

التعرف على أنماط الالتقاط بالاعتماد على إشارات حساسات EMGs بالاستعانة بقاعدة البيانات NINA PRO

عبد الله عبد الله¹، شادي البيطار²، د. آصف جعفر³

1 مهندس، ماجستير تحكم وروبوتيك، المعهد العالي للعلوم التطبيقية والتكنولوجيا،
abdallah.abdallah@hiast.edu.sy
2 باحث رئيسي، المعهد العالي للعلوم التطبيقية والتكنولوجيا،
shadi.albitar@hiast.edu.sy
3 مدير بحوث، المعهد العالي للعلوم التطبيقية والتكنولوجيا،
asef.jafar@hiast.edu.sy

الملخص:

يركز هذا البحث على تطوير التحكم بطرف صناعي كبديل ذكي للطرف المبتور بالاستعانة بالإشارات الكهربائية العضلية EMG لتعويض حركات الالتقاط التي تقوم بها اليد البشرية. بداية، تمت دراسة حركات الالتقاط التي تستطيع اليد البشرية القيام بها بالإضافة لدراسة نماذج الأذرع البديلة المنجزة عالمياً وإمكاناتها. بناء عليه، اقترحنا تصنيف حركات الالتقاط في أربع اصناف بناء على عدد الأصابع المشاركة بعملية الالتقاط بالإضافة الى وضع الراحة. جرى الاعتماد في الدراسة على النسخة الخامسة من قاعدة البيانات NINA PRO والتي تفترض وجود سوارين من الحساسات العضلية يتضمن كل منها ثمانية حساسات مثبتة على ساعد الطرف المبتور بحيث يكون هناك انزياح زاوي بينها. تعتمد الخوارزمية المقترحة على تحويل اشارات الحساسات العضلية الى مصفوفة مقيسة بأبعاد تعتمد على عدد الحساسات وعلى معدل تحصيل البيانات خلال النافذة الزمنية للحركة، ومن ثم تحويل المصفوفة الى صورة بتدرج رمادي. بالاعتماد على خوارزميات التعلم العميق، تم اختبار عدة نماذج حيث استطعنا تصنيف هذه الاشارات ضمن الأصناف الخمسة بكفاءة عالية وبدقة تصنيف 95.89% باستخدام الشبكات العصبونية التلافيفية CNN.

الكلمات المفتاحية: طرف صناعي، الاشارات الكهربائية العضلية، حركات الالتقاط، قاعدة البيانات، التعلم العميق، الشبكات العصبونية التلافيفية

تاريخ الإيداع: 2023/8/29

تاريخ القبول: 2023/10/24



حقوق النشر: جامعة دمشق - سورية،
يحتفظ المؤلفون بحقوق النشر بموجب
الترخيص CC BY-NC-SA 04

Grasping Type Recognition based on EMG signals using NINA PRO dataset

Abdallah ABDALLAH¹, Chadi ALBITAR²,
Dr. Assef JAFAR³

¹ Engineer, Higher Institute for applied Sciences and Technology, Robotics, abdallah.abdallah@hiast.edu.sy

² Assistant Professor, Higher Institute of applied Sciences and Technology, Vision and Robotics, shadi.albitar@hiast.edu.sy

³ professor, Higher Institute for applied Sciences and Technology, Artificial Intelligence, asef.jafar@hiast.edu.sy

ABSTRACT:

This research focuses on developing the control of a prosthetic limb as a smart alternative to the amputated limb by using EMG signals to compensate for the grasping movements of the human hand. First, we studied the grasping movements that human hand can perform, in addition to studying the models of prosthetic arms made globally and their capabilities. Accordingly, we proposed to classify the grasping movements into four classes based on the number of fingers involved in the grasping process in addition the resting position. The study relied on the fifth version of the NINA PRO database, which assumes the presence of two armband of muscle sensors, each one includes eight sensors mounted on the forearm of the amputated limb., so that there is an angular shift between them. The proposed algorithm is based on converting the signals of muscle sensors into a scaled matrix with dimensions that depend on the number of sensors and the rate of data acquisition during the time window of movement, and then converting the matrix into a grayscale image. Depending on the deep learning algorithms, several models were tested, where we able to classify there signals within the five classes with high efficiency and with a classification accuracy of 95.87% using CNN convolutional neural networks.

Keywords: Prosthetic Grasping Movements, NINA PRO Database, Muscle Sensors, Deep Learning, Classification, Convolutional Neural Network.

Received: 29/8/2023
Accepted: 24/10/2023



Copyright: Damascus University- Syria, The authors retain the copyright under a CC BY- NC-SA

1. مقدمة عامة:

بعد العمل على تصميم بدائل للأطراف المبتورة مجالاً مهماً منذ القدم، فمثلاً وصل عدد الأشخاص الذين تعرضوا لعمليات بتر في الأطراف نتيجة الحرب في سوريا عام 2017 إلى 86000 شخص وذلك بحسب منظمة الصحة العالمية. في البدايات تم تصميم مجموعة متنوعة من الأطراف الصناعية التي تعتمد في عملها على التصميم الميكانيكي فقط، ومع زيادة التطور تم إدخال المحركات والحساسات ودارات التحكم ضمن التصاميم المصنعة. مع تزايد التطور التكنولوجي والعلمي ومواكبة لهذا التطور، ونتيجة لظهور خوارزميات الذكاء الصناعي وتقنيات الرؤية الصناعية، حصلت قفزة نوعية جديدة في مجال تصميم الأطراف الصناعية وصناعتها. نتيجة لذلك يزداد توجه الباحثين والمهندسين حديثاً نحو مجال تصميم وتطوير الأطراف الصناعية البديلة كوسيلة لتعويض الطرف المبتور ومحاولة تمكين المصاب من استعادة حياته الطبيعية،

إن تمكين الكف الصناعية البديلة من محاكاة اليد البشرية قدر الإمكان ضمن فضاء الحرية المتاح والقيام بحركات الالتقاط الأساسية يتطلب أيضاً تحقيق 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، والموازنة بين هذا الأمر وبين تخفيض كلفة التنفيذ حيث يعد هذا المجال تحدياً مفتوحاً.

في السنوات الأخيرة تم استخدام تقنية الاشارات الكهربائية العضلية EMGs على نطاق واسع في التحكم في الأطراف الصناعية نظراً لأنها تقنية غير جراحية وغير باهظة الثمن ويسهل تنفيذها، ويعد تمييز هذه الاشارات التي تعبر عن الحركات المختلفة الجزء الأساسي في تطبيقات الأذرع التي تستخدم الاشارات العضلية. نظراً للطبيعة العشوائية وغير الخطية وغير المستقرة لهذا النوع من الاشارات فمن غير

العملي استخدام الاشارات الخام لذلك يتم معالجة البيانات قبل استخدامها (Dario Farina, 2002) ركزت الأدبيات سابقاً على استخراج السمات من الإشارات العضلية (Redlarski, 2019) لتكون دخلاً لخوارزميات التصنيف، وتم اقتراح العديد من السمات الفعالة في المجال الزمني والترددية والتي أعطت نتائج جيدة باستخدام الخوارزميات التقليدية للذكاء الصناعي (Jingwei Too, 2019).

لاحقاً للتطور الكبير الذي شهده مجال التعلم العميق في مجال التعرف على الصور، اقترح الباحثون استخدام الشبكات العصبونية العميقة لتصنيف الاشارات العضلية (Yuheng Wu, 2018) كونها لا تتطلب استخراج سمات محددة. نقترح في بحثنا هذا خوارزمية تعتمد على التعلم العميق في كشف حركات الالتقاط لكف صناعي، حيث تشمل خوارزمية معالجة الإشارات العضلية وتحويلها الى صورة ليتم تصنيفها ضمن أحد الحركات المعتمدة.

2. الدراسة المرجعية:

تم العمل في العديد من الابحاث على تحويل الاشارات العضلية الى صور بطرق مختلفة ومن ثم استخدام شبكات التعلم العميق في تصنيف هذه الصور، وقد تم اعتماد قاعدة بيانات NINA PRO للمقارنة بين نتائج الأبحاث المختلفة. اقترح البحث (Yusuke Yamanoi, 2017) تحويل الاشارات العضلية المستخرجة من 5 حساسات EMG الى صورة باستخدام تحويل فورييه القصير STFT وتم العمل على تصنيفها باستخدام الشبكات العصبونية التلافيفية CNN وقد تم الوصول الى دقة تعرف 88%. في (Xiaolong Zhai, 2017) تم تحويل الاشارات العضلية الى صور عن طريق تطبيق تحويل فورييه السريع FFT ومن ثم تحليل الصور إلى المركبات الأساسية (PCA) التي هي مدخل لشبكة CNN وكانت أعلى دقة تم الوصول إليها 88.43% في (Yuanfang Wan, 2018) تم تحويل إشارات 16 حساساً بعد القيام بعملية تقييس إلى مصفوفات مربعة 16×16 ومن ثم تحويلها الى صورة بتدرج رمادي ومن ثم استخدام شبكات CNN للتصنيف وقد صنّفوا مجموعة من حركات المعصم الأساسية ووصلوا الى 97% دقة تصنيف. في (Ulysse C'ot'e-Allard, 2019) تم العمل على تحويل الاشارات

أساسية لكل إصبع على حدة، والثاني 8 حركات أساسية للأصابع مجتمعة، و9 حركات أساسية للمعصم والثالث 23 حركة التقاط لأغراض مختلفة الشكل. تم التركيز في هذا العمل على الجزء الأخير من الحركات والذي يمثل حركات الالتقاط كونه موضوع بحثنا.

3. الخوارزمية المقترحة:

3.1 اختيار صفوف الحركات

بشكل عام، تتحقق عمليات الالتقاط بمساعدة اليد وذلك من خلال الأصابع وراحة الكف، حيث يوجد العديد من أنماط الالتقاط التي يمكن ليد الإنسان تحقيقها. تم تصنيف هذه الأنماط في مجموعات اعتماداً على أربعة اعتبارات أساسية (Redlarski، 2019) وهي نوع الالتقاط، وضعية الإبهام، نمط مقابلة الإبهام للكف، عدد القوى المطبقة في الاتجاهات المختلفة. يعتمد عدد الأنماط التي يقوم الكف الاصطناعي بتنفيذها على عدد درجات الحرية التي يتيحها التصميم الميكانيكي. يعرض الجدول (1) مجموعة مختارة من الكفوف الصناعية الإلكترونية التجارية. تم التركيز على الأيدي الصناعية عالية الأداء، مع عدد كبير من درجات الحرية، والتي يمكن أن تسمح بأكبر عدد ممكن من أنماط الالتقاط.

من خلال دراسة النماذج المطروحة تجارياً، نلاحظ أن الكفوف الصناعية مازالت غير قادرة على مواكبة اليد البشرية في القيام بجميع الحركات، حيث أن 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 مجموعة من الأصابع سوية بواسطة محرك واحد. نلاحظ أن كل النماذج لا تسمح بالحركة الدورانية الجانبية عند قاعدة الأصابع، أي أن للأصابع درجة حرية دورانية واحدة، وذلك يحد من قدرتها على القيام بالعديد من الحركات.

العضلية إلى رسوم طيفية باستخدام نوافذ HANN وإيضاً باستخدام التحويل CWT وتم تصنيف هذه الصور باستخدام الشبكات المدربة مسبقاً وكانت أعلى دقة تم الوصول إليها هي 70%. وفي (Lin Chen، 2020) تم استخدام تحويل فوربييه القصير STFT واستخدام شبكة LSTM-CNN وكما تم استخدام التحويل CWT ومن ثم استخدام شبكات التعلم العميق لتصنيف الصور الناتجة ومقارنة نتائجها حيث كانت أعلى دقة 71%. وفي (Jorge Arturo Sandoval-Espino، 2022) تم الدمج بين استخراج الميزات وتشكيل الصور حيث تم الاعتماد على الميزات المستخرجة في تشكيل الصور بعدة طرق من خلال تطبيق تحويل فوربييه ثنائي البعد ومن ثم استخدام الشبكات العصبونية CNN لتصنيف الصور حيث تم الوصول إلى دقة تعرف على إشارات 50 حركة مأخوذة من مجموعة من حساسات delsys tringo حوالي 97%.

في هذا العمل، اخترنا اعتماد قاعدة البيانات

في هذا العمل، اخترنا اعتماد قاعدة البيانات (Manfredo Atzori، NINA PRO، 2014) والتي غالباً ما يتم استخدامها لاختبار الخوارزميات المقترحة في مجال التعرف على حركات الكف الصناعي البديل، وقد اخترنا النسخة الخامسة منها (Stefano Pizzolato، 2017) والتي اعتمدت تحصيل قياسات من حساسات MYO THELAMIC وهي عبارة عن سوار يتضمن ثمانية حساسات لإشارات عضلية (EMG) حيث يتم تثبيت سورلين من هذه الحساسات على ذراع المبتور. تقدم مجموعة البيانات قياسات لحساسات أخرى أيضاً إلا أننا سنركز في عملنا على قياسات الحساسات العضلية فقط.

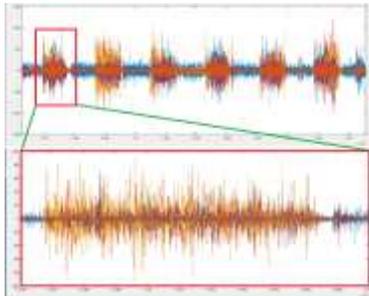
تحتوي النسخة الخامسة من قاعدة البيانات NINAPFRO على قياسات الإشارات العضلية من عشر أشخاص اصحاء (8 ذكور و2 إناث) بمعدل تحصيل 200Hz. أجريت عملية معالجة أولية لحذف الضجيج بترشيح الإشارات عند التردد 50Hz. تقسم الحركات التي تم تسجيلها إلى ثلاثة تمارين؛ الأول يحتوي على 13 حركة

الجدول (3) توزيع حركات الالتقاط ضمن الأصناف الخمسة

1	2	3	4	5
				
				
				
				
				
				

3.2 معالجة البيانات

كما ذكرنا سابقاً تم تسجيل الإشارات باستخدام سوارين من الحساسات العضلية مزاحين عن بعضهما بزاوية 22.5 درجة لتغطية العضلات الموجودة في الذراع قدر الإمكان. تظهر هذه البيانات كسلسلة زمنية بـ 16 قناة مع ما يقرب من 600,000 عينة لكل شخص. بتسجيل 6 تكرارات لكل حركة، قام كل شخص بإجمالي 312 حركة مقسمين على التمارين الثلاثة لقاعدة البيانات بحيث كانت مدة تنفيذ كل تكرار خمس ثوانٍ، وبما أن معدل تحصيل البيانات Hz200 بالتالي يمكن القول إن كل تكرار يتضمن 1000 عينة من كل حساس، وتوجد فترة راحة بين كل تكرارين لمدة ثلاث ثوانٍ.



الشكل (1) التكرارات الستة وطبيعة الإشارات لأحد التكرارات

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 بشكل يدوي باستخدام برنامج MATLAB وإعادة تجميعها بعد التخلص من فواصل الراحة، وفي هذه الحالة نتمكن من التعامل مع كل تكرار على حدة.

الجدول (1) مقارنة بين النماذج المختلفة لأشهر الكفوف البديلة التجارية

النموذج	عدد المحركات	وضع الإبهام	عدد الحركات
I-Limb Hand (Bionics T. , 2013)	5	مفعل يدوياً	24
Michelangelo Hand (Fascinated with Michelangelo, 2017)	3	مفعل اوتوماتيكياً	7
Bebionic Hand (GmbH, 2017)	5	مفعل يدوياً	14
Hero Arm (Bionics O. , 2019)	3-4	غير مفعل	4-6
The Ada Hand (O'Dell, 2017)	5	غير مفعل	5
LUKA Arm (Luke Arm System Datasheet)	6	مفعل اوتوماتيكياً	6

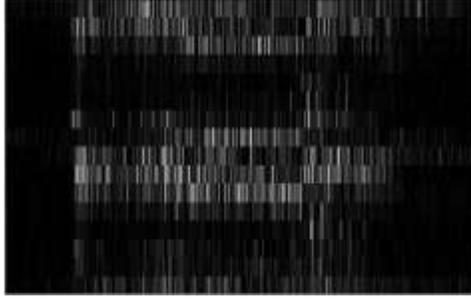
بالنسبة للإبهام، نلاحظ أنه في بعض النماذج يكون كغيره من الأصابع بدرجة حرية دورانية واحدة وفي بعضها يتم ضبط الإبهام يدوياً وبعضها الآخر يتم التحكم بدورانه عن طريق طريق محرك. بالتالي، من غير المجدي أخذ كل عمليات الالتقاط بالاعتبار وتنفيذها، حيث نلاحظ أن الكفوف الصناعية البديلة، ونتيجة لمحدودية درجات الحرية، 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 مقاربة والتي تعبر اليد الصناعية عنها بطريقة واحدة ضمن فضاء الحرية الممكن. بناء عليه، اقترحنا تصنيف حركات الالتقاط في أربع أصناف حسب عدد الأصابع المشاركة في الحركة بالإضافة لوضع الراحة كما هو مبين في الجدول (2).

الجدول (2) التصنيف المقترح لحركات الالتقاط لليد البشرية

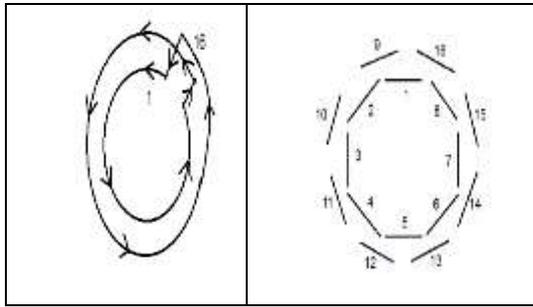
الصنف الأول	الالتقاط بخمسة أصابع
الصنف الثاني	الالتقاط بأربعة أصابع
الصنف الثالث	الالتقاط بثلاثة أصابع
الصنف الرابع	الالتقاط بإصبعين
الصنف الخامس	وضع الراحة

وبالتالي وبناء على التصنيف الذي قمنا باعتماده يمكننا توزيع الحركات الموجودة التمرين الثالث لقاعدة البيانات 5NINA PRO DB التي نعمل عليها بالمجموعات التالية كما في الجدول (3).

بالشكل (4) لتصبح أبعاد الصورة المعبرة عن كل حركة بالشكل (4) لتصبح أبعاد الصورة المعبرة عن كل حركة (18×1000).



الشكل (3) الاشارات العضلية بعد تحويلها الى صورة

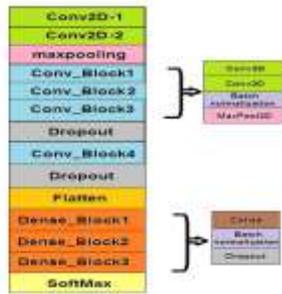


الشكل (4) توزع الحساسات وتسلسلها والمسار المقترح لإغلاق حلقة الحساسات

تمثل هذه الصور التي تم تشكيلها دخلاً 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. قمنا أيضاً باستخراج 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.

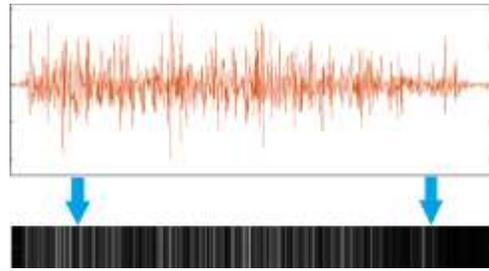
3.3 التصنيف

قمنا بتصميم شبكة تتألف من 14 طبقة موضحة بالشكل (5)



الشكل(5) طبقات الشبكة العصبونية التلافيفية المستخدمة

بداية، من أجل كل حساس من حساسات السوار، نعبر عن اشارته بشعاع يتضمن قيم القياسات (1000 عينة) والذي يمكن التعبير عنه كشرط أفقي بتدرجات رمادية. نظراً للطبيعة العشوائية وغير الخطية وغير المستقرة للإشارات العضلية، يجب العمل على معالجة الاشارات قبل استخدامها، وبما إن الاشارات الواردة من السوار تتأثر بالعديد من العوامل كالتعب، اقترحنا تطبيق عملية تقييس على الاشارات الواردة بطريقة max-min normalization بحيث يتم تقييس الاشارة ضمن المجال [0,1]، وبالتالي نحصل على صورة رمادية كما في الشكل (2).



الشكل (2) تحويل اشارة الحساس الى تدرج رمادي

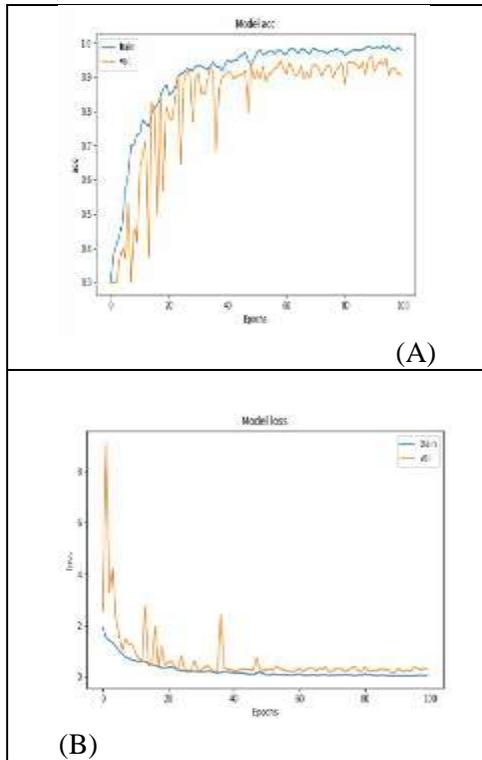
نلاحظ أيضاً أن حركات اليد الطبيعية لا تعتمد على عضلة واحدة أو شكل تقلص واحد، وإنما تتشارك عدة عضلات لأداء كل حركة، وبشكل تقلص يختلف من حركة لأخرى، فيما يعرف في الطب بالتآزر العضلية (Muscle Synergies)، لذلك تم العمل على تكوين صورة تجمع مساهمة العضلات المختلفة وتبين قيمة اشاراتها عند كل قراءة من خلال توضع الشرائط المعيرة عن الحساسات المختلفة ضمن مصفوفة واحدة، بالتالي نحصل على صورة مكونة من 16 شريطاً أفقياً بتدرج رمادي بأبعاد 16×1000 (الشكل (3)).

أخيراً، 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 توسيع الصورة المعبرة عن إشارات الحساسات وذلك بإغلاق السلسلة أي تكرار الحساس الأول في نهاية المصفوفة والحساس السادس عشر في بداية المصفوفة كما هو موضح

4. النتائج والمناقشة:

تم تمييز نموذج شبكة التصنيف باستخدام لغة بايثون اعتماداً 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 إلى قيمة عالية بالإضافة إلى رسم تابع خطأ التدريب (loss) وتابع التأكد من الخطأ (val) ونلاحظ بعد 100 طور تدريب أن قيمة الخطأ قد انخفضت بشكل كبير.

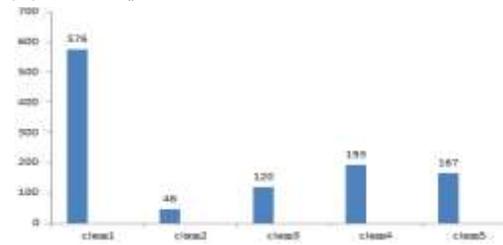
وصلت الدقة خلال مرحلة التدريب إلى 98.9% والتحقق إلى 96.8%.



الشكل (8) (A) تغير توابع الدقة والتأكد من الدقة (B) تغير توابع الخسارة والتحقق من الخسارة خلال 100 طور تدريب

تم اختبار النموذج المقترح على مجموعة اختبار. وبعدها قمنا برسم مصفوفة الارتباك (confusion matrix). أو كما تدعى أيضاً بمصفوفة المطابقة (الشكل (9)).

تم فصل الصور إلى مجموعتين؛ حيث تم وضع 66% كمجموعة تدريب و33% 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 وتكرارين لمجموعة الاختبار. فيكون شعاع الدخل X هو مجموعة التدريب والصور موزعة على الصفوف كما في الشكل (6)

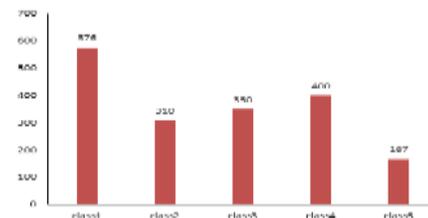


الشكل (6) توزيع الصور في مجموعة التدريب

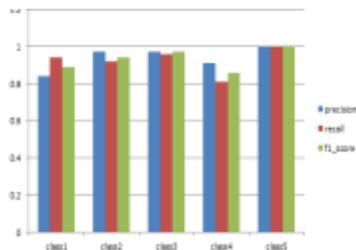
نلاحظ وجود عدم توازن بين الصفوف في بيانات التدريب حيث أن عدد الصور في الصنف الأول يفوق عدد الصور في باقي الصفوف مجتمعة. بالتالي قمنا بالعمل على حل هذه المشكلة وذلك من خلال تقنية توسيع البيانات حيث تم توليد صور جديدة من أجل تعزيز مجموعة البيانات.

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 إزاحة ترتيب الحساسات بمقدار حساس أو اثنين على الأكثر.

وكان توزيع الصور بعد عملية الزيادة كما في الشكل (7)

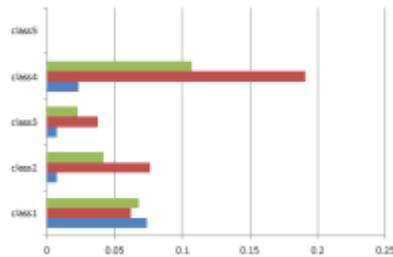


الشكل (7) توزيع الصور في الصفوف بعد زيادة البيانات



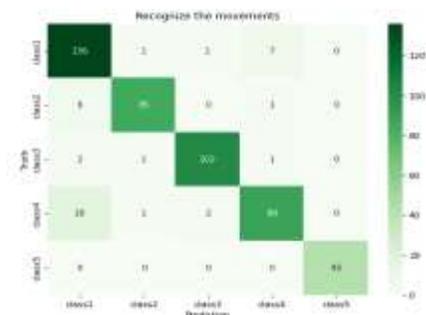
الشكل (10) قيم ال precision و ال recall وال f1-score لكل صف

معدل انذار الخطأ FAR أحد المقاييس المهمة التي تركز على النسب المصنفة بشكل خاطئ ويساوي المتوسط الحسابي لكل من قيمتي FPR, FNR حيث أن FNR تعبر عن نسبة الصور التي صنفتها النموذج على أنها ليست من صنف معين وهي بالفعل منه الى جميع الصور التي من هذا الصنف ، أما بالنسبة الى FPR فهي تعبر عن نسبة الصور التي صنفتها النموذج بشكل خاطئ على انها من صنف معين الى الصور التي ليست من هذا الصنف، ويفضل أن تكون قيمته أقل ما يمكن.



الشكل (11) قيم FAR, FNR, FPR لكل من الصفوف الخمسة

ونلاحظ في الشكل (11) 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. قمنا باستخدام شبكات التعلم المسبق ResNet من أجل مقارنة أداءها مع أداء الشبكة الخاصة بنا، وهي عبارة عن شبكات عصبية كلاسيكية تستخدم كأساس للعديد من مهام الرؤية الحاسوبية، وتعتبر أول شبكة عصبونية عميقة جداً ذات تغذية أمامية بمئات الطبقات، تستخدم وصلات التخطي أو الاختصارات للقفز فوق بعض الطبقات. يوجد العديد من الاصدارات لهذه الشبكات وهي: ResNet, ResNet101, ResNet50, 152ResNet، 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



الشكل (9) 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 الصنفين 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.

تساعدنا مصفوفة الارتباك في حساب البارامترات الأخرى المهمة في قياس مدى كفاءة النموذج كقيم precision و recall و F1-score حيث تعبر قيمة precision عن نسبة عدد الصور التي توقع النموذج أنها من صنف معين بشكل صحيح الى عدد الصور التي توقع النموذج أنها من هذا الصنف، وقيمة ال precision من أهم المعايير التي نحتاج 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 النموذج أنها من صنف معين بشكل صحيح الى عدد الصور الفعلية 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 الشكل (10) أن قيم ال precision وال recall عالية لجميع الصفوف وهذا مؤشر على جودة النموذج المقترح.

5. الخاتمة:

تقدم هذه الدراسة طريقة جديدة للتحكم بكف بديل باستخدام الاشارات العضلية EMG بالاعتماد على خوارزميات التعلم العميق والحساسات العضلية. تم الاعتماد في هذه الدراسة على قاعدة البيانات NINA PRO DB5 ومن ثم وضع آلية لتمثيل القياسات ضمن صورة بتدرج رمادي تعبر عن تأزر العضلات لتوليد عملية التقاط لتكون دخلاً لشبكة عصبونية عميقة حيث استخدمنا شبكة CNN. اخترنا تصنيف حركات الالتقاط ضمن خمس مجموعات بالاعتماد على إمكانات الكفوف الصناعية المتاحة تجارياً. حققت الخوارزمية المقترحة نتائج واعدة مقارنة مع باقي الأبحاث السابقة حيث حصلنا على دقة 95.89% بالإضافة الى اختبار نموذجنا باستخدام العديد من مقاييس أداء نماذج التعلم الآلي والتي بينت فعالية النموذج المقترح.

البيانات imagenet ونستخدم على خرجها طبقة dense ب1024 وحدة وطبقة dropout بمعدل 0.25 بالإضافة إلى طبقة الخرج softmax .

تم تدريب شبكة CNN الخاصة بنا بالإضافة الى شبكتي ResNet50, ResNet101 باستخدام قاعدتي البيانات المتوازنة بعد زيادة البيانات وغير المتوازنة وقد تفوقت شبكة CNN التي تم العمل عليها وأعطت دقة تصنيف أعلى من شبكتي التعلم المسبق وكانت النتائج كما هو مبين في الجدول (4) مما يدل على كفاءة النموذج الذي قمنا باقتراحه.

الجدول (4) مقارنة بين النموذج المقترح ونماذج ال ResNet

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

References

1. Dario Farina, Mauro Fosci “**Motor unit recruitment strategies investigated**” Appl Physiol ,92: 235–247, 2002
2. Angkoon Phinyomark, Chusak Limsakul “**Evaluation of EMG Feature Extraction for Hand Movement Recognition Based on Euclidean Distance and Standard Deviation**” IEEE Xplore, 2010
3. Jingwei Too, Abdul Rahim Abdullah, Norhashimah Mohd Saad “**Classification of Hand Movements based on Discrete Wavelet Transform and Enhanced Feature Extraction**” (IJACSA) International Journal of Advanced Computer Science and Applications Vol. 10, No. 6, 2019
4. Yuheng Wu, Bin Zheng, Yongting Zhao “**Dynamic Gesture Recognition Based on LSTM-CNN**” 978-1-7281-1312-8/18/\$31.00 ©2018 IEEE
5. Yusuke Yamanoi, Ryu Kato “**Control Method for Myoelectric Hand using Convolutional Neural Network to Simplify Learning of EMG Signals**” 978-1-5386-3194-2/17/\$31.00 © 2017 IEEE
6. Xiaolong Zhai, Beth Jelfs , Rosa H. M. Chan and Chung Tin “**Self-Recalibrating Surface EMG Pattern Recognition for Neuroprosthesis Control Based on Convolutional Neural Network**”, doi: 10.3389/fnins.2017.00379, 2017
7. Yuanfang Wan, Zishan Han, Jun Zhong and Guohua Chen “**Pattern recognition and bionic manipulator driving by surface electromyography signals using convolutional neural network**” doi:10.1177/1729881418802138, 2018
8. Ulyse C`ot`e-Allard, Cheikh Latyr Fall, Alexandre Drouin, Alexandre Campeau-Lecours, Cl`ement Gosselin, Kyrre Glette, and Benoit Gosselin “**Deep Learning for Electromyographic Hand Gesture Signal Classification Using Transfer Learning**”, 2019
9. Lin Chen, Jianting Fu , Yuheng Wu , Haochen Li and Bin Zheng “**Hand Gesture Recognition Using Compact CNN Via Surface Electromyography Signals**”, Sensors 2020, 20, 672; doi:10.3390/s20030672
10. Jorge Arturo Sandoval-Espino, Alvaro Zamudio-Lara , José Antonio Marbán-Salgado , J. Jesús Escobedo-Alatorre and J. Guadalupe Velásquez-Aguila “**Selection of the Best Set of Features for sEMG-Based Hand Gesture Recognition Applying a CNN Architecture**”, Sensors 2022, 22, 4972. <https://doi.org/10.3390/s22134972>

11. Manfredo Atzori, Arjan Gijsberts, Claudio Castellini, Barbara Caputo, Anne-Gabrielle Mittaz Hager, Simone Elsig, Giorgio Giatsidis, Franco Bassetto & Henning Mülle “**Electromyography data for non-invasive naturally-controlled robotic hand prostheses**” Scientific Data, DOI: [10.1038/sdata.2014.53](https://doi.org/10.1038/sdata.2014.53), 2014
12. Stefano Pizzolato, Luca Tagliapietra, Matteo Cognolato, Monica Reggiani, Henning Muller, Manfredo Atzori “**Comparison of six electromyography acquisition setups on hand movement classification tasks**” .<https://doi.org/10.1371/journal.pone.0186132>, 2017
13. Redlarski, J. Szkopek and G. “**Artificial-Hand Technology—Current State of Knowledge in Designing and Forecasting Changes**”, Applied Sciences, doi:10.3390/app9194090, 2019
14. “**I-Limb Ultra Revolution Brochure**”, Bionics, Touch, 2013
15. “**Fascinated with Michelangelo**”, Otto bock Healthcare GmbH, 2017
16. “**BeBionic: the Worlds Most Lifelike Bionic Hand**”, GmbH, Ottobock Healthcare, 2017
17. “**Hero Arm User Manual**”, Bionics, Open, 2019
18. O'Dell, S. Mayer and G. “**A smart prosthetic Device for transradial amputees**”, 2017
19. “**Luke Arm System Datasheet**” Mobius Bionics