

تحسين أداء أنظمة التصور الحركي المبنية على مخطط كهربائية الدماغ من خلال انتقاء الحزم الترددية

د. كندة أبو قاسم *

د. ألفت جولحة **

م. طارق علي ***

(تاريخ الإيداع ٢٠٢٣/٨/١ . قَبْلُ للنشر في ٢٠٢٣/١١/٢)

□ ملخص □

تحتوي أنظمة التصور الحركي في واجهة الدماغ والحاسوب (BCI-MI) باهتمام خاص لدى الكثير من الباحثين لما لها من أهمية علمية وطبية وإنسانية، وقد تعددت الأبحاث التي تناولت عمليات المعالجة الأولية، ولكن حتى يومنا هذا لم يتم بعد تحديد عمليات المعالجة الأولية التي تعطي أفضل توصيف للإشارات الدماغية EEG والتي بدورها تؤدي للوصول إلى أفضل نسبة تعرف على هذه الإشارات.

يقدم هذا البحث نظامي تعرف على الإشارات الدماغية EEG لمجموعة البيانات IV2b، الأول يستخدم خوارزمية التحليل التمييزي الخطي LDA كمصنف والثاني يستخدم آلة متجه الدعم SVM.

وتمت في مرحلة المعالجة الأولية دراسة المجالات الترددية المختلفة وكيفية تقسيم هذه المجالات الترددية إلى حزم فرعية باستخدام كل من النمط المكاني المشترك والنمط المكاني المشترك متعدد المرشحات FBCSP. وبالنتيجة تم الوصول إلى نسبة تعرف (81.96 %) باستخدام SVM كمصنف و FBCSP في مرحلة المعالجة الأولية.

الكلمات المفتاحية: الذكاء الاصطناعي، خوارزمية التحليل التمييزي الخطي، آلة متجه الدعم، واجهة الدماغ والحاسوب، مخطط كهربائية الدماغ، النمط المكاني المشترك، النمط المكاني المشترك متعدد المرشحات.

*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.

Improving the performance of EEG-based motor imagery systems through frequency bands selection

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

(Received 1/8/2023 . Accepted 2/11/2023)

□ ABSTRACT

Motor imagery systems in the brain-computer interface (BCI-MI) are of special interest to many researchers because of their scientific, medical and humanity importance. There have been many researches discussed pre-processing operations.

No pre-processing operations have been identified that give the best characterization of the EEG brain signals yet, which in turn lead to the best recognition rate for these signals.

This research proposes two systems for EEG signals recognition for the IV2b data set, the first using LDA as a classifier and the second uses SVM.

In the pre-processing stage we study the different frequency domains and how to divide these frequency domains into sub-bands using common spatial pattern and filter bank common spatial pattern. As a result the recognition ratio has been reached 81.96% using SVM as a classifier and FBCSP in the pre-processing stage.

Key words: Artificial intelligence, Linear Discriminate Analysis (LDA), Supported Vector Machine (SVM), Brain Computer Interface (BCI), Electroencephalography (EEG), Common Spatial Pattern (CSP), Filter Bank Common Spatial Pattern (FBCSP).


* 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.

مقدمة

يعتبر التصور الحركي (Motor Imagery) أو التعرف على الحركة التي تم تخيلها في الدماغ البشري (دون تنفيذها جسدياً) أحد أهم تطبيقات واجهة الدماغ والحاسوب، فعند تخيل حركة جسدية معينة يتأين الدماغ وينتج إشارات كهربائية قابلة للقياس والتسجيل تسمى مخطط كهربائية الدماغ EEG (Electroencephalography) كما يبين الشكل (1).



الشكل (١) التصور الحركي في واجهة الدماغ والحاسوب

تتم في البداية عملية تسجيل الإشارات الدماغية باستخدام عدة مجسات توضع في أماكن محددة على فروة الرأس، تليها عملية المعالجة المسبقة كالفلترية وإزالة الضجيج والتسوية وغيرها ثم عملية استخلاص السمات الزمنية أو الطيفية، لتتم عملية التصنيف والتعرف على الحركة التي تم تخيلها والاستفادة منها في تطبيقات معينة.

أجريت دراسة في عام ٢٠٢٠ استخدم فيها المصنف LDA والمجال الترددي (4-40 Hz) حيث تم تقسيم هذا المجال إلى حزم ترددية فرعية كل منها 4Hz متداخلة بمقدار النصف وتطبيق CSP على كل حزمة، تم الوصول لنسبة تعرف على التصور الحركي 46.96% باستخدام قاعدة بيانات محلية [1].

كما أجريت دراسة أخرى في نفس العام تم فيها دراسة نسب التعرف في أكثر من مجال ترددي والحصول على أعلى نسبة تعرف 90% عند استخدام المجال (4-40 Hz) من خلال CNN كمصنف ومجموعة البيانات Finger متقوفاً على خوارزميتي LDA 80% و SVM 82% [2].

وفي دراسة أخرى تم تقسيم المجال الترددي إلى ٥ حزم ترددية فرعية δ (1-4 Hz)، θ (4-8 Hz)، α (8-14 Hz)، β (14-31 Hz)، γ (31-51 Hz) والوصول لنسبة تعرف 96.1% باستخدام CNN كمصنف ومجموعة البيانات SEED [3].

من الدراسات السابقة يُلاحظ أنه لا يوجد اتفاق على المجال الترددي والحزم الترددية الفرعية التي تعطي أعلى نسبة تعرف ولم يتم مقارنة المصنفات المختلفة من حيث الأداء عند تغيير مجالات هذه الحزم واختلاف مجموعة البيانات المستخدمة. كما يُلاحظ أنه كلما ازداد عدد الحزم الفرعية كلما ازدادت العمليات الحسابية وبالتالي زيادة زمني التعرف والتدريب، لذلك لابد من دراسة تأثير تغيير مجال هذه الحزم على نسبة التعرف مع استخدام مصنفات مختلفة ومقارنة الأداء مع الطرق الأخرى الشائعة.

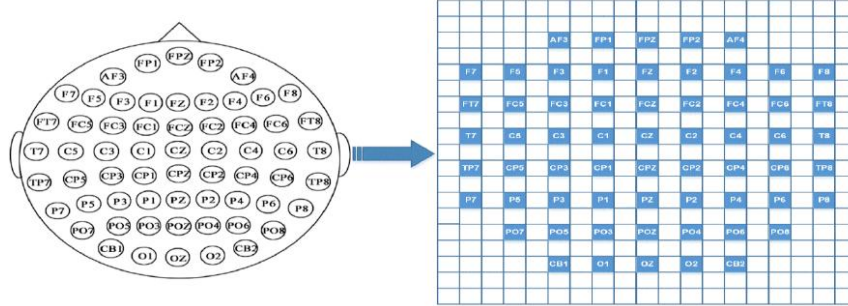
أهمية البحث وأهدافه:

إن زيادة نسبة التعرف على الإشارات الدماغية EEG يزيد من إمكانية تطبيق أنظمة تحكم بالاعتماد على إشارات الدماغ. ومن أهم هذه الأنظمة تلك التي تحدد الحركة التي تم تخيلها في الدماغ كتخيل تحريك أحد الأطراف في الدماغ دون تنفيذ الحركة فعلياً، فعند الحصول على نسب تعرف عالية يمكن تنفيذ أطراف صناعية آلية تنفذ الحركات التي تم تخيلها في الدماغ مباشرةً وبالتالي يمكن إيجاد حلول لأصحاب الأطراف المبتورة. يتم في هذا البحث تحسين نسبة التعرف من خلال دراسة تأثير تغيير الحزم الترددية على نسبة التعرف باستخدام كل من LDA و SVM كمصنفات.

طرائق البحث ومواده:

مخطط كهربية الدماغ (EEG) عبارة عن إشارات كهربائية يتم تسجيلها على شكل سلاسل زمنية متعددة القنوات يتم تسجيلها بواسطة أقطاب كهربائية (Electrodes) توضع على فروة الرأس الخارجية في أماكن محددة كما يبين الشكل (٢).


في هذا البحث يتم في البداية دراسة إشارات EEG وتحليلها في المجال الزمني ثم تحويلها إلى المجال الطيفي لنتناسب مع طبيعة المصنفات المستخدمة، بعد ذلك يتم دراسة تأثير ضبط وانتقاء الحزم الترددية والحزم الترددية الفرعية على نسبة التعرف. مجموعة البيانات المستخدمة في هذا البحث هي IV2b من أجل اختبار أداء المصنفين المقترحين، وتم العمل ضمن بيئة Google Collaboratory.



الشكل (2) أماكن تموضع أقطاب تسجيل إشارات EEG [3].

مجموعة البيانات

تم استخدام قاعدة البيانات (BCI Competition IV2b) المكونة من تسجيلات دماغية لتسعة مشتركين، وتحتوي على ٦٥٢٠ تصور حركي، وهو تسجيل النشاط الدماغي عند تخيل تحريك إحدى اليدين. تم تسجيل الإشارات الدماغية باستخدام ثلاث أقطاب EEG متوزعة على فروة الرأس وهي C3 و C4 و Cz كما يبين الشكل (٢)، وذات تردد تقطيع 250 Hz، وتم تمرير الإشارة عبر مرشح تمرير حزمة (0.5 Hz-100 Hz). وكذلك تم التسجيل من ثلاثة أقطاب أو لواقظ خاصة بحركة العين (Electrooculography) EOG. تحتوي قاعدة البيانات على صنفين من التصور الحركي (Motor Imagery)، الصنف الأول هو تخيل تحريك اليد اليمنى والثاني هو تخيل تحريك اليد اليسرى، حيث تم التسجيل لكل مشترك عبر جلستين في يومين مختلفين بفواصل زمنية أسبوع بين الجلستين، والشكل (3) يبين رسم لعينة عشوائية (تصور حركي واحد) من قاعدة البيانات IV2b.



الشكل (3) عينة عشوائية من قاعدة البيانات IV2b.

مرحلة المعالجة المسبقة

قبل تصنيف الإشارة الدماغية تمر في مرحلة المعالجة المسبقة حيث يوجد العديد من العمليات التي تتم على الإشارة قبل أن تصبح جاهزة للتصنيف كالفلتر وإزالة الضجيج وغيرها. إن مجموعة البيانات IV2b مرشحة مسبقاً وفق مرشح تمرير حزمة (0-100 Hz)، وسيتم فلترتها أيضاً في هذا البحث باستخدام مرشحات أخرى يتم ذكرها في الفقرات التالية ومن ثم تطبيق النمط المكاني المشترك والنمط المكاني المشترك متعدد المرشحات.

النمط المكاني المشترك (Common Spatial Pattern) CSP

تعد هذه الخوارزمية إحدى أهم طرق استخلاص السمات من خلال إيجاد المرشحات المكانية التي تزيد من إمكانية التمييز بين صنفين، وقد أثبتت فعالية استخدام هذه الطريقة في استخلاص السمات في أنظمة واجهة الدماغ والحاسوب، لكن على الرغم من كفاءتها وشعبيتها إلا أنها حساسة للضجيج وخاصة إذا كانت عينات التدريب قليلة.


يستخدم CSP المرشحات المكانية w وفق العلاقة (1):

$$J(w) = \frac{w^T X_1^T X_1 w}{w^T X_2^T X_2 w} = \frac{w^T C_1 w}{w^T C_2 w} \quad (1)$$

حيث تشير T إلى المنقول، X_i هي مصفوفة البيانات للصنف i (عينات التدريب هي الصفوف وقنوات التسجيل هي الأعمدة)، و C_i هي مصفوفة التباين المكاني للصنف i .

النمط المكاني المشترك متعدد الفلاتر (Filter Bank Common Spatial Pattern) FBCSP

يتم في هذه الخوارزمية تقسيم المجال الترددي للإشارة إلى عدة مجالات ترددية متداخلة أو غير متداخلة، ويتم تطبيق CSP على كل مجال منها منفرداً.



الشكل (4) النمط المكاني المشترك متعدد الفلاتر

يبين الشكل (4) مثال عن هذا النمط حيث تم ترشيح الإشارة باستخدام مرشح تمرير حزمة (4-30Hz) وتقسيم هذا المجال إلى حزم ترددية فرعية كل منها 4Hz متداخلة بمقدار النصف ثم تطبيق CSP على كل حزمة فرعية.

التصنيف

يتم في هذا البحث تصنيف التصورات الحركية من خلال التعرف على الإشارات الدماغية EEG التي تعبر عن تخيل تحريك اليد اليمنى أو اليسرى وذلك باستخدام خوارزميتين خطيتين للتصنيف وهما خوارزمية تحليل التمييز الخطي LDA وخوارزمية آلة متجه الدعم SVM.


خوارزمية تحليل التمييز الخطي (Linear Discriminate Analysis) LDA

تحليل التمييز الخطي (LDA) هو خوارزمية تعلم خاضعة للإشراف تستخدم لمهام التصنيف في التعلم الآلي، تُستخدم للعثور على مجموعة خطية من السمات التي تعطي أفضل فصل للأصناف في مجموعة البيانات. يعمل LDA عن طريق إسقاط البيانات على مساحة ذات أبعاد أقل تزيد من الفصل بين الأصناف، يقوم بذلك عن طريق إيجاد مجموعة من السمات الخطية التي تزيد من نسبة التباين بين الأصناف إلى التباين داخل الصنف . بمعنى آخر ، تجد الاتجاهات التي تعطي أفضل فصل بين أصناف البيانات المختلفة في فضاء السمات.

خوارزمية آلة متجه الدعم (Supported Vector Machine) SVM

خوارزمية آلة المتجه الداعم SVM هي خوارزمية تعلم آلي خاضع للإشراف يمكن استخدامها في مسائل التصنيف Classification أو التنبؤ Regression.

في خوارزمية SVM نرسم كل عنصر من عناصر البيانات كنقطة في الفضاء وكل سمة هي قيمة إحداثيات معينة، ثم نقوم بإجراء التصنيف من خلال إيجاد المستوي الفائق Hyper-plane الذي يميز بين الأصناف.



الشكل (٥) آلة متجه الدعم

تتمثل الفكرة الرئيسية لخوارزمية SVM في العثور على حد القرار (المستوى الفائق) الذي يفصل إلى أقصى حد بين الأصناف المختلفة في فضاء السمات، و يتم اختيار هذا المستوى الفائق ليكون المسؤول عن زيادة المسافة بين أقرب نقاط من كل صنف وتعرف هذه النقاط الأقرب بمتجهات الدعم، وتعرف المسافة بينها بالهامش كما يبين الشكل (٥).

وتتميز خوارزمية SVM بميزة تجاهل القيم المتطرفة والعثور على المستوى الفائق الذي يحتوي على الحد الأقصى للهامش، وبالتالي يمكننا القول أن تصنيف SVM قوي مع القيم المتطرفة.

معايير تقييم الأداء:

يتم تقييم أداء المصنف المقترح عن طريق قياس الدقة، حيث تعرف الدقة أو نسبة التعرف بأنها عدد العينات التي تم التعرف عليها بشكل صحيح على عدد العينات الكلي وتعطى بالعلاقة (٢).

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

سيناريوهات العمل

في السيناريو الأول تم إجراء ثلاث تجارب باستخدام ثلاث مجالات ترددية مختلفة: المجال الأول (0-100Hz) والثاني (0-36Hz) والثالث (7-35Hz)، ثم تم استخدام النمط المكاني المشترك CSP في عملية المعالجة المسبقة واستخدام LDA كمصنف من أجل تحديد المجال الترددي الأفضل في عملية التعرف وفق هذه المعطيات. أما في السيناريو الثاني فسوف تُستخدم نفس الحزم الترددية الثلاث المذكورة أعلاه ولكن باستخدام SVM كمصنف.

في السيناريو الثالث:

تُستخدم في مرحلة المعالجة المسبقة النمط المكاني المشترك متعدد المرشحات FBCSP على المجال الترددي الأفضل الذي تم إيجاده من السيناريوين الأول والثاني، حيث تم إجراء أربع تجارب. في التجربة الأولى يتم تقسيم المجال الترددي إلى حزم كل منها 4Hz غير متداخلة، وفي التجربة الثانية يتم تقسيم المجال الترددي إلى حزم 4Hz متداخلة بنسبة ٥٠%، وفي الثالثة تُستخدم حزم ترددية 6Hz غير متداخلة وفي الرابعة تُستخدم حزم ترددية 6Hz متداخلة بنسبة ٥٠% أما في الخامسة فتُستخدم حزم ترددية 6Hz متداخلة بنسبة 33.3%، والمصنف المستخدم في هذا السيناريو هو LDA.

السيناريو الرابع:

نكرر نفس خطوات السيناريو الثالث باستخدام SVM كمصنف.

وفي السيناريو الخامس:

نستخدم FBCSP من خلال تقسيم المجال الترددي إلى حزم دلتا (0.5-4Hz) و ثيتا (4-8Hz) ألفا (8-12Hz) بيتا (12-35Hz)، باستخدام كلاً من المصنفين.

النتائج ومناقشتها:

السيناريو الأول

في هذا السيناريو تم إجراء ثلاث تجارب بالاعتماد على CSP في عملية المعالجة المسبقة و LDA للتصنيف، باستخدام مجالات ترددية مختلفة حيث يتم استخدام هذه المجالات في أغلب الأبحاث العالمية، وذلك من أجل تحديد المجال الترددي الأفضل وفق معطيات هذا البحث.

جدول (١) نسب التعرف باستخدام LDA و CSP

المجال الترددي Hz	نسبة التعرف									
	avg	S9	S8	S7	S6	S5	S4	S3	S2	S1
0-100	68.78	68.75	81.41	62.66	52.58	73.43	92.27	62.13	60.24	65.56
0-36	68.64	69.15	79.07	68.91	49.12	73.63	92.13	63.53	56.34	65.91
7-35	79.11	82.44	84.09	77.36	85.19	82.08	97.38	56.20	62.85	84.45

يُلاحظ من الجدول (١) أن أفضل أداء هو عند استخدام المجال الترددي (7-35 Hz) بنسبة تعرف 79.11% متفوقاً بمقدار 11% عن المجالين الآخرين.

السيناريو الثاني

في هذا السيناريو تم إجراء ثلاث تجارب بالاعتماد على CSP في عملية المعالجة المسبقة و SVM للتصنيف باستخدام مجالات ترددية مختلفة، وذلك من أجل تحديد المجال الترددي الأفضل مع SVM.

جدول (٢) نسب التعرف باستخدام SVM و CSP

نسبة التعرف										المجال الترددي
avg	S9	S8	S7	S6	S5	S4	S3	S2	S1	
69.06	70.78	79.56	63.53	54.38	72.58	91.36	63.89	58.99	66.54	/0-100/Hz
69.56	69.98	79.84	69.44	51.08	72.74	92.09	66.69	57.60	66.63	/0-36/Hz
79.31	83.17	83.64	76.33	87.50	82.78	97.71	54.55	64.70	83.44	/7-35/Hz

يُلاحظ من الجدول (٢) أن أفضل أداء هو عند استخدام المجال الترددي (7-35 Hz) بنسبة تعرف 79.31% متفوقاً بمقدار 10% عن المجالين الآخرين.

السيناريو الثالث:

بعد أن وُجد المجال الترددي الأفضل في السيناريوين السابقين وهو (7-35 Hz)، يتم في هذا السيناريو إجراء تجارب باستخدام LDA للتصنيف و FBCSP في عملية المعالجة المسبقة، حيث يتم في كل تجربة تغيير الحزم الترددية الفرعية ونسبة التداخل بينها كما يبين الجدول (٣).

جدول (٣) نسب التعرف باستخدام LDA و FBCSP

نسبة التعرف										نسبة التداخل	الحزم الفرعية
avg	S9	S8	S7	S6	S5	S4	S3	S2	S1		
81.30	81.54	85.05	84.84	88.87	92.21	96.34	59.63	58.16	85.14	0%	4Hz
79.42	82.42	79.34	80.20	88.18	88.67	94.99	59.10	57.73	84.21	50%	4Hz
79.77	80.58	82.39	77.01	85.70	90.52	95.96	57.84	62.67	85.32	0%	6Hz
81.13	81.99	80.61	81.97	90.01	91.35	97.02	59.38	63.25	84.65	50%	6Hz
81.16	82.68	81.62	83.16	89.58	91.79	96.87	58.27	61.74	84.80	33.3%	6Hz

يُلاحظ من الجدول (٣) أن استخدام الحزم الفرعية بمقدار 4Hz غير متداخلة أفضل من أن تكون متداخلة وأعطى نسبة تعرف أفضل بمقدار 1.88%، كما أن استخدام حزم ترددية فرعية بمقدار 6Hz متداخلة أعطى أداء مشابه لاستخدام حزم ترددية 4Hz غير متداخلة آخذين بعين الاعتبار نسبة الخطأ وهي (1%)، إلا أن استخدام الحزم الترددية الفرعية 6Hz متداخلة بمقدار الثلث أفضل من ناحية زمن التنفيذ.

السيناريو الرابع:

يتم في هذا السيناريو تكرار نفس الخطوات التي تم إجراؤها في السيناريو الثالث ولكن باستخدام المصنف SVM لنحصل على النتائج المبينة بالجدول (٤).

جدول (٤) نسب التعرف باستخدام SVM و FBCSP

نسبة التعرف										نسبة التداخل	الحزم الفرعية
avg	S9	S8	S7	S6	S5	S4	S3	S2	S1		
81.96	84.25	83.94	83.57	89.11	92.07	97.20	59.54	60.83	87.16	0%	4Hz
81.64	81.99	82.62	82.77	89.51	91.95	97.46	61.65	60.80	86.04	50%	4Hz
80.45	81.29	84.19	77.07	84.73	91.75	97.61	55.80	65.63	86.01	0%	6Hz
81.56	82.37	82.56	81.57	88.57	93.09	97.50	59.43	60.94	88.08	50%	6Hz
81.60	82.89	81.96	82.35	87.92	91.71	97.77	57.70	64.29	87.84	33.3%	6Hz

يُلاحظ من الجدول (٤) أن استخدام الحزم الفرعية بمقدار 4Hz غير متداخلة أفضل من أن تكون متداخلة وأعطى نسبة تعرف أفضل بمقدار (0.32%)، كما أن استخدام حزم ترددية فرعية بمقدار 6Hz متداخلة أعطى أداءً مشابهاً لاستخدام حزم ترددية 4Hz غير متداخلة آخذين بالاعتبار نسبة الخطأ وهي 1%، إلا أن استخدام الحزم الترددية الفرعية 6Hz متداخلة بمقدار الثلث أفضل من حيث زمن التنفيذ.

السيناريو الخامس:

في هذا السيناريو يتم ترشيح الإشارة وفق مرشحي تمرير حزمة الأول (0-31 Hz) والثاني (8-31 Hz) ثم تقسيم كل مجال ترددي إلى مجالات فرعية كما هي مقسمة طبيياً. والتصنيف يتم وفق المصنفين LDA و SVM لنحصل على النتائج المبينة في الجدول (٥).

جدول (5) نسب التعرف وفق التقسيم الطبي

avg	نسب التعرف									المجال الترددي	المصنف
	S9	S8	S7	S6	S5	S4	S3	S2	S1		
80.47	82.24	83.27	77.22	85.79	91.11	96.99	62.13	63.85	81.63	0.5-31	LDA
80.02	81.30	85.05	74.04	85.13	89.76	97.71	58.51	62.82	85.87	8-31	LDA
80.63	77.49	84.28	76.32	85.99	88.90	97.30	65.12	66.78	83.56	0.5-31	SVM
80.39	83.15	84.18	76.04	84.91	88.51	97.74	59.38	63.89	85.71	8-31	SVM

يُلاحظ من الجدول ٥ أن أفضل نسبة تعرف هي عند استخدام المجال الترددي (0.5-31 Hz) وفق التقسيم الطبي وباستخدام المصنف SVM، ولكن مقارنة بالسيناريوهات السابقة لم تودَّ إلى أفضل أداء، بالتالي التقسيم وفق حزم فرعية (6 Hz) أعطى أفضل أداء مقارنةً مع باقي السيناريوهات.

الاستنتاجات والتوصيات

من النتائج السابقة نجد أن أفضل مجال ترددي للتعرف على الإشارات الدماغية وفق المصنفين LDA و SVM هو (7-35 Hz)، كما نلاحظ تفوق استخدام FBCSP على CSP في مرحلة المعالجة الأولية ولكن على حساب زمني التعرف والتدريب.

أما من ناحية المصنفات نلاحظ تفوق استخدام المصنف SVM على المصنف LDA بنسبة تتراوح من (0.22%) وحتى (1.26%).

المقترحات المستقبلية

تعاني خوارزميات الفصل الخطية من مشكلة تداخل العينات والتي يمكن أن تكون غير قابلة للفصل الخطي وكلما زاد عدد الأصناف كلما كان الفصل أصعب بسبب زيادة التداخل، لذلك يمكن تجريب خوارزميات أخرى مثل خوارزمية الجار الأقرب لحل هذه المشكلة.

ومن المقترحات الأخرى تحويل الإشارات الدماغية إلى صور واستخدام الشبكات العصبونية الالتقافية لتصنيفها.

المراجع:

[١] J, CHO; J, JEONG; O, KIM; S, LEE; 2020. *A Novel Approach to Classify Natural Grasp Actions by Estimating Muscle Activity Patterns from EEG Signals*. International Winter Conference on Brain-Computer Interface (BCI), Gangwon, Korea (South), pp. 1-4, doi:10.1109/BCI48061.2020.9061627.

[2] M, MIAO; W, HU; H, YIN; K, ZHANG; 2020, *Spatial-Frequency Feature Learning and Classification of Motor Imagery EEG Based on Deep Convolution Neural Network*. *Computational and Mathematical Methods in Medicine*, vol. 2020, Article ID 1981728, 13 pages.

[3] G, XIAO; M, YE; B, XU; Z, CHEN; Q, REN; 2023. *4D Attention-based Neural Network for EEG Emotion Recognition*. *Cogn Neurodyn*. VOL. 16, 805–818.

[٤]R, LEEB; F, LEE; C, KEINRATH; R, SCHERER; H, BISCHOF; G, PFURTSCHELLER; 2007. *Brain-computer communication: motivation, aim, and impact of exploring a virtual apartment*. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*. VOL. 15. NO. 4 .473–482.

[٥] JINLONG, D;MILANA K; JOHANNES V; DANIEL, B; JENS, H ; 2023. *Scatter-based common spatial patterns – a unified spatial filtering framework*. arXiv:2303.06019v1.

[٦]RESHAM, R ,S; NEELAMSHOBHA, N; 2022, 5 - *Concept of AI for acquisition and modeling of noninvasive modalities for BCI*. India. Department of Biomedical Engineering, National Institute of Technology Raipur, Artificial Intelligence-Based Brain-Computer Interface, India, ISBN 9780323911979, Pages 121-144.

[٧]SWEENEY, C ; ENNIS, E; MULVENNA, M; BOND, R; O ' NEILL, S; 2022. *How Machine Learning Classification Accuracy Changes in a Happiness Dataset with Different Demographic Groups*. *Computers*. VOL.11. NO.5 .

[٨]VÁZQUEZ, M; MAGHSOUDI, A; MARIÑO, I;2021. *An Interpretable Machine Learning Method for the Detection of Schizophrenia Using EEG Signals*. *Frontiers in Systems Neuroscience*. VOL. 15. NO. 652662.