

الجمهورية العربية السورية

المعهد العالي للعلوم التطبيقية والتكنولوجيا

قسم النظم الالكترونية والميكانيكية

دراسة خوارزميات التعرف على حركات اليد بالاعتماد على إشارات
حساسات EMGs باستخدام قاعدة البيانات NINA PRO

اعداد:

عبدالله عبدالله

دراسة أُعدت لنيل درجة الماجستير في التحكم والروبوتيك

اختصاص روبوتيك

اشراف:


د. أصف جعفر

د. شادي بيطار

Syrian Arab Republic

Higher Institute for Applied Sciences and Technology

Department of Electronic and Mechanical Systems



**Study of hand gesture recognition algorithms using
the EMGs signals based on NINA PRO dataset**

By:

Abdallah ABDALLAH

Submitted in Fulfillment of the Requirements

For Master's Degree in Control and Robotics

Specialty: **Robotics**

Under supervision of:

Dr. Chadi ALBITAR

prof. Assef JAFAR

المعهد العالي للعلوم التطبيقية والتكنولوجيا Higher Institute for Applied Sciences and Technology

المعهد العالي للعلوم التطبيقية والتكنولوجيا مؤسسة حكومية للتعليم العالي أحدثت بموجب المرسوم التشريعي رقم / 24 / لعام 1983، وذلك بهدف إعداد كوادر علمية متميزة من مهندسين وباحثين للإسهام الفاعل في عملية التطوير العلمي والتنمية في الجمهورية العربية السورية.

يمنح المعهد العالي درجة الإجازة في الهندسة في الاتصالات والمعلوماتية والنظم الإلكترونية والميكاترونيكس وعلوم وهندسة المواد وهندسة الطيران. يقبل المعهد العالي لدراسة هذه الاختصاصات شريحة منتقاة من المتفوقين في الشهادة الثانوية من الفرع العلمي. يتيح المعهد العالي أيضاً برامج ماجستير أكاديمي في نظم الاتصالات وفي التحكم والروبوتيك وفي نظم المعطيات الكبيرة ونظم المعلومات ودعم القرار وفي علوم وهندسة المواد وعلوم وهندسة البصريات. وأخيراً، يمنح المعهد العالي درجة الدكتوراه في الاتصالات والمعلوماتية ونظم التحكم والفيزياء التطبيقية. تحدث في المعهد العالي اختصاصات جديدة بحسب متطلبات سوق العمل وتوجهات البحث والتطوير المحلية والعالمية.

إلى جانب النشاط التعليمي، يمارس المعهد العالي عبر جهود أطره وفعالياته العلمية المختلفة نشاطاً حثيثاً في البحث والتطوير، إذ ينفذ مشاريع ودراسات واستشارات متنوعة لصالح الجهات العامة والخاصة في القطر، كما يتعاون مع جهات خارج القطر في بعض المشاريع البحثية والتطويرية. يسعى المعهد أيضاً، عبر دورات تدريبية نظرية وعملية متاحة للقطاعين العام والخاص وللأفراد، إلى إفادة أوسع فئة من المهتمين من إمكانيات

أطره العلمية ومختبراته. واستكمالاً لدوره الرائد في مجال التعليم ونشر العلم، ينشر المعهد العالي كتباً علمية عالية المستوى من نتاج أطره، منها ما هو تدريسي يوافق المناهج في المعهد العالي ويفيد شريحة واسعة من الطلاب الجامعيين عموماً، ومنها ما هو علمي ثقافي. يتيح المعهد العالي بعضاً من منشوراته على موقعه على الشبكة، كما يتيح إمكانية الاطلاع على رسائل الماجستير والدكتوراه المنفذة في المعهد العالي وعلى بعض منشورات طلابه وأطره من المقالات العلمية.

المعهد العالي للعلوم التطبيقية والتكنولوجيا، الجمهورية العربية السورية، دمشق، ص.ب.31983

Higher Institute for Applied Sciences and Technology – HIAST

P. O. Box 31983, Damascus, Syrian Arab Republic

هاتف – 00963115123819 فاكس 00963115140761

بريد الكتروني contact@hiast.edu.sy

موقع الكتروني www.hiast.edu.sy

إهداء

إلى وطني الغالي سوريا

إلى سندي وقوتي عائلتي الرائعة أبي وأمي وأخي وأختي

إلى أصدقائي الذين وقفوا إلى جانبي

كلمة شكر

أتقدم بالشكر الجزيل والامتنان العميق..

للأساتذة المشرفين على هذا العمل البحثي على متابعتهم المستمرة وتوجيهاتهم المثمرة..

الدكتور شادي البيطار والدكتور أصف جعفر

كما أتوجه بشكري إلى جميع أساتذتي في المعهد العالي للعلوم التطبيقية والتكنولوجيا

الملخص:

في الآونة الأخيرة ومع ازدياد استخدام الاطراف الصناعية لمساعدة المرضى ذوي الاعاقة ومع التطور في مجال الذكاء الاصطناعي ازداد الاهتمام بالأبحاث من اجل انتاج أطراف صناعية ذكية. تم في بحثنا تصميم نموذج من أجل التحكم بطرف صناعي علوي بديل ذكي باستخدام الاشارات الكهربائية العضلية EMG لتعويض اليد البشرية. قمنا بدراسة للحركات التي تستطيع اليد البشرية القيام بها ونماذج الأذرع البديلة المنحزة عالمياً وقدرتها على مواكبتها، وتم التركيز في البحث على حركات الالتقاط، والتي يعمل النموذج المقترح على تصنيفها في أربع اصناف بناء على عدد الأصابع المشاركة بعملية الالتقاط بالإضافة الى وضع الراحة. وبعد القيام بدراسة مرجعية لطرق معالجة البيانات، تم اقتراح تحويل اشارات الحساسات الى مصفوفة مقيسة بأبعاد تعتمد على عدد الحساسات ومعدل أخذ البيانات خلال النافذة الزمنية للحركة، ومن ثم تحويلها الى صورة بتدرج رمادي، والاعتماد على خوارزميات التعلم العميق في تصنيفها. جرى الاعتماد على قاعدة البيانات NINA PRO وبعد دراسة النسخ المختلفة تم الاعتماد على النسخة الخامسة منها وتطبيق خوارزمية العمل المقترحة على الاشارات الخام الموجودة فيها، و تمكن النموذج المقترح من تصنيف هذه الاشارات ضمن الأصناف الخمسة بكفاءة عالية وبدقة تصنيف 95.89% باستخدام الشبكات العصبونية التلافيفية CNN.

ABSTRACT

Recently, With the increase in the use of prosthetic arms to help handicapped people and with the development of artificial intelligence, research interest in the production of smart prosthetics has increased. In our research, we designed a model to control a smart alternative upper limb prosthesis to perform the tasks of a lost human hand using EMG electrical signals. We have studied the movements that the human hand can do and the designs of alternative arms that exist globally and their ability to keep pace with the human hand, and we have focused in research on grasping movements, which our proposed model classifies it into four classes based on the number of fingers involved in the grasping process in addition to the resting state. After we conducted a reference study on data processing methods, we proposed converting the sensors signals into a scaled matrix with dimensions that depend on the number of sensors and the rate of data acquisition during the movement time window, and then converting it to a grayscale image, and then relying on deep learning algorithms to classify it. We considered the NINA PRO database and after studying the different versions, we chose the fifth version of it and applied the proposed algorithm on the raw signals, our model was able to classify these signals within the five classes with an accuracy of classification 95.89% using Convolutional Neural Networks (CNN).

قائمة المصطلحات العلمية

الاختصار	ENGLISH	عربي
EMG	ElectroMyoGraphy	الإشارات العضلية
STFT	Short-Time Fourier Transform	تحويل فورييه قصير الزمن
CNN	Convolutional Neural Network	الشبكات العصبونية التلافيفية
FFT	Fast Fourier Transform	تحويل فورييه السريع
MLP	Multi-Layer Perceptron	المستقبلات متعددة الطبقات
PCA	Principal Component Analysis	تحليل العنصر الرئيسي
LSTM	Long Short-Term Memory	الذاكرة قصيرة الأمد المطولة
LCNN	Lookup-based Convolutional Neural Network	الشبكات العصبونية التلافيفية المبنية على البحث
DET	Discrete Fourier Transform	تحويل فورييه المتقطع
DWPT	Discrete Wavelet Packet Transform	تحويل حزم الموجة المتقطع
TD	Time Domain	المجال الزمني
FD	Frequency Domain	المجال الترددي
TFD	Time Frequency Domain	المجال الزمني الترددي
NINA PRO	Non-Invasive Adaptive Hand Prosthetics	بدائل اليد التكميلية غير الجراحية
CWT	Continuous Wavelet Transform	تحويل الموجة المستمر
AP	Action Potential	امكانات العمل
RMS	Root Mean Square	الجذر المتوسط المربع
ADL	Activity of Daily Living	أنشطة الحياة اليومية
DASH	Disabilities of the Arm, Shoulder and Hand	إعاقة اليد والكتف والذراع
SMR	signal-to-motion-artifact ratio	نسبة الإشارة الى الإشارة المرجعية
SPR	Signal to Power line interference ratio	نسبة الإشارة الى تداخل خط الطاقة
OHM	the power spectrum deformation ratio	نسبة تشوه طيف القدرة

DPR	the spectrum maximum-to-minimum drop in power density	انخفاض الطيف من الحد الأقصى الى الحد الأدنى في كثافة الطاقة
SHR	the signal-to-high-frequency-noise ratio	نسبة الإشارة الى الضجيج عالي التردد
SNR	the signal-to-noise ratio	نسبة الإشارة الى الضجيج
MPD	mean power density	متوسط كثافة الطاقة
IMU	Inertial Measurement Unit	وحدة قياس الممانعة
GUI	Graphical User Interface	واجهة مستخدم رسومية
TCP	Transmission Control Protocol	بروتوكول التحكم بالنقل
TP	True Positive	الايجابيات الصحيحة
TN	True Negative	السلبيات الصحيحة
FP	False Positive	الايجابيات الخاطئة
FN	False Negative	السلبيات الصحيحة
FAR	False Acceptance Rate	معدل القبول الخاطئ
FNR	False Negative Rate	معدل السلبيات الخاطئة
FPR	False Positive Rate	معدل الإيجابيات الخاطئة

المحتويات

IV	الملخص
V	ABSTRACT
VI	قائمة المصطلحات العلمية
X	قائمة الأشكال
XII	قائمة الجداول
1	مقدمة عامة
4	الفصل الأول
5	1.1 الغاية من البحث:
5	2.1 البنية التشريحية للذراع البشرية:
9	3.1 مشكلة البحث:
9	4.1 أهداف البحث:
10	5.1 المساهمات البحثية:
10	6.1 الدراسة المرجعية:
10	1.6.1 الدراسة المرجعية للتصاميم العالمية للأذرع الاصطناعية البديلة:
15	2.6.1 فلسفة التصميم التحكمي للأطراف الصناعية:
16	3.6.1 الدراسة المرجعية لطرق معالجة الاشارات وتصنيفها:
21	7.1 الخاتمة:
22	الفصل الثاني
23	1.2 الإشارات العضلية:
23	1.1.2 حساسات الإجهادات العضلية ElectroMyoGraphy:
25	2.1.2 Raw EMG Signal: الاشارات الخام
25	2.2 العوامل المؤثرة على الاشارات العضلية:
26	3.2 قاعدة البيانات NINA PRO:
27	1.3.2 محتويات قاعدة البيانات:

28	2.3.2 الحساسات المستخدمة:
32	3.3.2 بروتوكول التجميع:
35	4.3.2 مقاييس تقييم الإشارة [26]:
38	4.2 الخاتمة:
39	الفصل الثالث
40	1.3 قاعدة البيانات NINA PRO DB5:
42	1.1.3 تحصيل البيانات [27]:
46	2.3 معالجة البيانات:
46	1.2.3 تنظيم الإشارات Normalization:
47	2.2.3 تمثيل البيانات:
52	3.3 تصنيف الإشارات:
52	1.3.3 الشبكات العصبونية [28]:
53	2.3.3 الشبكات العصبونية التلافيفية:
55	3.3.3 الشبكة العصبونية المستخدمة:
57	4.3.3 المعطيات المستخدمة:
59	5.3.3 توسيع البيانات:
60	6.3.3 تنجيز وتدريب النموذج:
61	4.3 الخاتمة:
62	الفصل الرابع
63	1.4 اختبار دقة النتائج:
66	2.4 مقارنة النموذج المقترح مع نموذج ResNet:
68	3.4 اختبار زمن عمل الخوارزمية:
70	4.4 الخاتمة:
71	الخاتمة والأفاق المستقبلية:
72	المراجع:

قائمة الأشكال

- الشكل 1-1: الأقسام الرئيسية لذراع الإنسان 5
- الشكل 1-2: المخطط الحركي للذراع البشرية بدءاً بالمرفق 6
- الشكل 1-3: أقسام الهيكل العظمي للكف البشرية مع توضيح درجات الحرية 6
- الشكل 1-4: طرائق الالتقاط الممكنة لليد 7
- الشكل 1-5: حالات الالتقاط الأساسية 9
- الشكل 1-6: I-Limb Hand 11
- الشكل 1-7: Michelangelo Hand 11
- الشكل 1-8: Bebionic Hand 12
- الشكل 1-9: The Ada Hand 12
- الشكل 1-10: خوارزمية عمل الأذرع الاصطناعية 15
- الشكل 1-11: تحويل الاشارات الى صور عن طريق تحويل STFT 16
- الشكل 1-12: بنية الشبكة LSTM والمستقبلات MLP 17
- الشكل 1-13: بنية الشبكة LCNN 18
- الشكل 1-14: عملية تشكيل صور التدرج الرمادي في [19] 19
- الشكل 2-1: رسم توضيحي تخطيطي لدورة إزالة الاستقطاب / إعادة الاستقطاب داخل الأغشية العضلية 24
- الشكل 2-2: منطقة إزالة الاستقطاب على الأغشية العضلية 24
- الشكل 2-3: الإشارات العضلية الخام 25
- الشكل 2-4: انواع الحساسات المستخدمة في بناء قواعد البيانات NINA PRO 28
- الشكل 2-5: الحركات والايماءات التي تشكل قاعدة البيانات NINA PRO 34
- الشكل 2-6: الوصف للمستويات المختلفة ل SNR 36
- الشكل 3-1: السوار MYO THALMIC 40
- الشكل 3-2: مكونات سوار الذراع myo 41
- الشكل 3-3: النظام المستخدم لتجميع البيانات في قاعدة البيانات للنسخة الخامسة 43
- الشكل 3-4: التكرارات الستة وطبيعة الإشارات لأحد التكرارات 44
- الشكل 3-5: تباين الإشارات بين التكرارات الستة عند جميع الأشخاص ولجميع الحركات 45
- الشكل 3-6: التباين بين الحركات عند جميع الأشخاص ولجميع التكرارات 45
- الشكل 3-7: التباين بين اشارات الأشخاص عند جميع الحركات والتكرارات 45
- الشكل 3-8: تحويل اشارة الحساس الى تدرج رمادي 48
- الشكل 3-9: الاشارات العضلية بعد تحويلها الى صورة 48

- الشكل 3-10: توزيع الحساسات وتسلسلها والمسار المقترح لإغلاق حلقة الحساسات 49
- الشكل 3-11: الصورة النهائية الناتجة 50
- الشكل 3-12: وضع الراحة 51
- الشكل 3-13: (a) عصبون حقيقي، (b) عصبون صناعي مع بيان مداخله ومخارجه 53
- الشكل 3-14: طبقات الشبكة العصبونية التلافيفية المستخدمة 56
- الشكل 3-15: مجموعة من الصور في قاعدة البيانات 58
- الشكل 3-16: توزيع الصور في مجموعة التدريب 58
- الشكل 3-17: توزيع الصور في مجموعة الاختبار 59
- الشكل 3-18: توزيع الصور في الصفوف بعد زيادة البيانات 60
- الشكل 3-19: يبين الجزء (A) تغير توابع الدقة والتأكد من الدقة والجزء (B) يوضح تغير توابع الخسارة و التحقق من الخسارة خلال 100 طور تدريب 61
- الشكل 4-1: مصفوفة الإرتباك للنموذج المقترح 63
- الشكل 4-2: قيم ال precision و ال recall و ال f1-score لكل صف 65
- الشكل 4-3: قيم FAR ,FNR, FPR لكل من الصفوف الخمسة 66
- الشكل 4-4: مبدأ عمل الشبكة ResNet 67
- الشكل 4-5: مخطط خوارزمية العمل 68
- الشكل 4-6: يبين الشكل الصور المتشكلة من سلسلة الاشارات الواردة لأحد تكرارات حركة من الصنف الأول وتصنيفها 69

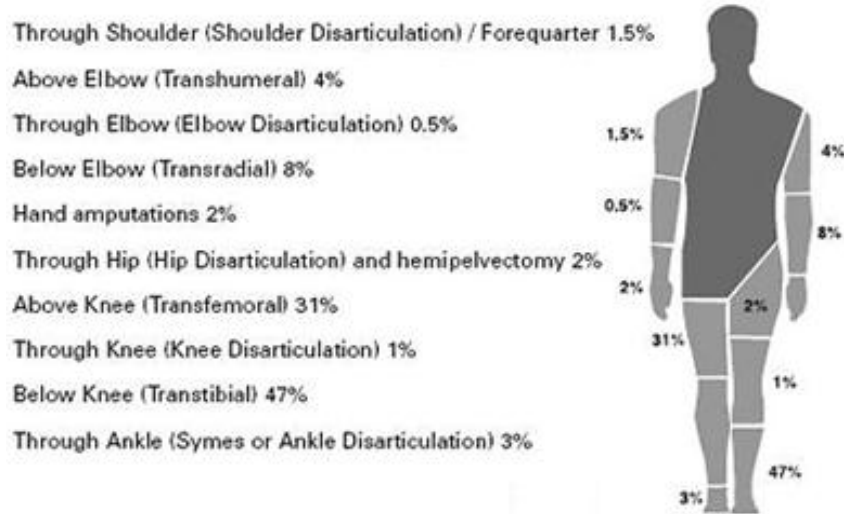
قائمة الجداول

- الجدول 1-1: مقارنة بين النماذج المختلفة لأشهر الكفوف الاصطناعية البديلة 13
- الجدول 1-2: التصنيف المقترح لحركات الالتقاط لليد البشرية 14
- الجدول 1-3: جدول يبين البيانات المستخدمة في عدة دراسات وطرق معالجتها وتصنيفها ودقة التصنيف 20
- الجدول 2-1: خصائص الحساسات المستخدمة في قاعدة البيانات NINA PRO [25] 29
- الجدول 2-2: معلومات عن الأفراد المشاركين في إنتاج النسخ المختلفة لقاعدة البيانات 32
- الجدول 2-3: مقاييس جودة الإشارة وكيفية حسابها 35
- الجدول 2-4: نتائج النسخ المختلفة لقاعدة البيانات باستخدام مقاييس جودة الإشارة: متوسط القيمة \pm الانحراف المعياري (min, median, max) 36
- الجدول 3-1: توزيع حركات الالتقاط ضمن الأصناف الأربعة 51
- الجدول 3-2: أعداد الصور في الصفوف 57
- الجدول 4-1: مقارنة بين النموذج المقترح ونماذج ال ResNet 67
- الجدول 4-2: الزمن اللازم لتنفيذ كل مرحلة من مراحل الخوارزمية 69

مقدمة عامة

يملك الإنسان منذ ولادته مجموعة من الحواس التي تساعد على التفاعل مع محيطه والاستجابة للمؤثرات الخارجية، ولكن ولعدة أسباب قد يخسر أحد هذه الحواس، ونتيجة لذلك يخسر كماً كبيراً من المعلومات والمعطيات عن محيطه، مما يضعف تفاعله ويحد من إمكانياته، ومن أصعب هذه الخسارات هي فقدان الإنسان أحد أطرافه مما يمنعه من متابعة أعماله اليومية بالشكل الطبيعي، عدا عن المشاكل النفسية والاجتماعية التي تتسبب بها هذه الخسارة.

نتيجة الحروب والصراعات المتزايدة في الآونة الأخيرة فإن أعداد الأشخاص الذين يفقدون أحد أطرافهم في تزايد كبير (الشكل (1))، فمثلاً نتيجة الحرب التي تتعرض لها بلدنا سورية بلغ عدد الأشخاص الذين تعرضوا لعمليات بتر في الأطراف عام 2017 إلى 86000 شخص وذلك بحسب منظمة الصحة العالمية، ونتيجة لذلك يزداد توجه الباحثين والمهندسين حديثاً نحو مجال تصميم وتطوير الأطراف الصناعية البديلة كوسيلة لتعويض الطرف المبتور ومحاولة تمكين المصاب من استعادة حياته الطبيعية، وذلك من خلال العمل على إيجاد تصاميم وأفكار متنوعة تساهم في مساعدة المصاب على القيام بالأعمال اليومية الأساسية.



الشكل 1: توزيع الاصابات على مناطق الجسم

تاريخياً، كانت عملية تعويض الأطراف المفقودة لديهم تتم بطرق وأشكال مختلفة، ولكن بدأت الأبحاث في مجال الأطراف الصناعية تتوسع بشكل كبير بعد الحرب العالمية الثانية وماتزال الأبحاث جارية في هذا المجال، حيث يعمل الباحثون والعاملون في هذا المجال لإيجاد تقنيات أكثر جودة وملائمة لاستخدامها في الأطراف البديلة، فتم تصميم مجموعة متنوعة من الأطراف الصناعية التي تعتمد في عملها على التصميم الميكانيكي فقط، حيث ساعد هذا النوع من الأطراف البديلة من تعويض عدد محدود من الأعمال الأساسية التي يحتاجها المريض. مع زيادة التطور وخاصة التطور في المجال المعلوماتي والإلكتروني بالإضافة لتطور تقنيات التصنيع المستخدمة، عمل الباحثون على إدخال هذه التقنيات في مجال صناعة الأطراف الصناعية فتم إدخال المحركات والحساسات ودارات التحكم ضمن التصميم المصنعة وذلك بهدف تحسين أدائها وزيادة فعاليتها وكفاءتها، وقد ساهم ذلك بنقلة نوعية في مجال تصميم وصناعة الأطراف الصناعية حيث تمكن الباحثون من تصميم أطراف صناعية بديلة أكثر قدرة على تحقيق مجموعة كبيرة من العمليات الأساسية اللازمة للمريض. مع تزايد التطور التكنولوجي والعلمي ومواكبة لهذا التطور وبهدف زيادة كفاءة وفعالية الأطراف الصناعية، ونتيجة لظهور خوارزميات الذكاء الصناعي وتقنيات الرؤية الصناعية بالإضافة لخوارزميات التعلم العميق، سعى الباحثون لإدخال هذه التقنيات والخوارزميات في عمليات التحكم والقيادة اللازمة للأطراف الصناعية مما أدى لقفزة نوعية جديدة في مجال تصميم الأطراف الصناعية وصناعتها، وساهم في الحصول على أطراف صناعية بديلة تشابه قدر الإمكان الأطراف البشرية الطبيعية وتحقق معظم عملياتها الأساسية اللازمة.

رافق هذا التطور والتحديث المستمر تغير كبير في التكاليف المترتبة على إدخال التقنيات والخوارزميات والتصاميم المتطورة في تصنيع هذه الأطراف، الأمر الذي شكل عائقاً كبيراً لدى شريحة واسعة من المرضى وذلك نتيجة الأسعار المرتفعة للأطراف الصناعية (الشكل 2)) والتي تحول دون إمكانية المريض من شرائها أو قبوله بأطراف بديلة ليست ذات أداء أو فعالية كبيرين.



الشكل 2: أسعار بعض الأطراف الصناعية الذكية

هذا الأمر دفع الباحثين والعاملين في هذا المجال للعمل الدائم على إيجاد حلول وأفكار جديدة تساهم في تصميم طرف بديل يحقق رغبات المريض وبسعر مقبول من خلال إيجاد توازن ما بين المتطلبات والتكاليف من جهة، والميزات والحركات التي تحققها هذه الأطراف من جهة أخرى، وهذا ما يجعل مجال تصميم وصناعة الأطراف الصناعية محط أنظار عدد كبير من الباحثين والمهندسين حيث يوجد مجال كبير لعمليات التطوير والتحديث.

نركز في هذا البحث على الجزء الأول من عملية التحكم بالذراع، ويشمل خوارزمية معالجة الاشارات وتصنيفها بتصنيف اقترحناه باستخدام شبكات التعلم العميق حيث يتضمن الفصل الأول تعريفاً بالبحث وأهدافه بالإضافة الى دراسة مرجعية لتصاميم الأذرع الاصطناعية والأبحاث ذات الصلة، والفصل الثاني يتضمن تعريفاً بالإشارات العصبية وبنيتها، بالإضافة الى دراسة قاعدة البيانات المختارة. في الفصل الثالث نعرض خوارزمية العمل المقترحة والتي تتضمن عمليات معالجة الإشارات العصبية، بالإضافة لدراسة للشبكات العصبونية العميقة والنموذج المقترح لتصنيف الاشارات، أما الفصل الرابع يتضمن تقييم النتائج وخاتمة ومجموعة من الآفاق المستقبلية لهذا العمل.

الفصل الأول

التعريف بالبحث

نعرض في هذا الفصل تعريفاً لبنية الذراع البشرية والأذرع الاصطناعية والنماذج المنفذة منها، مع تقديم دراسة مرجعية للأبحاث ذات الصلة وصولاً إلى تحديد مشكلة البحث وأهدافه.

1.1 الغاية من البحث:

هدف هذا البحث الى استثمار خوارزميات الذكاء الصناعي لتطوير التحكم بطرف صناعي علوي (كف صناعي) لتعويض الاشخاص فاقدى الأطراف العلوية عن مهام الالتقاط التي فقدوها نتيجة البتر، والوصول الى نموذج صلد قدر الامكان يساهم في زيادة فعالية الأيدي الصناعية وتسهيل استخدامها والمساهمة في توطین الأذرع الذكية.

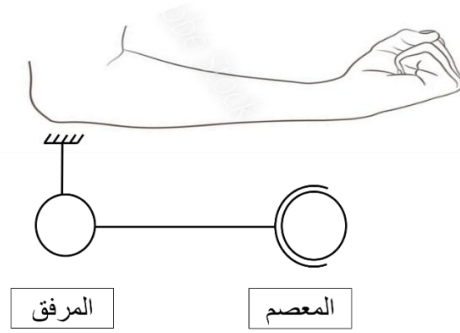
2.1 البنية التشريحية للذراع البشرية:

تتألف ذراع الإنسان من بنية معقدة من العظام والعضلات والأوتار والأربطة (الشكل (1-1)) التي تؤمن حركة الذراع وتشكل بنيتها العامة. تتألف ذراع الإنسان بدءاً بالمرفق من أربعة أقسام رئيسية وهي: المرفق Elbow، الساعد ويقسم إلى قسمين هما الزند Ulna والكعبرة Radius، المعصم Wrist والكف Hand.



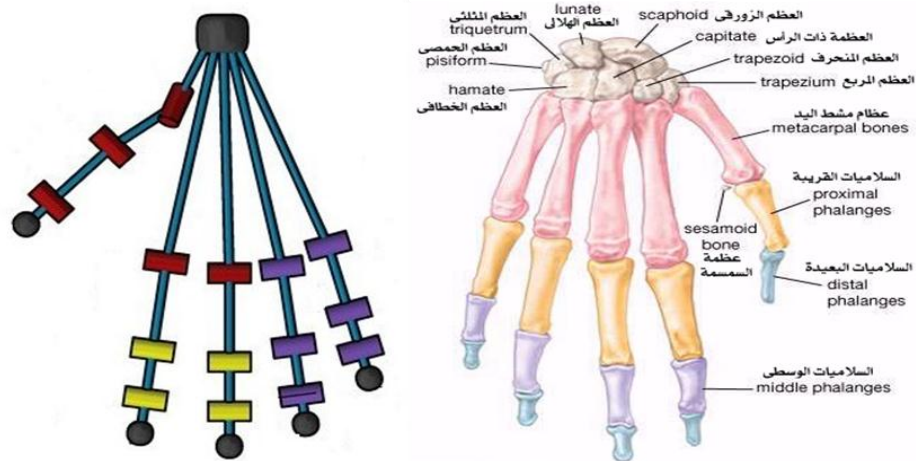
الشكل 1-1: الأقسام الرئيسية لذراع الإنسان

تحقق الذراع مجموعة من درجات الحرية، حيث لدينا درجة حرية واحدة في المرفق، وثلاث درجات حرية في المعصم (الشكل (2-1)).



الشكل 1-2: المخطط الحركي للذراع البشرية بدءاً بالمرفق

أما الكف (الشكل 1-3)) فهي تتألف من عظام المشط التي تشكل راحة اليد [1]، والأصابع التي تقسم إلى ثلاثة أجزاء هي: السلاميات القريبة (proximal) وهي الجزء السفلي من الإصبع، الوسطى intermediate وتمثل منتصف الإصبع، والبعيدة distal ويمثل طرف الإصبع من الأعلى)، باستثناء الإبهام الذي يتألف من السلامية القريبة والبعيدة فقط. تتحكم أربع وثلاثون عضلة في اليد والساعد في حركة هذا الهيكل العظمي مما يعطي اثنتين وعشرين درجة حرية رابطة. الجدير بالذكر أنه لا توجد عضلات داخل الأصابع لتحريكها، وإنما يتم تحريك الإصبع بالاستعانة بالأوتار التي تربط أجزاء الإصبع بعضلات الكف والساعد.



الشكل 1-3: أقسام الهيكل العظمي للكف البشرية مع توضيح درجات الحرية

تتحقق عمليات الالتقاط بمساعدة اليد وذلك من خلال الأصابع وراحة الكف، حيث يوجد العديد من أنماط الالتقاط التي يمكن ليد الإنسان تحقيقها. يعرض (الشكل 1-4) 33 طريقة ممكنة لالتقاط الأغراض، حيث نعتد لاحقاً على هذا الجدول في اختيار أنماط الالتقاط الأكثر استخداماً لتوظيفها في دراستنا في هذا المشروع. تم تصنيف هذه الطرائق لمجموعات اعتماداً على أربعة اعتبارات أساسية [2] وهي:

1- نوع الالتقاط Power, Intermediate, Precision.

2- وضعية الإبهام: مقابل لأطراف الأصابع Abducted، أو جانبي Adducted.

3- نمط مقابلة الإبهام للكف: Palm, Pad, Side.

4- عدد القوى المطبقة في الاتجاهات المختلفة (عدد الأصابع الافتراضية VF).

	Power					Intermediate			Precision					
	Palm		Pad			Side			Pad			Side		
Opp: VF:	3-5		2	2-3	2-4	2-5	2	3	3-4	2	2-3	2-4	2-5	3
Thumb Abducted	1: Large Diameter 2: Small Diameter 3: Medium Wrap 10: Power Disk 11: Power Sphere		31: Ring	28: Sphere Finger	18: Extension Type 26: Sphere 4-Finger Type	19: Distal Type	23: Adduction Grip		21: Tripod Variation	9: Palmar Pinch 24: Tip Pinch 33: Inferior Pincer	8: Prismatic 2 Finger 14: Tripod	7: Prismatic 3 Finger 27: Quadpod	6: Prismatic 4 Finger 12: Precision Disk 13: Precision Sphere	20: Writing Tripod
Thumb Adducted	17: Index Finger Extension	4: Adducted Thumb 5: Light Tool 15: Fixed Hook 30: Palmar					10: Lateral 29: Stick 32: Ventral	25: Lateral Tripod					22: Parallel Extension	

الشكل 1-4: طرائق الالتقاط الممكنة لليد

نستعرض فيما يلي سبع حالات أساسية للالتقاط:

Cylindrical Grasp-1: تستخدم فيه كافة الأصابع مع راحة الكف ويكون الإبهام مقابلاً للأصابع لتثبيت الجسم مما يحقق استقراراً كبيراً. يتم بهذه الطريقة التقاط أجسام اسطوانية الشكل ككأس مثلاً.

Pinch Grasp-2: نستعين بهذا النوع من الالتقاط عند التعامل مع الأجسام صغيرة الحجم، ونستخدم فيه السبابة والإبهام لالتقاط الأجسام الصغيرة والخفيفة.


Tripod Grasp-3: يتم فيها استخدام ثلاثة أصابع هي الإبهام والسبابة والوسطى لتحقيق الالتقاط المطلوب.

Spherical Grasp-4: يتم في هذا النمط استخدام خمسة أصابع لتثبيت الجسم.

Hook Grasp-5: يتم في هذه الطريقة استخدام سلاميات الأصابع لتستند عليها الأجسام، وقد يستخدم الإبهام لتحقيق استقرار جيد للجسم ضمن اليد.

Key Grasp-6: يتم في هذه الطريقة استخدام الجانب الداخلي من الإبهام مع جانب السبابة لتثبيت الأجسام، ومن أشهر الأمثلة على هذه الطريقة هي إمساك المفاتيح عند فتح الأبواب.

Parallel Extension-7: يتم في هذه الطريقة التقاط الجسم عن طريق مقابلة الإبهام لبقية الأصابع الممدودة بشكل موازٍ لأحد أسطح الجسم، كما هو الحال عند إمساك كتاب مثلاً.



الشكل 1-5: حالات الالتقاط الأساسية

3.1 مشكلة البحث:

إن تمكين الذراع البديلة من محاكاة اليد البشرية قدر الإمكان ضمن فضاء الحرية المتاح والقيام بحركات الالتقاط الأساسية وتحقيق أقل استهلاك طاقي وتصميم عملي يخفف العديد من التعقيدات وأولها التصميم الميكانيكي ودرجات الحرية وعدد المحركات التي تتحكم بعملية الالتقاط بالإضافة الى استخدام طرق لمعرفة الحركة التي يجب على الكف الصناعية تنفيذها والقيام بها ضمن الزمن الحقيقي، والموازنة بين هذا الأمر وبين تخفيض كلفة التنفيذ حيث يعد هذا المجال تحدياً مفتوحاً قدمت في ضوءه مقاربات عديدة نتحدث عنها في فقرة الدراسة المرجعية.

4.1 أهداف البحث:

على اليد الصناعية الذكية أن تخدم مجمل نواحي حياة الإنسان المصاب، مما يستلزم وجود وضعيات مختلفة ومتنوعة لليد الصناعية، وهذه الوضعيات تختلف حسب تصميم اليد ودرجات الحرية الخاصة بها بالتالي نقوم بدراسة الأذرع الصناعية وعملية التحكم بها وذلك أولاً بتحديد أنماط حركة اليد واقتراح تصنيفاً لها، ومن ثم دراسة المعلومات المقدمة من الحساسات العضلية والتي هي معلومات غير كافية لتحديد الوضعية المطلوبة. للتغلب على هذا الموضوع اتجهت الشركات التجارية في مجال الأطراف الصناعية إلى الاستعانة بدور الزمن أو بعدد معين من النبضات العضلية المتتالية لتحديد الوضع المطلوب. يعد هذا المبدأ طريقة غير طبيعية وغير تلقائية للتفاعل مع المستخدم، ويتطلب مستوى من التركيز ووقتاً طويلاً للتعلم. لذلك تم اللجوء الى معالجة

الإشارات العضلية قبل استخدامها حيث سنقوم بدراسة هذه الإشارات ومعالجتها قبل القيام بتصنيفها وتحديد الوضع المطلوب القيام به.

5.1 المساهمات البحثية:

1- اقتراح تصنيف حركات التقاط اليد البشرية ضمن خمسة أصناف حسب عدد الأصابع المشاركة في عملية الالتقاط.

2- اقتراح طريقة لتحويل الإشارة العضلية الى صورة تعبر عن تغير شدة الإشارات للحساسات المختلفة على شكل أشرطة ذات تدرج رمادي.

3- تم تصميم شبكة عصبونية تلافيفية CNN وتصنيف الصور التي تم تشكيلها.

6.1 الدراسة المرجعية:

1.6.1 الدراسة المرجعية للتصاميم العالمية للأذرع الاصطناعية البديلة:

يجب الموازنة بين عدد الأنماط التي يتم التعرف عليها ودرجات الحرية للأذرع، ونركز في هذه الدراسة المرجعية على مقارنة التصميم الميكانيكي ودرجات الحرية للأذرع المنفذة عالمياً مع عدد الحركات التي تنفذها هذه الأذرع. فيما يلي مجموعة مختارة من الأيدي الصناعية الكهربائية العضلية التجارية. تم التركيز على الأيدي الصناعية عالية الأداء ، مع عدد كبير من درجات الحرية، والتي يمكن أن تسمح بعدد أعلى من أنماط الحركة، ونذكر منها: [3] bebionic ، [4] Hero Arm ، [5] i-limb ultra-Revolution [6]LUKE ، [7] Michelangelo Hand ، [8] TASKA Hand ، [9]VINCENT evolution 3 Arm .

تسمح أذرع I-Limb Hand from Touch Bionics [5] بتنفيذ أنماط مختلفة للحركة والالتقاط حيث تم تفعيل كل إصبع بمحرك مستقل أيضاً (الشكل (1-6))، ولكن لا يتوفر في هذا التصميم محرك لتأمين دوران الإبهام وإنما يتم ضبطه يدوياً، ويتم توليد أوامر التحكم للمحركات بالاعتماد على الإشارات العضلية.



الشكل 1-6: I-Limb Hand

في حين تم تصميم اليد. Michelangelo Hand, Ottobock Inc. [7] بحيث تكون قريبة جداً من شكل اليد البشرية، وتتميز بوجود إبهام مفعل (الشكل (1-7))، كما تؤمن 7 أنماط للإمساك بحيث يتمكن المستخدم من أداء معظم المهام اليومية (فتح غطاء، إمساك مفتاح، استخدام مكواة... إلخ)، ويتم التحكم بهذه اليد عن طريق الإشارات العضلية.




الشكل 1-7: Michelangelo Hand

في الكف [3] Bebionic Hand محرك مستقل لكل إصبع، بالإضافة إلى محرك يحقق دوران الإبهام، وتتضمن الكف دارات ومعالجات للتحكم بموضع وحركة هذه الأصابع بدقة (الشكل (1-8)). تعتمد هذه اليد في تحديد طريقة الالتقاط على الإشارات العضلية، ويمكن أن تقوم بـ 14 نمطاً مختلفاً للإمساك بحيث تغطي معظم الأنشطة اليومية التي يقوم بها المستخدم.



الشكل 1-8: Bebionic Hand

تم تنفيذ الكف The Ada Hand بالطباعة ثلاثية الأبعاد [1]، ويتم تحريك كل إصبع في اليد من خلال أسلاك مشدودة تصل جميع أجزاء الإصبع مع المحركات الموجودة في راحة اليد (الشكل (1-9)). تؤمن هذه اليد خمسة أنماط مختلفة للإمساك بالأشياء، ولكنها تفتقر لمواصفات الأطراف عالية الأداء.



الشكل 1-9: The Ada Hand

بعد دراسة هذه التصاميم نجد أن الأيدي الصناعية مازالت غير قادرة على مواكبة اليد البشرية في القيام بجميع الحركات حيث إن درجات الحرية للأصابع غير كافية. إن عدد الأصابع المشاركة في الحركة يعد معياراً مهماً يميز الحركات عن بعضها البعض، تحتوي بعض النماذج على محرك مستقل لكل إصبع وبعضها الآخر يتم فيه تحريك الأصابع سوية بواسطة محرك مشترك.

نلاحظ أن كل النماذج لا تحتوي على الحركات الدورانية في قاعدة الأصابع بالتالي للأصابع درجة حرية دورانية واحدة وذلك يحد من قدرتها على القيام بالعديد من الحركات، أما بالنسبة للإبهام فتم العمل على مسألة المحرك

الدوراني حيث أنه في بعض النماذج يكون الإبهام كغيره من الأصابع لا يحتوي على درجة الحرية الدورانية وفي بعضها يتم ضبط الإبهام يدويا وبعضها الآخر يتم التحكم بدورانه طريق محرك.

الجدول 1-1: مقارنة بين النماذج المختلفة لأشهر الكفوف الاصطناعية البديلة

النموذج	عدد محركات التفعيل	وضع الإبهام	عدد الحركات التي تنفذها اليد	DOF	السعر
I-Limb Hand from Touch Bionics [5]	تحتوي خمسة محركات (محرك لكل اصبع)	مفعل يدويا لا يحتوي على محرك خاص	24	6	\$ 45,000
Michelangelo Hand, Ottobock Inc [7]	تحتوي ثلاثة محركات	الإبهام مفعل اوتوماتيكيا أي يوجد محرك خاص بتعديل وضعه	7	4	\$ 60,000
Bebionic Hand [3]	تحتوي خمسة محركات (محرك لكل اصبع)	الإبهام مفعل يدويا	14	6	\$ 11,000
Hero Arm [4]	تحتوي ثلاثة محركات أو أربعة	الإبهام غير مفعل	4 للنسخة الأولى و 6 للنسخة الثانية	5 للنسخة الأولى و 6 للنسخة الثانية	\$ 6,600
The Ada Hand [1]	تحتوي خمسة محركات (محرك لكل اصبع)	الإبهام غير مفعل	5	5	\$ 20,000
LUKA Arm [6]	تحتوي على ستة محركات	الإبهام مفعل اوتوماتيكيا	6	6	\$ 100,000

35,000 \$	8	23	الاجهام مفاعل اوتوماتيكيا	تحتوي على ستة محركات	TASKA Hand [8]
**	4	4	الاجهام غير مفاعل	تحتوي اربعة محركات	النموذج المصنع محليا

نلاحظ من الجدول 1-1 التأثير الكبير للتصميم الميكانيكي وعدد درجات الحرية في تفعيل الأصابع، ونلاحظ انه من غير المجدي أخذ كل عمليات الالتقاط وتنفيذها حيث نلاحظ أن الأذرع الاصطناعية ونتيجة لقلة درجات الحرية تقوم بتنفيذ أغلب الحركات بطريقة متشابهة لذلك كان من المهم القيام بدراسة للحركات التي تستطيع الكف القيام بها وذلك لتصنيف حركات اليد الطبيعية في مجموعات، حيث تضم كل من هذه المجموعات على حركات متقاربة والتي تعبر اليد الصناعية عنها بطريقة واحدة ضمن فضاء الحرية الممكن

وبالتالي تم اقتراح تصنيف حركات الالتقاط في أربع أصناف حسب عدد الأصابع المشاركة في الحركة بالإضافة لوضع الراحة.

الجدول 1-2: التصنيف المقترح لحركات الالتقاط لليد البشرية


الالتقاط بخمس أصابع	الصنف الأول
الالتقاط بأربع أصابع	الصنف الثاني
الالتقاط بثلاث أصابع	الصنف الثالث
الالتقاط بإصبعين	الصنف الرابع
وضع الراحة	الصنف الخامس

2.6.1 فلسفة التصميم التحكمي للأطراف الصناعية:

يمكن تصنيف التصميم المتبعة للأطراف الذكية بالاعتماد على نوع الإشارات التي تستخدمها من أجل تمييز الحركات:

- تصاميم تعتمد على الإشارات الدماغية كمصدر للأوامر.
- تصاميم تعتمد على الإشارات العصبية المقاسة من النهايات العصبية.
- تصاميم تعتمد على التحسس للإجهادات العضلية.

في السنوات الأخيرة تم استخدام تقنية الإشارات الكهربائية العضلية EMGs على نطاق واسع في التحكم في الأطراف الصناعية، نظرا لأنها تقنية غير جراحية وغير باهظة الثمن ويسهل تنفيذها، حيث يعد تمييز هذه الإشارات التي تعبر عن الحركات المختلفة الجزء الأساسي في تطبيقات الأذرع التي تستخدم الإشارات العضلية، ونظرا للطبيعة العشوائية وغير الخطية وغير الثابتة لهذا النوع من الإشارات [10] فمن غير العملي استخدام الإشارات بشكل مباشر، لذلك يتم معالجة البيانات قبل استخدامها. يمكن اعتبار الإشارات العضلية كمصدر للتحكم بالكفوف الصناعية، بحيث يتكون مخطط التحكم بشكل أساسي من ثلاثة أجزاء (الشكل 1-10): تسجيل الإشارات العضلية من الحساسات ومن ثم معالجتها وبعدها عملية التصنيف



الشكل 1-10: خوارزمية عمل الأذرع الاصطناعية


3.6.1 الدراسة المرجعية لطرق معالجة الاشارات وتصنيفها:

ركزت الأديبات سابقا على استخراج السمات من الاشارات العضلية [11] والتي تهدف الى تمييز اشارات EMGs عن طريق التعرف على السمات. تم اقتراح العديد من السمات الفعالة في المجال الزمني والترددية وتم الحصول على نتائج جيدة جدا باستخدام الخوارزميات التقليدية للذكاء الصناعي [12]، ومع ذلك من الصعب تحسين أداء التعرف على الحركات باستخدام الطرق التقليدية

اقترح الباحثون استخدام الشبكات العصبية العميقة (التعلم العميق) لتصنيف الاشارات العضلية [13] والتي لا تتطلب استخراج سمات، والذي حقق نجاحا كبيرا في تصنيف الصور، وتم العمل على تمثيل الاشارات العضلية على شكل صور.

نستعرض فيما يلي عددا من الدراسات التي ركزت على معالجة البيانات وتصنيفها.

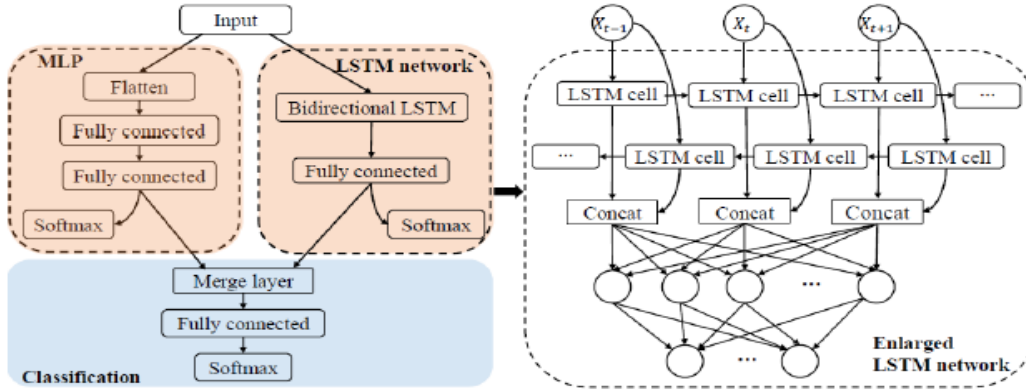
اقترح الباحثون في [14] و[15] تحويل الاشارات الى صورة وذلك عن طريق تحويل (STFT) Short-Time Fourier Transform ومن ثم تصنيفها.



الشكل 1-11: تحويل الاشارات الى صور عن طريق تحويل STFT

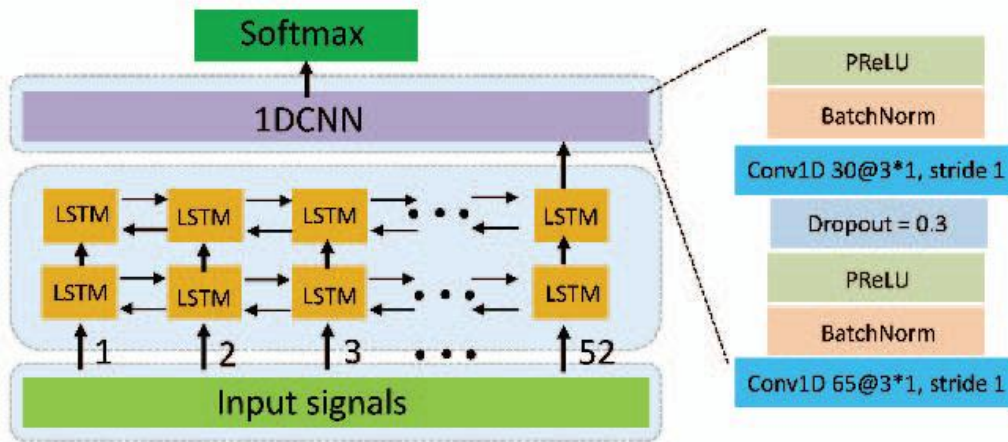
في [16] تم اقتراح مصنف ذاتي المعايرة يمكن تحديثه تلقائيا للحفاظ على أداء مستقر بمرور الوقت دون الحاجة الى اعادة تدريب المستخدم ويعتمد على شبكات CNN، حيث تتم عملية اعادة معايرة المصنف قبل التدريب بشكل روتيني باستخدام نسخة مصححة من نتائج جلسات الاختبار الاخيرة. تم تطبيق تحويل

فورييه السريع (FFT) بحيث ينتج عن كل مقطع من الاشارات مخطط طيفي، يتم بعدها ضبط شدة المخطط الطيفي بين 0-1 لكل قناة وبعدها يطبق تحليل PCA والذي يستخدم من أجل تقليل أبعاد البيانات بطريقة رياضية فنتج لدينا الصور التي يتم اعتمادها كمدخل لشبكة CNN. في [17] تم تصميم نموذج تمييز أنماط يستخدم وحدات (LSTM) والتي تعد جزءا من الشبكات العصبية المتكررة وتعمل كتل هذه الوحدات على تجهيز البيانات من أجل ادخالها إلى الشبكة وهي وحدات معقدة تحتوي على مكونات مختلفة مثل المدخلات الموزونة ووظائف التنشيط والمدخلات من الكتل السابقة والنواتج النهائية وتستند في عملها على عمليات الذاكرة قصيرة المدى لإنشاء ذاكرة طويلة المدى، وتم دمج وحدات LSTM بالمستقبلات متعددة الطبقات (MLP) وهي عبارة عن شبكة عصبونية تربط طبقات متعددة في رسم بياني موجه، والتي غالبا ما تستخدم لحل المشكلات التي تتطلب التعلم تحت الإشراف، وتم العمل على أمثلة بنية الشبكة عبر تحقيق عرض وعمق مناسبين للشبكة العصبونية للوصول الى افضل النتائج.



الشكل 1-12: بنية الشبكة LSTM والمستقبلات MLP

وفي [13] تم دمجها مع الشبكات العصبونية CNN في بنية واحدة تسمى LCNN حيث يتم استخدام LSTM لاستخراج المعلومات الزمنية من الاشارة فيما تقوم شبكة CNN بالتصنيف

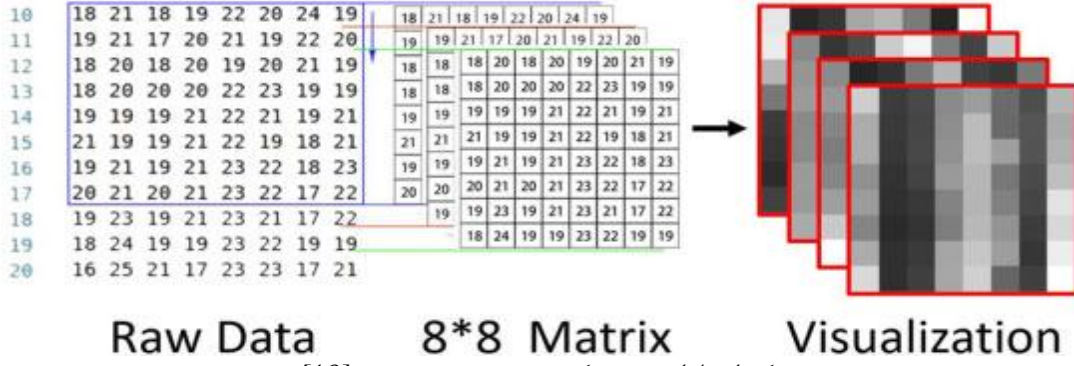


الشكل 1-13: بنية الشبكة LCNN

بنية هذه النموذج تتكون من طبقتين LSTM وكل طبقة تحتوي على 52 خلية وكل خلية تحتوي على 64 طبقة مخفية وخرج هاتين الطبقتين ينتقل الى شبكة CNN تحتوي طبقتين Convolution أحادية البعد، الطبقة الأولى تحتوي 65 فلتر $1*3$ متبوعة ب 30 فلتر $1*3$ وأخيرا توجد طبقة خرج وتم استخدام تابع التفعيل PReLU اللاخطي.

اقترحت [18] طريقة تصنيف تنقسم الى مرحلتين؛ الأولى تستخدم شبكة CNN لاستخراج المميزات مع الاعتماد على تقنية النوافذ المنزلقة حيث يتم تطبيق تحويل Discrete Fourier Transform (DET) لتحويل الإشارة الى المجال الترددي و Discrete Wavelet Packet Transform (DWPT) للتحويل الى المجال الزمني الترددي بالإضافة الى المجال الزمني الأصلي.

في [19] تم اقتراح خوارزمية تصنيف تعمل على تحويل الاشارات الى صور ذات تدرج رمادي حيث يتم تجميع الاشارات في مصفوفة مربعة طولها وعرضها مساو لعدد الحساسات ومن ثم تحويل قيمها الى بيكسلات.



الشكل 1-14: عملية تشكيل صور التدرج الرمادي في [19]

[20] تم العمل على استخراج أغلب المميزات الممكنة من البيانات في المجال الزمني TD وفي المجال الترددي FD وفي المجال الزمني الترددي TFD، وفي [15] تم استخراج المميزات في المجال الزمني TD ومميزات المجال الزمني المحسن ومميزات NINA PRO ومميزات SampEn pipeline والتعامل مع هذه المميزات المستخرجة وتصنيفها باستخدام الخوارزميات التقليدية.

تم العمل على تحويل الاشارات الى صور باستخدام تابع نوافذ HANN والتي تستخدم من أجل التحليل الطيفي للإشارة العضلية وبالتالي تنتج صورة لطيف الإشارة كما في [21] وتم استخدام التحويل Continue Wavelet Transform (CWT) في تشكيل الصور في [15][21] بحيث نحصل على صورة تعبر عن طيف الإشارة وتحتوي على معلومات مجال التردد.

تم في [22] العمل على استخراج اربع مجموعات من المميزات في المجال الزمني TD حيث تحتوي المجموعة الأولى TD1 على 6 ميزات والمجموعة الثانية TD2 على عشرة ميزات والمجموعة الثالثة TP-PSD1 على ميزتين والمجموعة الرابعة TP-PSD2 على خمس ميزات، وبعد ذلك تم العمل على تحويل الاشارات الى صور وذلك بعدة طرق منها استخدام تحويل فورييه على الاشارات وعلى الميزات المستخرجة.

وفي [23] تم اقتراح استخدام خوارزميات تعلم الآلة extreme learning machines و echo state machines كبديل منخفض التكلفة الحسابية للتعرف على الحركة من الإشارات الكهربائية العضلية، بالنسبة extreme learning machines هي طريقة تعلم بديلة لشبكات التغذية الأمامية أحادية الطبقة، وتعتمد أسلوب عمل مختلف بحيث يتم تعيين الأوزان بين المدخلات والطبقة المخفية بشكل

عشوائي ، بينما يتم تحديد أوزان المخرجات فقط تحليليًا. أما بالنسبة ل echo state machines تم اعتماد نهج جديد للتدريب واستخدام الشبكات العصبية المتكررة. تم مقارنة النتائج مع بعض الخوارزميات الأخرى.

الجدول 1-3: جدول يبين البيانات المستخدمة في عادة دراسات وطرق معالجتها وتصنيفها ودقة التصنيف

المرجع	البيانات المستخدمة	طريقة المعالجة	طريقة التصنيف	النتائج
Yusuke Yamanoi [14]	ثمان حركات وخمس حساسات EMG	STFT	CNN	88%
Xiaolong Zhai [16]	عشر حركات من nina pro db2,3	FFT , PCA	CNN	88.42 % 73.31 %
Yunan He [17]	التمرين 1 و 2 من NINA PRO DB5	-	MLP+ LSTM	75%
SHU SHEN [18]	التمرين 1 و 2 من NINA PRO DB5	DET, DWPT	LCNN	80%
Yuheng Wu [13]	التمرين 1 و 2 من NINA PRO DB5	LSTM	CNN	70% 60%
Ulysse Cote Allard [21]	التمرين 2 من NINA PRO DB5	HANN , CWT	CNN	70%
Jingwei Too [12]	6 حركات من 5 أشخاص	Features Extraction	KNN, LDA, NB, SVM	97.56%
Jorge Arturo [22]	NINA PRO DB2,3	Features Extraction + Image	CNN	97.61% 90.23%

نلاحظ بعد مراجعة الدراسات السابقة ان استخدام الاشارات العضلية للتحكم بالأطراف الاصطناعية قد وصل الى مرحلة متقدمة وتنقسم الأعمال في عدة توجهات منها استخراج السمات من الاشارات والتي تهدف الى تمييز اشارات EMGs عن طريق التعرف على السمات وتم اقتراح العديد من السمات الفعالة في المجال الزمني والترددية وتم الحصول على نتائج جيدة جدا باستخدام الخوارزميات التقليدية للذكاء الصناعي، ولكن أصبح من الصعب تحسين أداء التعرف على الحركات باستخدام الطرق التقليدية. التوجه الآخر استخدام الشبكات العصبية العميقة التي تعمل على تصنيف الاشارات دون استخراج سمات و التوجه الأهم وهو استخدام التعلم العميق في تصنيف الاشارات بعد تحويلها الى صور ولقد تحققت نتائج جيدة جدا في هذا المجال ومازال العمل جارياً على تحسين النتائج من خلال ابتكار طرق اخرى لتحويل الاشارات الى صور او من خلال استخدام الخوارزميات الحديثة للتعلم العميق لذلك يعد هذا التوجه توجهاً واعداً لذلك اقترحنا العمل ضمنه في هذا البحث حيث سنعمل على تمثيل الاشارات العضلية بصور حسب الخوارزمية المقترحة وتصنيف هذه الصور باستخدام الشبكات العصبونية العميقة.

7.1 الخاتمة:

قمنا في هذا الفصل بالتعريف بالبحث وأهدافه والتعرف على بنية اليد البشرية ودراسة مرجعية لنظيراتها الاصطناعية ونتيجة لهذه الدراسة اقترحنا تصنيف الحركات في خمسة أصناف، ومن ثم قمنا بدراسة مرجعية لطرق التعامل مع الإشارات العضلية والتي تعتبر أساس عملنا، وفي النهاية تم الاعتماد على طريقة تحويل الإشارات الى صورة وتصنيفها باستخدام تقنيات التعلم العميق.

الفصل الثاني

الإشارات العضلية EMG

نعرض في هذا الفصل تعريفاً بالإشارات العضلية وطريقة تشكيلها وبنيتها بالإضافة الى دراسة قاعدة البيانات *NINA PRO*.

1.2 الإشارات العضلية:


نهتم في هذا العمل بالإشارات التي تعبر عن نشاط العضلات ويتم تحصيلها عن طريق حساسات EMG [24] وفيما يلي شرح عن كيفية توليدها وقياسها.

1.1.2 حساسات الإجهادات العضلية ElectroMyoGraphy:

تحدث التقلصات العضلية تحت تأثير نشاط كهربائي (تحفيز كهربائي) مولد من خلايا عصبية تدعى العصبونات الحركية Motoneurons، أجسامها تقع عند الجبل الشوكي ونهاياتها تتصل بشكل مباشر مع العضلة الهدف. ينتشر التحفيز من قشرة الدماغ وحتى العضلات الهدف بشكل جهد كهربائي يسمى جهد التفعيل (AP) Action Potential، وتولد جهود التفعيل وتنتقل على طول أغشية الخلية العصبية عبر مرور شوارد Na^+ و K^+ كنتيجة لهذا التدفق الأيوني فإن النبضات العصبية تنتشر باتجاه الخلايا العضلية لتبدأ بتقلصاتها.

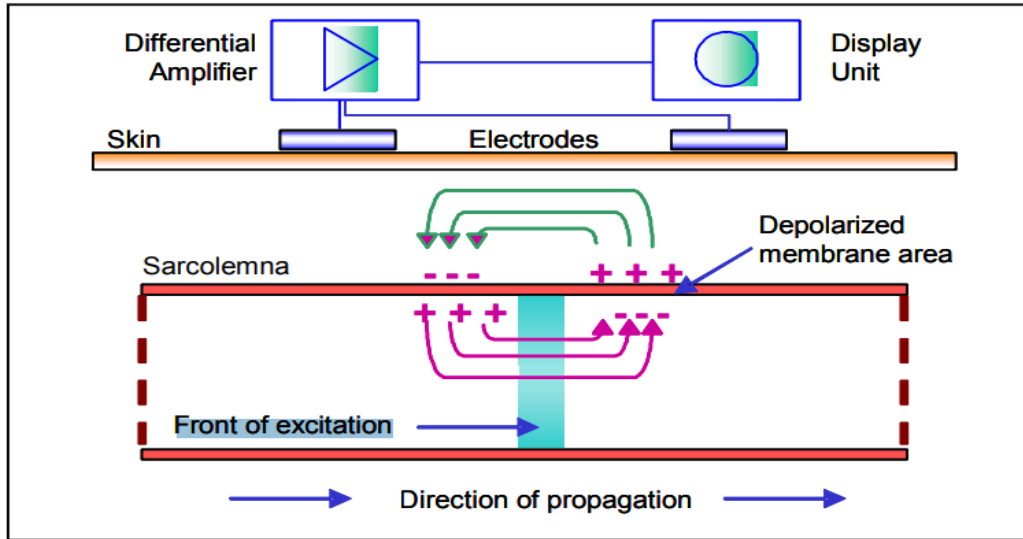
يشكل الاختلاف الأيوني بين داخل الخلية العضلية وخارجها جهداً للراحة عند غشاء الياف العضلات (حوالي -80 إلى -90 mv - عند عدم الانقباض) وينتج عن هذا الاختلاف الذي يتم الحفاظ عليه بواسطة العمليات الفيزيولوجية شحنة سالبة داخل الخلايا مقارنة بالسطح الخارجي.

مع وصول الإشارة العصبية للعضلة، تتدفق أيونات الصوديوم الموجبة إلى داخل الخلية بكميات كبيرة وتخرج أيونات البوتاسيوم بكميات صغيرة إلى خارج الخلية، ويؤدي ذلك إلى إزالة حالة الاستقطاب على جانبي الغشاء. وعندما تصل كمية أيونات الصوديوم إلى حد معين يتغير جهد العمل بسرعة من -80 إلى +30 mv لفترة قصيرة، وينتشر هذا الجهد على طول الألياف العضلية فيؤدي إلى انعكاس حركة أيونات الصوديوم والبوتاسيوم وعودة الاستقطاب.



الشكل 2-1: رسم توضيحي تخطيطي لدورة إزالة الاستقطاب / إعادة الاستقطاب داخل الأعشبية العضلية


تعطي إشارة EMG تمثيلاً لهذا النشاط البيولوجي وتنتج عن تراكم كل جهود التفعيل للخلايا العصبية المتواجدة تحت الزوج المعدني لإلكترودات EMG والمتواجدة على الجلد والمنحازة بشكل موازي لألياف العضلة. الإلكترودات السطحية مصنوعة من قرصين ناقليين وكل منهما موصول إلى دخل مضخم تفاضلي للتحسس لجهود تفعيل الخلايا العصبية.



الشكل 2-2: منطقة إزالة الاستقطاب على الأعشبية العضلية

2.1.2 Raw EMG Signal: الإشارات الخام

تعد الإشارات غير المرشحة (باستثناء مرورها عبر المضخم التفاضلي) وغير المعالجة هي الإشارات الخام في الشكل (2-3) تسجيلاً لثلاثة انقباضات للعضلة ذات الرأسين.



الشكل 2-3: الإشارات العضلية الخام

المطال الأعظمي للإشارة الناتجة يكون 10 mV (من -5 mV إلى +5 mV) ويعتمد على أبعاد ألياف العضلة وعلى المسافة بين العضلة والإلكترودات بالإضافة إلى خواص الإلكترود ذاته. في حالة الراحة للعضلات، يمكن رؤية خط أساس مخطط كهربية العضل الخالي من الضجيج إلى حد ما. بحيث لا تظهر العضلات الصحية في حالة الراحة أي نشاط مهم في مخطط كهربية العضلة بسبب عدم حدوث النشاط الفيزيولوجي في العضلة، وفي حالة تحفيز عدة عضلات متجاورة تزداد قوة الإشارة بشكل كبير نتيجة تراكم الإشارات عن طريقة نظرية تنعيم مثل نظرية (moving average) أو أخذ بارامتر معين مثل (المنطقة الواقعة تحت قيم المعدل العام).

2.2 العوامل المؤثرة على الإشارات العضلية:

- 1- خصائص الأنسجة حيث يعتبر جسم الإنسان موصلًا كهربائيًا جيدًا، ولكن للأسف تختلف الموصلية الكهربائية باختلاف نوع الأنسجة وسمكها والتغيرات الفيزيولوجية ودرجة الحرارة.
- 2- Physiological cross talk: قد تنتج العضلات المجاورة إشارات عضلية تشكل جزء من الإشارات العضلية المقاسة من خلال حساس لعضلة مجاورة أخرى. عادةً لا يتجاوز "Cross Talk" هذا 10% - 15% من محتويات الإشارة الإجمالية في حال وجوده

- 3- تغيير موضع الحساس بالنسبة للعضلة: يجب التأكد من تثبيت الحساسات بشكل جيد حيث يمكن ان تقرأ بعض التغيرات على أنها اشارات أو في حالة وجود ضغط خارجي.
- 4- التداخل مع الأجهزة الالكترونية الأخرى يمكن أن يؤدي الى تشويش في الإشارة.
- 5- جودة الحساسات تلعب دوراً كبيراً في جودة الاشارات بحيث يجب توخي الحذر عند اختيار الحساسات.

3.2 قاعدة البيانات NINA PRO:

قاعدة البيانات NinaPro [25] اختصار ل Non-Invasive Adaptive Hand

Prosthetics لمساعدة الأبحاث المهمة في مجال الأطراف الاصطناعية وإيجاد أرضية مشتركة للمقارنة.

تحتوي قاعدة البيانات إشارات عضلية تمثل 52 حركة مضمنة ومقسمة في 4 أصناف:

- 12 حركة أساسية للأصابع كل إصبع على حدة (بسط وقبض).

- 8 حركات أساسية لعدة أصابع مجتمعة.

- 9 حركات أساسية للمعصم.

- 23 حركة وظيفية، تخص التعامل مع الأشياء اليومية.

تتكون قاعدة البيانات Ninapro من 10 مجموعات قواعد البيانات:

- Dataset 1 بيانات من 27 شخص سليم مأخوذة من حساسات Ottobock

- Dataset 2 بيانات من 40 شخص سليم مأخوذة من حساسات Delsys Trigno

- Dataset 3 بيانات من 11 شخص فاقد للأطراف وفق 5 مستويات للبتير مأخوذة من حساسات

Delsys Trigno

- Dataset 4 بيانات من 10 أشخاص سليمين من حساسات Cometa

- Dataset 5 بيانات من 10 أشخاص سليمين من حساسات Thalmic Myo (double

& single)

- Dataset 6 بيانات من 10 أشخاص سليمين مأخوذة مرتين يومياً خلال 5 أيام اختبارات التكرارية.

- Dataset7 بيانات من 20 أشخاص سليمين و 2 شخص مبتوري الأطراف عبر حساسات Delsys Trigno

- Dataset8 بيانات من 10 أشخاص سليمين و 2 مبتوري الأطراف تم الحصول عليها عن طريق حساسات Cyberglove-II.

- Dataset 9 بيانات من 77 شخص سليم تم الحصول عليها عن طريق حساسات Cyberglove-II

- Dataset10 هي اول قاعدة بيانات متعددة الوسائط من اشخاص سليمين ومبتوري الأيدي تتضمن بيانات متعددة للأطراف الصناعية وتحليل الاحساس الوهمي بالطرف.

1.3.2 محتويات قاعدة البيانات:

كل شخص يقوم بثلاثة تمارين يتم تسجيلها في قاعدة البيانات ولكل شخص ملف ذو لاحقة .mat.

يحتوي الملف:

- Subject: رقم الشخص
- Exercise: رقم التمرين
- Emg: اشارات EMGs للأقطاب الكهربائية
- Acc: (36عمود) تحتوي على احداثيات الاقطاب ال (x,y,z) 12
- Glove: تتضمن اشارات غير معايرة من 22 مستشعر ل cyberglove
- Inclination: (عمودين) تتضمن مقاييس الميل (pitch , row)
- Restimulus: العنوان اللاحق للحركة
- Stimulus: التسمية الأصلية للحركة
- Repetition: مؤشر تكرار التحفيز
- Rereprtition: مؤشر تكرار اعادة التحفيز
- Force: (6 اعمدة) قيم القوة

• Forcecal: الحد الأقصى للقوة (الحد الاعلى والادنى للقوة)

2.3.2 الحساسات المستخدمة:

نلاحظ وجود اربعة انواع من حساسات ال EMG تم استخدامها في بناء النسخ المختلفة لقاعدة البيانات وهي: Ottobock ، Delsys Trigno ، Cometa+ dormo setup ، Thalmic Myo (double & single) بالإضافة الى القفاز Cyberglove-II.




(a) Otto Bock 13 E200 setup



(b) Delsys Trigno setup



(c) Cometa + Dormo setup



(d) Double Myo setup

الشكل 2-4: انواع الحساسات المستخدمة في بناء قواعد البيانات *NINA PRO*

لكل نوع من هذه الحساسات خصائص معينة حيث تم تصنيفها في الجدول التالي انطلاقا من استخدامها في بناء قواعد البيانات المختلفة.

الجدول 2-1: خصائص الحساسات المستخدمة في قاعدة البيانات [25] NINA PRO

	Ninapro DB1 Ottobock 13E200-50	Ninapro DB2 Delsys Trigno Wireless	Ninapro DB4 Cometa miniWave + Dermo	Ninapro DB5 Thalmic Myo (double & single)
Input Range	N/A	11 mV (r.t.i.)	±2.5 mV	N/A
Output Range	N/A	±5 V	±2.5 V	N/A
Resolution	N/A	168 nV/bit	76 nV/bit	N/A
Bandwidth or Built-in Filters	90–450 Hz	20 ± 5 Hz– 450 ± 50 Hz	HPF at 10 Hz, LPF at 1kHz	Notch at 50 Hz
Sampling Frequency	100 Hz at 12 bit with NI-DAQ 6024E	2 kHz at 16 bit	2 kHz at 16 bit	200 Hz at 8 bit
Gain	5 (~14,000)	909 ± 5%	1,000	N/A
Size	(27 x 18 x 9.5) mm	(37 x 27 x 15) mm	electrode (50 x 36) mm; transmitter (33 x 23 x 19) mm	circumference: 19-34 cm; thickness: 11.43 mm
Mass	4.5 g	14.7 g	electrode 7.5 g; transmitter 35 g	93 g

- حساسات **ottobock**: تم استخدامها في النسخة الأولى لقاعدة البيانات، تم استخدام عشرة أقطاب من MyoBock 13E200–50 (Otto Bock HealthCare GmbH) مما يوفر نسخة مضخمة ومرشحة بمرشح حزمة bandpass والجذر التربيعي للمتوسط الحسابي (RMS) لإشارة sEMG الخام. تم ضبط نسب تضخيم الأقطاب الكهربائية عند حوالي 14000. هذه الأقطاب الكهربائية تستخدم بالفعل على نطاق واسع في الأطراف الصناعية؛ يتم تحسين وترشيح التردد من أجل تجنب تداخلات الترددات المنخفضة والعالية المنبعثة، على سبيل المثال من مصادر الطاقة 50–60 هرتز أو الهواتف المحمولة أو أنظمة الأمان. تم تثبيت هذه الأقطاب الكهربائية على الساعد باستخدام شريط مطاطي. تم الحرص بشكل خاص على وضع الأقطاب الكهربائية على الساعد، حيث يعتبر هذا عادةً خطوة حاسمة لإمكانية استخدام البيانات. تم الجمع بين طريقتين شائعتين في هذا المجال، وهما نزع العينات الكثيف واستراتيجية تحديد المواقع التشريحية الدقيقة. يتم وضع الأقطاب الكهربائية من نوع **ottobock**، ثمانية أقطاب

كهربائية متباعدة بشكل متساوٍ، حول الساعد عند ارتفاع المفصل العضدي؛ يتم وضع قطبين كهربائيين على نقطتي النشاط الرئيسية في العضلة المثنية السطحية والسطحية الباسطة للأصابع السطحية. بالنسبة لأقطاب ottobock تتم عملية ترشيح إشارات EMGs بتردد قطع منخفض يبلغ 5 هرتز باستخدام مرشح Butterworth من الدرجة الثانية ذي المرحلة الصفرية. هذا التردد المنخفض للقطع له ما يبرره في حالتنا، نظراً لأن ترشيح RMS على متن أقطاب ottobock يغير بشكل كبير الخصائص الطيفية للإشارة. في المقابل، لتسجيلات EMGs مجال طيفي عادةً ما بين 15 إلى 500 هرتز تقريباً.

- **حساسات delays trigon:** تم استخدامها في بناء النسختين الثانية والثالثة؛ تم استخدام 12 قطباً كهربائياً من (Delsys Trigno Wireless)، كل منها مزود ببطارية قابلة لإعادة الشحن قائمة بذاتها وبنطاق تشغيلي يصل إلى 40 متراً (يتضمن الإعداد أيضاً نقطة استقبال لاسلكية أساسية). يتم أخذ عينات من إشارات sEMG بمعدل 2kHz مع ضجيج أقل من 750 nV. تحتوي هذه الأقطاب الكهربائية أيضاً مقياس تسارع ثلاثي المحاور، حيث تم أخذ عينات منه بتردد تحصيل 148 هرتز وتم تثبيتها على الساعد باستخدام أشرطة لاصقة قياسية. تم وضع شريط مرن خالٍ من مادة اللاتكس المسببة للحساسية حول الأقطاب الكهربائية لإبقائها ثابتة أثناء عملية التسجيل. عند استخدام حساسات delays trigon، تم وضع قطبين على مناطق النشاط الرئيسية للعضلة ذات الرأسين العضدية والعضلة ثلاثية الرؤوس العضدية. تم تحديد مناطق النشاط الرئيسية عن طريق الجس.

أقطاب Delsys ليست محمية ضد تداخلات خطوط الطاقة، والتي يمكن أن تؤثر على الإشارة المعاد تشفيرها في حالات معينة. لذلك، قبل المزامنة، تم ترشيح إشارات Delsys sEMG من تداخل خط الطاقة 50 هرتز (والتوافقيات) باستخدام مرشح Hampel.

- **حساسات MyoThalamic:** قامت شركة Thalmic بإطلاق Myo، وهو شريط لاسلكي منخفض التكلفة يحتوي على 8 مستشعرات تفاضلية EMGs ووحدة IMU ذات 9

محاور. يبلغ سعر سوار Myo الآن 199 دولاراً، أي ما يقرب من 4-3 أقل من أقطاب ottobock التفاضلية المزدوجة المستخدمة في الأطراف الصناعية وما يقرب من 100 مرة أقل من نظام sEMG اللاسلكي الكامل (مثل أنظمة Delsys Trigno و Cometa Wave). يرتدي الشخص على ذراعه سوار Myo أحدهما بجانب الآخر. يتم وضع سوار Myo العلوي بالقرب من الكوع مع وجود القطب الكهربائي الأول على المفصل العضدي. يوضع سوار Myo السفلي أسفل السوار الأول مباشرة، ويميل 22.5 درجة لملاء الفجوات التي خلفتها أقطاب Myo الأخرى. ومع ذلك، فإن Thalmic Myo لا يزال غير مميز بشكل جيد للأغراض البحثية ونادراً ما تتم مقارنته بالإعدادات الأخرى. تحتوي أقطاب Myo تحتوي على مرشح للتردد عند 50 هرتز.

- **حساسات Cometa Wave Plus Wireless SEMG:** هذه الحساسات معروفة جيداً في المجال السريري وفي الأبحاث العلمية. يتكون النظام من 16 قطباً كهربائياً لاسلكياً ويكلف حوالي 120 مرة أكثر من سوار الذراع Myo. يتم وضع ثمانية أجهزة استشعار حول الساعد عند ارتفاع عظم العضد الراديوي وتم وضع مستشعرين على نقطتي النشاط الرئيسية لثني الأصابع السطحية والباسط للأصابع السطحية. يتم وضع مستشعرين آخرين على مناطق النشاط الرئيسية للعضلة ذات الرأسين العضدية والعضلة ثلاثية الرؤوس العضدية. بالنسبة لأقطاب cometa تحتوي على مرشح تمرير عالي 10 هرتز، ومرشح تمرير منخفض 1000 هرتز لمقاومة التعرج.
- **القفاز Cyberglove-II:** فهو عبارة عن قفاز بيانات لالتقاط الحركة، مزود بقياسات مشتركة. يستخدم تقنية استشعار الانحناء المقاومة الخاصة لتحويل حركات اليد والأصابع بدقة إلى بيانات زاوية مشتركة رقمية في الزمن الحقيقي. يقوم الجهاز بإرجاع 22 قيمة مكممة على 8 بت تتناسب مع هذه الزوايا لمتوسط دقة أقل من درجة واحدة اعتماداً على حجم يد الشخص.

بالتالي تم انتاج عدة نسخ من قاعدة البيانات NINA PRO التي تم توصيفها في الجدول (2-2)

الجدول 2-2: معلومات عن الأفراد المشاركين في انتاج النسخ المختلفة لقاعدة البيانات

	Ninapro DB1 Otto Bock 13E200	Ninapro DB2 Delsys Trigno Wireless	Ninapro DB4 Cometa miniWave + Dormo	Ninapro DB5 Thalnic Myo (double & single)	Kruskal Wallis p-value
Available subjects	27	40	10	10	
Considered subjects	10	10	10	10	
Males	7	7	6	8	
Females	3	3	4	2	
Right-handed	9	9	8	10	
Left-handed	1	1	2	0	
Avg. Age (years)	28±4.6	28±3.1	29.6±9.24	28±3.97	0.9978
Avg. Height (cm)	173.1±7.6	173±11	178.2±7.39	172.2±9.88	0.4386
Avg. Weight (kg)	68.6±12.0	69.9±13.8	69.1±8.03	68.6±9.1	0.9976
Avg. BMI (Kg/m ²)	22.8±3.18	23.29±3.72	21.66±1.48	23.17±2.66	0.6834

3.3.2 بروتوكول التجميع:

قبل التجربة، يُطلب من كل شخص الموافقة والإجابة على الأسئلة بما في ذلك العمر والجنس والطول والوزن. يضاف في حالة مبتوري الأطراف، أيضاً تاريخ البتر ونوعه وسببه ونسبة الساعد المتبقية ومعلومات حول استخدام الأطراف الاصطناعية (التجميلية، والحركية، والكهربية العضلية) ونوع ودرجة الإحساس الوهمي بالأطراف ومعيار DASH (إعاقة الذراع والكتف واليد). يتم حساب النسبة المئوية المتبقية من الساعد كنسبة بين طول الساعد المبتور والطول الباقي من الكوع إلى الرسغ. بعد ذلك، طلب من الأشخاص الجلوس على مكتب، ومراعاة أن تكون وضعية حركة الذراع مريحة، وإراحة أذرعهم على سطح المكتب. يقدم جهاز كمبيوتر محمول أمام الشخص محفزات بصرية لكل مهمة، مع تسجيل البيانات أيضاً من أجهزة القياس.

تنقسم التجربة إلى جزء تدريبي واحد وثلاثة تمارين تتناول أنواعاً مختلفة من الحركات، يقطعها وقت الراحة لتجنب الإرهاق العضلي. تتكون مرحلة التدريب من مزيج مكثف من التمارين حتى يصبح المشاركون على دراية بالتجربة.

أثناء التدريبات التي تم إجراؤها باستخدام Cyberglove II، طُلب من الأشخاص السليمين محاكاة أفلام الحركة المعروضة على شاشة الكمبيوتر المحمول بيدهم اليمنى، بينما طُلب من الأشخاص المبتورين ذوي الأذرع المبتورة تقليد الحركات بالطرف المفقود بشكل طبيعي قدر الإمكان نظراً لأن الهدف الرئيسي لبيانات الحركة هو السماح بتصنيفها، فقد طُلب من جميع الأشخاص التركيز على محاكاة الحركات بدلاً من ممارسة قوى عالية. تم اختيار مجموعة الحركات من أدوات تصنيف حركات اليد والروبوتات وإعادة التأهيل بهدف تغطية غالبية حركات اليد التي تتم مواجهتها في أنشطة الحياة اليومية (ADL). استمر كل تكرار للحركة 5 ثوانٍ، وتناوب مع وضعية راحة تدوم 3 ثوانٍ، لم يكن تسلسل الحركات عشوائياً بل تم وضع الحركات المتشابهة بشكل متتالي، طُلب من الأشخاص السليمين تنفيذ التجربة بيدهم اليمنى، بينما طُلب من الأشخاص المبتورين التفكير في تكرار الحركات بشكل طبيعي قدر الإمكان بالطرف المفقود. من المهم ملاحظة أن مبتوري الأطراف لا يستطيعون بشكل عام تقديم أي حقيقة أساسية موثوقة بسبب عدم القدرة على تشغيل أي جهاز استشعار مع الطرف المفقود. في التكرار ذي الصلة، تم التحايل على هذه المشكلة الأساسية غير القابلة للحل إما عن طريق (أ) توجيه الأشخاص لتنفيذ مهمة بكلتا اليدين ومعرفة الحركة المنفذة من الطرف السليم؛ أو عن طريق (ب) مطالبتهم باتباع حافز بصري (إما على شاشة أو بواسطة مرآة تعكس مما يقوم به الشخص باليد السليمة).

في قاعدة البيانات الأولى كان عدد التكرارات لكل حركة 10 تكرارات كل تكرار يستمر لمدة 5 ثواني ومع فترة الراحة تدوم 3 ثواني.

في قواعد البيانات الأخرى (2,3,4,5) كان عدد التكرارات لكل حركة 6 تكرارات؛ كل تكرار يأخذ 5 ثواني وفترة الراحة تدوم 3 ثواني.

تتكون كل قاعدة بيانات من ثلاث تمارين (1,2,3)؛ كل تمرين يحتوي على جزء من الحركات الموجودة في قاعدة البيانات ويتم تقسيم هذه التمارين حسب الحركات وانماط القوة إلى أربع تمارين جزئية (A,B,C,D). التمرين A يحتوي على 12 حركة أساسية للأصابع (باللون الأزرق)، والتمرين B هي 8 تكوينات متساوية القياس ومتساوية التوتر و 9 حركات أساسية للمعصم (باللون الأحمر)، التمرين C يشمل

23 حركة امساك وحركات وظيفية (باللون الاخضر)، والتمرين D يشمل 9 انماط للقوة (باللون البنفسجي) ووضع الراحة (باللون الابيض).



الشكل 2-5: الحركات والايماءات التي تشكل قاعدة البيانات NINA PRO

4.3.2 مقاييس تقييم الإشارة [26]:


قاعدة البيانات الأولى والتي تستخدم حساسات Ottobock معالجة مسبقا وتقدم نسخة مصححة من الجذر التربيعي لإشارة Emg وليس الإشارة الأولية نفسها (raw data) كباقي قواعد البيانات. بالنسبة لباقي قواعد البيانات تم حساب ستة مقاييس لجودة الإشارة لتحديد مستوى التلوث بأنواع مختلفة من الضجيج في الإشارات: نسبة الإشارة إلى الإشارة المرجعية (SMR)، ونسبة تداخل الإشارة إلى خط الطاقة (SPR)، ونسبة تشوه طيف القدرة (OHM)، ونسبة الإشارة إلى الضجيج عالي التردد (SHR)، وانخفاض الطيف من الحد الأقصى إلى الحد الأدنى في كثافة الطاقة (DPR)، والإشارة إلى الضجيج (SNR). الجدول (2-3) يبين كيفية حساب كل مقياس والحدود المقبولة لكل منها:

الجدول 2-3: مقاييس جودة الإشارة وكيفية حسابها

Metric	Measurement	Equation	Acceptable Level
SMR	Motion artifact (0-20Hz)	$\frac{P_{signal}}{P_{0-20Hz}}$	> 12 dB
SPR	Power line interference and its harmonics (50,100....Hz)	$\frac{P_{signal}}{P_{50,100.....x Hz}}$	N/A
OHM	Low and High frequency noise particularly 20-50Hz	$\frac{(M_2/M_0)^{0.5}}{M_1/M_0}$	< 1.4
SHR	High frequency noise (upper 20% frequency)	$\frac{P_{signal}}{P_{upper20\%}}$	> 15 dB
DPR	Sufficient sampling frequency and white Gaussian noise	$\frac{MPD_{highest}}{MPD_{lowest}}$	> 30 Db
SNR	Baseline noise when resting	$\frac{P_{signal}}{P_{rest}}$	الشكل 2-6

مقاييس جودة الإشارة هي: مع تحويل القيم إلى (ديسيبل) باستخدام العلاقة $10\log(\text{value})$ حيث p_{0-20} تمثل إجمالي قدرة الإشارة ومجموع جميع كثافات الطاقة الأقل من 20 هرتز و $p_{50,100,\dots}$ هي كثافة الطاقة عند 50 هرتز وتردداتها التوافقية حتى نصف تردد أخذ العينات، Mn هي اللحظات الطيفية ذات الرقم n ، و $p_{upper\ 20\%}$ هو مجموع كثافات الطاقة عند الترددات الـ 20% العليا (على سبيل المثال 800-1000 هرتز للإشارات التي تم الحصول عليها بتردد أخذ عينات 2000 هرتز)، أما MPD هو متوسط كثافة الطاقة لـ 13 نقطة متتالية يتم إزاحتها عبر جميع الترددات، p_{rest} هو إجمالي شدة الإشارة المقاسة أثناء الراحة.

أهم المقاييس هو نسبة الإشارة إلى الضجيج (SNR) وهو يشير إلى الضجيج في خلفية الإشارات يتم تقييم الإشارات حسب قيم SNR كما هو مبين في الشكل (2-6).



الشكل 2-6: الوصف للمستويات المختلفة لـ SNR

يبين الجدول (2-4) مقاييس جودة الإشارات لقواعد البيانات المتاحة

الجدول 2-4: نتائج النسخ المختلفة لقاعدة البيانات باستخدام مقاييس جودة الإشارة: متوسط القيمة \pm الانحراف المعياري

(min, median, max)

Dataset	SMR	SPR	OHM	SHR	DPR	SNR
2	21.5 ± 4.8 (9.5, 21.1, 45.2)	15.6 ± 0.7 (12.6, 15.5, 19.9)	1.3 ± 0.1 (1.2, 1.3, 5.5)	35.3 ± 3.0 (23.5, 35.5, 45.3)	53.2 ± 3.1 (41.0, 53.4, 65.6)	8.6 ± 3.5 (-8.9, 8.7, 21.2)
3	18.82 ± 5.73 (1.8, 18.3, 47.9)	14.5 ± 0.6 (12.4, 14.4, 26.2)	1.3 ± 0.6 (1.2, 1.3, 15.1)	32.3 ± 4.7 (22.6, 32.8, 43.3)	49.2 ± 5.1 (31.5, 49.7, 61.7)	6.4 ± 5.5 (-10.9, 5.6, 20.5)
4	21.8 ± 5.6 (11.2, 20.3, 55.8)	15.4 ± 1.4 (13.6, 15.3, 41.7)	1.4 ± 0.4 (1.2, 1.4, 18.9)	17.9 ± 3.5 (8.5, 17.8, 41.0)	34.6 ± 3.8 (23.3, 34.7, 47.7)	10.8 ± 4.0 (-2.6, 10.9, 25.1)
5	15.4 ± 2.6 (10.4, 14.9, 35.9)	20.1 ± 1.1 (16.3, 20.0, 24.2)	1.1 ± 0.01 (1.1, 1.1, 1.2)	-1.3 ± 0.4 (-2.7, -1.4, 1.0)	14.7 ± 1.7 (9.4, 14.7, 24.6)	13.1 ± 3.8 (-3.8, 13.1, 25.4)

نلاحظ أن معدل SMR, SPR هي أفضل من القيم المتوقعة بالنسبة لكل قواعد البيانات.

أما بالنسبة ل OHM فكان المتوسط ايضا ضمن النطاق المقبول مع بعض القيم غير المقبولة.

بالنسبة ل DPR ، كان المتوسط اعلى بكثير من المستوى المقبول لجميع قواعد البيانات ماعدا النسخة الخامسة.

تدعم هذه النتيجة دراسة تشير إلى أن استخدام معدل تحصيل البيانات 200 هرتز كما في النسخة الخامسة بدلا من 1000 هرتز أو أعلى كما في النسخ الاخرى يؤدي الى انخفاض كبير في المعلومات التمييزية المستخدمة في التعرف على الاشارات. بالنسبة ل SNR كان المتوسط مقبول ولكن موسى بالتحسين في النسخ الثانية والثالثة أما بالنسبة للنسخ الرابعة والخامسة فإن معدل SNR في مستوى "تأثير ضئيل للضجيج".

بعد دراسة نتائج اختبار النسخ المختلفة من قاعدة البيانات نلاحظ تفوق عدد من النسخ بعدة معايير وتأخرها في معايير أخرى لذلك قمنا بالمفاضلة بينها، قمنا باختيار النسخة الخامسة والتي تعتمد على سوارين $MYO THALMIC$ حيث كانت الأفضل في معيار SNR وكانت نتائجها جيدة بالنسبة لمعايير SMR, SPR, OHM بينما كانت نتائجها بحاجة الى تحسين بالنسبة لمعايير DPR, SHR وبالمفاضلة بين المعايير المختلفة وبين التكلفة المادية والفنية كانت حساسات $MYO THALMIC$ من أفضل الخيارات لتحصيل الإشارات العضلية، وتم الاعتماد عليه في بناء نموذج التحكم الخاص بنا، ونظراً لوجود الإشارات الخام مسجلة في قاعدة البيانات $NINA PRO DB5$ ، نقوم بتنفيذ الخوارزمية المقترحة عليها لنتمكن من مقارنة نتائج هذا العمل مع الدراسات الأخرى.

4.2 الخاتمة:

تم في هذا الفصل دراسة بنية الاشارات العضلية وخصائصها، بالإضافة الى دراسة قاعدة البيانات NINA PRO وهي من أهم قواعد البيانات للإشارات العضلية، قمنا بدراسة النسخ المختلفة لها وتقييمها ودراسة جودة الإشارات للنسخ المختلفة وأخيرا تم اختيار النسخة الخامسة منها والتي تستخدم حساسات سوار MYO THALMIC لتحصيل الإشارات

الفصل الثالث

خوارزمية التعرف على الإشارات العضلية

نعرض في هذا الفصل خوارزمية العمل المقترحة، ودراسة لطبيعة إشارات الحساسات المختارة وعمليات المعالجة المقترحة بالإضافة إلى دراسة الشبكات العصبونية العميقة المستخدمة والعمليات النهائية على البيانات قبل التدريب وأخيراً نتائج التدريب والاختبار.

1.3 قاعدة البيانات NINA PRO DB5:

أحد الفوارق الأساسية بين قواعد البيانات المختلفة هو نوع الحساس المستخدم وفي قاعدة البيانات الخامسة تم استخدام السوار MYO THALMIC. تم إنتاج سوار الذراع Myo، الموضح في الشكل (3-1)، من قبل شركة Thalmic Labs الكندية، ويستخدم بشكل أساسي للحصول على الإشارات الكهربائية العضلية التي تنتجها عضلات الساعد.




الشكل 3-1: السوار MYO THALMIC

السوار مزود بثمانية أقطاب EMG، ووحدة IMU ذات 9 محاور تتكون من مقياس تسارع ثلاثي المحاور، وجيروسكوب ثلاثي المحاور ومقياس للحقل المغناطيسي ثلاثي المحاور ومحرك اهتزاز يستخدم لتنبيه المستخدم. المواصفات الفنية له:

- معالج Freescale kinetis ARM Cortex M4 120Mhz
- MK22FN1M MCU
- رقاقة BLE NRF51822
- محرك اهتزاز
- وحدة IMU (MPU-9150) بتسع محاور
- 8 مضخمات ST 78589 (واحد لكل حساس)

- بطاريتي ليثيوم 3.7V-260mAh

تتم إدارة عمليات السوار بواسطة معالج ARM Cortex M4، بينما يتم نقل البيانات من خلال شريحة BLE NRF51822. تم تمييز شريحة BLE NRF51822 للإرسال اللاسلكي باللون الأزرق، متحكم ARM Cortex M4 باللون الأحمر، والهوائي الذي ينقل البيانات باللون الرمادي، ومحرك الاهتزاز لتعليقات المستخدم باللون البني وموصل micro-USB باللون الأرجواني. يتم استخدام الأخير لإعادة شحن البطارية وتحديث البرامج الثابتة للجهاز. تُستخدم بطاريتا ليثيوم قابلتان لإعادة الشحن، كما هو موضح في الشكل (2-3)، لتزويد سوار الذراع بالتغذية الكهربائية؛ ويمكن إعادة شحنها لتوفير قيمة جهد تبلغ 5 فولت عن طريق موصل micro-USB.



الشكل 2-3: مكونات سوار الذراع myo

تم الاعتماد في هذه الدراسة على النسخة الخامسة من قاعدة البيانات، وكما في النسخة الأخرى تم تسجيل الاشارات العضلية ل 10 أشخاص سليمين (8 ذكور و 2 اناث). أثناء تنفيذ التمارين الثلاث (يحتوي التمرين

A على 12 حركة أساسية للمعصم وبينما يحتوي التمرين B على 17 حركة أساسية للأصابع والتمرين C يحتوي على 23 حركة التقاط).

1.1.3 تحصيل البيانات [27]:

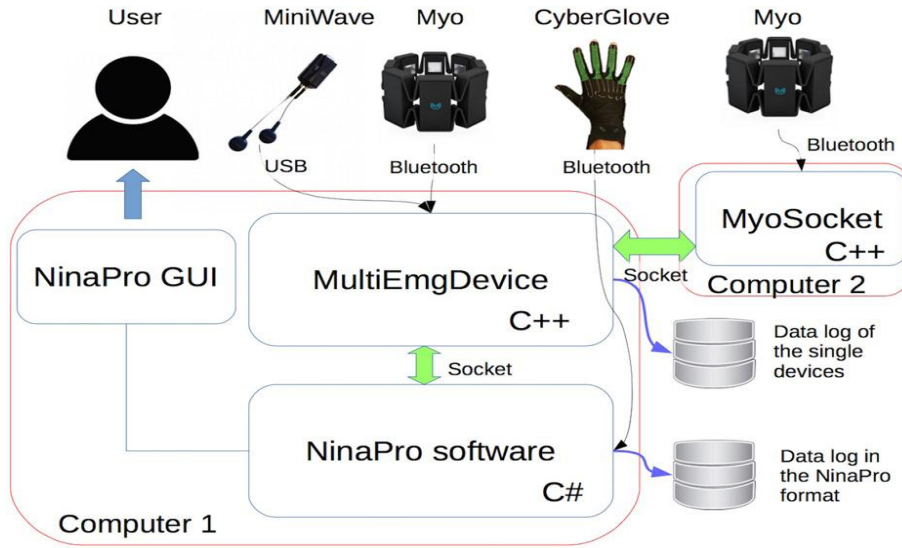
يرتدي الشخص سوارين Myo أحدهما بجانب الآخر. يتم وضع سوار Myo العلوي بالقرب من المرفق، ووضع السوار السفلي أسفل السوار الأول، مائلًا بمقدار 22.5 درجة لملء الفجوات التي خلفتها أقطاب سوار Myo العلوي.

يقوم سوار Myo بتحصيل الاشارات من 8 مستشعرات sEMG بتردد 200Hz مكمنة على 8 بت وتدفق البيانات من خلال اتصال بلوتوث منخفض الطاقة إلى الكمبيوتر الذي يقوم بتشغيل تطبيق Myo Connection. يتطلب تحصيل البيانات من سوار Myo حل مشكلتين رئيسيتين. الأولى تتعلق بالطابع الزمني لكل إطار، ويقصد بالطابع الزمني الوقت الذي يستقبل فيه برنامج Myo Connection الإطار المكون من 8 بت. تم تحسين استهلاك الطاقة للسوار عن طريق إرسال حزم من 1 أو 2 أو 4 إطارات بمعدلات غير منتظمة. لذلك، قد يتم تسجيل إطارات متتالية بنفس الطابع الزمني، مما يجعلها غير قابلة للاستخدام لتحليل البيانات. من أجل حل هذه المشكلة، تم تطوير إجراء خاص بطابع زمني لبيانات المستشعر. كانت الصعوبة الثانية تتعلق بالبرنامج المقدم مع السوار (MyoConnect and Software Development Kit). حاليًا، لا يسمح البرنامج باستقبال بيانات EMG المتدفقة من أكثر من سوار Myo. لحل هذه الصعوبة، تم تطوير برنامج لتسجيل البيانات المتزامنة من جهازين.

البرنامج الأصلي المصمم لقاعدة البيانات NINAPRO يسمح بتسجيل البيانات من العديد من الحساسات المستخدمة في النسخ السابقة (Ottobock, Delsys Tringo) ويوفر واجهة رسومية GUI للمستخدم ولكنه غير متوافق مع السوار MYO THALMIC لذلك تم تصميم برنامج MultiEmgDevice والذي يسمح بتسجيل البيانات من حساسات متعددة في نفس الوقت وإرسال البيانات عبر موصل TCP الى تطبيق NINAPRO بعد أن تم تعديله. يمكن للبرنامج MultiEmgDevice تسجيل البيانات من سوار MYO ولكن لا يسمح بتصميم MYO

Connection بالتسجيل من أكثر من سوار كما ذكرنا سابقا لذلك تم انشاء برنامج ثان Myo-Socket الذي يتم تنصيبه على كمبيوتر ثان ويقوم هذا الكمبيوتر بإرسال البيانات الى الكمبيوتر الأول. تتواصل التطبيقات الثلاثة (NINAPRO, MultiEmgDevice, Myo-Socket) مع بعضها البعض ويتم تحصيل البيانات الكاملة، كما وتم قياس قيمة ال ping بين جهازي الكمبيوتر وكان المتوسط بشكل دائم أقل من ميلي ثانية وهي قيمة جيدة جدا.

نلاحظ أن النظام الموصوف مرن للغاية، لأنه يستخدم ملفات تكوين XML وخيارات تسجيل مختلفة لتبسيط عملية التصحيح. تم تجميع البيانات المسجلة وحفظها في ملفات ذات اللاحقة .mat. يبين الشكل (3-3) كيفية الترابط بين الأجهزة المختلفة وتحصيل البيانات من السوار وبعض الحساسات الأخرى المستخدمة في بناء قاعدة البيانات.




الشكل 3-3: النظام المستخدم لتجميع البيانات في قاعدة البيانات للنسخة الخامسة

يتم حفظ كل تمرين من التمارين الثلاث على حدة؛ التمرين الأول يحتوي على بيانات ل 12 حركة والتمرين الثاني يحتوي على بيانات ل 17 حركة والتمرين الثالث يحتوي على بيانات ل 23 حركة.

تم تسجيل الاشارات باستخدام سوارين myo thalamic مزاحين عن بعضهما بزاوية 22.5 درجة لتغطية اليد بشكل كامل؛ كل سوار يحتوي على ثمانية حساسات بتردد تحصيل بيانات لهذا السوار 200Hz. تبدو


هذه البيانات كسلسلة زمنية ب 16 قناة مع ما يقرب من 600000 قراءة لكل شخص. بتسجيل 6 تكرارات لكل حركة، قام كل شخص بإجمالي 312 حركة مقسمين على التمارين الثلاث مدة تنفيذ كل تكرار خمس ثواني وتوجد فترة راحة بين كل تكرارين ثلاث ثواني. بالتالي يمكن القول إن كل تكرار يتضمن 1000 عينة من كل حساس.



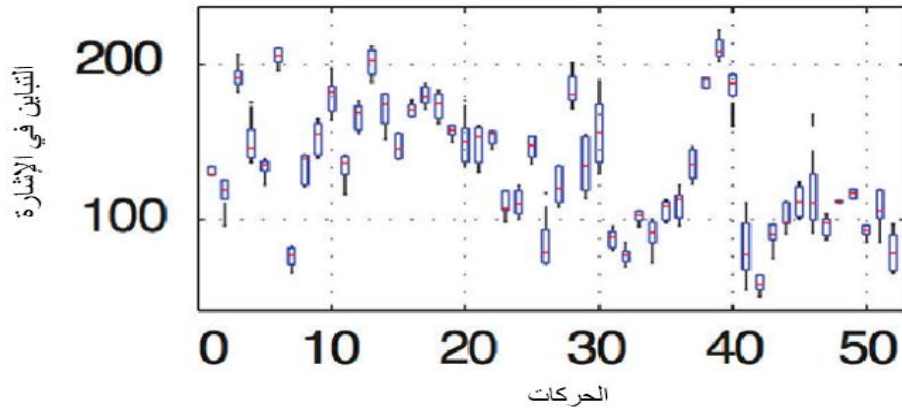
الشكل 3-4: التكرارات السننة وطبيعة الإشارات لأحد التكرارات

الاشارات الواردة من السوار تمر عبر مرشح تمرير عند 50Hz فقط، وذلك لحماية الاشارات من التداخلات مع مصادر الطاقة المجاورة.

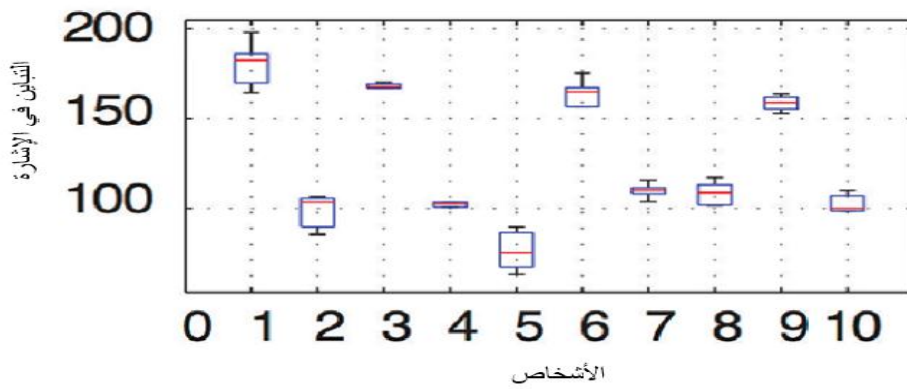
بدراسة نتائج تحليل البيانات الواردة من الحساسات والمبينة في الأشكال (3-5، 3-6، 3-7):



الشكل 3-5: تباين الإشارات بين التكرارات الستة عند جميع الأشخاص ولجميع الحركات



الشكل 3-6: التباين بين الحركات عند جميع الأشخاص ولجميع التكرارات



الشكل 3-7: التباين بين إشارات الأشخاص عند جميع الحركات والتكرارات

نلاحظ من خلال الدراسة السابقة أن التكرارات الستة للإشارات عند الشخص نفسه متشابهة الى حد كبير، ولكن يبرز الاختلاف عند الانتقال من شخص الى آخر وهو شيء متوقع بسبب طبيعة الاشارات العضلية التي تتأثر بالعديد من العوامل والتي قمنا بذكرها سابقا، وهي من المشكلات التي تعيق تعميم النماذج.

ايضا من الملاحظات الناتجة عن طريقة تجميع البيانات في NINA PRO، أن الشخص يقوم بتنفيذ الحركات بشكل متتالي دون توقف الا لعدة ثواني، بالتالي فهناك تأثير واضح للتعب الناتج عن كثرة التكرارات، وهنا تكمن الحاجة الى معالجة هذا الامر.

2.3 معالجة البيانات:

نظرا للطبيعة العشوائية وغير الخطية وغير المستقرة للإشارات العضلية يجب العمل على معالجة الاشارات قبل استخدامها، وبما إن الاشارات الواردة من السوار myo thalamic غير معالجة وتتم فلترتها باستخدام مرشح تمرير عند 50Hz فقط، وقد تؤثر العديد من العوامل على قوة الاشارة كتعب العضلات بالتالي يجب تنظيم الاشارات الواردة.

1.2.3 تنظيم الإشارات Normalization:

في الإحصاء، يشير مصطلح "التنظيم" إلى تصغير مجموعة البيانات. تساعد تقنيات التنظيم هذه في مقارنة القيم المقيسة المقابلة من مجموعتين أو أكثر من مجموعات البيانات المختلفة بطريقة يلغي تأثيرات التباين في مقياس البيانات بين يوم وآخر او بين حالتي راحة وتعب.

Min-Max Normalization: يتم إجراء التحويل الخطي على البيانات الأصلية. يتم حساب مجال القياس بطرح الحد الأدنى من الحد الأقصى لقيمة البيانات، وتشتق معادلة التنظيم بطرح الحد الأدنى للقيمة مبدئيًا من القياس، ثم نحسب ناتج قسمة النتيجة الثانية على الأولى.

$$X_{\text{new}} = \frac{X - X_{\text{min}}}{X_{\text{max}} - X_{\text{min}}}$$

نلاحظ أن البيانات قد تكون مزاحة عن الزمن المخصص لتنفيذ كل حركة وذلك بسبب تغير توقيت رد فعل الانسان، لذلك قمنا بتحديد البيانات المعبرة عن كل تكرار للحركات واقتطاعها وإعادة تجميعها بعد التخلص من فواصل الراحة وفي هذه الحالة نتمكن من التعامل مع كل تكرار على حدة دون وجود احتمال للأخطاء وبالتالي المقدرة على البدء بعملية المعالجة.


قمنا بتطبيق التنظيم على البيانات الواردة من كل حساس وبحساب القيمة المطلقة لقيم الاشارة ضمن المجال $[0,1]$.

2.2.3 تمثيل البيانات:

كما ذكرنا في الدراسة المرجعية فإننا سنعمل وفق التوجه المبني على تحويل الاشارات الى صورة، فقمنا بدراسة عدة طرق لتمثيل الاشارات، في البداية قمنا بجمع اشارات الحساسات في اشارة واحدة ومن ثم معالجتها، ولكن عملياً، إن حركات اليد الطبيعية لا تعتمد على عضلة واحدة أو شكل تقلص واحد وإنما تتشارك عدة عضلات لأداء كل حركة، وبشكل تقلص يختلف من حركة لأخرى، فيما يعرف في الطب بالتآزرات العضلية **Muscle Synergies**، وعملية الجمع تقوم بإخفاء التباين في مساهمة اشارات الحساسات المختلفة في تكوين الاشارة الكلية، أي مقدار مساهمة العضلات المختلفة في تشكيل نمط الالتقاط. لذلك تم العمل على تكوين صورة تجمع مساهمة العضلات المختلفة وتبين قيمة اشاراتها عند كل قراءة.


كما ذكر سابقاً، قمنا باختيار حركات الالتقاط وعددها 23 حركة، وتم تسجيل الاشارات العضلية لكل حركة بتكراراتها الستة. يمتد كل تكرار لخمس ثوان، وبما أن معدل تحصيل البيانات 200Hz بالتالي تم تجميع 1000 عينة لكل تكرار من 16 حساساً، بالتالي يمكن التعبير عن المعطيات بمصفوفة 16×1000 .

قمنا بالتعامل مع اشارة كل حساس بشكل منفرد، بحيث يعبر عن اشارة كل حساس بشريط أفقي بتدرجات رمادية وذلك بتحويل قيم المصفوفة المعبرة عن الحركة بعد القيام بعملية التسوية وتحويل قيمها الى المجال $[0,1]$ إلى قيم pixels في المجال $[0,255]$.



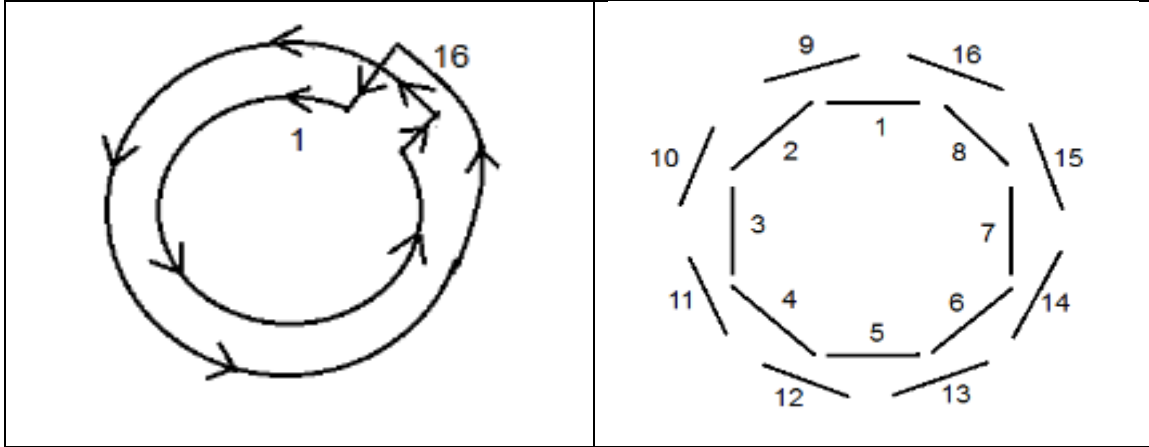
الشكل 3-8: تحويل اشارة الحساس الى تدرج رمادي

وبعدها قمنا بجمع هذه الشرائط المعبرة عن الحساسات المختلفة، بالتالي نحصل على صورة مكونة من 16 شريطا افقيا بتدرج رمادي وهي الصورة التي تعبر عن حركة.



الشكل 3-9: الاشارات العضلية بعد تحويلها الى صورة

عند دراسة تموضع السوار حول الذراع نلاحظ أنه من الممكن أن يحدث انزياح في تموضع الحساسات، بالتالي للحفاظ على تأثير التموضع المكاني للحساسات تم اقتراح تعديل تسلسل الحساسات ضمن الصورة وذلك بإغلاق السلسلة كما هو موضح بالشكل (3-10).




الشكل 3-10: توزيع الحساسات وتسلسلها والمسار المقترح لإغلاق حلقة الحساسات

بالتالي يصبح التسلسل كالتالي:

$$16 \leftarrow 15 \leftarrow 14 \leftarrow 13 \leftarrow 12 \leftarrow 11 \leftarrow 10 \leftarrow 9 \leftarrow 16 \leftarrow 8 \leftarrow 7 \leftarrow 6 \leftarrow 5 \leftarrow 4 \leftarrow 3 \leftarrow 2 \leftarrow 1$$

$$1 \leftarrow$$

وتصبح المصفوفة المعبرة عن كل حركة (18×1000) والتي يتم تحويلها الى صورة حسب الطريقة السابقة.









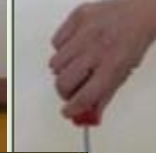










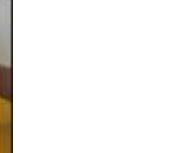







الشكل 3-11: الصورة النهائية الناتجة


تمثل هذه الصور التي تم تشكيلها دخل لخوارزميات التعلم العميق التي ستقوم بتصنيفها، حيث يتم تشكيل ست صور لكل حركة وعدد حركات الالتقاط 23 حركة، بالتالي تم تشكيل 138 صورة لكل شخص من الأشخاص العشرة.

كما ذكرنا سابقا فقد تم تصنيف حركات الالتقاط في أربع أصناف حسب عدد الأصابع المشاركة في الالتقاط (الصنف الأول تتم الحركة بخمس أصابع والصنف الثاني بأربع أصابع والثالث بإصبعين والرابع بثلاث أصابع)، بالتالي تم تصنيفها كما في الجدول (3-1).

الجدول 3-1: توزيع حركات الالتقاط ضمن الأصناف الأربعة

					
					CLASS1
					
					CLASS2
					CLASS3
					CLASS4

تم ذكر وضعية الراحة كأحد الوضعيات للكف البشري، إلا أنه خلال تشكيل قاعدة البيانات لم يتم تنفيذها من قبل المشاركين كأحد الأوضاع بل اقتصر تسجيل الاشارات المعبرة عنه على البيانات المسجلة أثناء فترات الراحة التي تفصل بين تكرارات الحركات.



الشكل 3-12: وضع الراحة

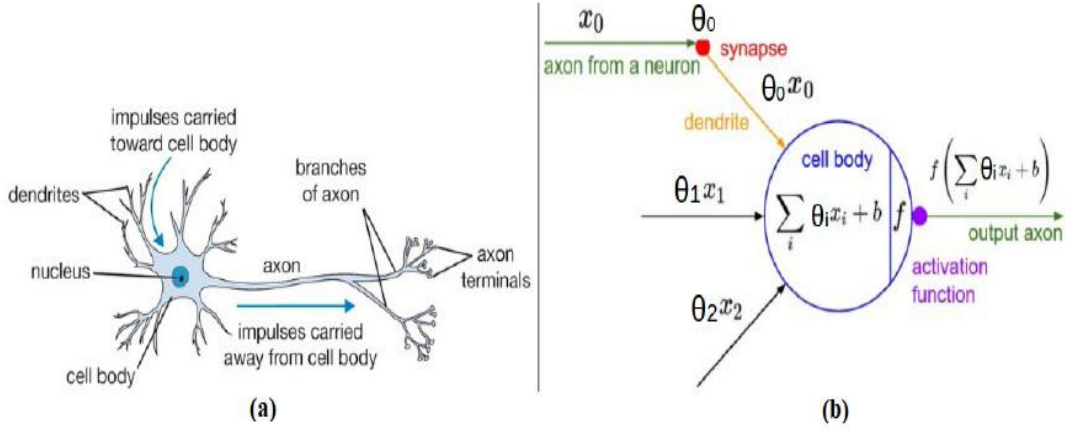
لذلك تم العمل على استخراج بيانات وضع الراحة من الفواصل بين التكرارات، وتجميعها وتشكيل صور تعبر عن هذا الوضع بنفس الطريقة التي تم العمل بها للحركات المختلفة، وتم تشكيل 250 صورة تعبر عن وضع الراحة وتم ادراجهم كصنف خامس.

3.3 تصنيف الإشارات:

أثبتت خوارزميات التعلم العميق كفاءتها في تصنيف الصور. ونقدم في هذا الفصل شرحاً تفصيلياً عن النموذج الذي تم اقتراحه في هذه الأطروحة. تصنيف الصور، كما يوحي الاسم، هو مشكلة إدخال صورة وإخراج الصف الذي تنتمي إليه "في مشكلتنا خمسة صفوف والتي تم اقتراحها حسب عدد الأصابع المشاركة في عملية الالتقاط بالإضافة الى وضع الراحة". ويعتبر التصنيف جوهر الرؤية الحاسوبية والطريقة التقليدية المتبعة هي وصف السمات واكتشافها، ولكن هذه الطريقة غير فعالة في التصنيفات المعقدة، لذلك هذه الطرق لم تعد مستخدمة الآن. في الوقت الحاضر تم اعتماد طرق التعلم العميق مثل الشبكات العصبونية والتي قدمت مساهمات مهمة جدا في مجال تصنيف الصور.

1.3.3 الشبكات العصبونية [28]:

تم استيحاء فكرة العصبون الصناعي والشبكة العصبونية الصناعية من بنية واتصال العصبونات الحقيقية في أدمغة الكائنات، والتي تقوم بأعدادها التي تتجاوز المليارات بربط ومعالجة المعلومات الحسية من سمع وبصر وغيره. يتصل العصبون الحقيقي بغيره من خلال نهاياته العصبية، ويقوم بتوليد نبضة عصبية من خلال محواره المرتبط مع نهايات العصبونات الأخرى عند تجاوز الاشارات الواردة لعتبة كمونية معينة. نجد كثيرا من التشابهات الوظيفية بين العصبون الحقيقي ونظيره الصناعي، فالأخير يعالج الاشارات الواردة الى مداخله بتوسيط مثقل مع ازاحة، ليتم بعدها تفعيل الخرج من خلال تابع تفعيل. يبين الشكل (3-13) التشابهات الوظيفية بين العصبونين الحقيقي والافتراضي.



الشكل 3-13: (a) عصبون حقيقي، (b) عصبون صناعي مع بيان مداخله ومخارجه

تتعدد البنى المكونة للشبكات العصبونية بحسب طبيعة الهدف منها، من مسائل تصنيف أو نمذجة أو استخراج سمات الى غير ذلك. ويرافق كل تصنيف منها توزيع معين في توصيل العصبونات أو طبقات خاصة تتولى مهمة محددة. من أهم الأنواع المستخدمة هي الشبكات العصبونية التلافيفية والتي تسجل كفاءة عالية جداً في تصنيف الصور لذلك سوف نقوم بالاعتماد عليها في الخوارزمية المقترحة.

2.3.3 الشبكات العصبونية التلافيفية:

تأتي فكرة الشبكات العصبونية التلافيفية (CNN) Convolutional Neural Networks من بنية وتوصيل مركز الادراك البصري في الكائنات الحية، حيث تتحفز مجموعة من العصبونات عند ورود مؤثرات على منطقة محددة تسمى بحقل الاستقبال receptive field. تتكامل حقول الاستقبال بين مجموع العصبونات حتى تغطي كامل حقل الرؤية. إن من أهم ميزات هذه الشبكات فعاليتها الكبيرة في التعامل مع المداخل ذات الحجم الكبير (كالصور بشكل أساسي) وقدرتها على استخراج السمات المفيدة بغض النظر عن موقعها في صورة الدخل. إن استخدام الطبقات التلافيفية له فعالية كبيرة مقارنة بالطبقات كاملة الاتصال، حيث أننا نحتاج في الأخيرة الى عدد كبير من العقد أي عدد كبير من الأوزان حتى في الشبكات ذات العمق البسيط، بينما تحقق الشبكات التلافيفية مهمة استخراج السمات بفعالية أكبر وبعدها أقل من المعاملات متجنبة بذلك مشكلة المشتقات المتلاشية. تتألف عقد الطبقات التلافيفية من فلاتر تطبق عمليات تلافيفية على حقل استقبال خاص بها وعلى كامل عمق الصورة، حيث يجري تخفيض أبعاد

السمات المستخرجة تدريجياً بإدخال طبقات تجميعية $pooling\ layers$ بين الطبقات التلافيفية تطبق عملياتها بشكل محلي أو شامل، وأبرز أشكالها التجميع بالقيمة العظمى والتجميع بالمتوسط. بالمحصلة يجري تصميم الطبقات التلافيفية وفق ثلاث معاملات عامة $hyper\ parameter$ وهي: عدد الفلاتر، حجم الفلتر، وحجم النافذة التجميعية. أيضاً يوجد طبقات $Batch\ Normalization$ والتي يتم فيها اجراء تسوية بين طبقات الشبكة العصبونية ويتم جراء ذلك على دفعات صغيرة بدلاً من مجموعة البيانات الكاملة، مما يسرع عملية التدريب. وطبقات $Dropout$ وتعمل هذه الطبقات على إبطال مساهمة بعض الخلايا العصبونية تجاه الطبقة التالية ويترك جميع الخلايا الأخرى بدون تعديل، وبالتالي منع حدوث حالة تدريب زائد. أيضاً طبقة $Flatten$ والتي تعمل على تحويل البيانات الى مصفوفة أحادية البعد وترتبط هذه الطبقة بنموذج التصنيف النهائي. طبقة $Dense$ هي طبقة متصلة بعمق، مما يعني أن الخلايا العصبونية للطبقة متصلة بكل خلية عصبونية في الطبقة السابقة، وهي أكثر الطبقات استخداماً في الشبكات العصبونية، وتعمل على تصنيف الدخل، وتتصل مع طبقة $Softmax$ والتي تعد طبقة الخرج وتحتوي على عدد عصبونات مساوي لعدد حالات الخرج.

تابع التفعيل $activation\ function$ هو تابع يطبق على القيمة الناتجة ضمن العقدة والمكونة من تركيب خطي لقيم عقد الطبقة السابقة، وتختلف صيغته حسب التطبيق الذي يستخدم الشبكة العصبونية. تستخدم ثلاثة أشكال شهيرة لهذه التوابع على تفاوت بينها بتحقيق فعالية التعلم للشبكة العصبونية:

$$ReLU(x) = \max(0, x) , \quad \tanh(x) = 2\text{sigm}(2x) - 1 , \quad \text{sigmoid}(x) = \frac{1}{1+e^{-x}}$$

تابع التنشيط المستخدم هو تابع التنشيط الخطي المصحح أو $ReLU$ للاختصار هي دالة خطية متعددة التعريفات ستخرج المدخلات مباشرة إذا كانت موجبة، وإلا فإنها ستخرج صفراً. لقد أصبحت وظيفة التنشيط الافتراضية للعديد من أنواع الشبكات العصبونية لأن النموذج الذي يستخدمها يسهل تدريبه ويحقق غالباً أداءً أفضل.

نظراً لأنه يتم تنشيط عدد معين فقط من الخلايا العصبونية، فإن وظيفة $ReLU$ تكون أكثر كفاءة من الناحية الحسابية عند مقارنتها بوظائف sigmoid و TanH . تعمل $ReLU$ على تسريع نزول التدرج

نحو الحد الأدنى لتابع الخسارة نظراً لخصائصها الخطية غير المشبعة. أحد سلبياته هو أنه يجب استخدامه فقط داخل الطبقات المخفية لنموذج شبكة عصبية اصطناعية.

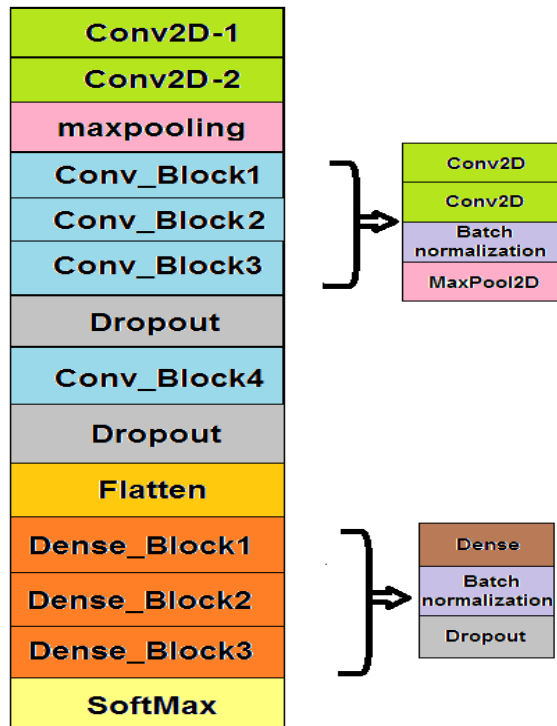
3.3.3 الشبكة العصبونية المستخدمة:

تم استخدام الشبكات العصبونية التلافيفية CNN لتصنيف الصور المعبرة عن الاشارات العضلية التي تم تشكيلها؛ تتألف بنية هذه الشبكة من 14 طبقة بشكل عام كما في الشكل (3-14)

- الطبقتان الأولى والثانية هما من نوع convolutional2D ب 16 فلتر (3*3) وبتابع تفعيل Relu وخط الحشو "same" بالتالي يبقى حجم الصورة كما هو عند خرج الطبقة.
- الطبقة maxpooling والتي تعمل على تخفيض حجم الصورة الى النصف حيث كانت قيمة ال pool size تسوي 2،
- المجموعات الثلاث conv_block الأول والثاني والثالث والتي تحتوي على طبقات داخلية متماثلة هي طبقتين convolutional2D عدد الفلاتر فيها في المجموعات الثلاث (8،16،32) على الترتيب وتليها طبقة Batch Normalization ومن ثم طبقة maxpooling بقياس 2.
- طبقة dropout بمعدل حذف 0.15 والتي تلعب دوراً مهماً في تدريب شبكات CNN لأنها تمنع التخصيص الزائد لبيانات التدريب. إذا لم تكن هذه الطبقة موجودة، فإن الدفعة الأولى من عينات التدريب تؤثر على التعلم بطريقة عالية بشكل غير متناسب. سيؤدي هذا بدوره إلى منع تعلم الميزات التي تظهر فقط في عينات أو مجموعات لاحقة.
- مجموعة conv_block مشابهة للمجموعات السابقة ولكن بعدد فلاتر 64.
- طبقة dropout بمعدل حذف 0.15
- طبقة Flatten والتي تجهز البيانات من أجل مرحلة التصنيف.
- ثلاث مجموعات dense_block كل منها تحتوي على طبقات داخلية متماثلة هي طبقة dense بعدد أفقية للمجموعات الثلاث (64،32،16) على الترتيب تليها طبقة Batch

Normalization ومن ثم طبقة dropout بمعدل حذف للمجموعات الثلاث (0.7,0.5,0.3) على الترتيب.

- طبقة Softmax وهي طبقة الخرج، تحتوي على خمس عصبونات تعبر عن حالات الخرج الخمسة -
 يبحث أن مجموع أوزانها التي تعبر عن الاحتمالات لكل صنف مساوي للواحد.



الشكل 3-14: طبقات الشبكة العصبونية التلافيفية المستخدمة


4.3.3 المعطيات المستخدمة:

تم توليد الصور التي يعتمد عليها العمل وفق الطريقة التي تم ذكرها سابقاً وعددها 1630 صورة مقسمة على الأصناف الخمسة.

الجدول 3-2: أعداد الصور في الصفوف


الصف	عدد الصور
1	850
2	60
3	180
4	290
5	250

تم فصل الصور الى مجموعتين؛ حيث تم وضع **66%** كمجموعة تدريب و**33%** كمجموعة اختبار، ونظراً لأن البيانات تم جمعها من عشرة أشخاص فقد تم مراعاة هذا الأمر عند تقسيم البيانات حيث تم الحرص على وجود صور معبرة عن الحركات لجميع الأشخاص في مجموعتي التدريب والاختبار، فيما أن كل شخص كرر كل حركة ست مرات، تم تقسيم البيانات أربعة تكرارات لمجموعة التدريب وتكراران لمجموعة الاختبار.




الشكل 3-15: مجموعة من الصور في قاعدة البيانات

فيكون شعاع الدخل X هو مجموعة التدريب والصور موزعة على الصفوف كما هو مبين في الشكل (3-16).



الشكل 3-16: توزيع الصور في مجموعة التدريب

أما بالنسبة لبيانات الاختبار فقد تم توزيع الصور ضمن الصفوف كما هو مبين في الشكل (3-17).




الشكل 3-17: توزيع الصور في مجموعة الاختبار

نلاحظ وجود حالة عدم توازن بين الصفوف بالتالي قمنا بالعمل على حل هذه المشكلة وذلك من خلال تقنية توسيع البيانات.

5.3.3 توسيع البيانات:

تم توليد صور جديدة من أجل تعزيز مجموعة البيانات ومن أجل حل مشكلة عدم توازن البيانات في الصفوف، حيث نجد أن عدد الصور في الصنف الأول يفوق عدد الصور في باقي الصفوف مجتمعة وتم ذلك من خلال الطريقة التالية.

أولاً، بما أن شدة الإشارة للحساسات قد تختلف من شخص لآخر أو حتى للشخص نفسه بين حالة الراحة وحالة التعب فتم العمل على توليد صور جديدة مع تغيير شدة بعض الحساسات وبالتالي إنتاج صور جديدة. ثانياً، تم أيضاً استغلال فكرة انزياح السوار بمقدار حساس أو اثنين على الأكثر بين شخص وآخر لذلك فقد تم العمل على ازاحة ترتيب الحساسات بمقدار حساس أو اثنين على الأكثر.

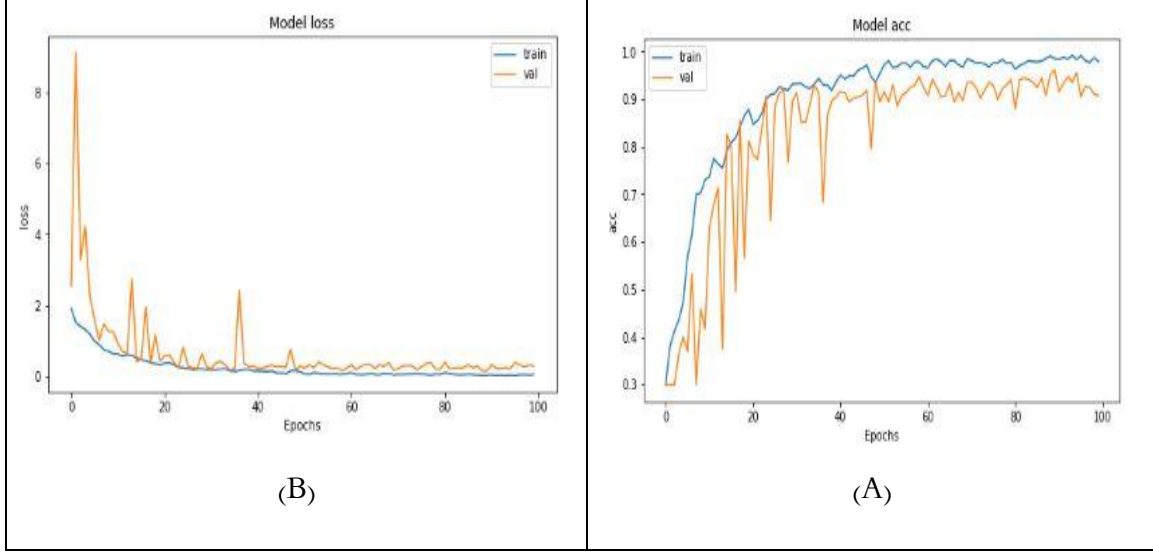


الشكل 3-18: توزيع الصور في الصفوف بعد زيادة البيانات

بهذه الطريقة قمنا بتوسيع قاعدة بيانات التدريب والاختبار عن طريق اضافة صور جديدة ومشتقة من المجموعة الأساسية وتم حل مشكلة التوازن بين الأصناف الى حد كبير وتقليل الفوارق في عدد الصور بشكل ملحوظ، تسمح زيادة البيانات بهذه الطريقة باختبار مدى قدرة النموذج على التعرف على الصور حتى في حال كانت قد تعرضت لبعض التشويش أو لانزياح في السوار على ذراع الشخص الذي يستعمله.

6.3.3 تنجيز وتدريب النموذج:

تم تنجيز النموذج باستخدام لغة بايثون اعتمادا على مكتبة Keras مع Tensorflow، والتي تقدم تغليفات للطبقات المختلفة عالية المستوى. تم تدريب النموذج على 100 طور تدريب وفق مجموعة البيانات والتقسيمات السابقة، وكما يوضح الشكل (40) فإن تابع دقة التدريب (train) وتابع التأكد من الدقة (val) يتقاربان وهذا دليل أن التدريب استقر بعد 100 طور، حيث وصلت الدقة الى قيمة عالية بالإضافة الى رسم تابع الخطأ للتدريب (loss) وتابع التأكد من الخطأ (val) ونلاحظ بعد 100 طور تدريب أن قيمة الخطأ قد انخفضت بشكل كبير.



الشكل 3-19: يبين الجزء (A) تغير توابع الدقة والتأكد من الدقة والجزء (B) يوضح تغير توابع الخسارة و التحقق من الخسارة خلال 100 طور تدريب

ومن خلال هذه التوابع، يقوم النموذج بالتدرب على عينة التدريب ومن ثم التحقق من نتائجه من خلال عينة الاختبار المذكورة سابقا ويحسن في قيم المعاملات المخفية لآخر طبقة في النموذج لكي يوائم مع الصور المراد التدريب عليها في كل طور. ويكرر هذه العملية على كل أطوار التدريب، وعند الطور 90 وما فوق تم ملاحظة أن الدقة لا تتحسن أكثر من عتبة معينة أي أصبح في كل مرة يتدرب النموذج على مجموعة من الصور من عينة التدريب ويتحقق من صور في عينة الاختبار ويحصل على دقة معينة. وفي مسألتنا هذه وصلت الدقة خلال مرحلة التدريب الى 98.9% والتحقق إلى 96.8%.

4.3 الخاتمة:

قمنا في هذا الفصل بدراسة البيانات في قاعدة البيانات NINA PRO DB5 ومن ثم قمنا بشرح خوارزمية العمل المقترحة والتي تنقسم الى قسمين رئيسيين الأول تمثيل البيانات حيث قمنا بتحويل الإشارات الى صورة بتدرج رمادي، والقسم الثاني وهو تصنيف هذه الصور باستخدام الشبكة العصبونية التلافيفية CNN المقترحة حيث تم تدريب واختبار هذا الشبكة وحصلنا على دقة تصنيف للصور 96% وهي نتيجة جيدة جداً.

الفصل الرابع

اختبار النموذج المقترح


نعرض في هذا الفصل اختبارات جودة النموذج المقترح

يوجد العديد من الأساليب للتأكد من كفاءة النموذج المقترح ومن صحة النتائج التي تم الوصول إليها نتيجة لتدريب واختبار الشبكة العصبونية بالإضافة الى ضرورة التأكد من زمن تنفيذ الخوارزمية والذي يعد معياراً مهماً في كفاءتها

1.4 اختبار دقة النتائج:

:confusion matrix

ضمن هذه المرحلة تم اختبار النموذج المقترح على مجموعة الاختبار التي تم تقسيمها سابقاً بشكل عشوائي من مجموعة المعطيات. بعد اختبار النموذج على هذه المجموعة قمنا برسم مصفوفة الارتباك (confusion matrix). أو كما تدعى أيضاً بمصفوفة المطابقة. يمثل كل صف من المصفوفة حالات الفئة المتوقعة بينما يمثل كل عمود حالات الفئة الفعلية (أو العكس بالعكس). ينبع اسم المصفوفة من حقيقة أنه يجعل من السهل رؤية ما إذا كان النظام مرتباً بين الأصناف (أي يخطئ بين أحد الأصناف على أنه صنف آخر). وهي تخطيط جدولي معين يسمح بتصوير أداء النظام.



الشكل 4-1: مصفوفة الارتباك للنموذج المقترح

من خلال مصفوفة الارتباك نلاحظ أن النموذج قد نجح في التمييز بين الأصناف الى حد كبير ونلاحظ أن أغلب الأخطاء كانت بين الصنف الأول والرابع وذلك كان متوقعا بالنسبة لنا حيث أن الأشخاص الذين قاموا باستعمال ثلاثة أصابع من أجل عملية الالتقاط قاموا بإغلاق الأصابع البقية بشكل عفوي دون الضغط عليها وبالتالي سيؤدي الى وجود تشابه بين الصنفين من حيث العضلات التي تم تفعيلها أثناء الحركة.

:F1-SCORE


تساعدنا مصفوفة الارتباك في حساب البارامترات الأخرى المهمة في قياس مدى كفاءة النموذج حيث يتم حساب مقاييس الأداء الأخرى والمبينة بالشكل (2-4) من خلال العلاقات التالية:

$$accuracy = \frac{TP + TN}{TP + FP + TN + FN}$$

$$Precision = \frac{TP}{TP + FP}$$

$$F1 - score = 2 * \frac{Precision * Recall}{Precision + Recall}$$

$$Recall = \frac{TP}{TP + FN}$$



الشكل 4-2: قيم ال precision وال recall وال f1-score لكل صف

تعتبر قيمة precision عن نسبة عدد الصور التي توقع النموذج أنها من صنف معين وكانت منه فعلا الى عدد الصور التي توقع النموذج أنها من هذا الصنف وقيمة ال precision من أهم المعايير التي تحتاج دراستها في بحثنا حيث أنه كلما انخفض عدد التوقعات الخاطئة، أي كانت قيمة precision أعلى، كان أداء النموذج أفضل. أما قيمة recall فتعبر عن نسبة الصور التي توقع أنها من صنف معين وكانت منه الى عدد الصور في هذا الصنف بالنسبة لقيمة f1_score فهي متوسط مرجح لكل من precision و recall وكلما كانت قيمته أقرب الى الواحد كان أداء النموذج أفضل، نلاحظ في حالتنا أن قيم ال precision وال recall عالية لجميع الصفوف وهذا مؤشر على جودة النموذج المقترح

معدل انذار الخطأ FAR:


هو أحد المقاييس المهمة التي تركز على النسب المصنفة بشكل خاطئ ويساوي المتوسط الحسابي لكل من قيمتي FNR , FPR حيث يفضل أن تكون قيمته أقل ما يمكن.

$$FNR = \frac{FN}{TP + FN}$$

$$FPR = \frac{FP}{FP + TN}$$

$$FAR = \frac{FPR + FNR}{2}$$

ويتم حسابه لكل الأصناف الموجودة في قاعدة البيانات كما هو مبين في الشكل (3-4).




الشكل 4-3: قيم FAR , FNR , FPR لكل من الصفوف الخمسة

ونلاحظ القيم المنخفضة حيث أن قيم FPR لا تزيد عن 0.1 أما بالنسبة ل FNR فقيمها أقل من 0.2 و FAR أقل من 0.15 مما يدل على كفاءة النموذج المختار لتصنيف الصور.

2.4 مقارنة النموذج المقترح مع نموذج ResNet:

تم استخدام شبكات التعلم المسبق ResNet اختصاراً ل Residual Networks، وهي عبارة عن شبكة عصبية كلاسيكية تستخدم كأساس للعديد من مهام الرؤية الحاسوبية، وتعتبر أول شبكة عصبونية عميقة جداً ذات تغذية أمامية بمئات الطبقات، وهي أعمق بكثير من الشبكات العصبونية الأقدم منها. تُستخدم وصلات التخطي أو الاختصارات للقفز فوق بعض الطبقات.



الشكل 4-4: مبدأ عمل الشبكة ResNet

يوجد العديد من الاصدارات لهذه الشبكات وهي: ResNet50 , ResNet101, ResNet152. وتعد ResNet 50 الأكثر شيوعاً وتستخدم عندما يكون عدد الصور التي يتم تصنيفها غير كبير حيث تكون نتائجها أفضل من النسختين الأعلى وتعطي النسختان 101, 152 نتائج أفضل عندما يكون عدد الصور كبيراً، وتعتمد هذه الشبكات على الأوزان الناتجة عن التدريب على قاعدة البيانات imagenet ونستخدم على خرجها طبقة dense بـ 1024 وحدة وطبقة dropout بمعدل 0.25 بالإضافة إلى طبقة الخرج softmax.

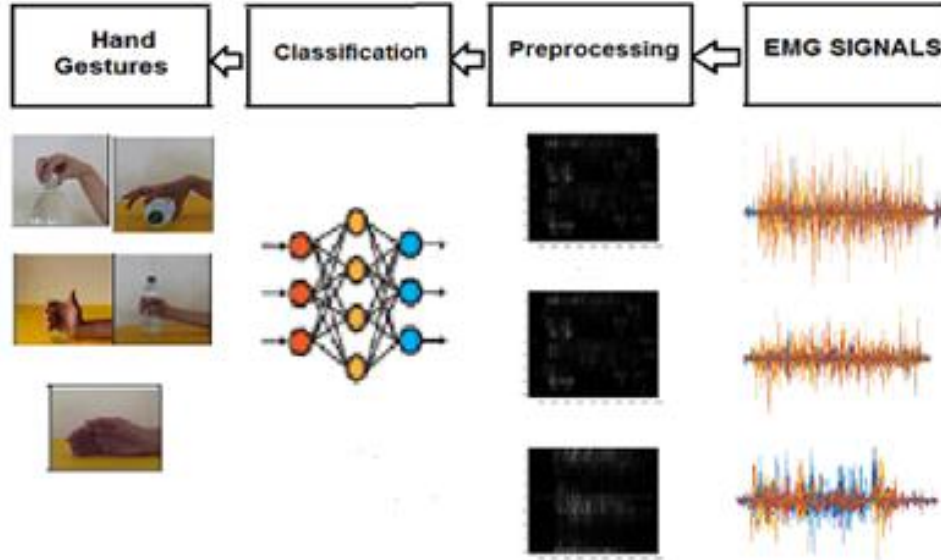
تم تدريب النموذج باستخدام قاعدتي البيانات المتوازنة وغير المتوازنة وقد أعطت شبكة CNN التي تم العمل عليها أعلى دقة تصنيف من شبكتي ال ResNet 50,101 وكانت النتائج كما هو مبين في الجدول (1-4)

الجدول 1-4: مقارنة بين النموذج المقترح ونماذج ال ResNet

	قاعدة البيانات غير المتوازنة	قاعدة البيانات المتوازنة
CNN	90.76%	95.89%
ResNet50	88.26%	91.79%
ResNet101	89.96%	94.23%

3.4 اختبار زمن عمل الخوارزمية:

تتضمن خوارزمية العمل تحصيل البيانات من الحساسات ومعالجتها وفق الطريقة المقترحة ومن ثم تصنيفها باستخدام شبكة CNN المقترحة والتي تعطينا حركة الالتقاط المقابلة للإشارات. ويظهر الشكل (4-5) مخطط سير العمل ضمن الخوارزمية.



الشكل 4-5: مخطط خوارزمية العمل


يجب أن يكون زمن تطبيق الخوارزمية أقل ما يمكن. وبما أن زمن استمرار تنفيذ الحركة الواحدة في قاعدة البيانات هو خمس ثواني بالتالي فإننا سنتعامل مع نافذة محددة من الإشارات بطول 5 ثانية. يبين الجدول (4-2) الزمن الوسطي لتنفيذ كل جزء من أجزاء خوارزمية العمل على النافذة الواحدة على حاسب بمعالج

Intel (R) Core(TM) i5_2410M CPU @2.30GHz و ذاكرة وصول عشوائي
RAM 3GB

الجدول 4-2: الزمن اللازم لتنفيذ كل مرحلة من مراحل الخوارزمية

المرحلة	متوسط الزمن اللازم لتنفيذها
معالجة البيانات	185 ms
التصنيف	25 ms

بعد حساب الأزمنة تبين أن الزمن اللازم للتعامل مع الاشارات وتصنيفها هو 210ms وهو زمن صغير ومناسب، بالتالي سنقوم بإنشاء نافذة منزلقة وهي خمس ثواني أي 1000 عينة، سنقوم بإزاحة نافذة العمل بمقدار 250ms على طول سلسلة الاشارات.



الشكل 4-6: يبين الشكل الصور المتشكلة من سلسلة الاشارات الواردة لأحد تكرارات حركة من الصنف الأول وتصنيفها

تبين التجربة أن النموذج المقترح استطاع التعرف على الحركة قبل اكتمال وصول الاشارات المعبرة عنها وهذا يدل على صلادة النموذج وقدرته على التعرف على الاشارات الواردة.

4.4 الخاتمة:

تم في هذا الفصل اختبار النموذج المستخدم بعدة معايير وقد أثبتت النتائج أن النموذج المقترح جيد جداً، وأخيراً تم اختبار زمن تطبيق خوارزمية العمل كاملة وكانت النتائج جيدة جداً حيث تبين مدى صلادة النموذج المقترح.

الخاتمة والأفاق المستقبلية:

إن الهدف الرئيسي لهذا البحث هو استثمار خوارزميات الذكاء الصناعي لتطوير التحكم بطرف صناعي علوي (كف صناعي) لتعويض الأشخاص فاقدى الأطراف العلوية. تمت دراسة التصاميم المنحزة في مجال الأطراف الاصطناعية، وبالإضافة الى دراسة الحركات التي يمكن لليد البشرية ونظيرتها الاصطناعية القيام بها وتحديد حركات الالتقاط وتصنيفها ضمن خمسة أصناف حسب الأسلوب الذي قمنا باقتراحه. تم دراسة الاشارات العضلية والاعتماد على قاعدة البيانات nina pro والتي تعد أهم قاعدة لبيانات الاشارات العضلية، تم اختيار النسخة المناسبة لقاعدة البيانات وباستخدام برنامج matlab قمنا بمعالجة قاعدة البيانات وتفكيكها ليسهل علينا معالجة البيانات ومن ثم قمنا بمعالجة البيانات وتحويلها الى صور تدرج رمادي تعبر عن حركات الكف حسب خوارزمية العمل التي اقترحناها. وفي النهاية استخدمنا الشبكات العصبية التلافيفية CNN لتصنيف هذه الصور في الأصناف الخمسة المقترحة، وذلك بالاعتماد على مكتبات Tensorflow و Keras وباستخدام لغة البرمجة Python ولقد حصلنا على نتائج جيدة جدا وكانت دقة التصنيف حوالي 96%. كما قمنا بدراسة للبنية الالكترونية الملائمة لتنفيذ هذا النظام بشكل عملي. يمهد هذا البحث للعديد من الخطوات المستقبلية، حيث يمكن استبدال فكرة النافذة المنزقة بشبكة عصبونية تتعرف على قيام الشخص بحركة ما. أيضا تطبيق الخوارزمية المقترحة عملياً وباستخدام بيانات من شخص ذو طرف مبتور وذلك للتحقق من فعاليتها. بالإضافة الى تنفيذ مشروع ذراع بديلة متكاملة تعتمد على النظام الذي قمنا ببنائه مما قد يسهم في حل مشكلة العديد من الأشخاص مبتوري الأطراف ومحاوله اعادة جزء من حياتهم الطبيعية قبل حدوث البتر.

المراجع:

- [1] S. M. a. G. O'Dell, "A smart prosthetic Device for transradial amputees," 2017.
- [2] J. S. a. G. Redlarski, "Artificial-Hand Technology—Current State of Knowledge in Designing and Forecasting Changes," *Applied Sciences*, 2019.
- [3] O. H. GmbH, "BeBionic: the Worlds Most Lifelike Bionic Hand," 2017.
- [4] O. Bionics, "Hero Arm User Manual," 2019.
- [5] T. Bionics, "'I-Limb Ultra Revolution Brochure," 2013.
- [6] "Luke Arm System Datasheet," *Mobius Bionics*, 2017.
- [7] "Fascinated with Michelangelo," *Otto bock Healthcare GmbH*, 2017.
- [8] T. Prosthetics, "<http://www.taskaprosthetics.com>," 2018. [Online].
- [9] "VINCENTevolution3: Design and function in perfection," *Vincent Systems*, 2019.
- [10] M. F. DARIO FARINA, "Motor unit recruitment strategies investigated," *J Appl Physiol* ,92: 235–247, 2002.
- [11] C. L. Angkoon Phinyomark, "Evaluation of EMG Feature Extraction for Hand Movement Recognition Based on Euclidean Distance and Standard Deviation," *IEEE Xplore*, 2010.
- [12] A. R. A. M. S. Jingwei Too, "Classification of Hand Movements based on Discrete Wavelet Transform and Enhanced Feature Extraction," (*IJACSA*) *International Journal of Advanced Computer Science and Applications*, 2019.
- [13] B. Z. Z. Yuheng Wu, "Dynamic Gesture Recognition Based on LSTM-CNN," *IEEE*, 2018.
- [14] R. K. Yusuke Yamanoi, "Control Method for Myoelectric Hand using Convolutional Neural Network to Simplify Learning of EMG Signals," *IEEE International Conference*, 2017.
- [15] J. F. ., Y. W. ., H. L. a. B. Z. Lin Chen, " Hand Gesture Recognition Using Compact CNN Via Surface Electromyography Signals," *Sensors*, 2020.

- [16] B. J. ., R. H. M. C. a. C. T. Xiaolong Zhai, " Self-Recalibrating Surface EMG Pattern Recognition for Neuroprosthesis Control Based on Convolutional Neural Network," 2017.
- [17] O. F. N. B. H. O. a. N. Y. Yunan He, "Surface EMG Pattern Recognition Using Long Short-Term Memory Combined with Multilayer Perceptron," *IEEE*, 2018.
- [18] K. G. ., X.-R. C. M. Y. a. R.-C. W. SHU SHEN, " Movements Classification of Multi-Channel sEMG based on CNN and Stacking Ensemble Learning," *IEEE*, 2019.
- [19] Z. H. J. Z. a. G. C. Yuanfang Wan, " Pattern recognition and bionic manipulator driving by surface electromyography signals using convolutional neural network," *International Journal of Advanced*, 2018.
- [20] A. R. A. ., N. M. S. Jingwei Too, " Classification of Hand Movements based on Discrete Wavelet Transform and Enhanced Feature Extraction," *IJACSA) International Journal of Advanced Computer Science and Applications*, 2019.
- [21] C. L. F. A. D. A. C.-L. C. G. K. G. a. B. G. Ulysse C^ot^oe-Allard, " Deep Learning for Electromyographic Hand Gesture Signal Classification Using Transfer Learning," 2019.
- [22] A. Z.-L. ., J. A. M.-S. ., J. J. E.-A. a. J. G. V.-A. Jorge Arturo Sandoval-Espino, "r "Selection of the Best Set of Features for sEMG-Based Hand Gesture Recognition Applying a CNN Architecture," *Sensor*, 2022.
- [23] G. R. N. M. J. S. V. a. W. P. d. S. Rafaela Covello de Freitas, "Surface electromyography classification using extreme learning machines and echo state networks," 2022.
- [24] P. Konrad, "A Practical Introduction to Kinesiological Electromyography," Noraxon INC. USA, 2006.
- [25] A. G. C. C. B. C.-G. M. H. S. E. G. G. B. & H. M. Manfredo Atzori, "Electromyography data for non-invasive naturally-controlled robotic hand prostheses," *SCIENTIFIC DATA*, 2014.
- [26] A. P. E. S. Jason Chang, "Assessment of EMG Benchmark Data for Gesture Recognition Using the NinaPro Database," *IEEE*, 2020.
- [27] L. T. M. C. M. R. M. M. A. Stefano Pizzolato, "Comparison of six electromyography acquisition setups on hand movement classification tasks," 2017.
- [28] Y. B. A. C. a. Y. B. I. Goodfellow, "Deep learning," *MIT press Cambridge*, 2016.

