

Effect of Changing CNN Classifier Parameters on EEG Signals Recognition Ratio

Dr. Kinda Abo Kassem^{*}
Dr. Oulfat Jolaha^{**}
Tarek Ali^{***}

(Received 15 / 2 / 2023. Accepted 9 / 8 / 2023)

□ ABSTRACT □

Brain Computer Interface (BCI), especially systems for recognizing brain signals using EEG (Electroencephalography), is one of the important research topics that arouse the interest of many researchers currently. Convolutional Neural Nets (CNN) is one of the most important deep learning classifiers used in this recognition process, but the parameters of this classifier have not yet been precisely defined so that it gives the highest recognition rate and the lowest possible training and recognition time.

This research proposes a system for recognizing EEG signals using the CNN network, while studying the effect of changing the parameters of this network on the recognition rate, training time, and recognition time of brain signals, as a result the proposed recognition system was achieved 76.38 % recognition rate, And the reduction of classifier training time (3 seconds) by using Common Spatial Pattern (CSP) in the preprocessing of IV2b dataset, and a recognition rate of 76.533% was reached by adding a layer to the proposed classifier.

Keywords: Deep Learning, Convolutional Neural Nets (CNN), Brain Computer Interface (BCI), Electroencephalography (EEG), Common Spatial Pattern (CSP).

Copyright



:Tishreen University journal-Syria, The authors retain the copyright under a CC BY-NC-SA 04

^{*} Associate Professor, Department of Computers and Automatic Control Engineering, Faculty of Mechanical and Electrical Engineering, Tishreen University, Lattakia, Syria.

^{**} Associate Professor, Department of Computers and Automatic Control Engineering, Faculty of Mechanical and Electrical Engineering, Tishreen University, Lattakia, Syria.

^{***} Postgraduate Student (Ph.D.), Department of Computers and Automatic Control Engineering, Faculty of Mechanical and Electrical Engineering, Tishreen University, Lattakia, Syria.

تأثير تغيير معاملات المصنف CNN في نسبة التعرف على إشارات EEG

د. كندة أبو قاسم*

د. ألفت جولحة**

طارق علي***

(تاريخ الإيداع 15 / 2 / 2023. قُبِلَ للنشر في 9 / 8 / 2023)

□ ملخص □

يُعدّ موضوع واجهة الدماغ والحاسوب (Brain Computer Interface) BCI وخاصةً أنظمة التعرف على الإشارات الدماغية باستخدام مخطط كهربائية الدماغ (Electroencephalography) EEG من المواضيع البحثية الهامة التي تثير اهتمام الكثير من الباحثين في الوقت الراهن، وتعد الشبكات العصبونية الالتقافية (Convolutional Neural Nets) من أهم مصنفات التعلم العميق المستخدمة في عملية التعرف هذه، إلا أنه لم يتم بعد تحديد بارامترات هذا المصنف بشكل دقيق بحيث يعطي أعلى نسبة تعرف ممكنة وبأقل زمن تدريب وتعرف ممكن.

يقترح هذا البحث نظام تعرف على إشارات EEG باستخدام شبكة CNN مع دراسة تأثير تغيير بارامترات هذه الشبكة على نسبة التعرف كذلك على زمني التدريب والتعرف على الإشارات الدماغية، وبالنتيجة تم الحصول بواسطة نظام التعرف المقترح على نسبة تعرف % 76.38، وإنفاص زمن تدريب المصنف (3 seconds) باستخدام النمط المكاني المشترك (Common Spatial Pattern) CSP في عملية المعالجة المسبقة لقاعدة البيانات IV2b، كما تم الوصول لنسبة تعرف % 76.533 من خلال إضافة طبقة للمصنف المقترح.

الكلمات المفتاحية: التعلم العميق، الشبكات العصبونية الالتقافية، واجهة الدماغ والحاسوب، مخطط كهربائية الدماغ، النمط المكاني المشترك.

حقوق النشر : مجلة جامعة تشرين- سورية، يحتفظ المؤلفون بحقوق النشر بموجب الترخيص



CC BY-NC-SA 04

* أستاذ مساعد، قسم هندسة الحاسبات والتحكم الآلي، كلية الهندسة الميكانيكية والكهربائية، جامعة تشرين، اللاذقية، سورية.
** أستاذ مساعد، قسم هندسة الحاسبات والتحكم الآلي، كلية الهندسة الميكانيكية والكهربائية، جامعة تشرين، اللاذقية، سورية.
*** طالب دراسات عليا (دكتوراه)، قسم هندسة الحاسبات والتحكم الآلي، كلية الهندسة الميكانيكية والكهربائية، جامعة تشرين، اللاذقية، سورية.

مقدمة:

يقوم الدماغ بالتحكم في معظم أنشطة الجسم، كمعالجة ودمج وتنسيق المعلومات التي يتلقاها من الأجهزة الحسية، ويتخذ القرارات فيما يتعلق بالتعليمات المرسلّة إلى باقي أعضاء الجسم، ويتواجد الدماغ داخل الجمجمة ومحمي بواسطتها. يكون المخ الجزء الأكبر من دماغ الإنسان، وهو يتكون من نصفي الكرة المخية. وتتكون القشرة المخية من ست طبقات عصبية، في حين تتكون القشرة العريقة من ثلاث أو أربع طبقات فقط. على الرغم من أن نصفي الكرة المخية الأيسر والأيمن متشابهان إلى حد كبير في الشكل والوظائف، إلا أن بعض الوظائف مرتبطة بجانب واحد منه، مثل اللغة في الشق الأيسر والقدرة البصرية والمكانية في الشق الأيمن.

يُعتبر هذا البحث مزيجاً بين واجهة الدماغ والحاسوب والذكاء الاصطناعي.

الدراسات المرجعية:

أجريت العديد من الدراسات من أجل التعرف على الإشارات الدماغية باستخدام الذكاء الصناعي، حيث قام عدد من الباحثين في [1] بتقديم دراسة للتعرف على الإشارات الدماغية باستخدام مجموعة بيانات محلية مكونة من 21700 إشارة دماغية EEG وتم استخدام FBCSP (Filter Bank CSP) بعدد فلاتر متغير في المعالجة الأولية وشبكة CNN كمصنف، متوسط نسبة التعرف بلغ (74.15%) مع نسبة خطأ ($\pm 15\%$) عند نواة (Kernel) 3×3 وعدد مرشحات 10. كذلك تم إجراء دراسة للتعرف على الإشارات الدماغية المعبرة عن حركة اليد الفعلية والتصور الحركي (تخيل حركة اليد) باستخدام خوارزمية LDA (Linear Discriminant Analysis) للتصنيف و CSP في المعالجة الأولية، باستخدام قاعدة بيانات محلية، حيث تم تسجيل الإشارات العضلية لليد بشكل متزامن مع الإشارات الدماغية EEG، وتحويل الإشارات العضلية إلى مصفوفة أصفار وأحاد بحجم 6×30 وتخزينها كمجموعة بيانات، ثم تدريب المصنف LDA للتعرف على إشارات EEG من خلال تحويلها إلى مصفوفة ثنائية بنفس الحجم ومقارنتها مع مجموعة البيانات، وكانت نسبة التعرف $63.98 \pm 7.54\%$ على الحركة الفعلية و $46.96 \pm 15.3\%$ على التصور الحركي [2].

كما قُدمت دراسة للتعرف على الإشارات الدماغية باستخدام شبكة CNN كمصنف وقاعدة البيانات المستخدمة Finger، حيث تحتوي مجموعة البيانات هذه على إشارات EEG تعبر عن حركة حقيقية أصابع اليد الواحدة بشكل منفرد، شارك في التسجيل عشر أشخاص بتردد تسجيل 1000Hz وتم الوصول لنسبة تعرف 80% باستخدام SVM (Support Vector Machine) كمصنف [3].

أجريت دراسة أخرى للتعرف على إشارات EEG، استخدمت فيها شبكة GAN (Generative Adversarial Networks) لإضافة عينات مزيفة إلى مجموعة البيانات، كما استخدم مصنف CNN بأربع طبقات التفاضلية وطبقتي Max pooling، وتم الوصول لنسبة تعرف $67.97 \pm 15.86\%$ على مجموعة البيانات IV2b عند إضافة 3000 عينة مزيفة إلى مجموعة البيانات [4].

تجدر الإشارة إلى أن تقييم الأداء يجب أن يتم على نفس مجموعة البيانات، فاستخدام نواة محددة لمصنف CNN يعطي نتائج مختلفة حسب مجموعة البيانات المستخدمة. يلاحظ من النتائج التي تم الوصول إليها في تلك الأبحاث أنه لا يمكن تعميمها على جميع قواعد البيانات والمصنفات حيث أن البارامترات المستخدمة في هذه الأبحاث لا تعطي أفضل أداء بالضرورة، لذلك لابد من دراسة تأثير تغيير بارامترات المصنف على نسبة التعرف وزمني التدريب والتعرف.

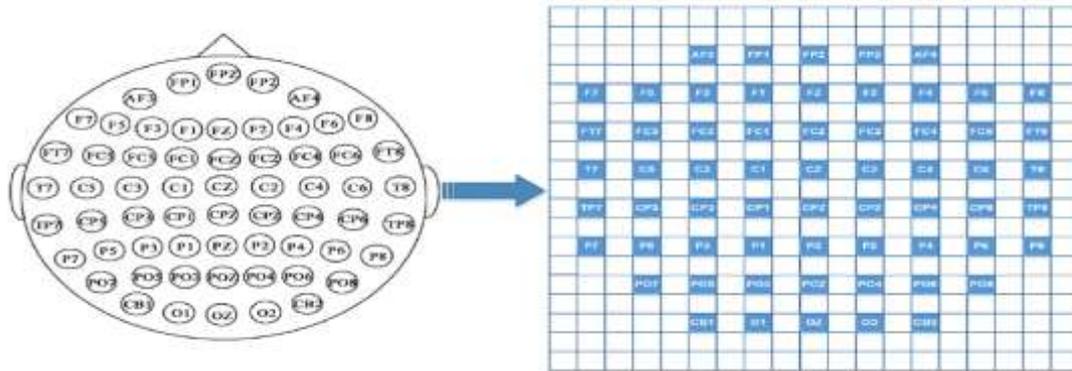
أهمية البحث وأهدافه:

تكمن أهمية البحث في كون زيادة نسبة التعرف تسهم في تطبيق أنظمة التصور الحركي عملياً، بالتالي يساهم في إيجاد الحلول لأصحاب الأطراف المبتورة، فعند التعرف على الحركة التي تم تخيلها في الدماغ يمكن توجيه الأوامر من الدماغ لهذه الأطراف وتنفيذها عن طريق الطرف الصناعي الآلي. يتم في هذا البحث بناء نظام تعرف على إشارات EEG باستخدام شبكة CNN ودراسة تأثير تغيير بارامترات هذه الشبكة على نسبة التعرف.

طرائق البحث ومواده:

في البداية يتم تحليل الإشارات الدماغية زمنياً وطيفياً ومن ثم تطبيق عملية المعالجة المسبقة واكتشاف العلاقة بين طبيعة الإشارات الدماغية EEG ومعاملات المصنف CNN المستخدم، بعد ذلك يتم دراسة تأثير تغيير هذه المعاملات على نسبة التعرف. مجموعة البيانات المستخدمة في هذا البحث هي IV2b من أجل اختبار أداء المصنف المقترح. وتم العمل ضمن بيئة Google Collaboratory.

مخطط كهربية الدماغ (EEG) عبارة عن سلسلة زمنية متعددة القنوات تلتقط النشاط الكهربائي المسجل من فروة الرأس من مواقع محددة بواسطة أقطاب كهربائية (Electrodes) كما يبين الشكل (2).



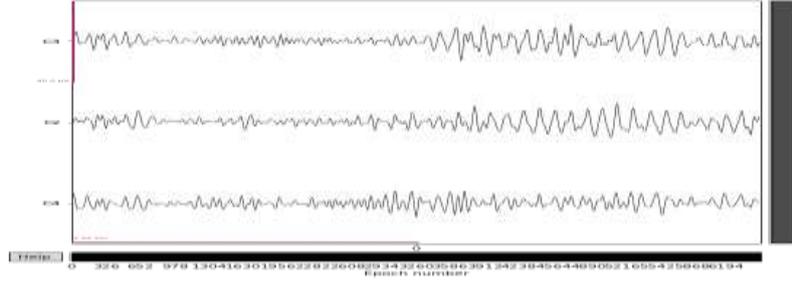
الشكل (2) أماكن تموضع أقطاب تسجيل إشارات EEG [4].

وعادة تستخدم أنظمة تسجيل إشارات EEG أقطاباً كلاً منها متصل بسلك منفرد، حيث يتم تحديد مواقع وأسماء الأقطاب من خلال نظام 10-20 العالمي مما يضمن توحيد أسماء الأقطاب في جميع المختبرات.

قاعدة البيانات المستخدمة:

تم استخدام قاعدة البيانات (BCI Competition IV2b) وتتكون من بيانات لعدد 9 مشتركين، وتحتوي على 6520 تصور حركي. تم تسجيل الإشارات الدماغية باستخدام ثلاث أقطاب EEG هي: C3 و C4 و Cz، وذات تردد تقطيع 250 Hz، وتم تمرير الإشارة عبر مرشح تمرير حزمة (0.5 Hz-100 Hz).

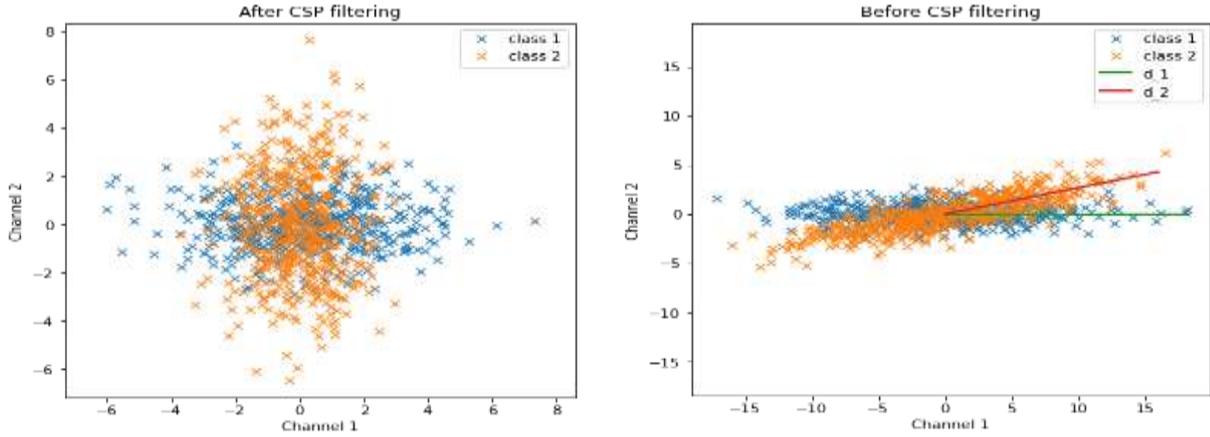
تحتوي قاعدة البيانات على صنفين من التصور الحركي (Motor Imagery)، الصنف الأول هو تخيل تحريك اليد اليمنى والثاني هو تخيل تحريك اليد اليسرى، الشكل (3) يبين رسم تصور حركي واحد من قاعدة البيانات IV2b.



الشكل (3) عينة عشوائية من قاعدة البيانات IV2b.

النمط المكاني المشترك Common Spatial Pattern

تعتمد فكرة CSP على استخدام مجموعة من التحويلات الخطية لزيادة التباين بين الأصناف المستهدفة، من خلال الانتقال إلى فضاء جديد هو CSP، حيث يتم حساب مصفوفة التباين المتبادل بين الأصناف ثم حساب مصفوفة التحويل، وتطبيق المرشحات التي تعطي أعلى تباين بين الأصناف، يبين الشكل (4) الإشارة قبل وبعد تطبيق CSP.

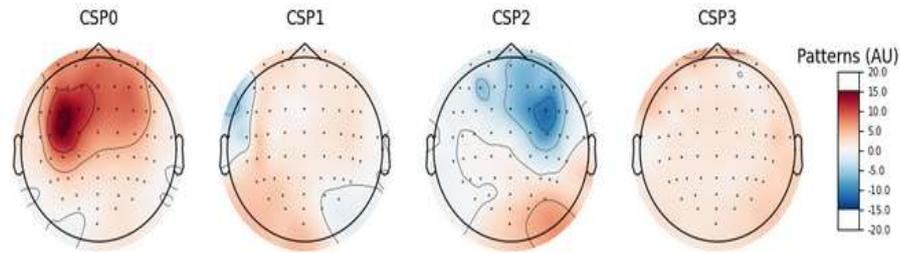


الشكل (4) الإشارة قبل وبعد تطبيق النمط المكاني المشترك.

لنكن لدينا X_1 و X_2 نافذتين من إشارة متعددة القنوات، تحدد خوارزمية CSP المكون w^T بحيث يتم تكبير نسبة التباين بين النافذتين وفق العلاقة (1)[5]:

$$w = \operatorname{argmax}_w \frac{\|wX_1\|^2}{\|wX_2\|^2} \quad (1)$$

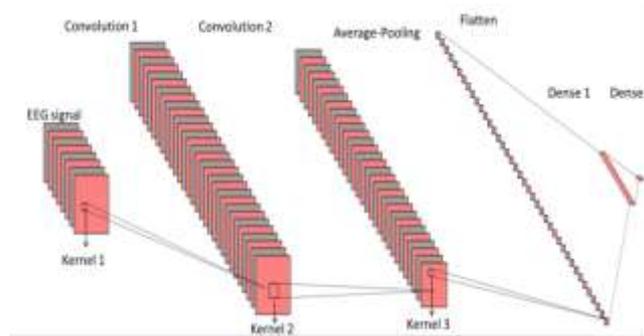
يمكن تطبيق طريقة CSP على الإشارات متعددة القنوات بشكل عام، وهي موجودة بشكل شائع في التطبيق على إشارات مخطط كهربائية الدماغ (EEG) على وجه الخصوص، والشكل (5) يوضح الإشارات الدماغية EEG بعد تطبيق النمط المكاني المشترك CSP بأربع فلاتر على قاعدة البيانات EEGBCI، حيث نلاحظ أن المرشح CSP2 يعطي أكبر تباين بين الأصناف وتبين المسطرة بجانب الشكل قيمة النشاط الطيفي المعبرة عن كل تدرج لوني.



شكل (5) مخطط كهربائية الدماغ طيفياً عند استخدام CSP

استخدام CSP في المجال الزمني ينتج عنه مصفوفة ذات أبعاد (1,126,3) لكل تصور حركي في مجموعة البيانات IV2b، بينما في المجال الطيفي ينتج مصفوفة (3,3,1) وهي لا تتناسب طبيعة المصنف CNN. بناء المصنف:

تم بناء المصنف باعتماد شبكة CNN تتكون من الطبقات الآتية: طبقتين التفاضليتين (Conv2D) ثم طبقة تجميع (Average pooling) تليها طبقة تسطيح (Flatten) وطبقتي تكثيف (Dense) (أي طبقتي ترابط تام Fully connected) الأولى مكونة من 80 عصبون والثانية التي تعتبر طبقة الخرج مكونة من عصبونين. كما يبين الشكل (6). دخل شبكة CNN هو عبارة عن الإشارات الدماغية بعد تحويلها لمصفوفة، كل تكرار أو تصور حركي (Epoch) عبارة عن مصفوفة رقمية بأبعاد (3,1126,1)، حيث 3 هو عدد قنوات التسجيل أو الأقطاب و 1126 عدد العينات الزمنية لكل قناة، والشكل (7) يبين دخل وخرج كل طبقة في المصنف عندما يكون عدد الفلاتر 40 فلتر لكل طبقة.



الشكل (6) شبكة CNN المقترحة.

يوضح الجدول (1) دخل وخرج كل طبقة في شبكة CNN المقترحة في التجربة رقم 4 من السيناريو الثاني، كما يبين عدد المعاملات الناتجة عن كل طبقة وعدد المعاملات الكلي، ويتغير عدد هذه المعاملات بشكل كبير مع تغيير النواة Kernel لكل طبقة حيث أن عدد المعاملات يتراوح في هذا البحث بين 200,000 و 2,200,000. المعاملات في الجدول (Parameters) تشير إلى الوزن والتغيرات الأخرى التي يتم تعديلها خلال عملية تدريب واختبار الشبكة، ويمكن من خلالها تقدير تعقيد المصنف فكلما زاد عدد المعاملات زادت الكلفة الزمنية والحسابية.

جدول (1) قيم الدخل والخرج والمعاملات الناتجة عن كل طبقة في التجربة 4 من السيناريو الثاني

Layer	Layer type	Kernel	Output shape	Parameters	Activation Fn
1	Conv2d	20,1	(None,1126,3,40)	840	Relu
2	Conv2d	1,3	(None,1126,3,40)	4840	Relu
3	Average_pooling2d	100,1	(None,21,3,40)	0	-
4	Flatten	-	(None,2520)	0	-
5	Dense1	-	(None,80)	201860	Relu
6	Dense2	-	(None,2)	162	Softmax
Total parameters		207522			
Trainable Parameters		207522			
None Trainable Parameters		0			
Optimizer: Adam, Model: Sequential, Patch size: 32					

معايير تقييم الأداء:

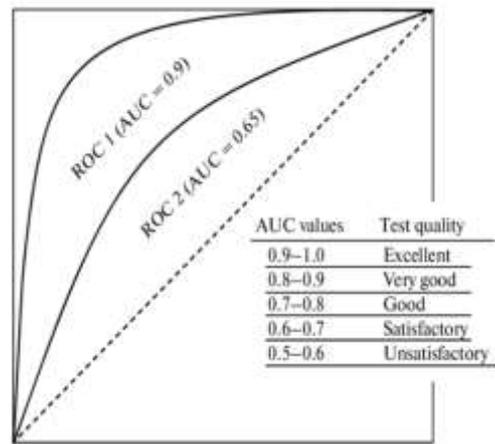
يتم تقييم أداء المصنف المقترح عن طريق قياس الدقة والمنطقة تحت المنحني AUC التي تعتبر المعيار الأهم في قياس دقة التعرف عند وجود صنفين فقط. تحسب بالعلاقة (2) [10].

$$\text{Accuracy} = \frac{\text{True Positive} + \text{True Negative}}{\text{True Positive} + \text{True Negative} + \text{False Positive} + \text{False Negative}} \quad (2)$$

True Positive (TP): الحالات الصحيحة الموجبة، True Negative (TN): الحالات الصحيحة السالبة، False Positive (FP): الحالات الخاطئة الموجبة، False Negative (FN): الحالات الخاطئة السالبة، ويتم الحصول على هذه القيم من مصفوفة الارتباك الموضحة في نتائج السيناريوهات.

المنطقة تحت المنحني ROC (AUC)

يعدّ AUC (Area Under The Roc Curve) معياراً مهماً لتقييم المصنّفات حيث يقيس درجة الثقة بالمصنّف بالاعتماد على منحني ROC (Receiver Operating Characteristic Curve)، حيث أن المنحني ROC يصف أداء المصنّف وفق عتبات مختلفة، لرسم هذا المنحني نعتبر معدل الحالات الصحيحة الموجبة (TPR) هي المحور Y ومعدل الحالات الخاطئة الموجبة (FPR) هي المحور X، وتمثل الزاوية اليسار العليا الحالة المثالية. تتراوح قيمة AUC بين (0) كأسوأ أداء و (1) كأفضل أداء كما يبين الشكل (8).



الشكل (8) المعيار AUC بالاعتماد على المنحني ROC [11]

أما بالنسبة للزمن فيقسم إلى قسمين زمن التدريب وهو الزمن اللازم لتدريب المصنف وزمن الاختبار وهو الزمن اللازم لاختبار النظام المقترح.

سيناريوهات العمل:

تم العمل وفق ثلاث سيناريوهات مختلفة، وتم استخدام 80% من مجموعة البيانات IV2b في عملية التدريب و 20% في عملية الاختبار.

السيناريو الأول تم فيه اختبار شبكة CNN مع تغيير بعض البارامترات حتى الوصول لأفضل أداء لدراسة تأثير تغيير البارامترات على الأداء، أما في السيناريو الثاني فقد تم تطبيق CSP في المعالجة المسبقة للإشارة مع استخدام الشبكة ذات البارامترات التي أعطت أفضل أداء في السيناريو الأول لدراسة جدوى استخدام CSP في المجال الزمني. السيناريو الثالث تم فيه دراسة تأثير إضافة الطبقات على نسبة التعرف والكلفة الزمنية، من خلال إضافة طبقة التفاضلية (Conv2d) بين الطبقة الأولى والثانية.

بارامترات شبكة CNN التي تم تغييرها في السيناريوهات المقترحة هي نواة الطبقة الأولى Kernel 1 ونواة الطبقة الثانية Kernel 2 ونواة الطبقة الثالثة Kernel 3 والخطوة Stride في طبقة Average pooling.

النتائج والمناقشة:

تم في هذا البحث العمل على منصة google colab لإجراء المحاكاة من حيث تصميم واختبار النظام المقترح، نسخة python3، باستخدام ذاكرة وصول عشوائي 12.7 GB ومعالج رسومات GPU بذاكرة 15 GB وحجم التخزين 78.2 GB.

السيناريو الأول:

تم إجراء 11 تجربة باستخدام نواة مختلفة لكل طبقة في شبكة CNN، واختبار أداء الشبكة على قاعدة البيانات IV2b من حيث نسبة التعرف وزمني التدريب والتعرف والمعيار AUC.

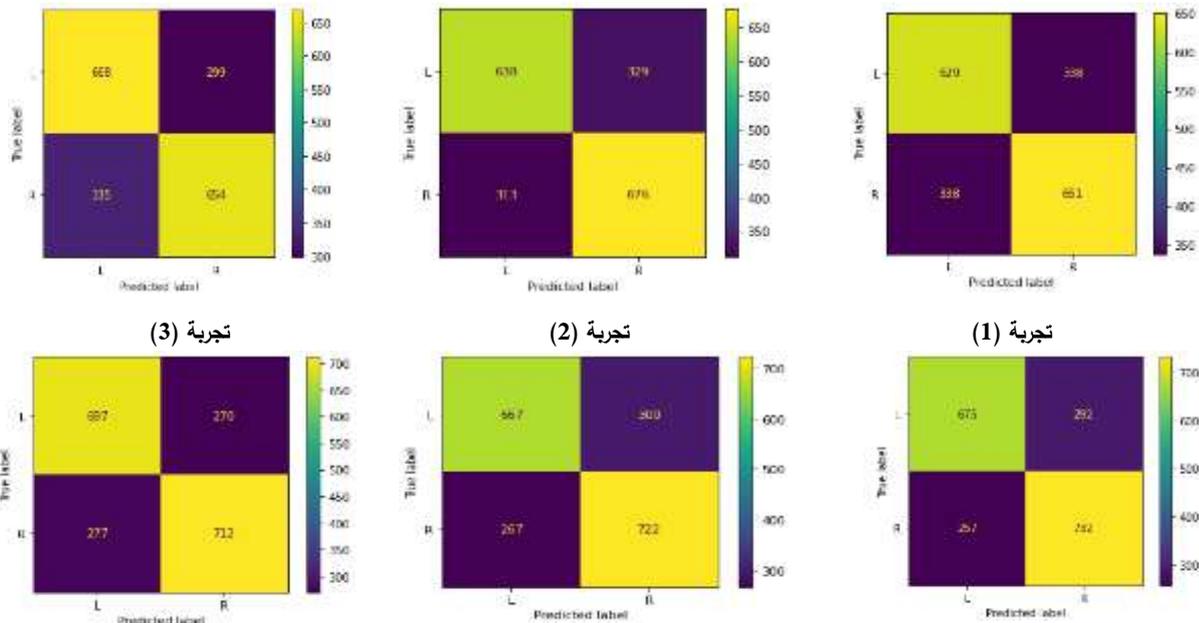
زيادة حجم النواة ينتج عنه زيادة في الكلفة الزمنية، ولتجنب هذه الزيادة نقوم بتكبير الخطوة Stride في الطبقة Average pooling، حيث تشير Stride إلى الخطوة التي تمشي بها النواة وكلما كانت أكبر أدت إلى تقليل الخرج الناتج عن الطبقة المذكورة.

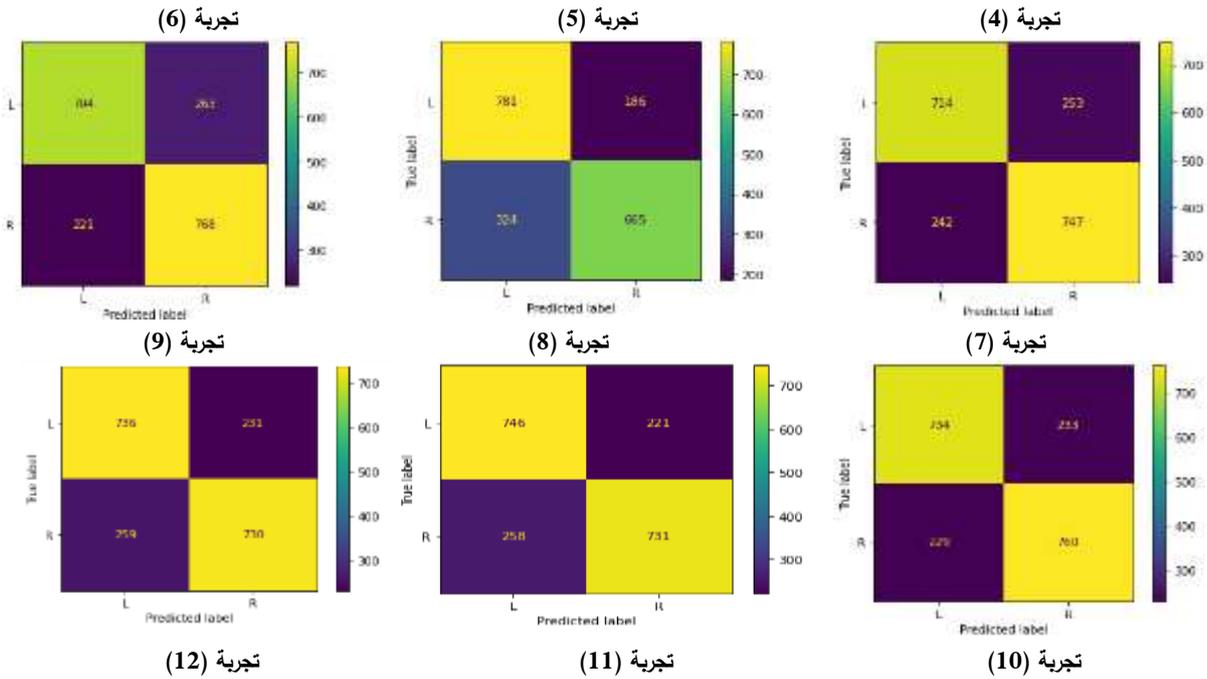
يلاحظ من الجدول (2) أن أفضل نتائج كانت عند استخدام نواة (35,1) للطبقة الأولى و(1,3) للطبقة الثانية بنسبة تعرف 76.38%، وأما أسوأ أداء كان عند استخدام نواة (3,3) للطبقة الأولى و (3,3) للطبقة الثانية بنسبة تعرف 65.439%. والفارق بين أفضل وأسوأ أداء تم الوصول إليه هو 10.941% من حيث نسبة التعرف و (14.615 Seconds) من حيث زمن التدريب. كما يلاحظ أن النواة 3,3 أعطت أسوأ نسبة تعرف باستخدام المصنف المقترح وقاعدة البيانات IV2b.

الجدول (2) تأثير تغيير معاملات المصنف CNN على نسبة التعرف.

AUC	نسبة التعرف	زمن الاختبار (ms)	زمن التدريب (sec)	معاملات المصنف				رقم التجربة
				Stride	Kernel 3	Kernel 2	Kernel 1	
0.6797	0.65439	3	90.194	1,1	3,3	3,3	3,3	1
0.70686	0.67177	3	87.399	1,1	3,1	1,3	3,1	2
0.70901	0.67586	4	101.332	1,1	5,1	1,5	5,1	3
0.75120	0.71932	5	109.739	5,1	10,1	1,10	10,1	4
0.74439	0.71012	6	204.263	10,1	20,1	1,20	20,1	5
0.77754	0.72034	7	204.700	15,1	30,1	1,25	25,1	6
0.78729	0.74693	7	204.990	25,1	50,1	1,25	25,1	7
0.79889	0.73926	3	84.221	50,1	100,1	1,3	25,1	8
0.80430	0.75255	3	84.659	50,1	100,1	1,3	30,1	9
0.81480	0.76380	3	75.579	50,1	100,1	1,3	35,1	10
0.80871	0.75511	3	71.811	50,1	100,1	1,3	40,1	11

يوضح الشكل (9) كيفية التعرف على العينات بناءً على مصفوفة الارتباك، حيث (L) تشير إلى تخيل تحريك اليد اليسرى و(R) تشير إلى تخيل تحريك اليد اليمنى.





الشكل (9) نتائج التعرف في السيناريو الأول بناءً على مصفوفة الارتباك.

المحور العمودي في الشكل (9) يعبر عن القيم الحقيقية والمحور الأفقي يعبر عن خرج المصنف، ويختلف اللون حسب القيم كما توضح المسطرة بجانب كل شكل، ومن خلال هذه القيم يتم حساب (TP, TF, FP, FN) بالتالي حساب الدقة والمنطقة تحت المنحني AUC.

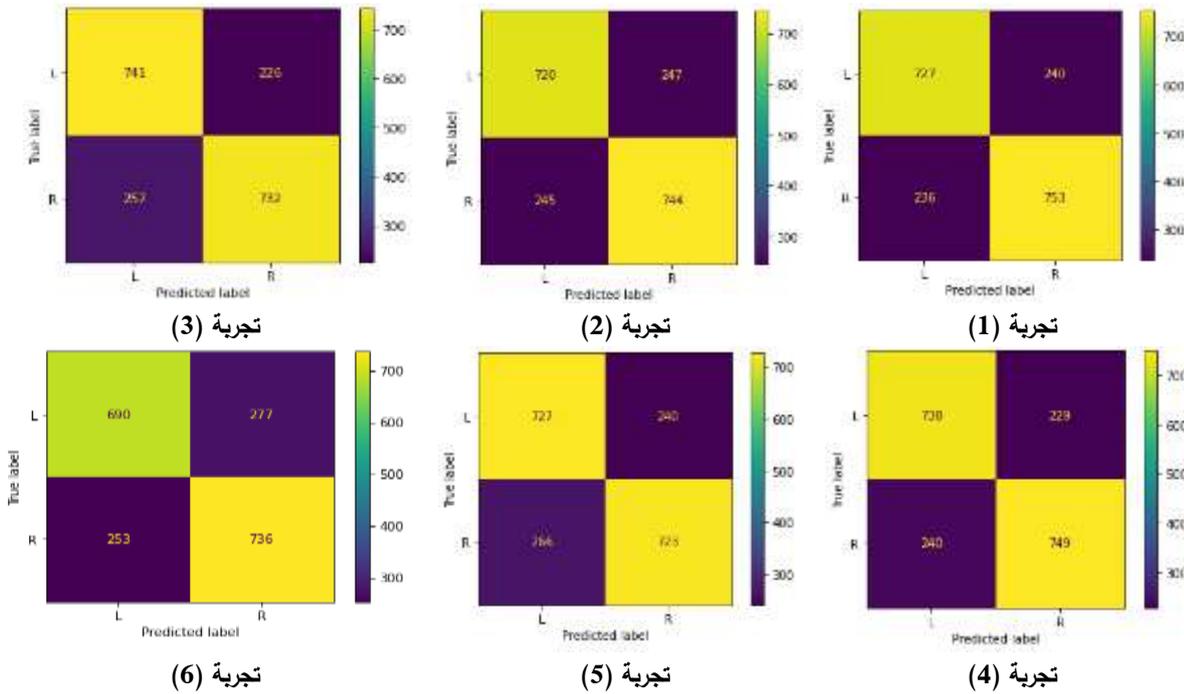
السيناريو الثاني:

تم إجراء 6 تجارب استخدمنا فيها النمط المكاني المشترك CSP في عملية المعالجة المسبقة للبيانات وتغيير معاملات المصنف لنحصل على النتائج المبينة بالجدول (3)، حيث يلاحظ أن أفضل أداء عند استخدام CSP في المعالجة الأولية مع قناع 35.1 في الطبقة الأولى و 1,3 في الثانية بنسبة تعرف 76.022%، أي أن استخدام CSP لم يؤثر على الأداء بشكل ملحوظ من حيث نسبة التعرف ولكن زمن التدريب أقل بأربع ثواني وسطياً. ووجد أن استخدام قناع دائري (3,3) أعطى أسوأ أداء بنسبة تعرف 72.903% مقارنة باستخدام قناع أحادي البعد.

الجدول (3) تأثير تغيير معاملات المصنف CNN على نسبة التعرف عند استخدام CSP في المعالجة الأولية.

AUC	نسبة التعرف	زمن الاختبار (ms)	زمن التدريب (Seconds)	معاملات المصنف				رقم التجربة
				Stride	Kernel 3	Kernel 2	Kernel 1	
0.80698	0.75664	4	71.792	50,1	100,1	1,3	35,1	1
0.80492	0.74846	4	71.783	50,1	100,1	1,3	30,1	2
0.80635	0.75306	4	71.634	50,1	100,1	1,3	25,1	3
0.80605	0.76022	3	71.564	50,1	100,1	1,3	20,1	4
0.79759	0.74130	4	75.739	50,1	100,1	1,3	15,1	5
0.79022	0.72903	5	108,117	50,1	100,1	3,3	5,1	6

ويوضح الشكل (10) كيف تم التعرف على العينات بناءً على مصفوفة الارتباك، حيث (L) تشير إلى تخيل تحريك اليد اليسرى و(R) تشير إلى تخيل تحريك اليد اليمنى.



الشكل (10) نتائج التعرف في السيناريو الثاني بناءً على مصفوفة الارتباك

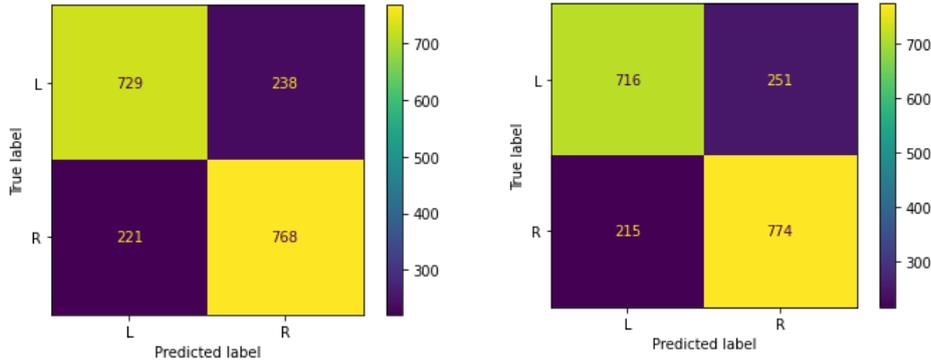
السيناريو الثالث:

قمنا بإضافة طبقة التفاضلية conv2d لشبكة CNN لدراسة تأثير إضافة طبقة على أداء الشبكة، حيث أجرينا تجربتين وتغيير النواة في كل تجربة كما يبين الجدول (4).

الجدول (4) تأثير تغيير معاملات المصنف CNN على نسبة التعرف عند إضافة طبقة جديدة.

AUC	نسبة التعرف	زمن الاختبار (ms)	زمن التدريب (Seconds)	معاملات المصنف				رقم التجربة	
				Stride	Kernel 3	Kernel 2	Kernel added		
0.81060	0.76175	7	250.213	50,1	100,1	1,3	10,1	35,1	1
0.80581	0.76533	7	265.177	50,1	100,1	10,3	25,1	50,1	2

يُلاحظ من الجدول (3) أن إضافة طبقة إلى المصنف بشكل مدروس أدت إلى تحسن نسبة التعرف بشكل طفيف (0.2 %) بالمقارنة مع أفضل حالة في السيناريو الأول، ولكن زيادة زمن الاختبار (4 ms) أي الضعف تقريبا، وزيادة زمن التدريب (189.598 Sec). ويوضح الشكل (11) كيف تم التعرف على العينات بناءً على مصفوفة الارتباك.



تجربة (2)

تجربة (1)

الشكل (11) نتائج التعرف في السيناريو الثالث بناءً على مصفوفة الارتباك

الاستنتاجات والتوصيات:

استخدام قناع أفقي (m,1) في الطبقة الأولى من المصنف، وقناع عمودي (1,n) في الطبقة الثانية حيث n يساوي عدد القنوات أو المستشعرات أدى إلى تحسين نسبة التعرف (11.1%).

استخدام النمط المكاني المشترك (CSP) في المجال الزمني مع المصنف CNN ليس له تأثير ملحوظ على نسبة التعرف، واستخدامه في المجال الطيفي لا يتناسب مع طبيعة المصنف CNN ولكن يمكن استخدامه مع مصنفات أخرى مثل (Support Vector Machine) SVM.

كما أن إضافة طبقات إلى المصنف تؤدي إلى زيادة نسبة التعرف، ولكن يتم ذلك على حساب زيادة زمن التدريب والتعرف بشكل كبير، مع عدم القدرة على تحسين الأداء بشكل ملحوظ.

بعد دراسة وتحليل النتائج نقترح ما يلي:

- استخدام شبكات CNN هجينة مع مصنفات أخرى كمصنف الغابة العشوائية (Random Forest Classifier).
- زيادة عمليات المعالجة الأولية واستخدام خوارزميات تتناسب مع طبيعة المصنف CNN.
- استخدام المصنفات الشهيرة مثل Google net و Alex net بعد معالجة الإشارات الدماغية لتصبح مناسبة لهذه الشبكات.

References:

- [1] C. GUAN, S. LEE. *Subject-Independent Brain-Computer Interfaces Based on Deep Convolutional Neural Networks*. IEEE Transactions on Neural Networks and Learning Systems, vol. 31, no. 10, pp. 3839-3852, 2019.
- [2] J. CHO, J. JEONG. O. KIM, S. LEE. *A Novel Approach to Classify Natural Grasp Actions by Estimating Muscle Activity Patterns from EEG Signals*. arXiv:00556v1, 2020.
- [3] M. MIAO, W. HU, H. YIN, K. ZHANG. *Spatial-Frequency Feature Learning and Classification of Motor Imagery EEG Based on Deep Convolution Neural Network*. Computational and mathematical methods in medicine, Vol. 1981728. 2020.
- [4] Y. SONG, L. YANG, L. XIE, L. JIA. *Song, Common Spatial Generative Adversarial Networks based EEG Data Augmentation for Cross-Subject Brain-Computer Interface*. ArXiv:2102.04456, 2021.
- [5] K. GHANBAR, T.REZAI, A. FARZAMNIA, I. SAAD. *Correlation-based common spatial pattern (CCSP): A novel extension of CSP for classification of motor imagery signal*. PLoS ONE, Vol.16, NO. 3, 2021.

- [6] G. XIAO, M. YE, B. XU, Z. CHEN, Q. REN. *4D Attention-based Neural Network for EEG Emotion Recognition*. arXiv:2101.05484, 2021.
- [7] R. LEEB, F. LEE, C. KEINRATH, R. SCHERER, H. BISCHOF, G. PFURTSCHELLER. *Brain-computer communication: motivation, aim, and impact of exploring a virtual apartment*. IEEE Transactions on Neural Systems and Rehabilitation Engineering 15, 473–482, 2007.
- [8] ZOLTAN J. KOLES, MICHAEL S. LAZARET, STEVEN Z. ZHOU. *Spatial patterns underlying population differences in the background EEG*. Brain topography, Vol. 2 (4) pp. 275-284, 1990.
- [9] H. MEISHERI, N. RAMRAO, S. MITRA, *Multiclass Common Spatial Pattern for EEG based Brain Computer Interface with Adaptive Learning Classifier*. arXiv: abs/1802.09046, 2018.
- [10] M. CONGEDO, L. KORCZOWSKI, A. DELORME AND F. LOPES DA SILVA. *Spatio-temporal common pattern: A companion method for ERP analysis in the time domain*. Journal of Neuroscience Methods, Vol. 267, pp. 74-88, 2016.
- [11] C. SWEENEY, E. ENNIS, M. MULVENNA, R. BOND, S. O'NEILL. *How Machine Learning Classification Accuracy Changes in a Happiness Dataset with Different Demographic Groups*. Computers, VOL.11, NO.5, 2022.
- [12] O. Trifonova, P. Lokhov, *metabolic Profiling of Human Blood*. Biomeditsinskaya Khimiya, Vol. 60, No. 3.pp. 281-294, 2014.