

الكشف عن الأنماط الحركية في الكف الصناعي باستخدام الشبكات العصبونية الالتفافية

د. محمد أيهم درويش*

د. سحر عبد الكريم العلي**

أوس محمد محمد***

(تاريخ الإيداع ٢٠٢٥/٤/٢٢ . قُبل للنشر في ٢٠٢٥/٧/٣١)

□ ملخص □

تم في هذا البحث تطوير نموذج ذكاء اصطناعي يعتمد على الشبكات العصبونية الالتفافية Convolutional Neural Networks (CNN) لتصنيف الإشارات العضلية الكهربائية (EMG) المرتبطة بحركات مثل الإغلاق (Closing)، والمقص (Scissor)، والفتح (Opening)، والإشارة "OK". يُعد تحليل إشارات EMG مجالاً حيوياً في التطبيقات الطبية والهندسية، حيث يُستخدم في تطوير الأطراف الصناعية الذكية، وأجهزة إعادة التأهيل، وأنظمة التحكم بالإيماءات.

تم الحصول على قاعدة البيانات من موقع Kaggle، حيث استخدمت حساس Myoelectric (MYO) Sensor، لجمع بيانات الإشارات العضلية الكهربائية ومن ثم خضعت لمعالجة شملت التقييس البيانات لضمان دقة النموذج. ومن ثم تم تصميم شبكة عصبية التلافافية متعددة الطبقات، حيث تُستخرج الأنماط المميزة من الإشارات عبر طبقات الالتفاف، بينما تتولى الطبقات الكثيفة (Dense Layers) تحليل الميزات المُستخرجة لاتخاذ قرارات تصنيف دقيقة.

تم تدريب النموذج المصمم مع تطبيق تقنيات تحسين الأداء مثل Dropout للحد من فرط التعلّم. أظهرت النتائج تحقيق النموذج لدقة تصنيف بلغت ٩٧٪ على بيانات الاختبار، مما يعكس كفاءته في التعرف على أنماط الإشارات العضلية. كما أظهرت منحنيات الأداء استقراراً أثناء التدريب، مما يدل على قدرة النموذج على التعميم دون التعرض لمشكلة فرط التكيف.

الكلمات المفتاحية: الشبكات العصبونية الالتفافية - الإشارات العضلية الكهربائية - الأطراف الصناعية الذكية - حساس MYO - الطبقات الكثيفة.

*أستاذ - قسم هندسة الأتمتة الصناعية - كلية الهندسة التقنية - جامعة طرطوس - طرطوس - سورية.

**أستاذ مساعد - قسم هندسة الأتمتة الصناعية - كلية الهندسة التقنية - جامعة طرطوس - طرطوس - سورية.

***طالب دكتوراه - قسم هندسة الأتمتة الصناعية - كلية الهندسة التقنية - جامعة طرطوس - طرطوس - سورية.

Movement Patterns Detection in the Prosthetic Hand Using Convolutional Neural Networks

Dr. Mohammad Ayham Darwish*

Dr. Sahar Abdulkarim Al Ali**

Aous Mohammad Mohammad***

(Received 22/4/2025 . Accepted 31/7/2025)

□ ABSTRACT □

In this research we introduce an artificial intelligence (AI) model based on Convolutional Neural Networks (CNNs) to classify electromyographic (EMG) signals associated with hand movements such as Closing, Scissor, Opening, and the "OK" sign. EMG signal analysis is a vital field in medical and engineering applications, where it is used in the development of smart prosthetics, rehabilitation devices, and gesture control systems.

The database is obtained from the Kaggle website. A MYO Myoelectric Sensor collects the electromyographic signal data, which then undergoes processing that includes data standardization to ensure model accuracy. Subsequently, a multi-layer Convolutional Neural Network is designed, where convolutional layers extract distinctive patterns from the signals, while dense layers analyze the extracted features to make accurate classification decisions.

The designed model is trained using performance optimization techniques such as Dropout to reduce overfitting. The results show that the model achieves a classification accuracy of 97% on the test data, which reflects its efficiency in recognizing EMG signal patterns. Furthermore, the performance curves demonstrate stability during training, indicating the model's ability to generalize without experiencing overfitting.

Keywords: Convolutional Neural Networks – Electromyographic Signals – Smart Prosthetic Limbs – MYO Sensor – Dense Layers.

*Professor – Industrial Automation Engineering – Faculty of Technical Engineering – Tartus University – Tartus – Syria.

**Assistant Professor – Industrial Automation Engineering – Faculty of Technical Engineering – Tartus University – Tartus – Syria.

***PHD Student – Industrial Automation Engineering – Faculty of Technical Engineering – Tartus University – Tartus – Syria.

١. المقدمة:

يعد فقدان الأطراف من العوامل التي تؤثر بشكل كبير على حياة الأفراد، حيث يحدّ من قدرتهم على أداء الأنشطة اليومية ويقلل من كفاءتهم في التفاعل مع بيئتهم المحيطة [1]. في هذا السياق، تلعب الأطراف الصناعية دوراً محورياً في تعويض الوظائف الحركية المفقودة، مما يمكّن الأفراد من استعادة قدراتهم على تنفيذ المهام بشكل أكثر كفاءة [2].

في السنوات الماضية كانت الأطراف الصناعية التقليدية تعتمد في عملها على تقنيات ميكانيكية بسيطة أو على أنظمة استجابة محدودة تستند إلى تحليل الإشارات العضلية المباشرة [3]. هذه الإشارات هي إشارات كهربائية تنشأ نتيجة النشاط العضلي عند قيام الشخص بحركة معينة، ويتم التقاطها بواسطة أجهزة استشعار موضوعة على سطح الجلد فوق العضلات [4]، تقوم هذه الأجهزة بتحويل الإشارات الكهربائية الصادرة عن العضلات إلى مدخلات تُستخدم لتحفيز الحركات في الأطراف الصناعية، ولكن هذه الأنظمة تواجه قيوداً كبيرة في قدرتها على التفاعل مع الحركات المعقدة أو المتعددة [5]. حيث كانت تقتصر القدرة على تحليل الإشارات العضلية على مستويات محدودة، مما يصعب عليها التمييز بين الحركات الدقيقة أو التنسيق بين حركات متعددة [6]، إضافةً إلى ذلك كانت الاستجابة في كثير من الأحيان تقتصر على حركات محددة مسبقاً، مما يؤدي إلى محدودية الاستخدام ويزيد من الحاجة إلى تدريب طويل وشاق لتحقيق التحكم الفعّال في الأطراف الصناعية [7].

قام الباحثون Mohapatra وزملاؤه في عام ٢٠٢٤ [8] بتحسين دقة تصنيف الإيماءات اليدوية باستخدام إشارات sEMG، باستخدام قاعدة بيانات NinaPro DB5 القياسية التي تم جمعها من ٢٧ مشاركاً شملت مجموعة متنوعة من الحركات اليدوية مثل OK, Opening, Scissor, Closing، اعتمدت الدراسة على مجموعة من الميزات المشتقة يدوياً من إشارات sEMG مثل طول الموجة، متوسط القيمة المطلقة، الانحراف المعياري والجذر التربيعي لمتوسط الإشارة، ومن ثم تم تدريب نموذج تعلم الآلة (SVM (Super vector machine)، وأظهرت نتائج الاختبار دقة ٨٤٪، بالرغم من الأداء الجيد إلا أنها استخدمت عدد قليل من الميزات مما يؤدي إلى تدهور الأداء مع زيادة عدد الإيماءات، بالإضافة إلى ذلك لم تتضمن الدراسة الأشخاص ذوي الإعاقات الحركية، مما قد يحد أيضاً من تعميم النتائج، كما أجرى الباحثون Swati Shilaskar وزملائها في عام ٢٠٢٤ [9]، دراسة حول تصنيف الإيماءات اليدوية باستخدام إشارات التخطيط الكهربائي للعضلات (EMG)، مستفيدين من ميزات المجال الترددي والتحويل المويجي بهدف تحسين دقة التصنيف. اعتمدت الدراسة على قاعدة بيانات جامعة كاليفورنيا (UCI) للتعلم الآلي، التي تضم ١٥٠٠٠ عينة تشمل أوضاع اليد في حالة الراحة، ثني المعصم، وتمديد المعصم، ولتحسين جودة الإشارات، تم تطبيق مرشحي Notch و Butterworth لتقليل الضجيج، ثم استخدمت تقنيات المجال الترددي (FD) لتحليل ترددات الإشارة، بالإضافة إلى التحويل المويجي المتقطع (DWT) لاستخراج الميزات الهامة ودراسة التغيرات الزمنية والترددية، تم تدريب نموذج الغابات العشوائية (Random Forest)، حيث حققت الدراسة دقة تصنيف بلغت ٨١.٦٩٪، ورغم أن هذه النتيجة جيدة، إلا أن الدراسة اقتصرت على ثلاث إيماءات فقط، مما يحد من إمكانية تطبيقها في تصنيف عدد أكبر من الإيماءات في البيئات العملية. في دراسة أجراها Kyung Hyun Lee وزملاؤه عام ٢٠٢٢ [10]، تم استخدام الشبكات العصبونية الاصطناعية (ANN) لتصنيف حركات اليد بالاعتماد على إشارات التخطيط الكهربائي للعضلات (EMG) شملت الدراسة عشرة مشاركين نصفهم من الإناث، حيث أدوا حركات مختلفة مثل Closing, Opening, Scissor، وإشارة OK وخضعت الإشارات لعملية معالجة مسبقة لإزالة الضجيج وتحسين جودتها، ثم

قُسمت البيانات بنسبة ٩٠٪ للتدريب و ١٠٪ للاختبار. حقق النموذج دقة تصنيف بلغت ٩٤٪، وبالرغم الدقة العالية للنموذج، توجد بعض القيود في الدراسة باستخدام عينة صغيرة قد لا تكون كافية لتعميم النتائج على نطاق أوسع.

٢. مشكلة البحث:

الأطراف الصناعية التي تعتمد على الإشارات العضلية الكهربية (EMG)، تعاني النماذج التقليدية للتصنيف من صعوبة في تحقيق استجابة دقيقة وفعالة. من أبرز التحديات التي تواجهها هذه النماذج عدم الدقة في التعرف على الحركات الدقيقة، حيث يؤدي تداخل الإشارات العصبية مع الضجيج إلى انخفاض دقة التصنيف. بالإضافة إلى ذلك، يختلف نمط الإشارات العضلية بين الأفراد، مما يحد من قدرة النماذج التقليدية على التعميم والتكيف مع المستخدمين المختلفين.

٣. أهمية وأهداف البحث:

تكمن أهمية هذا البحث في تطوير نظم التحكم التي تعتمد على الذكاء الاصطناعي لتحليل البيانات الحركية متعددة الأبعاد، مما يتيح تصميم كفوف صناعية أكثر ذكاءً ومرونة وقدرة على التكيف مع الحركات الطبيعية.

يهدف البحث إلى بناء نموذج ذكاء اصطناعي قادر على تحليل البيانات الحركية واستخلاص الأنماط الحركية لتحسين أداء نظم التحكم في الكف الصناعي لتكون أكثر دقة وفعالية.

٤. طرائق البحث وموارده:

تم تنفيذ هذا البحث باستخدام لغة البرمجة python ضمن بيئة العمل Visual Studio Code على جهاز حاسوب شخصي يمتلك المواصفات وحدة معالجة مركزية intel Core i5-8250u بسرعة 1.80 GHz وذاكرة نظام 8GB.

يتضمن البحث عدة مراحل بدءاً من الحصول على قاعدة البيانات وصولاً إلى مرحلة التعرف على الحركة من خلال بناء شبكة عصبونية التلافيفية CNN. ويبين الشكل (1) المخطط الصندوقي لأهم مراحل العمل خلال هذا البحث.



الشكل (1): المخطط الصندوقي لمراحل العمل.

٥. قاعدة البيانات المستخدمة:

تم الحصول على قاعدة بيانات خارجية محملة من موقع Kaggle تحتوي على 11678 عينة مقسمة إلى أربعة حركات:

- ✓ الأولى 2943 عينة لحركة Opening
- ✓ الثانية 2922 عينة لحركة OK
- ✓ الثالثة 2910 عينة لحركة Closing

✓ الرابعة 2903 عينة لحركة Scissor

تم تسجيل هذه الحركات من مجموعة أشخاص مبتوري الساعد بواسطة الحساس MYO والذي يحتوي على 8 أقطاب مثبتة على سطح الجلد، حيث تقيس النشاط الكهربائي الناتج عن العضلات الموجودة تحنها. يقوم كل شخص بتنفيذ كل حركة 6 مرات لمدة 20 ثانية في كل مرة، حيث أن جميع التسجيلات تمت باستخدام نفس الساعد الأيمن وفي فترة زمنية قصيرة وتم تجميع كل التسجيلات في ملف CSV. يتضمن كل صف في مجموعة البيانات 8 قراءات متتالية لكل المستشعرات الثمانية (64 قراءة) والعمود الأخير يشير إلى الحركة الناتجة التي تم تنفيذها أثناء تسجيل البيانات حيث تم ترميز (0 Closing, 1 Scissor, 2 Opening,) (3 OK) ويوضح الجدول (١) عينة من قاعدة البيانات المستخدمة، كما يوضح الشكل (٢) الأنماط الحركية المسجلة في قاعدة البيانات.

الجدول (١): عينة من قاعدة البيانات المستخدمة

	0	1	2	3	4	5	6	7	8	9	...	55	56	57	58	59	60	61	62	63	64
0	26.0	4.0	5.0	8.0	-1.0	-13.0	-109.0	-66.0	-9.0	2.0	...	-28.0	61.0	4.0	8.0	5.0	4.0	-7.0	-59.0	16.0	0
1	-47.0	-6.0	-5.0	-7.0	13.0	-1.0	35.0	-10.0	10.0	-4.0	...	-25.0	47.0	6.0	6.0	5.0	13.0	21.0	111.0	15.0	0
2	-19.0	-8.0	-8.0	-8.0	-21.0	-6.0	-79.0	12.0	0.0	5.0	...	-83.0	7.0	7.0	1.0	-8.0	7.0	21.0	114.0	48.0	0
3	2.0	3.0	0.0	2.0	0.0	22.0	106.0	-14.0	-16.0	-2.0	...	-38.0	-11.0	4.0	7.0	11.0	33.0	39.0	119.0	43.0	0
4	6.0	0.0	0.0	-2.0	-14.0	10.0	-51.0	5.0	7.0	0.0	...	38.0	-35.0	-8.0	2.0	6.0	-13.0	-24.0	-112.0	-69.0	0


5 rows × 65 columns



الشكل (٢): الأنماط الحركية المسجلة في قاعدة البيانات.

٦. المعالجة الأولية للبيانات:

تعد المعالجة الأولية للبيانات خطوة أساسية في تحليل البيانات، حيث تتضمن سلسلة من العمليات التي تهدف إلى تنظيف وتحويل البيانات الخام إلى صيغة قابلة للاستخدام في النماذج التحليلية، ويبين الشكل (٣) المخطط الصندوقي لأهم مراحل المعالجة الأولية للبيانات.



الشكل (٣): المخطط الصندوقي لأهم مراحل المعالجة الأولية للبيانات.

١.٦ التعامل مع القيم المفقودة:

القيم المفقودة تحدث عندما لا تحتوي الخلايا في البيانات على معلومات، وقد تؤثر بشكل كبير على دقة التحليل لذلك يجب إزالة الصف أو العمود الذي يحتوي على قيم مفقودة، لذلك قمنا بعملية فحص لجميع البيانات الموجودة ضمن قاعدة البيانات وتأكدنا من عدم وجود عينة فارغة، حيث كان لجميع الأعمدة عدد العينات نفسه ويبين الشكل (٤) عدد العينات الموجودة في كل عمود.


Column	Non-Null Count	Dtype
0	11678 non-null	float64
1	11678 non-null	float64
2	11678 non-null	float64
3	11678 non-null	float64
4	11678 non-null	float64
5	11678 non-null	float64
6	11678 non-null	float64
7	11678 non-null	float64
8	11678 non-null	float64
9	11678 non-null	float64
10	11678 non-null	float64
11	11678 non-null	float64
12	11678 non-null	float64
13	11678 non-null	float64
14	11678 non-null	float64
15	11678 non-null	float64
16	11678 non-null	float64
17	11678 non-null	float64
18	11678 non-null	float64
19	11678 non-null	float64
63	11678 non-null	float64
64	11678 non-null	int64

الشكل (٤): عدد العينات في كل عمود.

٢.٦ تنسيق القيم:

تم التأكد من أن البيانات في كل عمود تكون بالتنسيق نفسه، على سبيل المثال، إن جميع الأرقام تحتوي على الفواصل العشرية نفسها، ويوضح الشكل (٥) ناتج عملية التحقق.

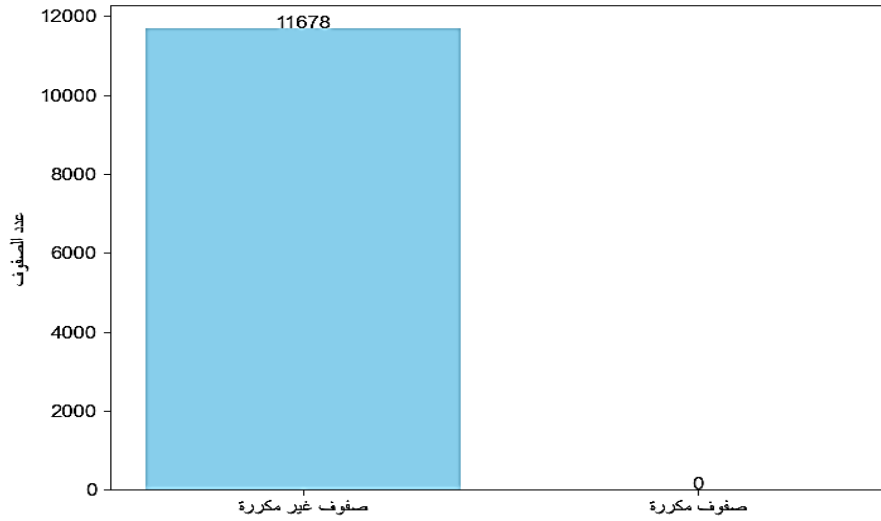
تحقق من الفواصل العشرية في الأعمدة



الشكل (5): ناتج عملية التحقق من الأرقام.

٣.٦ التعامل مع البيانات المكررة:

قد تؤدي البيانات المكررة إلى نتائج غير دقيقة في التحليل، لذلك إذا كانت هناك صفوف مكررة في البيانات (أي نفس القيم في جميع الأعمدة)، فيجب إزالتها لضمان أن التحليل يعتمد على بيانات فريدة، وفي قاعدة البيانات التي نعمل عليها تم التحقق من عدم وجود بيانات مكررة ويبين الشكل (٦) ناتج عملية التحقق من البيانات المكررة.



الشكل (6): ناتج عملية التحقق من البيانات المكررة.

٤.٦ التقييس:

هو عملية تحويل القيم العددية في مجموعة البيانات إلى نطاق محدد بين [0-1]، بهدف تحقيق توازن بين جميع المتغيرات

وتقليل تأثير القيم الكبيرة أو الصغيرة جداً وخاصةً عند التعامل مع البيانات التي تحتوي على نطاقات قيم مختلفة ويعطى التقييس بالعلاقة (١) [11]، كما يوضح الجدول (٢) عينة من قاعدة البيانات بعد تطبيق عملية التقييس:

$$data(new) = \frac{data - data_{min}}{data_{max} - data_{min}} \quad (1)$$

حيث: $data$ القيمة الأصلية قبل عملية التقييس.

$data_{min}$ أصغر قيمة في البيانات.

$data_{max}$ أكبر قيمة في البيانات.

الجدول (٢): عينة من قاعدة البيانات بعد تطبيق عملية التطبيع

	0	1	2	3	4	5	6	7	8	9	...	54	55	56
0	0.603922	0.517647	0.521569	0.533333	0.498039	0.450980	0.074510	0.243137	0.466667	0.509804	...	0.584314	0.392157	0.741176
1	0.317647	0.478431	0.482353	0.474510	0.552941	0.498039	0.639216	0.462745	0.541176	0.486275	...	0.090196	0.403922	0.686275
2	0.427451	0.470588	0.470588	0.470588	0.419608	0.478431	0.192157	0.549020	0.501961	0.521569	...	0.000000	0.176471	0.529412
3	0.509804	0.513725	0.501961	0.509804	0.501961	0.588235	0.917647	0.447059	0.439216	0.494118	...	0.290196	0.352941	0.458824
4	0.525490	0.501961	0.501961	0.494118	0.447059	0.541176	0.301961	0.521569	0.529412	0.501961	...	0.737255	0.650980	0.364706

5 rows × 64 columns

٧. تقسيم البيانات:

تم تقسيم البيانات إلى مجموعتين (70% تدريب - 30% اختبار)، كما هو موضح بالشكل (٧) وهي:

١. مجموعة التدريب (training set): هي المجموعة التي تم تدريب النموذج عليها.
 ٢. مجموعة الاختبار (test set): تستخدم فقط لتقييم أداء النموذج النهائي.
- هذا التقسيم يوفر للنموذج حيزاً تعليمياً كافياً للتعلم من البيانات، وفي نفس الوقت يضمن وجود بيانات جديدة يمكن استخدامها لتقييم الأداء بدقة وموضوعية، مما يُعطي مؤشرات حقيقية عن مدى فعالية النموذج عند تطبيقه في الواقع.



الشكل (٧): تقسيم البيانات إلى مجموعتين.

٨. الشبكات العصبونية الالتفافية:

تتكون الشبكة العصبونية الالتفافية من ٤ طبقات أساسية [12]:
 الطبقة الالتفافية Convolutional layer يُطبق في طبقة التلافيف مُرشح Filter ويُعرف أيضاً بـ kernal من شأنه تحديد وجود سمات أو أنماط معينة في الصورة الأصلية (الدخل)، كما يمكن استخدام عدة مرشحات في الطبقة الواحدة بغية استخراج سمات مختلفة ومن بين هذه المرشحات:
 • مرشحات الكشف عن الحواف وتُستخدم لاكتشاف البدايات والنهايات السريعة لنشاط عضلي.

- مرشحات التنعيم للتقليل من الضجيج العالي أو التموجات السريعة غير المهمة.
- مرشحات التردد تفصل ترددات EMG المفيدة (مثل ٢٠-٤٥٠ Hz) عن الضجيج (مثل 50Hz من الكهرباء).

• مرشحات لالتقاط الأنماط العصبونية العضلية التي تظهر عندما تنشط مجموعة عضلية بشكل معين.

يكون المُرشح ذو حجم صغير ليمسح الصورة كاملةً ويطبق العمليات الحسابية المناسبة بين قيم المُرشح والنقاط اللونية (Pixels) بغية استخراج السمات Features، وعادةً ما تكون الجداء الداخلي فيما بينها، وتعطى بالعلاقة (٢) [12]:

$$Z_{i,j} = \sum_{u=0}^{f_h-1} \sum_{v=0}^{f_w-1} x_{i,j} \cdot w_{u,v} , \text{ with } \begin{cases} i = u + i * s_h \\ j = v + j * s_w \end{cases} \quad (2)$$

حيث: $Z_{i,j}$ خرج عملية الالتفاف الموجود في السطر (i)، العمود (j) في خريطة السمات الناتجة.

$x_{i,j}$ هو قيمة البكسل في الدخال في الموقع i, j

$w_{u,v}$ هو وزن المرشح عند الموقع u, v

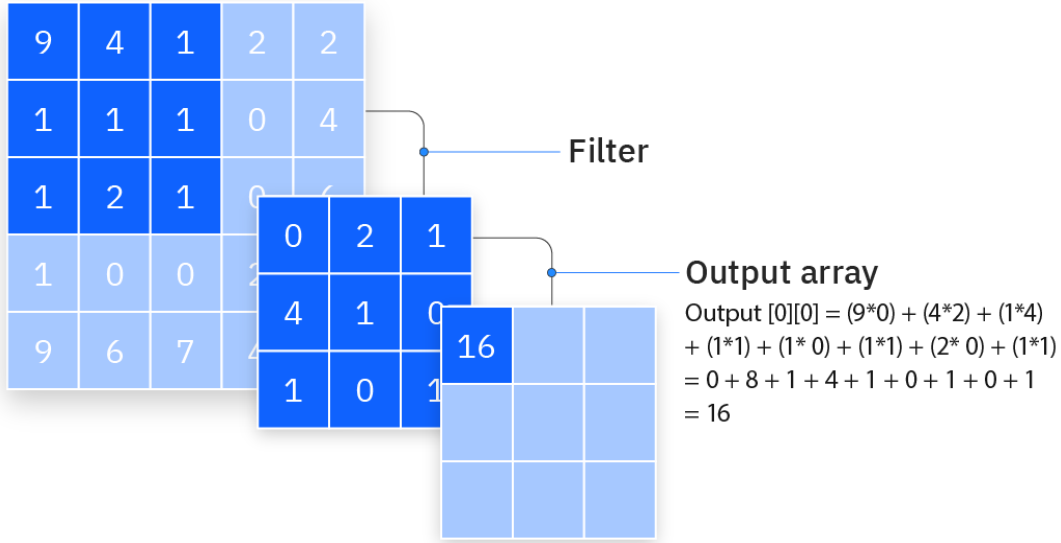
s_h, s_w مقدار الخطوة (strides) في الاتجاه العمودي (الأسطر) والأفقي (الأعمدة)

f_h, f_w أبعاد المرشح

يُعاد ضبط قيم المرشح خلال عملية التدريب الدورية وعند تدريب الشبكة لعدد مُعيّن من التكرارات (epochs)، وكل تدريب يعني إدخال كل أمثلة التدريب مرة واحدة، تسرع هذه المرشحات البحث عن سمات مُتميزة في الصورة.

يتم توظيف الطبقات المخفية الأولى في استخراج السمات البسيطة والواضحة، مثل الحواف في الاتجاهات المُختلفة وما إلى ذلك، ومع التعمق أكثر في الطبقات المخفية في الشبكة، تزداد درجة تعقيد السمات التي يجب تحديدها واستخراجها، والشكل (٨) يعبر عن الطبقة الالتفافية [12].

Input

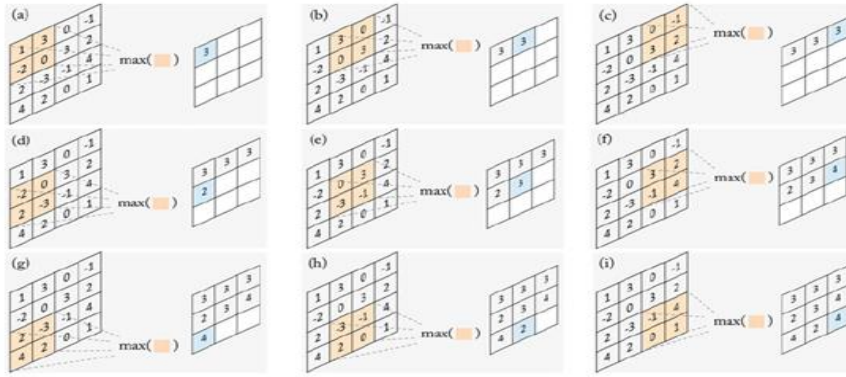


الشكل (٨): الطبقة الالتفافية

١- طبقة التجميع Pooling Layer

في هذه الطبقة، ننقل إلى خريطة المعالم لاكتشاف السمات الأكثر دقة. هناك نوعان من التجميع: الحد الأقصى والمتوسط.

يعني Max pooling أننا نختار أكبر قيمة من الخريطة المميزة في كل خطوة، بينما يعني متوسط التجميع average pooling أننا نضيف القيم التي نكتشفها من الخريطة ونقسمها على عددها [12].



الشكل (٩) max pooling layer

٢- طبقة تسطيح المدخلات **flatten layer** تقوم هذه الطبقة بتحويل المصفوفة إلى شعاع لأن دخل الطبقة المتصلة بالكامل FC يجب أن يكون شعاع.

٣- الطبقة كاملة الاتصال **Fully connected layer** إنها الطبقة الأخيرة في نموذج CNN، فهي تصنف المدخلات في إحدى التسميات المكتشفة.

٩. بناء الشبكة الالتفافية:

يُعد تحديد عدد طبقات الالتفاف في بناء الشبكات العصبونية الالتفافية (CNN) عاملاً يؤثر بشكل كبير على أداء النموذج، ولتحديد العدد الأمثل لهذه الطبقات، تم الاعتماد على نهج التجربة والتحليل، تم إنشاء نموذج أولي بسيط عبارة عن طبقة التفاف واحدة وتم تقييم أدائه باستخدام مجموعة من مؤشرات الأداء (الدقة - الخسارة)، وبناءً على النتائج الأولية، تم تحسين النموذج تدريجياً من خلال إضافة طبقات التفاف إضافية لزيادة عمق الشبكة.

تم تنفيذ هذا النهج بشكل منظم، حيث أُضيفت طبقة واحدة أو اثنتان في كل مرحلة، مما أتاح دراسة تأثير هذه التعديلات على الأداء العام للنموذج. أظهرت هذه الخطوة أهمية العمق في تعزيز قدرة الشبكة على استخراج ميزات أكثر تعقيداً وذات مستوى أعلى، مثل الأنماط التركيبية والعلاقات غير المباشرة داخل البيانات، ويوضح الجدول

(4) البنية النهائية للشبكة العصبونية الالتفافية التي تم التوصل إليها.
الجدول (٤): البنية النهائية للشبكة العصبونية الالتفافية المستخدمة

نوع الطبقة	تابع التنغيع	الخطوة	حجم المرشح
Conv1	ReLU	١	٣
Conv2	ReLU	١	٣
Conv3	ReLU	٢	٥
Dropout (0.4)			
Conv4	ReLU	١	٣
Conv5	ReLU	١	٣
Conv6	ReLU	٢	٥
Dropout (0.4)			
طبقة الـ Flatten			
طبقة الدخل للشبكة العصبونية كاملة الاتصال	ReLU		عصبونات بطول طبقة الـ Flatten

١٢٨ عصبون			ReLU	طبقة مخفية للشبكة العصبونية كاملة الاتصال
٤ عصبونات			Softmax	طبقة الخرج للشبكة العصبونية كاملة الاتصال

١. الطبقة الأولى تمثل هذه الطبقة أول طبقة التفاف في الشبكة تُطبق مرشحات عددها ٣٢ بحجم 3×3 على بيانات الدخل وتستخدم تابع التفعيل ReLU لإزالة القيم السالبة مما يساهم في تحسين عملية التعلم، ويُعطى تابع ReLU بالعلاقة (٣) [12]:

$$f(x) = \max(0, x) \quad (3)$$

٢. الطبقة الثانية إضافة طبقة التفاف ثانية لتحسين استخراج الميزات من البيانات واستمرار استخدام نفس الحجم وعدد المرشحات للتأكيد على تعلم الأنماط المتكررة في البيانات.

٣. الطبقة الثالثة طبقة التفاف ثالثة تستخدم مرشحات بحجم 5×5 لاستيعاب ميزات أكثر شمولاً وذات نطاق أوسع، وخاصية strides=2 تعمل على تقليل أبعاد البيانات المستخرجة بمقدار النصف، مما يقلل التعقيد الحسابي.


٤. الطبقة الرابعة Dropout(0.4) تُستخدم لتقليل احتمالية فرط التعلم (Overfitting) أثناء التدريب، تعمل على تعطيل ٤٠٪ من الوحدات العشوائية في كل خطوة تدريب، مما يجعل النموذج قادراً على تعلم ميزات أكثر تعميماً.

٥. الطبقة الخامسة طبقة التفاف رابعة قمنا فيها بزيادة عدد المرشحات إلى ٦٤، مما يُمكن النموذج من استخراج ميزات أكثر تفصيلاً وذات مستوى أعلى.


٦. الطبقة السادسة طبقة التفاف خامسة تعزيز العمق في تعلم الميزات من خلال طبقة إضافية بنفس الثوابت للطبقة السابقة، مما يساهم في استيعاب أنماط أكثر تعقيداً.

٧. الطبقة السابعة طبقة التفاف سادسة استخدمنا مرشحات بحجم أكبر (5×5) مع تقليل الأبعاد باستخدام strides=2 تساهم هذه الطبقة في تقليل تعقيد البيانات مع الحفاظ على التفاصيل المهمة.

يظهر كل من الشكل (٩) منحنى الدقة لكل من معطيات التدريب والاختبار بينما يظهر الشكل (١٠) منحنى الخسارة لكل من معطيات التدريب والاختبار.



الشكل (٩): منحنى الدقة لكل من معطيات التدريب والاختبار



الشكل (١٠): منحنى الخسارة لكل من معطيات التدريب والاختبار

يعكس الشكلان (٩، ١٠) أداء النموذج أثناء مرحلتي التدريب والاختبار، حيث تتوقف عملية التدريب عند التكرار رقم 12 مع حفظ الأوزان والمعاملات المستنتجة. يظهر تقارب ملحوظ بين منحنىي التدريب والاختبار، مما يشير إلى غياب فرط التعلم (Overfitting) ويؤكد على استقرار عملية التدريب. حقق النموذج دقة 97% لكل من بيانات التدريب والاختبار، مما يدل على قدرته على تصنيف معظم الإشارات في مجموعة البيانات بكفاءة. كما يُظهر منحنى الخسارة انخفاضاً تدريجياً ومستمراً، مما يعكس تحسن أداء النموذج وقدرته على تقليل الخطأ أثناء التدريب، مما يعزز موثوقيته وفعاليته في التعلم.

١٠. تقييم أداء النموذج:

لتحليل أداء النموذج، تم تمثيل مصفوفة الارتباك (confusion matrix) التي تعكس معدلات التنبؤات الصحيحة والخاطئة، مما يوضح قدرة النموذج على تصنيف البيانات بدقة، ومن خلال هذه المصفوفة يمكن تحديد نسبة الحالات التي تم تصنيفها بشكل صحيح مقابل تلك التي لم يتم توقعها بدقة. تم تقييم النموذج باستخدام معايير الأداء الأساسية التي تشمل كل من الدقة (Accuracy)، الخصوصية (Specificity)، الحساسية (Sensitivity)، ومقياس F1-score، مما يتيح تقيماً متكاملاً لجودة التنبؤات، ويوضح الشكل (11) مصفوفة الارتباك، بينما يستعرض الجدول (5) مقاييس الأداء التفصيلية للنموذج التالية: الدقة: هي مقياس لعدد التنبؤات الصحيحة التي قدمها النموذج لمجموعة بيانات الاختبار الكاملة، وهي مقياس أساسي جيد لقياس أداء النموذج، وتُعبّر عن مدى قرب القيمة المقاسة من القيمة الفعلية (الحقيقية)، وتعطى بالعلاقة التالية [13]:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

١. الاستدعاء (الحساسية): عدد الحالات الإيجابية الفعلية التي يتم التنبؤ بها بشكل صحيح باستخدام النموذج، وتعطى بالعلاقة التالية [13]:


$$Recall = \frac{TP}{TP + FN} \quad (3)$$

٢. الخصوصية: عدد العينات الخاطئة التي تم كشفها على العدد الإجمالي للعينات الخاطئة، وتعطى بالعلاقة [14]:

$$SP = \frac{Tn}{Tn + Fp} \quad (4)$$

٣. المقياس (F1-score): ويعبر عن العلاقة التوافقية بين المقياسين (precision) و (recall)، ويعطى بالعلاقة [14]:

$$F1 - score = \frac{2 * Tp}{2 * Tp + Fn + Fp} \quad (5)$$



الشكل (١١): مصفوفة الارتباك

تشير مصفوفة الارتباك إلى أداء النموذج في تصنيف الحركات المختلفة، حيث تظهر دقة عالية في التنبؤ، مع وجود بعض الأخطاء في التصنيف بين الأنماط المختلفة:

- بالنسبة لنمط Closing، من أصل 899 حركة مسجلة، تمكن النموذج من تصنيف 897 حركة بشكل صحيح، بينما أخطأ في تصنيف حالتين فقط، حيث تم تصنيفهما بشكل خاطئ على أنهما من نمط Opening.

- بالنسبة لنمط Scissor، من أصل 883 حركة مسجلة، نجح النموذج في تصنيف 867 حركة بشكل صحيح، في حين أخطأ في 16 حالة، حيث تم تصنيف 12 منها على أنها Closing، و 3 على أنها OK، و 1 على أنها Opening.

- بالنسبة لنمط Opening، من أصل 847 حركة مسجلة، تم تصنيف 809 حركة بدقة، بينما تم تصنيف 38 حركة بشكل خاطئ، منها 8 على أنها Closing، و 5 على أنها Scissor، و 25 على أنها OK.

- بالنسبة لنمط OK، من أصل 875 حركة مسجلة، تمكن النموذج من تصنيف 838 حركة صحيحة، بينما أخطأ في 37 حالة، حيث تم تصنيف 8 منها على أنها Closing، و 15 على أنها Scissor، و 14 على أنها Opening.

الجدول (5): نتائج أداء النموذج

اسم الخوارزمية	Accuracy	Recall	F1 - score
CNN	%٩٧	%٩٧.٥	%٩٧.٢٥

من خلال الجدول (5)، يتضح أن النموذج المستخدم قادر على تصنيف العينات بفعالية، حيث تم حساب المقاييس بناءً على العلاقات (2-3-5). فقد حقق دقة (Accuracy) بلغت 97٪، مما يعني أن النموذج تمكن من تصنيف 97٪ من الحركات بشكل صحيح، مما يعكس كفاءته العالية في التنبؤ بحركات الكف الصناعي. كما أظهر الاستدعاء (Recall) نسبة 97.5٪، ما يدل على قدرة النموذج على اكتشاف 97.5٪ من الحركات الصحيحة مع تقليل الأخطاء السلبية الكاذبة (False Negative) أما المقياس التوافقي (F1-score) فقد بلغ 97.25٪، مما يظهر توازناً جيداً بين الدقة والاستدعاء، مما يعني أن النموذج لا يقتصر على تصنيف الحركات بدقة فقط، بل يحقق أيضاً توازناً بين تقليل الأخطاء الإيجابية الكاذبة والسلبية الكاذبة.

يبين الجدول (6)، مقارنةً بين أداء النموذج المقترح وأداء الدراسات المرجعية:

الجدول (6): نتائج أداء النموذج المقترح وأداء الدراسات المرجعية

رقم الدراسة	اسم الخوارزمية	Accuracy
[8]	SVM	%84
[10]	ANN	%94
الدراسة الحالية	CNN	%97

نلاحظ من الجدول (6) أن النموذج المستخدم أعطى أفضل دقة من النماذج المستخدمة في الدراسات السابقة وذلك لأن الدراسات (8,10) استخدمت عينة صغيرة وهذا لا يعد كافياً، بالإضافة إلى أن الدراسة لم تتضمن الأشخاص ذوي الإعاقات الحركية.

١.١ الاستنتاجات:

1. أظهر النموذج المقترح دقة عالية بلغت 97٪ لكل من بيانات التدريب والاختبار، مما يؤكد كفاءته في تصنيف الإشارات الكهربائية للعضلات.
2. تبين أن استخدام الشبكات العصبونية الالتفافية (CNN) ساهم بشكل فعال في تحسين دقة تصنيف الإيماءات اليدوية.
3. أظهر كل من منحنى الدقة والخسارة استقراراً في عملية التدريب دون وجود مؤشرات على فرط التعلم مع بيانات التدريب .
4. يمكن للنموذج المقترح أن يكون قاعدة لتطوير أنظمة تحكم أكثر تطوراً في الأطراف الصناعية، مما يساهم في تحسين حياة المرضى.

١.٢ التوصيات:

1. توسيع قاعدة البيانات المستخدمة لتشمل مجموعة أوسع من الإيماءات وزيادة عدد المشاركين، لضمان تعميم أفضل للنموذج .
2. تجربة نماذج ذكاء اصطناعي هجينة تجمع بين الشبكات العصبونية الالتفافية وتقنيات أخرى مثل التعلم العميق التكراري (RNN) لتحسين أداء النموذج .
3. اختبار النموذج عملياً على أجهزة الأطراف الصناعية للتحقق من كفاءته في البيئات الحقيقية وتعديل البارامترات وفقاً لاحتياجات المستخدمين.

المراجع

1. Smith, J., Doe, A., & Johnson, M. (2019). Impact of limb loss on daily activities: A comprehensive review. *Journal of Rehabilitation Research*, 45(3), 215-230.
2. Jones, B., & Brown, C. (2020). Advancements in prosthetic limb technology: A systematic review. *Biomedical Engineering Journal*, 12(1), 45-60.
3. Miller, T., et al. (2018). Mechanical prosthetics: Past, present, and future developments. *International Journal of Prosthetics*, 8(2), 112-125.
4. Garcia, L., & Lee, H. (2021). Electromyographic signal acquisition and processing for prosthetic control. *IEEE Transactions on Biomedical Engineering*, 68(4), 755-770.
5. Chen, R., et al. (2022). Limitations of myoelectric prostheses in complex movement recognition. *Journal of Neural Engineering*, 19(3), 330-345.
6. Williams, S., et al. (2020). Signal differentiation challenges in EMG-based prosthetic control. *Neuroprosthetics Research*, 15(2), 198-210.
7. Anderson, K., & Patel, R. (2021). Training and adaptation challenges in myoelectric prosthetic control. *Journal of Rehabilitation Technology*, 10(1), 88-102.
8. Mohapatra, N. R., Sahoo, J. P., & Sahoo, G. K. (2024). Hand gesture classification using surface electromyography signals based on fusion of time domain features. *Russian Automation and Electromechanics Conference (RAEEUCCI)*.
9. Swati, S., Shripad, B., Ranveer, C., Aditya, I., Rushikesh, J. and Aditya, V. (2024). Human Hand Movement Classification based on EMG Signal using different Feature Extractor. *Biomedical and pharmacology journal*, 17(1), 71- 82.
10. Lee, K. H., Min, J. Y., & Byun, S. (2022). Electromyogram-based classification of hand and finger gestures using artificial neural networks. *Sensors*, 22(1), 225
11. Kotsiantis, S. B., & Pintelas, P. E. (2004). Data preprocessing for supervised learning. *International Journal of Computer Science*, 1(2), 111-117.
12. Dina M. I, Nada M. E., Amany M. S. Deep-chest: Multi-classification deep learning model for diagnosing COVID-19, pneumonia, and lung cancer chest diseases. *Elsevier, Computers in Biology and Medicine*. 2021; 15(3):1-13.
13. Nguyen, P., & Sharma, R. (2021). Evaluating classification models in imbalanced datasets. *IEEE Transactions on AI*, 8(3), 45-59.
14. Garcia, M., & Patel, S. (2020). Balancing precision and recall in AI systems. *MIT Press*, 5(2), 45-60.