة) دون اختراق الدماغ ومن ثم تسجيل الإشارة فإن هذه الطريقة تسمى: ECoG وإذا تم الوصول إلى داخل القشرة الدماغية ومن ثم وضع الإلكترودات وتسجيل الإشارة فإن هذه الطريقة تسمى: Intracortical Recording ويبين الشكل الآتي طرق تسجيل الإشارات الكهربائية الحيوية من الدماغ.



الشكل (3-11) طرق تسجيل الإشارات الدماغية

4-3 الخاتمة:

استعرضنا في هذا الفصل البناء العام للجهاز العصبي من الناحيتين التشريحية والفيزيولوجية، واستعرضنا التلايف والشقوق المكونة للدماغ ودورها الوظيفي، كما تطرقنا إلى الخلية العصبية بنيةً ووظيفةً، ومن ثم شرحنا نظام ال BCI بشكل مفصل وكيفية قراءة إشارات الدماغ وطرقها.

الفصل الرابع

الأمواج الدماغية وطرق المعالجة

**The brain waves and methods of
processing**



4-1 المقدمة:

واجهة الدماغ حاسوب تعبر عن نظام تواصل مباشر بين الدماغ وجهاز الحاسوب، هذه القناة تمنح إمكانية نقل المعلومات من وإلى الدماغ على شكل إشارات كهربائية، إذ يتم قراءة النشاطات الكهربائية من الدماغ باستخدام أقطاب كهربائية توضع على سطح الجمجمة (قراءة خارجية) أو سطح الدماغ مباشرة (قراءة داخلية)، وهذا النوع من الاتصال (دماغ حاسوب) يسمح للمستخدم أن يرسل أوامر للحاسوب عن طريق التفكير، كما يمكنه إرسال المعلومات إلى الدماغ (حاسوب دماغ) عن طريق تحفيز الدماغ بإرسال إشارات كهربائية ضعيفة.

انطلقت البحوث في هذا المجال في سبعينيات القرن الماضي في جامعة كاليفورنيا في لوس إنجلوس في إطار منحة من مؤسسة العلوم الوطنية، وكان مجال البحث هو التركيز في المقام الأول على الأطراف الاصطناعية في التطبيقات التي تهدف إلى استعادة تلف السمع أو البصر أو الحركة، وفي آخر عشر سنوات لقي هذا المجال اهتمام الكثير من الباحثين من مختلف المجالات، والسبب الرئيس يعود إلى تطور الأدوات التقنية والخوارزميات الرياضية لمعالجة إشارات الدماغ بشكل أفضل.

أصبح هذا المجال خصباً لاستقطاب الباحثين في الكثير من المجالات على رأسها المجالات الطبية والهندسية، على الرغم من انطلاق هذا المجال في سبعينيات القرن الماضي إلا أن الطريق مازال طويلاً لتطوير نظام يستطيع التفاعل مع الدماغ بشكل عملي، وهناك تطبيقات كثيرة لهذا المجال، ابتداءً من التطبيقات الطبية لمساعدة المعوقين على التحكم بالأطراف الاصطناعية إلى الاستخدامات العملية والترفيهية مثل كتابة رسائل نصية عن طريق التفكير.

إن عملية معالجة إشارات الدماغ تعتمد على متغيرات وعوامل مجهولة مسبقاً، حيث تختلف من شخص لآخر وتختلف أيضاً بحسب الأمر (المهمة المطلوب التفكير بها)، حيث يختلف شكل إنطواء القشرة الدماغية من شخص لآخر (حتى عند التوأم) وأيضاً تختلف الخريطة الوظيفية للدماغ، وبالتالي يختلف مكان توضع الحساسات من تجربة إلى أخرى ونضيف إلى ذلك أن ديناميكية الدماغ غير ثابتة وتختلف مع مرور الزمن لذلك كان لابد من استخدام مجموعة من البرامج والأدوات لمعالجة تلك الإشارة وفهمها.

4-2 الأمواج الدماغية:

الموجات الدماغية عبارة عن موجات كهربائية ذات ترددات معينة، وهي تنتج عن عمل ونشاط الخلايا العصبية في الدماغ أو العصبونات Neurons. فعلياً تمثل الموجات الدماغية أفكارنا ومشاعرنا وأحاسيسنا وردات فعلنا.


تقسم الموجات الدماغية لعدة حزم ترددية Bandwidths، حيث تمثل كل حزمة مئة هذه الحزم نمطاً معيناً من النشاطات العقلية. ومن المنطقي أن نلاحظ أن الحزم عالية التردد تمثل النشاط العقلي المركز والشديد وهي المعروفة باسم أمواج Gamma بينما تمثل الحزم منخفضة التردد نشاطاً عقلياً منخفضاً، مثل حالة النوم وتعرف هذه الأمواج باسم Delta. وبالتالي فإن الموجات الدماغية ستختلف بحسب النشاط الدماغى الضي يقوم به الإنسان وبحسب الأحاسيس التي يشعر بها. فعندما نشعر بالتعب والاسترخاء تكون الموجات الدماغية ذات الترددات المنخفضة هي المسيطرة والأكثر انتشاراً، بينما تنتشر الموجات الدماغية عالية التردد عندما بحالة تركيز عالٍ ونشاط شديد.

يتم قياس تردد الأمواج الدماغية بوحدة "الهرتز" وفيما يأتي تصنيف الأمواج الدماغية وفقاً للحزم الترددية التي تنتمي إليها.

4-2-1 أنواع الأمواج الدماغية:

- موجات دلتا Delta Waves [0.1-4]Hz:


وهي أبطأ الموجات الدماغية من حيث سرعة الانتشار، وهي ذات تردد منخفض جداً ويتم توليد هذه الأمواج في الحالات الراحة والسكون كحالات التأمل الهادئ أو النوم العميق. كما أن موجات دلتا مصدر المشاعر الخاصة بالتعاطف، حيث يبين الشكل موجة دلتا.



الشكل (1-4) موجة دلتا

- موجات ثيتا Theta Waves [4-8]Hz:


تظهر موجات ثيتا في أغلب الأحيان في أثناء النوم (ليس النوم العميق الذي تظهر فيه موجات دلتا)، وقد تظهر في بعض الأحيان في حالات التأمل الطويل والعميق، يتم تشبيه موجات ثيتا على أنها الطريق للوصول للذكريات والمعلومات المخزنة ضمن الدماغ، كما أن موجات ثيتا مسؤولة عن سحب حواسنا من التركيز على الوسط المحيط إلى التركيز على الإشارات التي يتم توليدها ضمن الدماغ. موجات ثيتا أيضاً هي المسؤولة عن الأحلام، حيث تعمل موجات ثيتا على توليد صور ومشاهد حية ومعلومات ومعارف لا ترتبط بالإدراك والوعي المباشر الذي نحصل عليه من حواس السمع والبصر وغيرها.. إلخ، حيث يوضح الشكل موجات ثيتا.



الشكل (2-4) موجة ألفا

- موجات ألفا [8-12]Hz Alpha Waves:

تظهر موجات ألفا أثناء النشاطات العقلية المتصلة بالإدراك والوعي، ولكنها تمثل نشاطات عقلية هادئة، حيث تمثل موجات ألفا الحالة الهادئة للدماغ، وهي تعني أن الدماغ واعٍ ويدرك ما حوله، ولكنه غير نشط أو فعال، ويمكننا تشبيهه بحالة "Stand By" الخاصة بجهاز الحاسوب، حيث إن الحاسوب لا يقوم بتنفيذ أي عمل يتطلب قدرات المعالج، إلا أنه جاهز لاستقبال أي إشارة أو تنبيه وهنا الشكل يوضح موجات ألفا.




الشكل (3-4) موجة ألفا

- موجات بيتا [12-32]Hz Beta Waves:

تظهر موجات بيتا بشكل كبير عندما يكون الدماغ بحالة وعي وإدراك ويقوم أيضاً بتنفيذ وظائف ومهام متنوعة، وهي ترتبط جميعها بالإدراك والوعي الناتج عن الحواس. تمثل أمواج بيتا حالة النشاط الدماغية، وعندما تنتشر عبر الدماغ فهذا يعني أننا نقوم بوظائف متنوعة مثل التفكير وحل المشاكل والنظر والاستماع ونلتقي التنبيهات المختلفة، ويبين الشكل موجة بيتا التي بدورها تنقسم إلى ثلاث حزم ترددية أخرى [2] على الشكل الآتي:


- موجات بيتا المنخفضة Beta1: وهي موجات تغطي الحزمة الترددية [12-15]Hz وهي تمثل أخفض حالة من نشاطات اليقظة والوعي والإدراك الدماغية.
- موجات بيتا المتوسطة Beta2: وهي الموجات التي تغطي الحزمة الترددية [15-20]Hz وهي تمثل تزايد تركيز النشاط العقلي الدماغية.
- موجات بيتا العالية Beta3: وهي الموجات التي تغطي الحزمة [20-32]Hz حيث تمثل هذه الموجات الأفكار المعقدة، وتعلم الخبرات الجديدة وحالات الإثارة الدماغية.



الشكل (4-4) موجة بيتا

- موجات غاما $[Gamma\ Waves > 30]Hz$:

موجات غاما هي أسرع الموجات الدماغية وأعلاها من حيث التردد. تمثل موجات غاما حالات التركيز العقلي الشديد والتفكير المركز والمنظم، كما تمثل أيضاً استجابة عدة مناطق دماغية من أجل المساهمة في عملية تفكير مركزة واحدة. كانت موجات غاما تعتبر عبارة عن نشاط دماغي إضافي ليس له أي معنى، إلا الأبحاث قد بينت أنها تمثل فعلياً أعلى درجات النشاط الدماغي وقد بين الشكل موجة غاما. أحد الألغاز المتعلقة بموجات غاما أنها تمتلك تردداً أعلى من قيمة تردد انتقال الإشارات عبر العصبونات نفسها، وكيفية توليد ونشوء موجات غاما الدماغية لا يزال يعتبر أحد الألغاز الهامة في مجال علم الأعصاب [2].



الشكل (4-5) موجة غاما

3-4 معالجة إشارات الدماغ EEG Processing:

تتكون الإشارات التي تتم قراءتها من الدماغ على إشارات الدماغ المرادة بالإضافة إلى إشارات تشويش (Artifacts) وهي الإشارات التي يكون مصدرها غير الدماغ، وأغلب مصادر تلك الإشارات هي مصادر حيوية مثل حركة العين والعضلات وضربات القلب بالإضافة إلى مصادر تكون خارج الجسم مثل حركة الأقطاب الكهربائية والتشويش الذي يحصل عليها.

يتم تحديد التشويش عن طريق ترشيح الإشارات الكهربائية ذات التردد الأعلى أو الأقل من تردد إشارات الدماغ الطبيعية كما وتصنف الإشارات الدماغية تبعاً للمنطقة التي تنشط بها والمجال الترددي كما هو مبين في الجدول :

الجدول (4-1) يبين أنواع أمواج الإشارات الدماغية وتردد كل منها والحالة التي تنشط عندها تلك الموجات

نوع الموجة	المنطقة التي تنشط بها	المجال الترددي	الحالة الطبيعية التي تنشط بها
Delta	الجبهة	[0.1-4] Hz	التأمل و النوم العميق
Theta	القشرة الصدغية	[4-8] Hz	الأحلام
Alpha	مؤخرة الرأس	[8-12] Hz	الراحة أثناء إغلاق العينين
Beta	جانبي الرأس	[12-30] Hz	الإدراك والتفكير والتركيز الشديد
Gamma	القشرة الحسية الجسدية (Somatosensory Cortex)	More than 30 Hz	فرط النشاط الدماغى والتفكير العميق المعقد والتركيز الشديد

4-4 الأدوات المستخدمة في عملية معالجة إشارات الدماغ:

إن جميع حساسات الدماغ تقوم بقراءة إشارات تشابهية في نفس الوقت، وبالتالي فإن إشارة الدماغ ستكون متداخلة لذلك تعتبر معقدة رياضياً مما يستوجب استخدام خوارزميات علم الإحصاء لفصل تلك النشاطات الكهربائية المترابطة للحصول على واجهة ذات أداء مثالي، وقد تم تطوير مجموعة من الأدوات مبنية في بيئات برمجية مختلفة بهدف معالجة تلك الإشارات.

حيث يوجد العديد من الأدوات المتاحة التي تمكننا من معالجة إشارات الدماغ ونذكر منها:

▪ BioSig:

وطوّرت في معامل TU Graze منذ عام 2002، وتعتبر من أقدم الأدوات المتوفرة كمصدر مفتوح لاستخدامها مع برنامج Matlab، إذ تحتوي على عدد كبير من مختلف البيانات الإحصائية ولا تدعم التطبيقات التي تتطلب تجاوب مباشر (Real Time)، ولكن تستخدم في التحليلات بشكل غير مباشر (Offline) ولا تحتوي واجهة رسومية لاستخدامها، وإنما تتطلب كتابة أكواد مما يجعل التعامل معها نوعاً ما صعباً على المستخدم [13].

▪ BCI2000:

وطوّرت في مركز Wadsoworth منذ عام 1999، وهي نظام مطور باستخدام لغة C++ ، حيث تم تطويره ليستخدم في تطبيقات واجهة الدماغ حاسوب التي تتطلب العمل بشكل مباشر (معالجة فورية) وتحتوي على نظام متكامل يشمل معالجة إشارات الدماغ ويسمح بالتحكم الكامل بالتجربة ويدعم معظم أجهزة قياس النشاطات الكهربائية، ولكنها تقفد إلى معالجة الإشارة بطرق متورة وخوارزميات تعلم الآلة حيث يصعب على المستخدم تطوير النظام .

▪ Open Vipe:

تم تطويرها في INRIA منذ 2011 باستخدام لغة C++ حيث تستخدم البرمجة المرئية Visual Programming وبرمجة تدفق البيانات Data Flow Programming وتحتوي على واجهة سهلة الاستخدام وتركز على استخدام معالجة الإشارة بطرق بسيطة كما أنها لاتدعم معالجة الأنظمة لإضافة ملاحق برمجية لتطوير النظام [14,15] .

▪ g.BSanalyze:

نظام تجاري تم تطويره من g.tec وهو قائم على برنامج Matlab، يحتوي على كم هائل من الخوارزميات المطورة ويحتوي على واجهة مستخدم رسومية ذات دقة عالية، ولكنه يدعم الأجهزة التي يتم تطويرها من قبل g.tec فقط .

▪ BCILAB:

وطوّرت في مركز Swartz منذ عام 2010 وتعتمد في تشغيلها على برنامج Matlab كما [16,17] أنها تدعم التحليل المباشر وغير المباشر وتحتوي عدد كبير من الخوارزميات المتعلقة بواجهة الدماغ حاسوب لمعالجة الإشارة واستخدام تقنيات تعلم الآلة، وأيضاً تحتوي على واجهة رسومية لتسهيل المهمة على المستخدم بالإضافة إلى أنها تقبل إضافة ملاحق (Plug in) لتطوير نظام واجهة الدماغ حاسوب، ولكنها لاتدعم الكثير من الأجهزة الخارجية، ولكن يمكن ربطه بشكل مباشر باستخدام الأنظمة الأخرى BCI2000 .

▪ EEGLAB:

عبارة عن صندوق أدوات MATLAB يوزّع بموجب ترخيص BSD المجاني لمعالجة البيانات من تخطيط كهربية الدماغ (EEG) وتخطيط الدماغ المغناطيسي (MEEG) وإشارات الفيزيولوجيا الكهربائية الأخرى. إلى جانب جميع أدوات المعالجة الأساسية، تنفذ EEGLAB تحليل المكونات المستقلة (ICA) ، وتحليل الوقت / التردد، ورفض التشوهات (Artifacts)، والعديد من أنماط تصور البيانات. تسمح EEGLAB للمستخدمين باستيراد بيانات الفيزيولوجيا الكهربائية الخاصة بهم في حوالي 20 تنسيقاً للملفات الثنائية، والمعالجة الأولية للبيانات، حيث يمكن التخلص من مكونات ICA المصطنعة في البيانات. بالإضافة أنه يمكن معالجة وتحليل مكونات ICA التي تمثل نشاط الدماغ.

تسمح EEGLAB للمستخدمين [12] بتجميع البيانات من عدة أشخاص، وتجميع مكوناتهم المستقلة باتباع عملية العنقدة (Clustering).

في عام 1997 أطلقت مجموعة من وظائف معالجة البيانات لأول مرة على الإنترنت بواسطة Scott Makeig في مختبر علم الأحياء العصبية الحاسوبية الذي يديره Terry Sejnowski في معهد Salk، تحت اسم "صندوق أدوات ICA / EEG". وفي عام 2000، صمم Arnaud Delorme واجهة مستخدم رسومية فوق هذه الوظائف جنباً إلى جنب مع بعض وظائف إزالة التشوهات من الإشارة، وأصدر الإصدار الأول من الأداة في عام 2003، اتحدت جهود كل من Delorme و Makeig لإطلاق أول نسخة مستقرة وموثقة بالكامل من EEGLAB وكان ذلك في عام 2004، حيث حصلت EEGLAB على تمويل من المعاهد الوطنية للصحة لمواصلة تطوير برامج البحث.


▪ MNE:

وهي أداة لتحليل بيانات MEG و EEG ضمن لغة Python حيث صُممت لمعالجة الإشارات الدماغية بما في ذلك التحليل الترددي والزمني للإشارة، إضافةً إلى العديد من الوظائف والمهام المتطورة جداً كالمعالجة الأولية للإشارات ونمذجة البيانات وعرضها بالاعتماد على طرق تعلم الآلة والخوارزميات الأخرى.

4-5 المعالجة الأولية لإشارات الدماغ EEG Preprocessing:


استخدمت الأداة EEGLAB بالإضافة لبعض الأكواد بلغة Python من أجل المعالجة الأولية للبيانات قبل الدخول في مرحلة استخراج السمات والتصنيف وصولاً إلى الخرج المطلوب، حيث يمكننا من خلال الأداة المعتمدة على برنامج Matlab من تحميل أي نوع أو تنسيق من بيانات أو إشارات الدماغ ومن بعدها إضافة إحداثيات الإلكتروتودات التي استخدمت في عملية تحصيل البيانات ومن ثم تحميل إحداثيات الإشارات وهنا يقصد بها ما الغرض الذي تم التوصل إليه من عملية تحصيل هذا النوع من البيانات ثم نبدأ بعد ذلك بعملية المعالجة حيث يمكننا مرشح من نوع FIR ويستخدم ضمن المجال الترددي [8-30] Hz لأن هذا المجال هو التردد المهم في عملية تحليل إشارات الدماغ الحركية EEG MI حيث يهمننا هنا الحزمتين التردديتين (ألفا وبيتا) لأنهما لهما التأثير الأكبر في حالة حركة اليدين أو الرجلين التي يكون فيها منبع تلك الإشارات من الباحة الحسية الحركية Sensorimotor Cortex وبعد عملية الترشيح يمكننا تخفيض عدد العينات المتخذة من الإشارة Down Sampling بحيث لا يتم التأثير الكبير على الإشارة وبعد ذلك تأتي عملية تحديد أو اختيار البيانات المرغوب بها فالبيانات المستخدمة في دراستنا تم تحصيلها من خلال 25 قناة وهنا تكمن الإشارة إلى أنه من غير الضروري استخدام كل تلك الإشارة أولاً لعدم أهميتها جميعها وثانياً من أجل تقليل

التكلفة الحسابية وزمن التنفيذ فيمكننا اختيار قنوات محددة يمكننا الاعتماد عليها في الدراسة، ومن بعد ذلك يأتي دور الأداة في عملية التخلص من التشوهات في الإشارة (Artifacts) ورفع نسبة الإشارة إلى الضجيج SNR وكما ذكرنا سابقاً أنواع التشوهات التي تؤثر على إشارات الدماغ وهنا يمكن استخدام خوارزمية أو طريقة تسمى تحليل المكونات المستقلة ICA حيث بعد استخدام هذه الطريقة من خلال الأداة نكون قد تخلصنا بنسبة كبيرة من تلك التشوهات وإزالة المكونات (Components) غير المرغوب فيها من الإشارة بعد ذلك نكون قد قطعنا شوطاً كبيراً منة عملية معالجة البيانات وتجهيزها لعملية استخراج السمات Features Extraction، وهنا لدينا في الشكل مخطط عام لكيفية معالجة إشارات الدماغ:



الشكل (4-6) مخطط عام لكيفية المعالجة الأولية لإشارات الدماغ واستخراج السمات والتصنيف

مرحلة المعالجة الأولية للبيانات (إشارات الدماغ) تعتبر من أهم المراحل خلال التصنيف وصولاً للخروج المرغوب به والدقة المطلوبة، وهنا نستعرض مخططاً تفصيلياً لمرحلة المعالجة الأولية باستخدام أداة EEGLAB كما في الشكل :



الشكل (4-7) مخطط تفصيلي لعملية المعالجة الأولية للإشارات الدماغية


6-4 الخاتمة:

آلية ودقة تحصيل إشارات الدماغ واستخدام المرشحات المناسبة ومن بعدها استخدام الطرق والخوارزميات الجيدة في عملية المعالجة الأولية هي من أهم المراحل التي يجب علينا التركيز عليها لكي نصل إلى بيانات جيدة قابلة للتصنيف وتعطي نتائج ودقة عالية وفيما سبق تم شرح الخطوات العامة والتفصيلية لمرحلي الحصول على البيانات وكيفية معالجتها.

الفصل الخامس

استخلاص السمات والتصنيف

Feature Extraction and Classification




5-1 المقدمة:

كانت عملية التخطيط الكهربائي للدماغ في البداية مقصورةً على دراسة حالات الصرع والأمراض العقلية المرافقة لها، ولكن مع دخول تقنية BCI إلى مراكز الأبحاث في سبعينيات القرن الماضي أصبح لابد من إيجاد خوارزميات جديدة تساعد في تحليل الأمواج الدماغية وفهمها للتمكن من الحصول على أمر تحكم حيث تدعى هذه الخوارزميات بخوارزميات الترجمة حيث يتم ترجمة الإشارات الناتجة من المرحلة السابقة إلى أوامر بواسطة الحاسب، ويمكن أن نلاحظ من المراحل السابقة أن إشارة الدماغ هي إشارة ليست دورية وغير منتهية لذلك من الصعب تحليلها بواسطة تحويل فورييه والطرق التقليدية الأخرى.

5-2 تحويل فورييه Fourier Transformation:

قام العالم جوزيف فورييه في عام 1822 بإنتاج ما يعرف بتحويل فورييه، وهو طريقة من أجل تمثيل الإشارات الدورية باستخدام سلسلة من موجات الجيب وجيب التمام، طوّرت من أجل أية إشارة حتى لو لم تكن دورية بإنهاء دورها للانتهاء، عندها ينتج ما يعرف بتحويل فورييه، ويقوم التحويل بنقل الإشارة من مجال الزمن إلى مجال التردد وبالعكس [24].



الشكل (5-1) تحويل فورييه بترددات مختلفة

إن تحويل فورييه $X(f)$ يفكك الإشارة الزمنية $x(t)$ باستخدام الموجات الجيبية التي هي موجات طويلة ذات ترددات مختلفة.

$$X(f) = \int_{-\infty}^{\infty} x(t) e^{-i2\pi ft} dx$$


حيث يمكن إيجاد تحويل فورييه العكسي من العلاقة:

$$x(t) = \int_{-\infty}^{\infty} X(f) e^{+i2\pi ft} dx$$

نلاحظ أن المعلومات المتعلقة بالزمن ستختفي، لكن لا تفقد بسبب تكاملها، لذلك تحويل فورييه سيكون دالة بالتردد فقط ولا يستطيع أن يبين لنا ماهي الفترة الزمنية التي حصل فيها التردد كما أن تحويل فورييه يصبح غير فعال للإشارات غير الثابتة (متغيرة التردد) لكونه لا يزودنا بمعلومات عن المحتوى الترددي خلال الزمن، لهذا السبب تم تطوير ما يعرف بتحويل فورييه القصير زمنياً (STFT).

5-3 تحويل فورييه القصير زمنياً Short Time Fourier Transformation:

يقدم هذا التحويل حلاً للمشكلة السابقة عن طريق استخدام ما يعرف بالنافذة ثابتة العرض كما في الشكل، إذ يقوم هذا التحويل بتمثيل الإشارة زمنياً وترددياً على حساب دقتها الزمنية والترددية، إذ هذا يتعلق بالنافذة المستخدمة [25].



الشكل (5-2) تحويل STFT

يتم تحريك النافذة على طول الإشارة مع إجراء التحليل بضرب الإشارة بتابع النافذة في عدة نقاط زمنياً، والتابع الأسّي ينقل الإشارة من مجال الزمن إلى مجال التردد، ونعبر عنه بالعلاقة:


$$X(t, f) = STFT \{x(t)\} = \int_{-\infty}^{\infty} x(\tau) h(\tau - t) e^{-j 2\pi f \cdot \tau} d\tau$$

$$x(t) = STFT^{-1} \{X(t, f)\} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} X(\tau, f) e^{+j 2\pi f t} d\tau \cdot df$$

إن النافذة الزمنية تحقق ما يأتي:

$$h(t) \geq 0 \quad \forall t ; \quad h(-t) = h(t) ; \quad \int_{-\infty}^{\infty} h(t) dt = 1$$


يقوم تحويل فورييه القصير زمنياً بتقسيم مستوي (التردد-الزمن) بدقة موحدة لكل الترددات، ولكن في بعض التطبيقات يجب أن تعامل الترددات العالية بشكل مختلف عن الترددات المنخفضة، وبالتالي فإن المشكلة في هذا التحويل هو الضياعات الزمنية والترددية، إذ إنه عند استخدام نافذة صغيرة يتم الحصول على دقة عالية من أجل العناصر التي تتغير بسرعة، بينما لا تكون هذه الدقة عالية للعناصر المتغيرة ببطء، ويحدث العكس عند استخدام نافذة كبيرة.



الشكل (3-5) تحويل فورييه القصير زمنياً عند ترددات مختلفة


4-5 التحويل المويجي Wavelet Transformation:

التحويل المويجي هو تطوير للطريقة السابقة إذ إنه يستخدم نافذة متغيرة العرض بدلاً من استخدام نافذة ثابتة العرض، حيث يتم تغيير عرض النافذة للحصول على المعلومات مختلفة التردد على طول الموجة فيتم الحصول على ما يعرف بالموجات التي يختلف ترددها بحسب عرض النافذة المستخدم [25] كما في الشكل الآتي:



الشكل (4-5) التحويل المويجي

وفي مقارنة بين الموجات Wavelets مع الموجات الجيبية والتي هي أساس تحليل فورييه نجد أن المنحنيات الجيبية ليس لها مدة محدودة، حيث إنها تمتد $[-\infty, +\infty]$ وتكون المنحنيات الجيبية سلسلة يمكن التنبؤ بها، تميل الموجات إلى أن تكون غير منتظمة وغير متماثلة، والشكل يوضح التحويل المويجي عند تدرجات مختلفة.



الشكل (5-5) التحويل المويجي عند تدريجات مختلفة

فتقوم النافذة الصغيرة بإنتاج موجبة مضغوطة تتضمن العناصر ذات التردد المرتفع والتي تعرف أيضاً بالعوامل التفصيلية، وتقوم النافذة الكبيرة بإنتاج موجبة ممددة تتضمن العناصر ذات التردد المنخفض والتي تعرف أيضاً بالعوامل التقريبية، ويمكن تعريف الموجبة على أنها إشارة محدودة الطول الزمني تمتلك قيمة متوسطة تساوي الصفر، ويعطى تحويل الموجبة بالعلاقة:

$$W_x(t, s) = \frac{1}{\sqrt{s}} \int_{-\infty}^{\infty} x(\tau) \psi^*\left(\frac{\tau - t}{s}\right) d\tau$$

حيث إن τ : هو فارق الزمن بالثواني.

ψ^* : المرافق العقدي للموجة ψ .

وأن $s \in \mathbb{R}^+ - \{0\}$ هو التدرج الذي يتناسب عكسياً مع التردد

تدعي $\psi(t)$ بالموجة الأم.

ويعطى معكوس تحويل الموجبة بالعلاقة الآتية:

$$x(t) = \frac{1}{c_\psi} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} W_x^\psi(\tau, s) \frac{1}{s^2} \psi\left(\frac{t - \tau}{s}\right) d\tau \cdot ds$$

حيث إن:

$$c_{\psi} = \int_{-\infty}^{\infty} \frac{|\Psi(f)|^2}{|f|} df$$

بشرط $c_{\psi} < \infty$ (محدود)، وهذا يؤدي بدوره إلى:

$$\Psi(0) = 0 \rightarrow \int_{-\infty}^{\infty} \psi(t) dt = 0$$

لذلك فإن الموجة يجب أن تكون متذبذبة، ولتحقيق مبرهنة بارسفال بطاقة قياسية يجب أن تكون $\psi(t)$ قابلة للتكامل تربيعياً كما يأتي:

$$\int_{-\infty}^{\infty} |\psi(t)|^2 dt = 1$$


5-4-1 الموجة الأم:

تُضغط الموجة عند التدرج المنخفض وتمديدها عند التدرج المرتفع، ولأنه يتم إجراء الحسابات للموجة بدلالة الزمن والتدرج، فإن تمثيل الموجة يتم على محوري الزمن والتدرج ويسمى بالموجة الأم والذي نحصل من خلاله على بقية الموجات بتغيير قيمة التدرج والانتقال، وفيما يلي بعض الأمثلة على الموجة الأم:

• Morlet Wavelet:

يبين الشكل موجة مورلت وتعطى بالعلاقة:

$$\psi(t) = e^{-t^2/2} \cos(5t) \xleftrightarrow{FT} \Psi(f) = \sqrt{2\pi} e^{-(2\pi f - 5)^2/2} + \sqrt{2\pi} e^{-(2\pi f + 5)^2/2}$$




الشكل (5-6) التحويل الموجي

• Haar Wavelet :

يبين الشكل موجة هار وتعطى بالعلاقة:

$$\psi(t) = \begin{cases} 1 & 0 \leq t \leq 0.5 \\ -1 & 0.5 < t < 1 \\ 0 & \text{elsewhere} \end{cases} \xleftrightarrow{FT} \Psi(f) = j e^{-j\pi f} \sin(\pi f / 2) \cdot \text{sinc}(\pi f / 2)$$




الشكل (5-7) Haar Wavelet

• Mexican Hat Wavelet :

يوضح الشكل موجة القبعة المكسيكية وتعطى بالعلاقة:

$$\psi(t) = (1 - t^2) e^{-t^2/2} \xleftrightarrow{FT} \Psi(f) = \sqrt{2\pi} (2\pi f)^2 e^{-(2\pi f)^2/2}$$



الشكل (5-8) Mexican Hat Wavelet

• Shannon Wavelet:

موجة شانون وتعطى بالعلاقة:

$$\psi(t) = \text{sinc}(t/2) \cdot \cos(3\pi t/2) \xleftrightarrow{FT} \Psi(f) = \begin{cases} 1 & 0.5 \leq |f| \leq 1 \\ 0 & \text{elsewhere} \end{cases}$$

يرتبط التدرج بالتردد حسب العلاقة القريبية الآتية:

$$s \approx f_m \cdot f_s / f$$

حيث إن:

$$f_m = \arg[\max\{\Psi(f)\}]$$

f_s : هو تردد النمذجة (بالهرتز) المستعمل لنمذجة الموجة الأم $\psi(t)$ أثناء تحويل فورييه لها $\Psi(f)$.
يجرى التحليل بطريقة مشابهة لـ STFT، إذ تُزاح النافذة على طول الإشارة من أجل تدرية معينة (عرض معين للنافذة)، ثم تكرر العملية لمختلف التدرجات (النوافذ)، لكن المشكلة هي العدد الهائل من الموجات الناتجة بسبب استخدام جميع التدرجات في عملية التحليل والكم الهائل من المعلومات التي تنتج أيضاً لنفس السبب، وبالتالي فإن عملية المعالجة تتطلب زمناً طويلاً، لذلك تم حل المشكلة باستخدام المويجي المنقطع DWT.

5-5 التحويل المويجي المنقطع Discrete wavelet transform:

إن الفرق الأساسي بين هذا التحويل والتحويل المويجي المستمر هو أن هذا التحويل يستخدم عدداً محدداً من التدرجات بدلاً من إجراء التحويل من أجل كافة التدرجات، ويتم ذلك عن طريق اختيار مقاطعات زمنية في الإشارة، وينتج عن التحويل كمية كافية من المعلومات بحيث يكون زمن الحساب قليلاً ومع الحفاظ على المعلومات الأساسية الموضفة للإشارة (أي دون خسارة معلومات هامة)، ويعطى تحويل الموجة المنقطع بالعلاقة:

$$f[n] = \frac{1}{\sqrt{M}} \sum_k W_\phi[j_0, k] \phi_{j_0, k}[n] + \frac{1}{\sqrt{M}} \sum_{j=j_0}^{\infty} \sum_k W_\psi[j, k] \psi_{j, k}[n]$$

حيث إن:

$$\psi_{j, k}[n], \phi_{j_0, k}[n], f[n]$$

هي توابع منفصلة معرفة ضمن المجال $[0, M-1]$.

$$W_{\phi}[j_0, k] = \frac{1}{\sqrt{M}} \sum_n f[n] \phi_{j_0, k}[n]$$

$$W_{\psi}[j, k] = \frac{1}{\sqrt{M}} \sum_n f[n] \psi_{j, k}[n] \quad j \geq j_0$$

لكن المشكلة التي قد تواجهنا هي كيف يمكننا الحصول على كل الأطياف (الموجات) حتى الوصول إلى الصفر، إذ أننا عندما نمدد الإشارة فإن الجزء الذي نحصل عليه هو من نصف الإشارة فقط، ولكن ماذا بشأن النصف الثاني، لحل هذه المشكلة فإننا لا نلجأ إلى الحصول على كل الأطياف حتى الوصول إلى الصفر، بل يتم استخدام ما يشبه القفل، ويقوم هذا القفل بإنهاء عملية التحليل عند الوصول إلى قيمة يتم تحديدها مسبقاً بحيث تكون هذه القيمة صغيرة بما فيه الكفاية لكي نحصل على عدد كافٍ من الموجات، وبالتالي الحصول على المعلومات الموصفة للإشارة، وهذا القفل عبارة عن طيف تمرير تردد منخفض وهو جزء من تابع التدرج كلما كانت قيمة القفل أصغر، أي كان طيف تابع التدرج أصغر كلما نتج عدد أكبر من الموجات، وكلما زادت لمعلومات التدرج، لكن يجب مراعاة أن لا نجعل القفل ينتج عدداً قليلاً من الموجات بحيث يكون التحليل غير فعال.

بعد ذلك تقسم الإشارة إلى العوامل التفصيلية التي تعرف مسبقاً، إذ تشكل هذه العوامل (التقريبية والتفصيلية) الموجات التي يتم إنتاجها بضرب الإشارة المدروسة بالموجة الأم. وبما أن الموجات هي عبارة عن أطواف مختلفة التردد من الإشارة الأصلية فيتم تحقيقها بإدخال الإشارة على مرشحات، بحيث يتم استخدام مجموعات متتابعة من مرشحات التمرير المنخفض والمرتفع وهذا ما يسمى بشجرة مالات. ينتج مرشح التمرير المرتفع العوامل التفصيلية، بينما مرشح التمرير المنخفض مع تابع التدرج العوامل التقريبية.

في كل مرحلة تحليل ينتج مرشح تمرير نصف الحزمة (المرتفع والمنخفض) إشارات ذات مجال ترددي مساوٍ لنصف المجال الترددي للإشارة الأصلية. وهذا يضاعف الدقة الترددية للإشارة وهذا يعني إمكانية الحصول على المزيد من تفاصيل الإشارة في كل مرحلة تحليل، ويتم الحصول على الإشارة الأصلية بالتجميع المتسلسل لكل العوامل الناتجة سابقاً (العوامل التفصيلية والعوامل التقريبية) بدءاً من آخر مرحلة تحليل.

5-6 تحليل كثافة طيف الطاقة للإشارة الدماغية Power Spectrum Density:

الكثافة الطيفية للطاقة (PSD) تُستخدم لاستخراج الميزات من الإشارة. يعرف على أنه تحويل فورييه (FT) لتابع الارتباط التلقائي أثناء حالة الثبات (Stationary Condition). قياس تخمينات أو تقديرات طيف الطاقة هو عادة يتم من خلال طريقتين:

طريقة غير بارامترية (Non-Parametric) وكمثال عنها (Welch's Method) والطريقة البارامترية (Parametric) وكمثال عنها (Yule Walker PSD).

الطريقة البارامترية لتقدير بارامترات طيف الطاقة تفترض أن الإشارة تقبل بتوليد نموذج من خلال تابع معروف، ومن ثم بعد ذلك تقوم بتقدير البارامترات في النموذج المفترض.

Welch's Method: في هذه الطريقة تتداخل قطاعات البيانات وتقسم على نوافذ ليتم حساب البارامترات والرسم البياني الطيفي للإشارة.

حيث تكون النافذة الدورية المقابلة للإشارة $Y_i(t)$

$$\varphi_j(w) = \frac{1}{MP} \left| \sum_{t=1}^M v(t) y_j(t) e^{-iwt} \right|^2$$

حيث P تشير إلى طاقة النافذة الزمنية

$$\{v(t)\}, \text{ given by } P = \frac{1}{M} \sum_{t=1}^M |v(t)|^2$$

تقوم هذه الطريقة بتقدير البارامترات للكثافة الطيفية من خلال متوسط الرسم البياني الطيفي للإشارة

$$\Phi_W(w) = \frac{1}{S} \sum_{j=1}^S \Phi_j(w)$$

ومن خلال تداخل قطاعات البيانات يمكن الحصول على المزيد من متوسطات الرسوم البيانية الدورية الطيفية للإشارة وبالتالي ينخفض تباين الكثافة الطيفية للإشارة المقدّر بارامترات.

Yule Walker PSD: تحدد هذه الطريقة تقديرات الانحدار التلقائي (AR) للإشارة. هذه الطريقة تحسب بارامترات الانحدار التلقائي AR من خلال تشكيل تخمينات متحيزة لتابع الارتباط التلقائي للإشارة، وحل مشكلة تقليل الجذور الصغرى لخطأ التنبؤ الأمامي.

$$\begin{bmatrix} r(1) & r(2) & \cdots & r(p) \\ r(2) & r(1) & \cdots & r(p-1) \\ \vdots & \vdots & \ddots & \vdots \\ r(n) & \cdots & r(2) & r(1) \end{bmatrix} \begin{bmatrix} a(2) \\ a(3) \\ \vdots \\ a(p+1) \end{bmatrix} = \begin{bmatrix} -r(2) \\ -r(3) \\ \vdots \\ -r(p+1) \end{bmatrix}$$

5-7 المرشح المكاني المشترك Common Spatial Pattern:

تعد خوارزمية الأنماط المكانية الشائعة (CSP) طريقة لاستخراج الميزات التي تستخدم المرشحات المكانية لزيادة إمكانية تمييز صنف معين على حساب الصنف الآخر وهي كثيرة الاستخدام من أجل استخراج السمات من التخييلات الحركية MI .

واستخدام خوارزمية عامل التصنيفية المكاني المشترك CSP مهماً نظراً لتأثيرات الحجم التي تحدث من خلال طبقات الجمجمة وفروة الرأس والدماغ ، تخضع إشارات الدماغ المستخلصة لبعض التشوهات فذلك كان لابد من استخدام هذه الخوارزمية من أجل التصنيفية المكانية [18]، حيث مرشح التصنيفية يقوم بحساب مصفوفة الإسقاط W وهي C*C حيث :

$$W^T E = Z$$

وبذلك نكون قد استقدنا من تلك الخوارزمية بتخفيف أو تقليل التشوهات في الإشارات الدماغية .
وهنا تجدر الإشارة إلى أن خوارزمية التصنيف المكاني مفيدة جداً خاصةً في تصنيف الإشارات الدماغية الحركية EEG-MI

ويتم حساب متوسط مصفوفة التباين المكاني من خلال المعادلة:

$$R_c = \frac{1}{N_c} \sum_{i=1}^{N_c} \frac{E_{i,c} E_{i,c}^T}{\text{tr}(E_{i,c} E_{i,c}^T)}$$

يمكننا العثور على مرشح مكاني يزيد من تباين صنف واحد على حساب الصنف الآخر عن طريق الحل :

$$\arg \max_w \frac{w^T R_c w}{w^T R_{\bar{c}} w}$$

ويمكن تحويل حاصل القسمة السابق Rayleigh الى القيمة الذاتية المعممة Generalized Eigenvalue Problem:

$$\mathbf{R}_c \mathbf{w} = \lambda \mathbf{R}_{\bar{c}} \mathbf{w}$$

حيث:

λ : eigenvalue


$$\mathbf{W}_{csp} = [\mathbf{w}_1, \dots, \mathbf{w}_{2m}]$$

$\mathbf{w}$: eigenvector

المرشح المكاني يتم تشكيله من خلال ال eigenvector بالاعتماد على قيم eigenvalues (maximum and minimum).

8-5 المصنف Support Vector Machine:


تعتمد هذه الخوارزمية على استخدام توابع فصل خطية أو غير خطية لتصنيف البيانات المدروسة إلى الأصناف المطلوبة كما في الشكل:



الشكل (5-9) خطوط الفصل ضمن خوارزمية SVM

يعتبر أداء هذه الخوارزمية أفضل ما يمكن عندما تكون خطوط الفصل أبعد ما يمكن عن النقاط المدروسة [35]، ويكون الهامش بين الخطوط أبعد ما يمكن، ويتم ذلك من خلال الخطوات الآتية:

أولاً: تعرّف خطوط الفصل كما في المثال الآتي حيث لدينا ثلاثة خطوط فصل (A,B,C) والمطلوب إيجاد تابع الفصل المناسب للفصل بين صنف النجوم وسنف الدوائر. ونتذكر دوماً اختيار خط الفصل المناسب وهنا أفضل خط هو B الذي يعطي أفضل تمييز بين الأصناف [25].



الشكل (5-10) الاختبار الأول لخطوط الفصل

ثانياً: أختبر سيناريو آخر لتوابع الفصل بناءً على نتيجة الاختبار الأول، وهنا أيضاً لدينا ثلاثة خطوط فصل (A,B,C) التي تعطى بالمعادلة الآتية:



$$g(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b$$

حيث $g(\mathbf{x})$ يمثل تابع الفصل الخطي، $\mathbf{x}$ تمثل شعاع السمات، $\mathbf{w}$ تمثل شعاع الأصناف المطلوبة. والمطلوب هو إيجاد أفضل خط فصل كما في الشكل، مع العلم أن المعادلات الواصفة لخطوط الفصل (A,B) هي:

$$\mathbf{w}^T \mathbf{x}^+ + b = 1$$

$$\mathbf{w}^T \mathbf{x}^- + b = -1$$

هنا أفضل خط هو الذي يعطي أكبر مسافة بينه وبين الأصناف المطلوب تصنيفها وتدعى هذه المسافة بالهامش (Margin) بين خط الفصل والأصناف، وهنا يظهر أن خط الفصل C يعطي أفضل هامش والذي يؤدي إلى أفضل دقة تصنيف.



الشكل (5-11) الاختبار الثاني لخطوط الفصل

يتم حساب عرض الهامش M من خلال المعادلة الآتية:

$$M = (\mathbf{x}^+ - \mathbf{x}^-) \cdot \mathbf{n}$$

$$= (\mathbf{x}^+ - \mathbf{x}^-) \cdot \frac{\mathbf{w}}{\|\mathbf{w}\|} = \frac{2}{\|\mathbf{w}\|}$$


حيث n : الشعاع الواحد لتابع الفصل الخطي، $\mathbf{X}^+$ و $\mathbf{X}^-$: هي نقاط المميزات على حدود الهامش، ومن هنا جاءت تسمية هذه الخوارزمية، أي من النقاط التي تقع على حدود الهامش وهي تمثل SV . والمطلوب أن يكون عرض الهامش أكبر ما يمكن أي عندما تكون $\frac{2}{\|\mathbf{w}\|}$ أكبر ما يمكن أو $\frac{1}{2}\|\mathbf{w}\|^2$ أصغر ما يمكن.

وأخيراً تابع الفصل الخطي بالعلاقة:

$$g(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b = \sum_{i \in SV} \alpha_i \mathbf{x}_i^T \mathbf{x} + b$$


حيث X_i مجموعة النقاط التي تقع على حدود الهامش وتنتهي إلى صنف محدد.

ثالثاً: تُعاد الخطوات السابقة من أجل اختيار خط الفصل الأفضل كما في الشكل، هنا إذا تم اختيار خط الفصل B فإن ذلك سيؤدي إلى تصنيف خاطئ في بعض الأحيان على الرغم من قيمة الهامش الأكبر مقارنة بخط الفصل A الذي يعطي أفضل عملية تصنيف مقارنة مع B .



الشكل (5-12) الاختبار الثالث لخطوط الفصل

في بعض الحالات لا يؤدي تابع الفصل الخطي الوظيفية المطلوبة منه في عملية الفصل كما في الشكل:




الشكل (5-13) النقاط الشاذة غير المصنفة

تؤدي بعض النقاط الشاذة إلى عدم نجاح عملية الفصل الخطي بشكل كامل، لذلك يُضاف المتحول ξ_i الذي يعمل على إعادة تصنيف بعض النقاط غير المصنفة بحيث يصبح عرض الهامش يعطى بالعلاقة:

$$\text{minimize } \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n \xi_i$$

لذلك يمكن لتابع الفصل ألا يكون خطأ مستقيماً وإنما يمكن أن يكون منحنياً فصل بين الأصناف، يمكن أيضاً استخدام عملية تحويل أو مقابلة بين فضاء الدخل وفضاء المميزات في الخرج والتي تنتج عنها استخدام تابع فصل خطي في عملية التصنيف كما في الشكل:



الشكل (5-14) عملية المقابلة بين فضاء الدخل وفضاء المميزات

عندها يكون تابع الفصل من الشكل الآتي:

$$g(\mathbf{x}) = \mathbf{w}^T \phi(\mathbf{x}) + b = \sum_{i \in SV} \alpha_i \phi(\mathbf{x}_i)^T \phi(\mathbf{x}) + b$$

حيث تمثل القيمة $K(\mathbf{x}_i, \mathbf{x}_j) \equiv \phi(\mathbf{x}_i)^T \phi(\mathbf{x}_j)$ التابع الأساس Kernel Function وهو التابع الذي يتوافق مع توزيع النقاط الواردة من شعاع المميزات الذي يتم اختباره، وفيما يأتي أمثلة لأشهر التوابع الأساس المستخدمة في هذه الخوارزمية والتي تمثل نواة عملية الفصل [28].

□ Linear kernel: $K(\mathbf{x}_i, \mathbf{x}_j) = \mathbf{x}_i^T \mathbf{x}_j$

□ Polynomial kernel: $K(\mathbf{x}_i, \mathbf{x}_j) = (1 + \mathbf{x}_i^T \mathbf{x}_j)^p$

□ Gaussian (Radial-Basis Function (RBF)) kernel:

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{2\sigma^2}\right)$$

□ Sigmoid: $K(\mathbf{x}_i, \mathbf{x}_j) = \tanh(\beta_0 \mathbf{x}_i^T \mathbf{x}_j + \beta_1)$

الشكل (5-15) يمثل أشهر التوابع الأساس التي يستخدمها المصنف SVM والتي تمثل نواة عملية الفصل

حيث يمكن تلخيص عمل الخوارزمية من خلال الخطوات الآتية:

- اختيار تابع الأساس Kernel Function المناسب.

- اختيار قيمة C التي تمثل عدد الأصناف المطلوبة على الخرج.
- إيجاد الحل الأفضل من حيث عرض الهامش وتابع الفصل.
- بناء تابع الفصل اعتماداً على النقاط الحدية الموجودة على الهامش (SV).



9-5 الخاتمة:

درست في هذا الفصل خوارزميات وطرق استخراج السمات (المميزات) حيث اختلف بعضها عن بعضها الآخر فمنها من يعمل على استخراج السمات الزمنية ومنها من يستخرج السمات الترددية ومنها من يستخرج الاثنين معاً ومنها من كان يعتمد على الترشيح المكاني لاستخراج المميزات المكانية، وأخيراً تم شرح مفصل لمصنف آلة دعم القرار (SVM).

الفصل السادس

المناقشة والنتائج والأعمال المستقبلية


Discussion, Results and Future Work



1_6 مقدمة:

سيكون هذا الفصل شرحاً تفصيلياً لعملية معالجة إشارات الدماغ والمراحل التي تمت بها، حيث استخدم برنامج MATLAB 2020a من أجل عملية المعالجة الأولية للبيانات كونه يوجد مكتبة أدوات Tool Box جاهزة للتعامل مع إشارات الدماغ ومعالجتها وهي EEGLAB ثم استخدمت لغة Python من أجل عملية استخراج السمات والتصنيف وبعدها عملية المحاكاة ولهذا الغرض تم استخدام هذه اللغة بسبب سهولة ربطها مع بيانات أخرى من أجل عملية المحاكاة والتحكم بالذراع.

يوضح الشكل الآتي المراحل التفصيلية لمراحل الجزء العملي من قراءة البيانات حتى تصنيف الحركات والتحكم بالذراع الروبوتية:




الشكل (1-6) مخطط يوضح عملة قراءة ومعالجة وتصنيف إشارات الدماغ الحركية لليد اليمنى واليسرى

2-6 كيفية استخلاص الإشارات والحصول عليها:


لدينا في قاعدة البيانات المعيارية التي تحتوي على 9 أشخاص أجريت تجارب من خلالها لتخيلات حركية لليد اليمنى واليسرى وحركة القدمين واللسان وكان لدينا أربعة أصناف على التوالي. في كل جلسة أجريت أكثر من تجربة مع وجود فاصل زمني طبعاً ليأخذ الشخص قسطاً من الراحة حيث كان هناك 6 تجارب تحتوي كل منها على 48-trials (12- trials لكل صنف من الأصناف الأربعة السابقة) فكان المجموع 288-trials في كل جلسة. حيث أخذ جزء من القاعدة وهو الأهم في دراستنا حيث تم الاستغناء عن صنف حركة الرجلين واللسان واستخدمت 3 قنوات من أصل 25 قناة (Electrode) كان 22 منها كإشارات EEG و 3 منها كإشارات EOG.

كان الأشخاص المشاركون يجلسون على كرسي مريح أمام شاشة الحاسوب. في بداية التجربة أي في اللحظة $t = 0$ s يظهر مؤشر على الشاشة السوداء. بالإضافة إلى ذلك، يتم إصدار نغمة تحذير صوتية قصيرة.

ثم بعد ثانيتين ($t = 2 \text{ s}$) تظهر إشارة (Cue) على شكل سهم يشير إما إلى اليسار، أو اليمين، أو الأسفل، أو الأعلى (المقابل لإحدى الأصناف الأربع التي تقابل اليد اليسرى، أو اليد اليمنى، أو القدم، أو اللسان) وتبقى على الشاشة لمدة ($t = 1.25 \text{ s}$). ثم بعد ذلك يأتي دور الشخص في تخيل إحدى الحركات السابقة (Motor Imagery) ويستمر لمدة ثلاث ثوانٍ وبعد ذلك يكون هناك حالة توقف لمدة أقل من ثانيتين لتسجيل الحالة الآتية، حيث الشكلين الآتيين يبينان كيفية تسجيل تلك البيانات والفترات الزمنية المتبعة [19] مع العلم أن ال MI يكون ضمن المجال [3-6] Sec فقط عند كل صنف:




الشكل (2-6) المخطط الزمني لجلسة واحدة



الشكل (3-6) المخطط الزمني للنموذج ككل

1-2-6 تسجيل الإشارات Data recording:

لدينا اثنان وعشرون قطبًا من Ag / AgCl (بمسافات بين الأقطاب الكهربائية تبلغ 3.5 سم) كانت تستخدم لتسجيل مخطط كهربية الدماغ. وتم تسجيل جميع الإشارات بشكل منفصل مع استخدام الخشاء الأيسر (شحمة الأذن) كمرجع والخشاء الأيمن كأرضي. وأخذت عينات الإشارات باستخدام مرشح تمرير حزمة BPF وذلك بين الترددات 0.5-100 Hz مع تفعيل (Notch Filter) عند التردد 50 Hz. حيث ضبطت قيمة المضخم (Amplifier) عند القيمة [1 mV] وتم تمكين كل ذلك من أجل التخلص قدر الإمكان من التشوهات في الإشارات قبل البداية بعملية المعالجة الأولية لها، وهنا يبين الشكل كيفية وضع الإلكتروودات ونوعها وعددها:



الشكل (4-6) يبين مكان تموضع الإلكترودات على فروة الرأس بالإضافة لموضع الإلكترودات العينية

وهنا لدينا الجدول الآتي الذي يوضح الأحداث وأنواعها وتوقيتها التي تم التوصل إليها ضمن البيانات المستخلصة من التسجيل السابق:

Event type	Description
276 0x0114	Idling EEG (eyes open)
277 0x0115	Idling EEG (eyes closed)
768 0x0300	Start of a trial
769 0x0301	Cue onset left (class 1)
770 0x0302	Cue onset right (class 2)
771 0x0303	Cue onset foot (class 3)
772 0x0304	Cue onset tongue (class 4)
783 0x030F	Cue unknown
1023 0x03FF	Rejected trial
1072 0x0430	Eye movements
32766 0x7FFE	Start of a new run

الشكل (5-6) قائمة بأنواع الأحداث التي تم تسجيلها

أخذت الإشارات عن طريق جهاز يعتمد على النظام System Ten-Twenty(10-20) وهذه القاعدة تم تحميلها عن الانترنت (لعدم توفر الجهاز أو الخوذة الخاصة باستخلاص إشارات الدماغ) وهي القاعدة تحتوي على بيانات

معيارية (Standard Dataset) ويستخدمها العديد من الباحثين، حيث لدينا هنا جدول يلخص محتوى قاعدة البيانات وتفاصيلها وهي باسم (BCI Competition Graz data set A 2008):

الجدول (1-6) تفاصيل قاعدة البيانات المستخدمة في البحث

عدد الأشخاص	عدد الأصناف	عدد التجارب في كل جلسة للشخص الواحد	عدد ال Trials في كل تجربة	عدد ال Trials لكل صنف	مجموع ال Trials لكامل الجلسة للشخص الواحد	القنوات Electrodes المستخدمة في عملية تسجيل الإشارات
9	4	6	48	12	288	EEG = 22 EOG = 3

لدينا أيضاً بعض البارامترات المتعلقة بقاعدة البيانات [19] السابقة، حيث استخلصت البيانات بمعدل تقطيع ($FS = 250 \text{ Hz}$) وكما هو مبين في الشكل (2-6) بأن لدينا لكل شخص أكثر جلسة في التجربة الواحدة وكل تجربة تحتوي علي 9-Run مقسمة على الشكل الآتي (1-3 for eye movements و 4-9 for motor imagery)، أيضاً لدينا كل:

1 Trial = 7-8 s

1 Run = 48 Trials = 336-384 s

1 Session = 6 Runs = 288 Trials = 2016-2304 s


يكون عدد العينات الكلي لكل شخص خلال زمن الجلسة وبالتردد السابق مع وجود 25 قناة على فروة الرأس على الشكل الآتي كما هو مبين في الجدول الآتي ولكن عدد العينات يختلف من شخص لآخر بسبب اختلاف زمن التسجيل:

الجدول (6-2) عدد العينات لكل شخص

Subject No.	Samples	Electrodes
Subject_01	672528	25
Subject_02	677169	25
Subject_03	660530	25
Subject_04	600915	25
Subject_05	686120	25
Subject_06	678980	25
Subject_07	681071	25
Subject_08	675270	25
Subject_09	673328	25


3-6 خطوات المعالجة الأولية: Preprocessing Steps

في البداية وكما ذكرنا أنه في قاعدة البيانات لدينا أربعة أصناف (حركة اليد اليمنى واليد اليسرى وحركة القدمين معاً بالإضافة لحركة اللسان)، حيث استعمل الجزء المهم من هذه القاعدة وهو استخدام صنفين فقط (حركة اليدين اليمنى واليسرى) من الأصناف الأربعة الموجودة، بعد ذلك لدينا خطوة اختيارية وهي تخفيض معدل النقطيع إلى أقل من 250 هرتز، وبذلك نكون قد قللنا عدد العينات المأخوذة خلال التسجيل الواحد للبيانات وبذلك نقل من التكلفة الحسابية وزمن التنفيذ لعملية المعالجة، بعد ذلك لدينا خطوة مهمة وهي عملية ترشيح تلك الإشارات إلى حزم ترددية محددة بناءً على الهدف من تلك البيانات فكما تم الذكر سابقاً عن الإشارات الدماغية تنقسم إلى أمواج كل موجة تنشط عند تأثير معين للدماغ ففي حالة النوم والراحة تنشط أمواج معينو وبنفس الوقت عند التركيز والحركة وفرط النشاط الفكري تنشط أوتظهر موجات أخرى، ومن هنا نأخذ الأمواج المتعلقة بالحركة ويكون فيها الدماغ في حالة تنبؤ بالحركة (تصور أو تخيل) وبهذه الحالة تكون الحزمتين النشطتين من الدماغ هما (ألفا وبيتا) أي بين الترددين [8-30] هرتز، حيث استخدم مرشح من نوع FIR وبعد ترشيح الإشارات كانت النتائج كالاتي:



الشكل (6-6) الإشارات قبل عملية الترشيح


بينما كانت النتائج بعد عملية الترشيح كالآتي:



الشكل (6-7) الإشارات بعد عملية الترشيح

بالمقارنة بين الشكلين السابقين يتبين الفرق بعد عملية الترشيح وقبلها.


بعد ذلك، تأتي عملية مهمة وهي إزالة الضجيج والشوائب [20] من الإشارة (Artifacts Removal) وكما هو مؤكد علمياً أن الإشارة الدماغية من أكثر الإشارات تشويشاً وذلك لتعرضها لتأثيرات كثيرة من الإشارات الحيوية الأخرى في الجسم (إشارات القلب، التنفس، حركة ووميض العينين وحركة العضلات..... إلخ) كل هذه الإشارات تؤثر على الإشارات الدماغية التي هي بطبيعتها تحتوي نسبة ضجيج كبيرة بحكم قرب المناطق الدماغية من بعضها بعضاً، والتأثير المتبادل فيما بينها، فكان لابد من استخدام خوارزمية تعمل على التخفيف والحد من تأثيرات الإشارات الأخرى، إذ تم اختيار خوارزمية تحليل المكونات المستقلة ICA، بشكل عام التشوهات التي من الممكن أن نشاهدها في إشارات الدماغ هي كالاتي:



الشكل (6-8) يبين التشوهات المرافقة للإشارات الدماغية في صف بيانات ال EEG


وكما هو مبين في الشكل السابق من أهم هذه التشوهات (الميلان الخطي Linear Trend، الاقترعية أو عدم الاستمرارية Discontinuity، الضجيج العالي High Noise، حدوث تردد عالٍ عابر سببه إشارات العضلات Transient High Frequency Event وأيضاً من الممكن ملاحظة تردد منخفض سببه حركة العينين Low Frequency Event.... إلخ) كل ذلك يؤثر بشكل كبير على القياس السليم والمعالجة الجيدة للإشارات الكهربائية للدماغ.

كما لدينا الشكل الآتي يبين مصادر تلك التشوهات ومنابع تأثيرها التي تشكل ضجيجاً كبيراً بالنسبة للإشارات الدماغية:




الشكل (6-9) مصادر الضجيج المؤثر على الإشارات الدماغية

ومن الواضح أن هناك أكثر من مصدر مؤثر على الإشارة، بعد ذلك أصبح لدينا رؤية حول طبيعة الإشارات الدماغية وماهي المصادر التي تؤثر عليها، ولدينا مثال توضيحي لكل إشارة تؤثر على الإشارة الدماغية مسببةً ضجيجاً فيها. واجتماع تلك الإشارات جميعها يشكل الإشارة الدماغية التي يجب ترشيحها وتنظيفها من أجل الحصول على بيانات جيدة قابلة للدراسة وإقامة الأبحاث عليها:




الشكل (6-10) تأثير كل إشارة على الإشارة الدماغية الصافية Pure EEG

خوارزمية ICA هي طريقة لفصل مجموعة من الإشارات، باعتبار أن الإشارات مستقلة إحصائياً عن بعضها، وهي أيضاً أسلوب إحصائي وحسابي للكشف عن العوامل المخفية التي تكمن وراء مجموعات من المتغيرات العشوائية أو القياسات أو الإشارات، لتوضيح الفكرة أكثر سوف نعرضها بمثال مبسط و هو وجود أشخاص كثيرة في حجرة و علينا فصل هذه الأصوات عن بعضها بعضاً.



الشكل(6-11) عملية فصل المصادر وهي الأصوات في حفلةCocktail-Party


وهنا لدينا مخطط يوضح عملية استخدام خوارزمية ICA من أجل فصل المصادر وتخمين المصدر من خلال الإسقاط المكاني:



الشكل(6-12) استخدام خوارزمية ICA لفصل المصادر وتخمينها

ومن خلال الخوارزمية السابقة يمكننا فصل المصادر العمياء المتعلقة بإشارات الدماغ أي (فصل إشارات العضلات والقلب والعين.... إلخ) عن إشارة الدماغ الأصلية، ولمعرفة كيفية عمل الخوارزمية في عملية المعالجة الأولية للإشارات الدماغية يجب أن نتبع عدة خطوات كالآتي:

أولاً عملية التمرکز (Centering): يتم من خلال عملية طرح شعاع متوسط قيمة إشارة EEG الأصلية (الممزوجة بإشارات أخرى)، مما يعمل على تبسيط خوارزمية ICA كالتالي، حيث $\mathbf{x} = \mathbf{x} - E\{\mathbf{x}\}$ هو الشعاع المتوسط للإشارات الدماغية المقاسة، وبعد انتهاء عمل الخوارزمية يضاف شعاع المتوسط.



الشكل (6-13) يمثل عملية التمرکز التي تحصل على البيانات

ثانياً عملية التبييض (Whitening): يمكن استخدام ارتباط إشارات المصدر لتبسيط مشكلة فصل المصادر العمياء BSS وهذا يعتمد على المتغيرات الإحصائية من الدرجة الثانية SOS حيث يتم تقليل وتخفيف التكرار والضجيج في الإشارة، مصفوفة التبييض M يتم اختيارها بحيث تكون مصفوفة التباين لإشارات المصدر مصفوفة واحدة، حيث يتم حساب مصفوفة الإشارة الأصلية بعد عملية التبييض من خلال التحويل الآتي:

$$\mathbf{x}_w(t) = \mathbf{M}\mathbf{x}(t)$$

حيث إن الإشارات المبيضة غير مرتبطة فيما بينها ويوجد تباين واحد مبين بالمعادلة الآتية:

$$\mathbf{R}_{\mathbf{x}_w\mathbf{x}_w} = E\{\mathbf{M}\mathbf{x}(t)\mathbf{x}(t)^T \mathbf{M}^T\} = \mathbf{M}\mathbf{R}_{\mathbf{x}\mathbf{x}}\mathbf{M}^T = \mathbf{I}$$

التبييض يقلل من الدمج الحاصل في مصفوفة الدوران Q ، لأنه يرتبط مكانياً باثنين من الإشارات البيضاء وهما $S(t)$ و $\mathbf{x}_w(t)$ ، حيث تحسب مصفوفة فك الدمج W من خلال ضرب مصفوفة التبييض بمصفوفة الدوران كالآتي:

$$\mathbf{W} = \mathbf{Q}\mathbf{M}$$

إن مصفوفة فك الدمج تقوم باستعادة النقاط العظمى (الذروات) من إشارات المصدر، حيث تقوم الخوارزمية باستعادة استقلالية الإشارات المشتركة ومن ثم تخمين المصادر وهذا يتم من خلال المعادلة الآتية:

$$\hat{\mathbf{s}}(t) = \mathbf{W}\mathbf{x}(t)$$

يتم حساب مصفوفة التباين من خلال المعادلة الآتية:


$$\mathbf{R}_{xx} = E\{\mathbf{x}(t)\mathbf{x}^T(t)\}$$

يكون تحليل eigen value (EVD) مناسباً لذلك، حيث يعطى التحليل من خلال المعادلة الآتية:

$$\mathbf{R} = \mathbf{E}\mathbf{\Lambda}\mathbf{E}^T$$

تكون $\mathbf{E}$ هي المصفوفة المتعامدة ل eigen-vectors للمصفوفة $\mathbf{R}$ ، وتكون $\mathbf{\Lambda}$ المصفوفة القطرية ل eigen-values، بعد ذلك يتم تحويل مصفوفة التباين $\mathbf{R}$ إلى مصفوفة واحدة Identity Matrix، تحسب مصفوفة التبييض Whitening Matrix التي تنقلنا من فضاء إلى فضاء إحداثي آخر وذلك من خلال المعادلة الآتية:

$$\mathbf{M} = (\mathbf{\Lambda}^{1/2}\mathbf{E}^T)^{-1}$$




الشكل (6-14) يمثل عملية تبييض البيانات Whitening

ثالثاً عملية ال Sphering وهي عبارة عن دمج العمليتين السابقتين مع بعضهما بعضاً كآلاتي:

$$\text{Centering} + \text{Whitening} = \text{Sphering}$$

إنّ هذه العملية ضرورية من أجل عملية تسريع عمل الخوارزمية، حيث عملية ال Sphering تقوم بإزالة البيانات ذات المتغيرات الإحصائية من الدرجة الأولى والثانية.

لدينا في الشكل الآتي اختصار توضيحي لكيفية عمل خوارزمية ICA في التخلص من المكونات Components غير المرغوبة في الإشارات الدماغية المصدرية:



الشكل (6-15) كيفية التخلص من المكونات غير المرغوبة باستخدام خوارزمية ICA

بعد ذلك لدينا عملية اختيار البيانات والتي يقصد فيها اختيار الإشارات الدماغية المرغوبة من الإشارات المصدرية وهنا يتم التخلص من الإشارات التي تتعلق العين EOG وهي آخر ثلاث إشارات من عدد الإشارات الكلي وهو 25 إشارة بعدد الحساسات المتوضعة على الرأس.

ملخص خطوات الخوارزمية:

- Center X by subtracting the mean
- Whiten X
- Choose a random initial value for the de-mixing matrix W
- Calculate the new value for W
- Normalize W
- Check whether algorithm has converged and if it hasn't, return to step 4
- Take the dot product of W and X to get the independent source signals

المقارنة بين خوارزميتي ICA و PCA [30] :


التشابه:

- استخراج السمات
- تقليل الأبعاد


الاختلاف:

- PCA يستخدم متغيرات من الدرجة الثانية للبيانات لانتاج مكونات غير مرتبطة مع بعضها بعضاً
- ICA تعمل على توليد مكونات مستقلة قدر الإمكان من خلال تقليل الاعتمادات على نتغيرات من الدرجة الثانية أو أكبر في البيانات المعطاة

ICA versus PCA



الشكل (6-16) الاختلاف بين خوارزميتي PCA و ICA بطريقة الحصول على المكونات



الشكل (6-17) الاختلاف بين خوارزميتي PCA و ICA من حيث آلية العمل

ومن الشكل الأخير يتبين أن خوارزمية PCA تقوم بضغط البيانات من أجل تقليل الأبعاد، بينما تقوم خوارزمية ICA بفصل المعلومات عن بعضها من أجل الحصول على بيانات أو مكونات مستقلة Independence Components.

4-6 عملية استخراج السمات Features Extraction:

كما ذكرنا سابقاً أن عملية استخراج السمات هي من أهم الخطوات في عملية معالجة الإشارات الدماغية، وهناك عدة طرق وخوارزميات من أجل استخراج المميزات من الإشارة فمنها من يعتمد على استخراج المميزات الترددية ومنها من يعمل على إخراج المميزات الزمنية ومنها يستخرج الاثنين معاً (الترددية-الزمنية) وفي حالتنا هنا استخدم مرشح مكاني لاستخراج المميزات المكانية من الإشارة وهو المرشح ذو النمط المكاني المشترك CSP وهو عبارة عن إجراء رياضي يستخدم في معالجة الإشارات لفصل إشارة متعددة المتغيرات إلى مكونات فرعية إضافة إلى أنه يعمل فرق توازن أو تحيز صنف عن صنف آخر وهو طريقة مجدية في البحث الذي يعمل على عملية تصنيف صنفين وهما حركة اليد اليمنى واليسرى، حيث يعتمد عليه بشكل كبير لتمييز الأحداث المتزامنة وغير المتزامنة ERD/ERS، وتم تقسيم الأحداث المتعلقة بحركة اليد اليمنى واليسرى والبالغ عددها 144 والتي تم تسجيلها بشكل عشوائي إلى 72-trials لليد اليمنى وذات الأمر 72-trials لليد اليسرى وذلك بعد معرفة طول وموقع كل حدث من الأحداث السابقة، وبذلك نكون قد قسمنا البيانات التي تهمنا في هذا البحث على قسمين متساويين كل قسم يحوي على الأحداث المتعلقة بكل صنف من أجل استخدام المرشح المكاني عليها، مع العلم أن المرشح استخدم على أكثر من حزمة ترددية بين ال 8- [282]Hz بعرض 4Hz لكل حزمة وبهذا ينتج لدينا سمات استخرجت من 5 حزم ترددية مما يزيد من دقة استخراج السمات على عرض النطاق الترددي وهذا يؤدي إلى زيادة دقة التصنيف، وهنا تسمى هذه العملية بنك الترشيح ذو النمط المكاني المشترك FBCSP، والجدول الآتي يبين عملية التقسيم:

الجدول (3-6) يبين التقسيم الحاصل لكل صنف عند جميع الأشخاص

Subject No.	Left	Right
Subject_01	(72, 22, 750)	(72, 22, 750)
Subject_02	(72, 22, 750)	(72, 22, 750)
Subject_03	(72, 22, 750)	(72, 22, 750)
Subject_04	(72, 22, 750)	(72, 22, 750)
Subject_05	(72, 22, 750)	(72, 22, 750)
Subject_06	(72, 22, 750)	(72, 22, 750)
Subject_07	(72, 22, 750)	(72, 22, 750)
Subject_08	(72, 22, 750)	(72, 22, 750)
Subject_09	(72, 22, 750)	(72, 22, 750)

في كل صنف كما هو موضح في الجدول لدينا (عدد العينات، عدد القنوات، عدد ال trials)، ثم بعد ذلك قسم عدد ال trials لكل صنف خلال عملية التدريب والاختبار فتم أخذ 70% من عدد ال trials لعملية التدريب و 30% لعملية الاختبار والبالغ عددها الإجمالي (72- trials) لكل صنف، ويبين الجدول الآتي عملية التقسيم:

الجدول (4-6) عدد ال trials لكل صنف خلال عملية التدريب

Training	Left	Right
Subject_01	(58, 22, 750)	(58, 22, 750)
Subject_02	(58, 22, 750)	(58, 22, 750)
Subject_03	(58, 22, 750)	(58, 22, 750)
Subject_04	(58, 22, 750)	(58, 22, 750)
Subject_05	(58, 22, 750)	(58, 22, 750)
Subject_06	(58, 22, 750)	(58, 22, 750)
Subject_07	(58, 22, 750)	(58, 22, 750)
Subject_08	(58, 22, 750)	(58, 22, 750)
Subject_09	(58, 22, 750)	(58, 22, 750)

ولدينا الجدول الآخر الذي عملية التقسيم خلال عملية الاختبار:

الجدول (5-6) عدد ال trials لكل صنف خلال عملية الاختبار

Testing	Left	Right
Subject_01	(14, 22, 750)	(14, 22, 750)
Subject_02	(14, 22, 750)	(14, 22, 750)
Subject_03	(14, 22, 750)	(14, 22, 750)
Subject_04	(14, 22, 750)	(14, 22, 750)
Subject_05	(14, 22, 750)	(14, 22, 750)
Subject_06	(14, 22, 750)	(14, 22, 750)
Subject_07	(14, 22, 750)	(14, 22, 750)
Subject_08	(14, 22, 750)	(14, 22, 750)
Subject_09	(14, 22, 750)	(14, 22, 750)

آلية عمل المرشح CSP :

بالبداية نقوم بحساب مصفوفة التباين المكاني Spatial Covariance لكل [21] صنف على حدة:

$$C = \frac{EE'}{\text{trace}(EE')}$$

حيث E هي إشارة الدماغ و E' تمثل منقول المصفوفة و $\text{trace}(EE')$ يمثل مجموع العناصر القطرية للمصفوفة E، بعد ذلك يتم حساب مصفوفة التباين المركب Composite Covariance Matrix:

$$\bar{C}_l = \frac{1}{14} \sum_{i=1}^{14} C_{li} \quad \text{وهي مصفوفة التباين المركب للصنف الأيسر بينما تكون مصفوفة التباين للصنف الأيمن}$$

$$\bar{C}_r = \frac{1}{14} \sum_{i=1}^{14} C_{ri} \quad \text{كالتالي:}$$

تم استخدام 14-Trials خلال عملية الاختبار.

ويكون متوسط مصفوفة التباين المركب للصنفين بالشكل الآتي:

$$C_c = \bar{C}_l + \bar{C}_r$$

وبعد ذلك يتم تحليل مصفوفة التباين :Decompose the Covariance Matrix

$$C_c = U_c \lambda_c U_c'$$

حيث C_c هي ال eigendecompose matrix، بعد ذلك يتم تحليل التباين المشترك المركب إلى متجه ذاتي eigenvector وقيمة ذاتية eigenvalue.

ثم يتم حساب مصفوفة التحول الأبيض :White Transformation Matrix

$$P = \sqrt{\lambda_c^{-1}} U_c'$$

حيث تكون قيم ال eigenvalues لحاصل ضرب المصفوفات PC_cP' هو المصفوفة الواحدية Identity Matrix

بعد ذلك يتم حساب المصفوفة المكانية من المرشح Spatial Matrix لكلا الصنفين تحريك اليد اليسرى واليمنى:

$$S_l = \overline{PC_l} P'$$

$$S_r = \overline{PC_r} P'$$

وبعدها يتم حساب مصفوفة الإسقاط بعد حساب تحليل المصفوفة المكانية لكل صنف :Projection Matrix

$$S_l = B \lambda_l B'$$

$$S_r = B \lambda_r B'$$

حيث تقوم كل من المصفوفة S_l و S_r بتشارك قيم ال eigenvalues ولكن بترتيب معاكس، حيث يتم الترتيب بشكل تصاعدي ثم تنازلي، حيث λ تمثل مصفوفة القيم الذاتية eigenvalues لكل صنف، ومنه يكون:

$$\lambda_l + \lambda_r = I$$

حيث I تمثل المصفوفة الواحدية.

وأخيراً يتم حساب مصفوفة الإسقاط W :

$$W = (B' P)'$$

وبهذا الشكل يعمل المرشح ذو النمط المكاني المشترك للتفريق بين صنفين بترجيح أحدهما عن الآخر بحيث ينحاز إلى صنف مقابل الآخر بناءً على قيم ال eigenvalues .

وتكون خطوات عمل خوارزمية المرشح CSP على الشكل الآتي:

Algorithm 1 CSP Algorithm

Input: a set of I preprocessed EEG trials $\mathbf{X}_i$ with known class $Y_i \in \{1, 2\}$.

Output: $\mathbf{W}$ projection matrix

- 1: **for** $i = 1$ to I **do**
 - 2: $\mathbf{P}_{\mathbf{X}_i} = \text{Cov}(\mathbf{X}_i)$ {Compute Sample Covariance matrix}
 - 3: **end for**
 - 4: $\mathbf{P}_1 = \mathfrak{A}(\mathbf{P}_{\mathbf{X}_i}, Y_i = 1)$ {Arithmetic mean of covariance matrices for class 1}
 - 5: $\mathbf{P}_2 = \mathfrak{A}(\mathbf{P}_{\mathbf{X}_i}, Y_i = 2)$ {Arithmetic mean of covariance matrices for class 2}
 - 6: $(\mathbf{P}_1 + \mathbf{P}_2)^{-1} \mathbf{P}_1 = \mathbf{W} \mathbf{D}_1 \mathbf{W}^T$ {Eigenvalue decomposition}
 - 7: **return** $\mathbf{W}$
-

وبعد ذلك يتم حساب ال Feature Vector لبيانات التدريب من خلال المعادلة الآتية:

$$f_p = \log\left(\frac{\text{var}(Z_p)}{\sum_{i=1}^{2m} \text{var}(Z_i)}\right)$$

حيث يشير $\text{Var}(Z_p)$ إلى تباين العينات في كل سطر من المصفوفة p وذلك من 1 وحتى السطر $2m$ بينما يشير $\sum_{i=1}^{2m} \text{Var}(Z_i)$ إلى مجموع كافة التباينات للعينات من السطر 1 وحتى السطر $2m$ والآن يكون لدينا المصفوفة $\mathbf{W}$ بالأبعاد $2m * N$ ، نطبق تلك المصفوفة على بيانات الدماغ الأصلية $\mathbf{E}$ ذات الأبعاد $N * T$ وبذلك نحصل على المصفوفة $\mathbf{Z}$ ذات الأبعاد $2m * T$ وبعد ذلك يكون حساب $\mathbf{Z}$ على الشكل الآتي:

$$\mathbf{Z} = \mathbf{W} * \mathbf{E}$$

حيث يكون خرج المرشح المكاني عبارة عن سمات Features لكل عينة Trial لكي يقوم المصنف بتصنيفها حيث لدينا هنا بيانات الاختبار والتي هي عبارة عن 28 عينة مقسومة إلى قسمين 14 لكل صنف في الخرج وهذا الخرج مرتب بشكل عشوائي حيث يمثل الجدول الآتي السمات لكل عينة في الخرج فنلاحظ أن كل سطر يمثل شعاع السمات لكل عينة في الخرج فيمثل السطر الأول شعاع من 4 قيم (Parameters) ويمثل حركة يمين أو يسار وهذه السمات سيتم تصنيفها من قبل المصنف SVM من أجل إعطاء الحركة المناسبة لكل شعاع بعد أن يتم اختيارها حسب تفاوت قيمة القيم الذاتية لكل صنف eigenvalues disparity.

الجدول (6-6) يمثل شعاع المميزات لكل حركة في الخرج

Hand Movement	Features			
Right	-0.74503825	-0.70139041	-0.60363762	-0.42928571
Right	-0.63386252	-0.52507941	-0.65171328	-0.60875002
Left	-0.46031142	-0.59174741	-0.66022204	-0.74753555
Right	-0.81433577	-0.6783247	-0.43957236	-0.56306801
Left	-0.49800234	-0.4259923	-0.72766534	-0.92037657
Right	-0.83847945	-0.84470931	-0.58218032	-0.34654206
Left	-0.46747498	-0.58463948	-0.66801062	-0.73478028
Right	-0.6097307	-0.58041659	-0.68547813	-0.5447112
Left	-0.49715712	-0.56258133	-0.60529492	-0.79653195
Right	-0.69913471	-0.69633517	-0.46859214	-0.58684383
Right	-0.80487633	-0.82600267	-0.45266683	-0.4667868
Right	-0.60709086	-0.66649288	-0.59468554	-0.5481088
Left	-0.4165459	-0.37479723	-0.88623495	-1.18752325
Left	-0.44646995	-0.47874772	-0.61613687	-1.16636258
Left	-0.48715347	-0.47004327	-0.71216974	-0.84938083

Left	-0.42131325	-0.46745384	-0.71046938	-1.06880602
Left	-0.39698411	-0.38019298	-0.90302612	-1.24096672
Right	-0.98579123	-0.80225596	-0.34339024	-0.5444363
Left	-0.38146675	-0.40310075	-1.00575561	-1.04297841
Left	-0.48356764	-0.28865603	-0.93439894	-1.38911375
Right	-0.70581857	-0.95359095	-0.4927347	-0.43145945
Left	-0.52597409	-0.60681256	-0.68079538	-0.60852828
Right	-0.70005692	-0.7417939	-0.50233781	-0.5160565
Right	-0.7765274	-0.66482377	-0.54290452	-0.48165904
Left	-0.53766059	-0.40171607	-0.7667761	-0.84645277
Right	-0.77161612	-0.76714043	-0.48974828	-0.47355874
Right	-0.65711879	-0.70513964	-0.40399087	-0.72555778
Right	-0.76847652	-0.67426085	-0.51445896	-0.50584958

5-6 التصنيف Classification:


بعد استخلاص السمات والمميزات من الإشارات الدماغية تبقى لدينا عملية تصنيف تلك الحركات الناتجة عن تلك الإشارات، وتم الاعتماد في ذلك على تقنيات ومصنفات تعلم الآلة ML ووقع الاختيار على مصنف آلة دعم القرار SVM لكي تتم مقارنة النتائج التي توصلنا لها مع عمل آخر قام بنفس الاختبار على نفس البيانات باستخدام نفس المصنف ولكن بدون عملية معالجة أولية Preprocessing للبيانات.

حيث تم استخدام المصنف مع نوع تبديل النواة Kernal أو الطريقة التي يعمل بها المصنف (Linear, RBF) وكانت النتائج لدقة المصنف عند بيانات التدريب على الشكل الآتي:



الشكل (6-18) دقة التصنيف لبيانات التدريب لكل شخص

وكانت نتائج دقة التصنيف للبيانات عند عملية الاختبار على النحو الآتي:



الشكل (6-19) دقة التصنيف لبيانات الاختبار لكل شخص

إنّ تقرير التصنيف الذي يقوم بعرض معايير مقاييس الدقة لكل صنف يكون على الشكل الآتي حيث لدينا:

-1.0: Left Hand Class

1.0: Right Hand Class

مع العلم أن خرج المصنف لكل Trials في عملية الاختبار والبالغ عددها (28) كما يأتي:


[1. 1. -1. 1. -1. 1. -1. 1. -1. 1. 1. 1. -1. -1. -1. -1. 1. -1. -1. 1. -1. 1. 1. -1. 1. 1.]

ومن خلال الجدول التالي تظهر نتيجة كل معيار حيث تبين أن دقة الصنف (-1) 92% بينما الصنف (1) 87%:

الجدول (6-7) يبين مقاييس معايير الدقة لتقرير التصنيف

	Precision	Recall	F1-Score	Support
-1.0	0.92	0.86	0.89	14
1.0	0.87	0.93	0.90	14
Accuracy			0.89	28
Macro Avg	0.89	0.89	0.89	28
Weighted Avg	0.89	0.89	0.89	28

سنعرض المخطط المتبع من قبل البحث الذي تتم المقارنة معه، والشكل الآتي يوضح ذلك [31]:




الشكل (6-20) المخطط المتبع من قبل البحث الذي تتم المقارنة معه

بعد ذلك تمت المقارنة من خلال الجدول الآتي بين النتائج التي تم الحصول عليها في هذا البحث والبحث الذي تتم المقارنة معه، وكانت النتائج كالاتي:

الجدول (6-8) مقارنة النتائج بين البحث الأساسي والبحث الذي جرت المقارنة معه

Subject No.	Accuracy in basic research "RBF"	Accuracy in basic research "Linear"	Accuracy in comparative research "Linear"	Accuracy in comparative research "RBF"
Subject01	90.47 +/- 5.11	88.88 +/- 6.22	86.83	85.41
Subject02	73.15 +/- 9.45	75.98 +/- 10.78	57.24	57.24
Subject03	97.43 +/- 2.10	97.39 +/- 2.13	86.45	80.95
Subject04	82.72 +/- 8.31	80.18 +/- 8.03	61.40	62.28
Subject05	78.44 +/- 3.91	77.61 +/- 1.30	61.23	67.03
Subject06	84.60 +/- 8.54	85.40 +/- 5.69	50.70	50.23
Subject07	79.24 % +/- 9.77	81.05 +/- 7.53	92.42	86.28
Subject08	99.13 +/- 1.74	98.26 +/- 2.13	87.82	87.45
Subject09	84.42 +/- 5.98	85.36 +/- 4.36	79.17	85.98
Average	85.51 +/- 6.10	85.56 +/- 5.35	73.70 +/- 15.9	73.65 +/- 14.5

كما يبين الشكل الآتي مصفوفة الالتباس لكلا الصنفين:



الشكل (6-21) مصفوفة الالتباس Confusion Matrix

ومن هذه المصفوفة يمكننا حساب بارامترات أو معايير التصنيف الآتية:

حيث أعطى المصنف SVM دقة تصنيف كلية بمقدار 89.2%


الجدول (6-9) نتائج بارامترات ومعايير التصنيف

Precision	Recall	Specificity	F1-Score
$TP/(TP+FP)$	$TP/(TP+FN)$	$TN/(TN+FP)$	$2 * (Precision * Recall) / (Precision + Recall)$
92%	85%	92%	88%

6-6 المحاكاة Simulation:

RoboDK هو برنامج برمجة ومحاكاة غير متصل بالإنترنت للروبوتات الصناعية. [22] يمكن استخدام برنامج المحاكاة في العديد من مشاريع التصنيع بما في ذلك الطحن واللحام والاختيار والوضع والتعبئة ووضع العلامات والتعبئة على منصات نقالة والطلاء ومعايرة الروبوت [23] والمزيد من التطبيقات الأخرى.


يحتوي RoboDK على مكتبة تضم أكثر من 500 روبوت من أكثر من 50 مصنعاً مختلفاً بما في ذلك ABB و Fanuc و Kuka و Motoman و Hwashi Robots و Universal Robots.




الشكل (6-22) واجهة البرنامج المستخدم في عملية المحاكاة

قمنا بداية بعملية الاتصال بين Python وبيئة RoboDK وبعد ذلك قمنا بأخذ خرج المصنف كقائمة List عبارة عن قيم الخرج الناتجة سابقاً والتعامل معها كمصفوفة وبعدها تم برمجة الذراع لتتحرك نحو اليمين عندما تأتي القيمة 1 بينما تتحرك نحو اليسار عند ورود القيمة -1 وهذا الورد العشوائي لقيم الخرج يجعل الذراع تتحرك بحسب الخرج الناتج عن المصنف حيث هناك فاصل زمني من لحظة قدوم الأمر للذراع ووضع ب 0.5 ثانية والتوقف أيضاً لمدة 0.5 ثانية ومن بعدها الانتقال للأمر الآخر وهكذا... حتى تنتهي قيم الخرج التي عددها 28 قيمة مختلفة في الترتيب مابين حركة يمين أو حركة يسار.

حيث لدينا هنا حركة الذراع ما بين يمين ويسار بحسب خرج المصنف.



الشكل (6-23) حركة تمثل انتقال الذراع نحو اليمين



الشكل (6-24) حركة تمثل انتقال الذراع نحو اليسار

وبعد تحرك الذراع وعند كل خرج يعود الذراع للوضع الافتراضي الذي انطلقت منه وهكذا حتى تنتهي عملية المحاكاة والعودة للوضع الافتراضي الأولي.

6-7 مناقشة النتائج والآفاق المستقبلية:

- نلاحظ من خلال جدول المقارنة السابق (6-8) أن المخطط الذي اتبعه الباحث في البحث المقارن معه لم يصل إلى الدقة التي توصل إليها هذا البحث، وذلك بعد القيام بعدد من العمليات لمعالجة البيانات والتي ذكرت سابقاً مع العلم تمت المقارنة مع البحث المعتمد على قاعدة البيانات نفسها والمصنف نفسه، ولكن البحث الآخر لم يقوم بعملية معالجة أولية لإشارات الدماغ، وبهذا يكون البحث قد طوّر عملية معالجة وتصنيف إشارات الدماغ من أجل تحسين دقة التصنيف من خلال تحسين معالجة الإشارات الدماغية بالاعتماد على السمات المكانية Spatial Features.
- من الممكن مستقبلاً استخدام قاعدة بيانات أخرى أو استخدام كامل البيانات في قاعدة البيانات المعيارية المتبعة في هذا البحث أو حتى استخدام جهاز لقراءة الإشارات من أي شخص Real Time Recording ومن الممكن أيضاً استخدام تقنيات أخرى في عملية معالجة البيانات وتصنيفها من خلال التعلم العميق والشبكات العصبونية للحصول على نتائج أفضل، ومن الممكن أيضاً استخدام التعليم المعزز Reinforcement Learning من أجل تدريب الذراع بشكل منفرد لتصبح ذراع ذكية ويمكنها التنبؤ بالحركة من خلال إدخال أي إشارة دماغية ولكن ذلك يتطلب بيانات ضخمة للتدريب ووقت تدريب كبير نسبياً عوضاً عن استخدامها هنا كأداة حركة فقط تأخذ حركتها من المصنف من أجل المحاكاة، بل تصبح أكثر ذكاءً وتطوراً.

- [1] Upendra Kumar Bhusan, Manish Yadav & Sumit Bharagava. (2015). EEG Analysis for Brainwaves under Closed Eye and Open Eye, vol.5
- [2] Rabie A. Ramadan, S. Refat, Marwa A. Elshahed & Rasha A. Ali. (2015). Basics of Brain Computer, vol.21
- [3] Qiang Gao, Lixiang Dou, Abdelkader Nasreddine Belkacem, & Chao Chen. (2017) Noninvasive Electroencephalogram Based Control of a Robotic Arm for Writing Task Using Hybrid BCI System, vol.9
- [4] Anupama H. S, N. K. Cauvery & Lingaraju G. M. (2014). Brain Controlled Wheelchair For Disabled. (IJCSEITR), vol.10
- [5] Geethu Suresh & S.Shanmugaraju . (2016). E-Sense Algorithm Based Wireless Wheelchair Control Using Brain Waves. (IOSR-JEEE).8
- [6] Marwan Nafea, Amirah 'Aisha Badrul Hisham, Nurul Ashikin Abdul-Kadir & Fauzan Khairi Che Harun. (2018). Brainwave-Controlled System for Smart Home Applications. (ICBAPS), vol.6
- [7] Hafeez Ullah Amin, Wajid Mumtaz, Ahmad Rauf Subhani, Mohamad Naufal Mohamad Saad & Aamir Saeed Malik. (2017). Classification of EEG Signals Based on Pattern Recognition Approach. Frontiers in Computational Neuroscience.
- [8] Hauke Dose, Jakob S. Møller, Sadasivan Puthusserypady & Helle K. Iversen. (2018). A Deep Learning MI-EEG Classification Model for BCIs. European Signal Processing Conference (EUSIPCO)
- [9] Jzau-Sheng Lin & Ray Shihb. (2018). A Motor-Imagery BCI System Based on Deep Learning Networks and Its Applications. IntechOpen.
- [10] Natasha Padfield, Jaime Zabalza, Huimin Zhao, Valentin Masero & Jinchang Ren. (2019). EEG-Based Brain-Computer Interfaces Using Motor-Imagery: Techniques and Challenges. Sensors.
- [11] Xiao & Yuee Fang. (2021). Motor Imagery EEG Signal Recognition Using Deep Convolution Neural Network. Frontiers in Neuroscience.
- [12] Delorme, A; Makeig, S. (2004). EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis. California San Diego, vol.21

- [13] Carmen Vidaurre,1 Tilmann H. Sander and Alois Schlögl.(2011). BioSig: The Free and Open Source Software Library for Biomedical Signal Processing, vol.12
- [14] Schalk, G. and J. Mellinger. (2010). A Practical Guide to Brain–Computer Interfacing with BCI2000
- [15] Yann Renard,, Fabien Lotte, Guillaume Gibert, Marco Congedo, Emmanuel Maby, Vincent Delannoy,Olivier Bertrand, Anatole L'ecuyer.(2010). OpenViBE: An Open-Source Software Platform to Design, Test and Use Brain-Computer Interfaces in Real and Virtual Environments, vol.46
- [16] Arnaud Delorme, Christian Kothe, Andrey Vankov, NimaBigdely-Shamlo, Robert Oostenveld, Thorsten Zander, ScottMakeig. (2008). MATLAB-Based Tools for BCI Research, vol.19
- [17] KOTHE,A,C;MAKEIG,S.BCILAB: A platform for brain-computer interface development.California San Diego, vol.24
- [18] Kai Keng Ang, Zheng Yang Chin, Haihong Zhang & Cuntai Guan. (2008). Filter Bank Common Spatial Pattern (FBCSP) in Brain-Computer Interface. International Joint Conference on Neural Networks (IJCNN 2008)
- [19] C. Brunner¹, R. Leeb¹, G. R. Müller-Putz¹, A. Schlogl² & G.Pfurtscheller¹, ¹Institute for Knowledge Discovery, Graz University of Technology, Austria. ²Institute for Human-Computer Interfaces, Graz University of Technology, Austria. BCI Competition. (2008). Graz data set A.
- [20] Shireen Elhabian & Aly Farag. (2009). A Tutorial on Data Reduction, Independent Component Analysis (ICA). University of Louisville, CVIP Lab.
- [21] Michael Hersche, Tino Rellstab, Pasquale Davide Schiavone, Lukas Cavigelli, Luca Benini and Abbas Rahimi. (2018). Fast and Accurate Multiclass Inference for MI-BCIs Using Large Multiscale Temporal and Spectral Features. IEEE European Signal Processing Conference (EUSIPCO).
- [22] Mihai, Dan. RoboDK: An Offline Programming and 3D Simulation Software for Industrial Robots". Smashing Robotics. Retrieved 5 January 2017.
- [23] Bonev, Ilian. "When you need someone from Canada to calibrate your robot in New Zealand". Control and Robotics Laboratory. Retrieved 23 January 2017.
- [24] الشيخ،عامر.تطوير آلية تحكم بالطرف الصناعي العلوي اعتماداً على إشارة العضلات.جامعة دمشق.2018

الملحق:

كود ربط الذراع في بيئة ال RoboDK بلغة البرمجة Python لأخذ الأوامر من خرج المصنف:

```
from robolink import * # API to communicate with RoboDK
from robodk import * # robodk robotics toolbox
from time import sleep
from pickle import load
import numpy as np

model = load(open('C:/Users/-----/modelAndTestData/model.pkl', 'rb'))
with open('C:/Users/-----/modelAndTestData/data.npz','rb') as f:
    testData = np.load(f)
def to_commond(data):
    commands = []
    for result in data:
        if result < 0:
            commands.append("left")
        else:
            commands.append("right")
    return commands

ypred = model.predict(testData)

commands = to_commond(model.predict(testData).tolist())
print(commands)
def move_to(robot,target_ref,ang,R):
    target_i = Mat(target_ref)
    pos_i = target_i.Pos()
    pos_i[0] = pos_i[0] + R*cos(ang)
    pos_i[1] = pos_i[1] + R*sin(ang)
    target_i.setPos(pos_i)
    # sleep(2)
    robot.MoveL(target_i)
    sleep(0.5)
    robot.MoveL(target_ref)

def robo_action(command,robot,target_ref):
    R = 400
```

```

if command == "right":
    ang = 3*pi/2
    move_to(robot,target_ref,ang,R)
elif command == "left":
    ang = pi/2
    move_to(robot,target_ref,ang,R)
else:
    print("error in command")

RDK = Robolink()
robot = RDK.ItemUserPick('Select a robot', ITEM_TYPE_ROBOT)
if not robot.Valid():
    raise Exception('No robot selected or available')

target_ref = robot.Pose()
pos_ref = target_ref.Pos()

robot.MoveJ(target_ref)
robot.setPoseFrame(robot.PoseFrame())
robot.setPoseTool(robot.PoseTool())
robot.setZoneData(10)
robot.setSpeed(100)

for com in commands:
    print(com)
    robo_action(command=com,robot=robot,target_ref=target_ref)
robot.MoveL(target_ref)

```

Abstract

The process of communication between the human brain and the computer is an important matter in our time for various reasons, so that the person can issue commands to electronic devices by reading the brain's electrical signals and translating them into software commands that the computer can understand and interpret. The field where brain signals (EEG) are taken as input to this system and translated into commands on a computer, where scientific research in the field of artificial intelligence and machine learning, especially in the so-called brain-computer interfaces, is no longer directed only to people with motor disabilities, but has become directed to general use in order to improve Experience our use of computers and human communication with the computer better.

Hence, in this study, EEG-MI data was used in order to classify those signals into right hand movements and left hand movements, using multiple algorithms and methods, including the Independent Component Analysis (ICA) algorithm in order to filter these signals and remove the effects of Noise resulting from the effect of some other vital signs such as muscle signals, heart, breathing, eye movement, etc., and then spatial filtering was used using the Common Spatial Pattern (CSP) filter, and then extracted the features for the classification process using machine learning algorithms based on Support Vector Machine (SVM), where the two classes were separated and good results were obtained with accuracy 89.2%

Key Words: Electroencephalogram, Motor Imagery, Independent Component Analysis, Machine Learning, Common Spatial Pattern, Support Vector Machine

**Syrian Arab Republic
Ministry of Higher Education and Scientific
Research
Damascus University
Faculty of Mechanical & Electrical Engineering
Computer and automation Engineering**



Improved the Preprocessing of Vital Signals to Control a Robotic Arm

Thesis submitted for the degree of Master in Robotic Engineering

Student

Eng. Huzaifa Merhj

Supervisor

Prof. Aghiad Al-katan

Associate Supervisor

Dr. Akram Massouh

Year

2023