

تحسين أداء أنظمة التصور الحركي باستخدام مصنفاة هجينة

* د. كندة أبو قاسم ** د. ألفت جولحة*** طارق علي

(الإيداع: 19 آب 2023، القبول: 6 كانون الأول 2023)

الملخص:

تلقي أنظمة التصور الحركي في واجهة الدماغ والحاسوب (BCI-MI Motor) Brain Computer Interface- Imagery) اهتماماً كبيراً من الباحثين في الفترة الأخيرة، وخاصةً تلك المبنية على مخطط كهربائية الدماغ (EEG (Electroencephalography)، حيث يتم تسجيل إشارات الدماغ EEG أثناء تخيل حركة معينة كتخيل تحريك اليد اليمنى، والتعرف عليها باستخدام أحد المصنفاة، وقد تنوعت عمليات المعالجة الأولية والمصنفاة المستخدمة في عملية التعرف هذه، ولكن حتى يومنا هذا لم ترق هذه الأنظمة إلى الدقة الكافية لتنفيذها عملياً، حيث تختلف دقة الأنظمة المتوفرة عند تجربتها على مجموعات بيانات مختلفة، إضافة إلى مجال خطأ كبير نسبياً. نقترح في هذه البحث نظام هجين للتعرف على التصورات الحركية باستخدام مخطط كهربائية الدماغ EEG، وبالاعتماد على مصنفاة تكديس هجينة كل منها مكون من عدة مصنفاة فرعية، مع استخدام النمط المكاني المشترك متعدد المرشحات (Filter Bank Common Spatial Pattern) FBCSP في المعالجة الأولية للإشارة، حيث تم الوصول لنسب تعرف 83.03%، 88.70%، 89.37% على مجموعات البيانات IV2a، IV2b، AlexMI على التوالي باستخدام المصنفاة المقترحة.

الكلمات المفتاحية: واجهة الدماغ والحاسوب، التصور الحركي، مخطط كهربائية الدماغ، النمط المكاني المشترك متعدد الفلاتر، مصنف تكديس، مصنف تصويت .

*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 Performance of Motor Imagery Systems using Hybrid Classifiers

Dr. kinda Abo Kassem* Dr. Oulfat Jolaha** Tarek Ali***

(Received: 19 August 2023, Accepted: 6 December 2023)

ABSTRACT:

Brain Computer Interface– Motor Imagery (BCI–MI) systems have the attention from a lot of researchers recently, especially systems based on EEG (Electroencephalography), where EEG brain signals are recorded while imagining a specific movement as an imagine moving the right hand, and recognizing it using a classifier. The preprocessing techniques and classifiers used in this recognition process have varied, but to this day they have not been sufficiently accurate to implement them in practical systems, as the accuracy of the available systems changes when tested on different data sets, in addition to the large error ratio. In this paper, we propose a hybrid recognition system for motor imagery using EEG signals, and based on a Hybrid stacking classifiers, each of it consisting of several sub–classifiers, with the use of the FBCSP (Filter Bank Common Spatial Pattern). in the signal preprocessing, where recognition ratio of 83.03%, 88.70%, 89.37% were reached on the IV2b, IV2a, AlexMI datasets, respectively.

Key words: Brain Computer Interface (BCI), Motor Imagery (MI), Electroencephalography (EEG), Filter Bank Common Spatial Pattern (FBCSP), Stacking Classifier, Voting Classifier.

* Associate professor, Department of Computers and Automatic Control Engineering, Faculty of Mechanical and Electrical Engineering, Tishreen University, Lattakia, Syria.

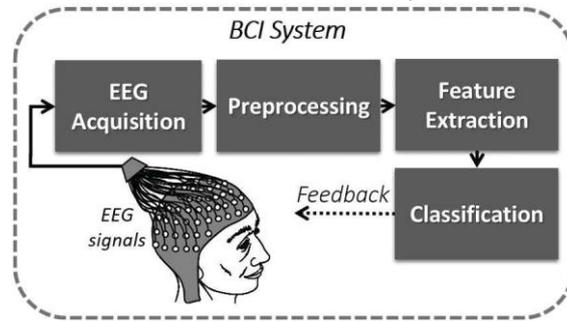
** Associate professor, Department of Computers and Automatic Control Engineering, Faculty of Mechanical and Electrical Engineering, Tishreen University, Lattakia, Syria.

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

المقدمة:

تلقى أنظمة واجهة الدماغ والحاسوب اهتماماً لافتاً في السنوات الأخيرة وفي الكثير من المجالات، حيث يمكن استخدامها في التطبيقات الطبية كالاكتشاف المبكر للأمراض والتحكم والأطراف الاصطناعية، ويمكن استخدامها في المجال الترفيهي كالألعاب وغيرها الكثير.

من أهم أنظمة واجهة الدماغ والحاسوب هي أنظمة التصور الحركي أي تخيل حركة في الدماغ والتعرف عليها دون تنفيذها فعلياً كتخيل تحريك أحد القدمين أو اللسان وغيرهم، ويتم تطبيق هذه الأنظمة عملياً من خلال تسجيل الإشارات الدماغية وتوصيفها على شكل إشارة كهربائية، حيث يتم الحصول على هذه الإشارات وتسجيلها عم طريق لصق عدة مستشعرات على فروة الرأس وتسجيل الكهرباء الموجودة في كل منطقة من الدماغ، ويتم تجميع الإشارات الناتجة عن جميع المستشعرات لنحصل على إشارة متعددة القنوات تسمى مخطط كهربائية الدماغ (Electroencephalography) EEG، والشكل (1) يبين المخطط الصندوقي لأنظمة التصور الحركي (BCI/MI).



الشكل رقم (1) مخطط أنظمة واجهة الدماغ والحاسوب [1]

قدمت دراسات عدة في مجال التعرف على التصورات الحركية MI-EEG (Motor Imagery-EEG)، ومنها دراسة قدمت عام 2021 للتعرف على مجموعة البيانات BCI-competition III المكونة من صنفين وخمسة مشتركين في التسجيل، تم فيها استخدام خوارزمية MSPCA (Multi Scale Principal Component Analysis) لإزالة الضجيج، وتحليل الحزمة الموجية متعدد الحزم من المستوى الخامس في استخلاص السمات، كما تم استخدام النمط المكاني المشترك CSP (Common Spatial Pattern) لتقليل السمات، ثم التصنيف باستخدام مصنفي تجميع الأول مكون من مصنف الغابة العشوائية مع مصنف الفضاء الفرعي العشوائي، والثاني مكون من مصنف (K Nearest Neighbors) KNN مع مصنف الغابة المتناوبة Rotation Forest Classifier، والوصول لمتوسط نسبة تعرف 94.83% [2].

قدمت دراسة أخرى للتعرف على التصورات الحركية، تم فيها إنشاء مجموعة بيانات محلية خاصة بالبحث تحتوي على أربع أصناف من التصورات الحركية وهي تخيل تحريك إحدى اليدين أو إحدى القدمين، إذ تم تسجيل الإشارات الدماغية باستخدام 24 قناة تسجيل ثم فلتر الإشارة وفق مرشح تمرير حزمة (8-35Hz)، أما في مرحلة استخلاص السمات فقد تم استخدام خوارزمية الارتباط المتبادل (Cross Correlation) CC لكل قناة على حدة ثم دمج السمات الناتجة، واستخدم مصنف تجميع مكون من خمس مصنفات فرعية هي: (Supported Vector Machine) SVM، (Naive Bayes) NB، (Discriminant Analysis) LDA، (Kernel Mean Matching) KMM، وأشجار القرار، إذ تم الوصول لنسبة تعرف 89.57% [3].

أجريت دراسة أخرى عام 2023 استخدم فيها تقنيتين لاستخلاص السمات هي CSP للحصول على السمات الترددية و PSD (Power Spectrum Density) للحصول على السمات الطيفية، ثم دمج السمات الناتجة عن الخوارزميتين وتصنيفها باستخدام مصنف تجميع مكون من مصنفين فرعيين هما مصنف (Kernel Mean Matching) KMM ومصنف

التعزيز التكيفي (Adaptive Boosting) Adaboost، إذ تم الوصول لنسب تعرف $91.5 \pm 4.4\%$ و $83.7 \pm 6.3\%$ على مجموعات البيانات IV2a و IV2b على التوالي [4].

كما أجريت دراسة أخرى عام 2023 للتعرف على التصورات الدماغية في ثلاث مجموعات بيانات عامة وهي (IV2a، OpenBMI، SMR-BCI)، تم في البداية ترشيح الإشارات الدماغية وفق مرشح تمرير حزمة 8-30Hz وتطبيق CSP للحصول السمات، لتدخل هذه السمات إلى المصنف MSAENET المقترح، والمكون من شبكة CNN بثلاث فروع ومشفر تلقائي (Auto Encoder) AE، ليتم دمج الخرج الناتج عن هذه الأفرع ويدخل إلى طبقة ترابط تام تقوم بالتصنيف النهائي، وصلت نسبة التعرف في هذه الدراسة إلى $69.98 \pm 12.15\%$ على مجموعة البيانات IV2a [5].

يُلاحظ من الدراسة الأولى الكلفة الحسابية العالية بسبب استخدام تحويل الموجات إضافة إلى CSP كما أن مجموعة البيانات المستخدمة في البحث صغيرة نسبياً، أما الدراسة الثانية لم يتم فيها تجريب النظام المقترح على مجموعة بيانات عامة من أجل المقارنة مع باقي الدراسات، كما يُلاحظ من نتائج الدراسات الثلاثة والرابعة نسبة الخطأ العالية التي تتراوح بين 4.4% حتى 12.15% .

لذلك نقترح في هذا البحث نظام هجين للتعرف على التصورات الحركية يعتمد على خوارزمية CSP لاستخلاص السمات، مع تقليل نسبة الخطأ إلى 1% ، واختبار النظام المقترح على عدة مجموعات بيانات.

أهمية البحث وأهدافه:

لتطبيق أنظمة التصور الحركي والتعرف على الحركة التي تم تخيلها في الدماغ وتحويلها إلى أوامر تحكم في كرسي أو طرف صناعي مثلاً، نحتاج أن نصل إلى نسبة تعرف عالية ومستقرة، والأنظمة الحالية لم تصل إلى الدقة الكافية بعد، لذلك فإنه من الضروري العمل على تحسين نسبة التعرف على الإشارات الدماغية EEG الخاصة بأنظمة التصور الحركي. يقدم البحث نظام تعرف باستخدام عدة مصنفات تكديس هجينة (Hybrid Stacking Classifier) لزيادة نسبة التعرف، واختبار النتائج على ثلاث مجموعات بيانات قياسية لاختبار شمولية وثبات النظام المقترح.

طرائق البحث ومواده:

يتم في هذا البحث العمل على ثلاث مجموعات بيانات قياسية هي (BCI-competition IV2a، BCI-competition IV2b and AlexMI)، إذ نقوم بتحميلها ومعالجتها والتعرف عليها باستخدام المصنف المقترح ومقارنة النتائج مع المصنفات الأخرى لتقييم الأداء، وتم هذا العمل على منصة Google Collaboratory.

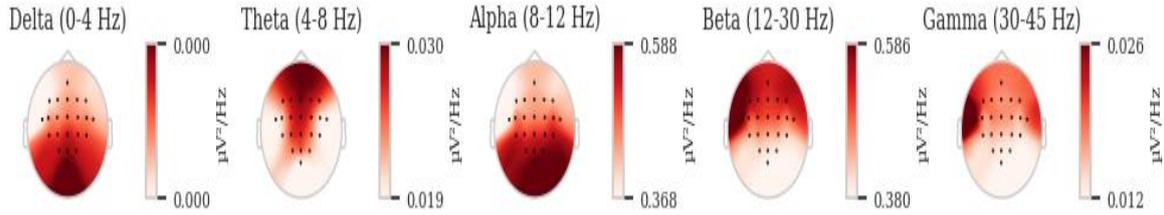
مجموعات البيانات:

تم استخدام ثلاث مجموعات بيانات من أجل اختبار شمولية وثبات النظام المقترح

• المجموعة الأولى (BCI-competition IV2a):

تحتوي هذه المجموعة على تسجيلات EEG لتسع أشخاص، إذ تمثل هذه التسجيلات تخيلات حركية وهي تخيل تحريك اليد اليسرى (class1)، تخيل تحريك اليد اليمنى (class2)، تخيل تحريك كلتا القدمين (class3)، تخيل تحريك اللسان (class4).

تم التسجيل عبر جلستين في يومين مختلفين وتحتوي كل جلسة على 288 تسجيل للشخص الواحد، تردد التسجيل المستخدم 250 Hz وتمت فلترة الإشارة عبر مرشح تمرير حزمة (0-100 Hz)، عدد الأقطاب المستخدمة لتسجيل الإشارة هو 22 والمسافة بين كل قطبين 3.5 cm [6].

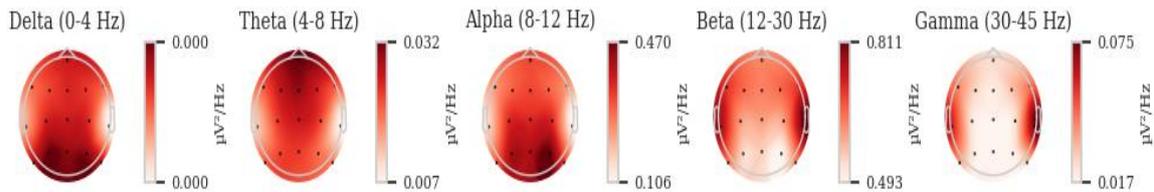


الشكل رقم (2) أماكن تموضع أقطاب التسجيل وتوزيع كثافة الطيف لمجموعة البيانات IV2a

تمثل النقاط السوداء في الشكل (2) أماكن تموضع الأقطاب، إذ تم إجراء متوسط حسابي للكثافة الطيفية لكامل قاعدة البيانات ورسمها، وتوضح المناطق الغامقة نشاط طيفي عالي.

• المجموعة الثانية (AlexMI):

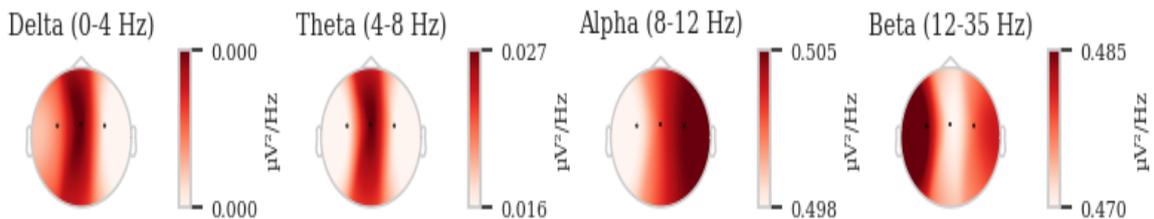
تحتوي قاعدة البيانات هذه على تسجيلات دماغية EEG لثمانية أشخاص، تمثل هذه التسجيلات تخيلات حركية وهي تخيل تحريك اليد اليمنى (class1)، تخيل تحريك الأرجل (class2) والاستراحة (class3)، تردد التسجيل هو (512 Hz) من خلال 16 قطب تسجيل وهي (Fpz, F7, F3, Fz, F4, F8, T7, C3, Cz, C4, T8, P7, P3, Pz, P4, P8). [7].



الشكل رقم (3) أماكن تموضع أقطاب التسجيل وتوزيع كثافة الطيف لمجموعة البيانات AlexMI

• المجموعة الثالثة (BCI-competition IV2b):

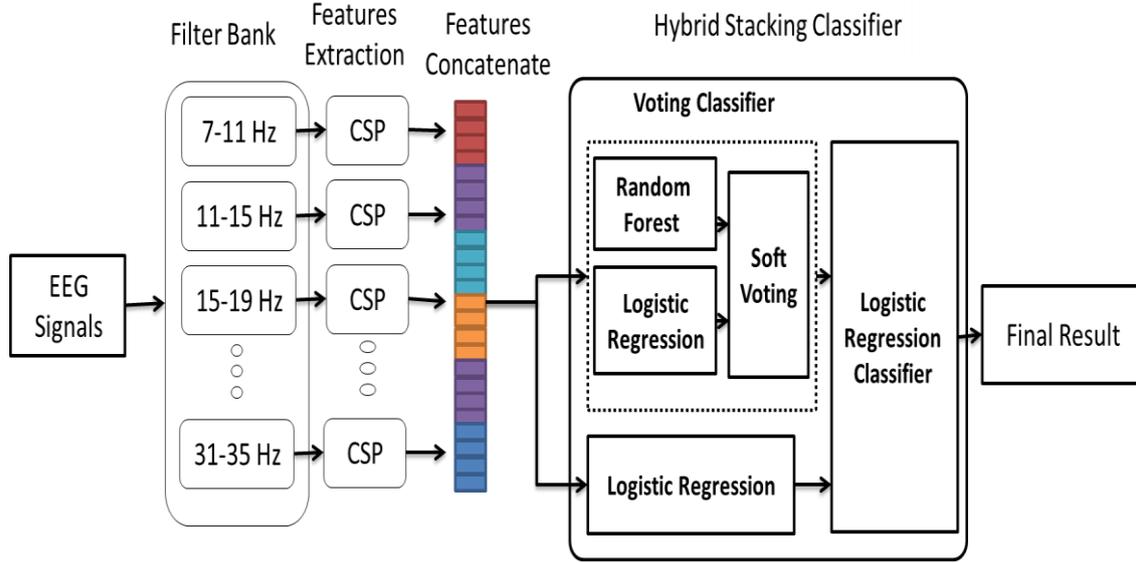
تحتوي قاعدة البيانات هذه على تسجيلات دماغية EEG لتسع أشخاص، تمثل هذه التسجيلات تخيلات حركية وهي تخيل تحريك اليد اليسرى (class1)، تخيل تحريك اليد اليمنى (class2)، وتحتوي على 6520 تسجيل، إذ تم التسجيل عبر جلستين مختلفتين بفاصل زمني قدره أسبوع وعبر ثلاث أقطاب تسجيل هي (C3,C4,Cz) [8]، تردد التسجيل المستخدم هو (250 Hz) وتم ترشيح الإشارة عبر مرشح تمرير حزمة (0-100 Hz).



الشكل رقم (4) أماكن تموضع أقطاب التسجيل وتوزيع كثافة الطيف لمجموعة البيانات IV2b

النظام المقترح:

يتم في البداية تحميل الإشارات الدماغية EEG المسجلة والمرشحة وفق مرشح تمرير حزمة (0-100Hz)، لتتم بعد ذلك مجموعة من عمليات المعالجة الأولية، ثم يتم التعرف على هذه الإشارات باستخدام مصنف التكديس الهجين (Hybrid Stacking classifier) المقترح.



الشكل رقم (5) إطار العمل للنظام المقترح عند استخدام المصنف المقترح A

يبين الشكل (5) المخطط الصندوقي لإطار العمل عند استخدام المصنف المقترح A إذ تدخل الإشارات الدماغية إلى مرحلة المعالجة الأولية التي يتم شرحها في سياق البحث، ثم تدخل نسخة عن السمات الناتجة إلى المصنفين الفرعيين الأول والثاني لينتج عن كل مصنف منهما قرار تصنيف، ويدخل خرج المصنفين السابقين إلى المصنف الفرعي الأخير الذي يتخذ قرار التصنيف النهائي.

المعالجة الأولية:

قبل التعرف على الإشارات الدماغية الموجودة في مجموعات البيانات المستخدمة يجب أن تمر بمجموعة من عمليات المعالجة الأولية والتي تتناسب مع طبيعة الإشارة وطبيعة المصنف المستخدم وهذه المراحل هي:

- تمرير الإشارة عبر مرشح تمرير حزمة (7-35Hz).
- تقسيم المجال الترددي إلى 7 حزم ترددية كل منها (4Hz) غير متداخلة لأن التداخل سيزيد الكلفة الحسابية.
- تطبيق خوارزمية CSP على كل حزمة ترددية بعد تحويل الإشارة إلى المجال الطيفي وحساب قوة كثافة الطيف لكل قناة.
- يتم دمج السمات الناتجة عن المرحلة السابقة معاً فنحصل بذلك على مصفوفة السمات التي تعبر عن الإشارة لتدخل بعد ذلك إلى المصنف المقترح.

يسمى التقسيم إلى حزم ثم تطبيق CSP على كل حزمة فرعية بالنمط المكاني المشترك متعدد المرشحات (FBCSP Filter bank Common Spatial Pattern).

التصنيف:

نقترح في بحثنا هذا خمس مصنفات تكديس هجينة كل منها مكون من ثلاث مصنفات فرعية (Meta-learner or sub-classifier) للحصول على مصنف نهائي أقوى من المصنفات المنفردة، إذ يتم تمرير نتائج كل مصنف فرعي إلى المصنف الفرعي النهائي ليقوم بالتصنيف مستخدماً نتائج بقية المصنفات كدخل.

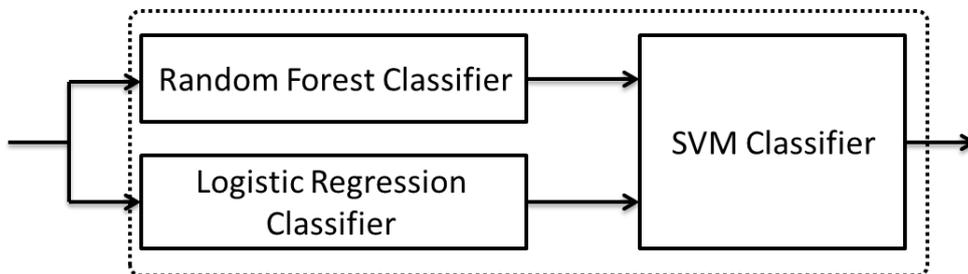
يتضمن كل مصنف مقترح عدة مصنفات فرعية إذ تم تجريب عدد كبير من المصنفات، وبناءً على تلك التجارب تم اختيار المصنفات الفرعية التي أعطت أعلى دقة لبناء المصنف الهجين وهذه المصنفات هي الآلة الداعمة الافتراضية SVM، الانحدار اللوجستي LR (Logistic Regression)، الغابة العشوائية (Random Forest) خوارزمية تعزيز التدرج الشديد XGBoost (extreme Gradient Boosting) ومصنف تصويت (Voting Classifier)، أما بالنسبة لترتيب المصنفات ضمن المصنف النهائي فإن ترتيب المصنفين الفرعيين الأول والثاني لا يؤثر على الأداء بشكل ملحوظ لأنه يحدث تغيير في ترتيب أعمدة مصفوفة الأوزان فقط، والمصنف الفرعي الثالث يتم اختياره مصنف خطي لأن دخله هو خرج المصنفين السابقين فقط، يبين الجدول التالي المصنفات المقترحة التي سنسميها هنا كما يرد في الجدول (1) لسهولة الشرح.

الجدول رقم (1) : المصنفات المقترحة

First Classifier	Second Classifier	Final Classifier	Classifier name
Voting Classifier	LR	LR	Classifier A
RF	LR	SVM	Classifier B
SVM	LR	SVM	Classifier C
LR	RF	LR	Classifier D
Voting Classifier	XGBoost	LR	Classifier E

أي أن المصنف A هو مصنف تكديس يحتوي على مصنفين فرعيين هما مصنف تصويت ومصنف الانحدار اللوجستي، إذ يتم تمرير نتائج هذين المصنفين الفرعيين إلى مصنف نهائي هو مصنف الانحدار اللوجستي الذي يعطي التصنيف النهائي كما يبين الشكل (5) ، علماً أن مصنف التصويت Voting Classifier المستخدم في البحث مكون من مصنفين فرعيين هما مصنف الانحدار اللوجستي ومصنف الغابة العشوائية، ويستخدم التابع Soft Voting [9] في الخرج.

Classifier B



الشكل رقم (6): المخطط التفصيلي للمصنف B المقترح

وكذلك الأمر بالنسبة لباقي المصنفات إذ أن المصنف B يعمل بشكل مشابه للمصنف A ولكن نستخدم مصنف الغابة العشوائية بدلاً من مصنف التصويت كما يبين الشكل (6)، أما المصنف C يستخدم مصنفين فرعيين هما مصنف الانحدار

اللوجستي ومصنف آلة متجه الدعم ثم تمرر نتائج المصنفين إلى مصنف نهائي SVM ليتخذ قرار التصنيف النهائي، و المصنف D يستخدم مصنفين فرعيين هما LR و RF والمصنف النهائي هو LR، أما المصنف الأخير E يستخدم مصنفين فرعيين هما Voting Classifier المذكور سابقاً ومصنف XGBoost وتمرر نتائج هذين المصنفين إلى مصنف LR ليتخذ قرار التصنيف النهائي.

معايير تقييم الأداء:

يتم اختبار أداء أنظمة التصور الحركي عالمياً باستخدام معيارين، الأول هو (ROC_AUC) عندما يكون عدد الأصناف 2 فقط، والثاني هو الدقة (Accuracy) في حال كان عدد الأصناف ثلاثة أو أكثر.

يتم حساب ROC-AUC من خلال رسم العلاقة بين معدل الحالات الصحيحة الموجبة TPR ومعدل الحالات الخاطئة الموجبة FPR، ثم حساب المساحة تحت هذا المنحني، إذ أن TPR تعطى بالعلاقة [10]:

$$TPR = \frac{True\ Positive}{True\ Positive + False\ Negative} \quad (1)$$

True Positive: عدد الحالات الصحيحة الموجبة.

False Negative: عدد الحالات الخاطئة السالبة.

و FPR تعطى بالعلاقة [10]:

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

False Positive: عدد الحالات الخاطئة الموجبة.

True Negative: عدد الحالات الصحيحة السالبة.

أما الدقة فيتم حسابها وفق العلاقة (3) [11]:

$$Accuracy = \frac{True\ Positive + True\ Negative}{True\ Positive + True\ Negative + False\ Positive + False\ Negative} \quad (3)$$

True Positive: عدد الحالات الصحيحة الموجبة.

False Negative: عدد الحالات الخاطئة السالبة.

False Positive: عدد الحالات الخاطئة الموجبة.

True Negative: عدد الحالات الصحيحة السالبة.

سيناريوهات العمل:

بدايةً يتم تحميل مجموعات البيانات المستخدمة في هذا البحث، ويتم التعامل مع كل مجموعة منها على حدة، ثم حساب نسب التعرف على كل مجموعة بيانات وفق المراحل التي تم ذكرها سابقاً ويتم تقسيم العمل إلى ثلاثة سيناريوهات.

السيناريو الأول يتم فيه حساب نسب التعرف على مجموعة البيانات IV2a باستخدام خمس مصنفات عادية وهي (XGBoost, SVM, KNN, LR, RF) وخمس مصنفات تكديس مقترحة هي Classifier A و Classifier B و Classifier C و Classifier D و Classifier E، إذ يتم استبدال المصنف A المبين في الشكل (5) بأحد هذه المصنفات في كل مرة.

السيناريو الثاني يتم فيه تكرار خطوات السيناريو الأول ولكن على مجموعة البيانات IV2b، وفي السيناريو الثالث نكرر نفس الخطوات على مجموعة البيانات AlexMI.

السيناريو الأول:

بعد تحميل مجموعة البيانات IV2a ومعالجتها وتصميم المصنفات نحصل على نسب التعرف المبينة في الجدول (2) إذ تشير S إلى (Subject) أي أن S1 هو المشترك رقم 1 الذي تم تسجيل إشارات EEG الخاصة به في قاعدة البيانات المذكورة، و AVG تشير إلى المتوسط الحسابي لنسبة التعرف.

الجدول رقم(2): نسب التعرف وفق السيناريو الأول

نسبة التعرف										المصنف
AVG	S9	S8	S7	S6	S5	S4	S3	S2	S1	
86.64	85.31	99.19	91.6	73.08	94.9	78.09	98.15	63.95	95.53	SVM
85.89	90.4	99.01	89.15	70.31	93.36	78.84	97.05	61.22	93.72	KNN
87.32	91.96	99.09	94.09	64.99	96.32	82.71	98.03	61.24	96.71	RF
88.51	90.21	99.71	93.1	75.84	95.38	85.66	98.55	62.57	95.65	LR
85.04	88.71	97.82	91.24	58.97	96.86	80.97	96.71	64.32	89.80	XGBoost
88.70	89.96	99.76	93.74	70.65	95.27	85.32	98.94	67.72	96.96	Classifier A
88.67	91.25	99.61	91.94	74.36	95.1	85.03	99.14	63.75	97.9	Classifier B
87.87	88.45	99.62	92.94	74.84	92.94	83.49	98.17	64.53	95.88	Classifier C
88.03	89.69	99.71	92.74	72.06	96.87	83.83	99.23	61.36	96.78	Classifier D
88.66	91.83	99.55	95.09	70.93	97.21	85.45	98.83	62.73	96.40	Classifier E

يُلاحظ من الجدول (2) أن المصنف Classifier A أعطى أفضل نسبة تعرف بمقدار 88.70% متفوقاً بمقدار 3.66% على أسوأ مصنف فرعي وهو XGBoost، وبمقدار 0.19% عن أفضل مصنف فرعي وهو LR، أي أن استخدام المصنفات الهجينة يؤدي إلى تحسن الأداء عن استخدام المصنفات المنفردة التي تعطي أداء متفاوت حسب طبيعة مجموعة البيانات.

السيناريو الثاني:

يتم تحميل مجموعة البيانات IV2b ومعالجتها بشكل مماثل للسيناريو الأول لنحصل على نسب التعرف المبينة في الجدول (3) إذ تم حساب نسبة التعرف باستخدام المعيار ROC-AUC لأن مجموعة البيانات هذه تحتوي على صنفين من التخيلات الحركية فقط.

يُلاحظ من الجدول (3) أن المصنف Classifier B أعطى أفضل نسبة تعرف بمقدار 83.03% متفوقاً بمقدار 5.61% على أسوأ مصنف فرعي وهو KNN، وبمقدار 0.48% عن أفضل مصنف فرعي وهو LR، وهذا يثبت تفوق النظام المقترح على المصنفات المنفردة بنسب تختلف من مصنف لآخر وترتبط بطبيعة مجموعة البيانات.

الجدول رقم(3): نسب التعرف وفق السيناريو الثاني

نسبة التعرف										المصنف
AVG	S9	S8	S7	S6	S5	S4	S3	S2	S1	
81.56	82.72	84.41	84.05	87.68	92.82	96.58	56.92	62.05	86.81	SVM
77.42	78.86	82.72	78.86	82.78	89.37	94.02	53.37	55.88	.0081	KNN
80.49	83.66	81.19	78.96	89.13	91.15	95.46	59.93	59.38	85.62	RF
82.55	.0086	83.38	85.68	90.13	94.06	97.32	60.26	61.11	85.03	LR
79.21	80.00	81.11	81.99	86.26	89.59	94.86	58.26	57.5	83.32	XGBoost
82.73	84.71	84.31	85.55	91.15	93.71	97.94	57.46	61.57	88.18	Classifier A
83.03	84.34	85.49	85.35	91.55	93.23	97.01	60.29	62.11	87.94	Classifier B
82.97	84.75	84.88	85.52	90.3	93.74	96.92	61.42	61.81	87.44	Classifier C
82.69	.0086	84.54	85.15	90.52	93.99	97.23	59.49	59.35	88.02	Classifier D
81.75	82.93	85.43	83.71	.0088	92.67	96.37	59.94	60.01	086.7	Classifier E

السيناريو الثالث:

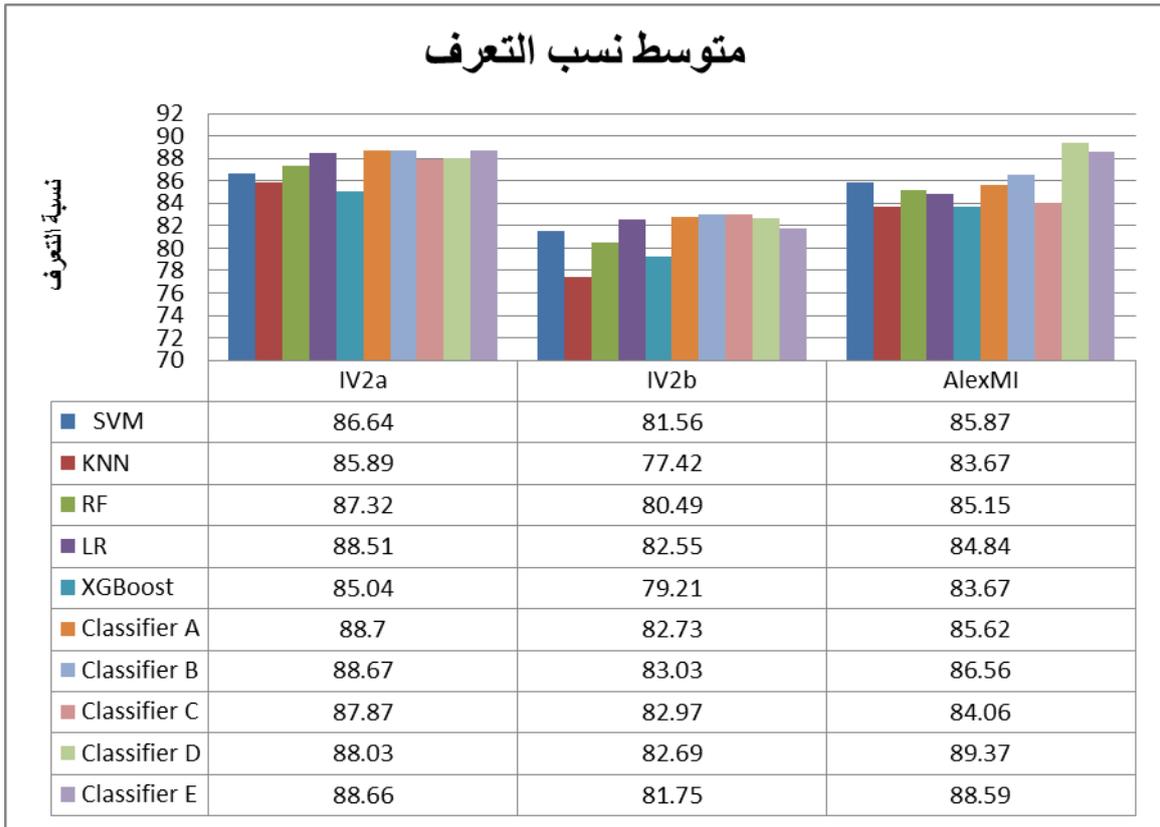
تكرر نفس خطوات السيناريو السابق ولكن باستخدام مجموعة البيانات AlexMI لنحصل على النتائج المبينة في الجدول (4).

يُلاحظ من الجدول (4) أن المصنف Classifier D أعطى أفضل نسبة تعرف بمقدار 89.37% متفوقاً بمقدار 5.7% على أسوأ مصنف فرعي وهو KNN، وبمقدار 3.5% عن أفضل مصنف فرعي وهو SVM، ويُلاحظ من النتائج تفوق مصنف SVM على مصنف LR وتفوق المصنف الهجين على المصنفات المنفردة بالتالي فإنها أكثر استقراراً من المصنف LR وذات دقة أعلى من المصنفات المنفردة.

الجدول رقم(4): نسب التعرف وفق السيناريو الثالث

نسبة التعرف									المصنف
AVG	S8	S7	S6	S5	S4	S3	S2	S1	
85.87	100	100	55	80	95	87.5	82.5	86.25	SVM
83.67	100	100	62.5	64.38	84.38	86.87	80.62	90.62	KNN
85.15	95	100	61.25	82.5	90	89.38	80	83.13	RF
84.84	97.5	100	65	66.25	97.5	82.5	90	80	LR
83.67	90.62	100	64.38	91.87	88.75	81.25	78.75	73.75	XGBoost
85.62	98.75	100	65	80	92.5	82.5	83.75	82.5	Classifier A
86.56	97.5	100	58.75	78.75	96.25	88.75	82.5	90	Classifier B
84.06	96.25	100	67.5	77.5	87.5	81.25	85	77.5	Classifier C
89.37	96.25	100	65	88.75	97.5	92.5	90	85	Classifier D
88.59	100	100	71.25	90	95	95	81.25	76.25	Classifier E

يبين الشكل (7) مقارنة بين المصنفات المستخدمة في جميع السيناريوهات السابقة.

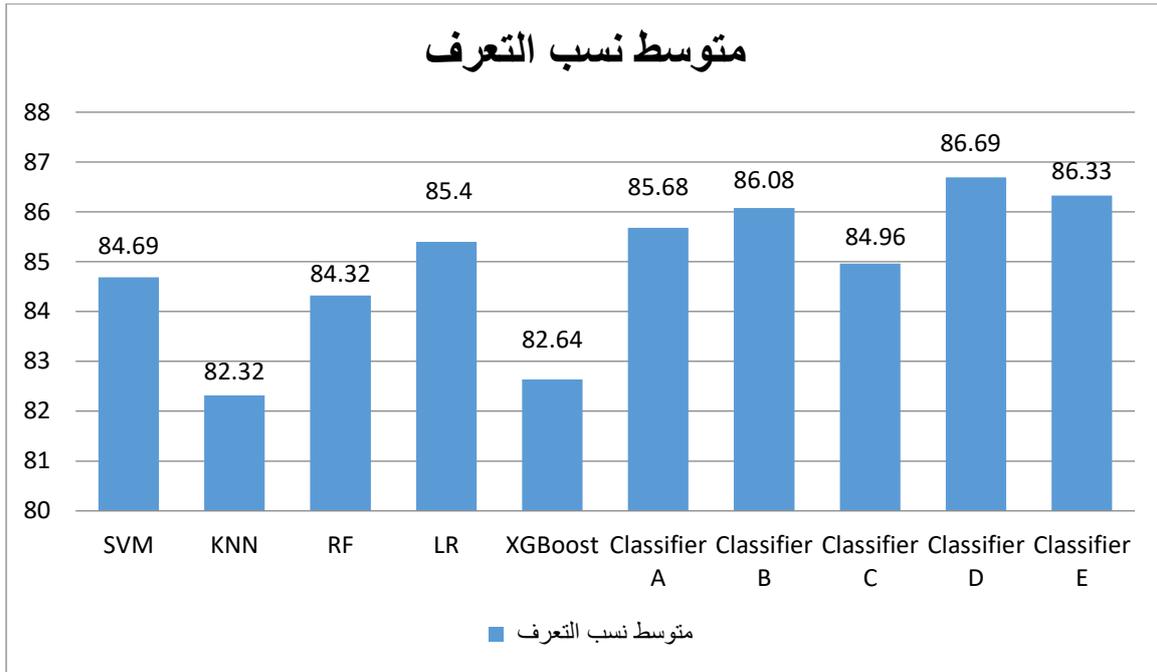


الشكل رقم (7) : متوسط نسب التعرف على مجموعات البيانات الثلاث

يُلاحظ من الشكل (7) تفوق المصنفات الهجينة المقترحة على المصنفات المنفردة بشكل ملحوظ، كما أنها أكثر استقراراً من المصنفات المنفردة، إذ أنها تعطي أداءً عالياً على مجموعات البيانات الثلاث.

الاستنتاجات:

بعد حساب نسب التعرف على مجموعات البيانات الثلاث نستطيع حساب المتوسط الحسابي لنسب التعرف الخاصة بكل مصنف من المصنفات المستخدمة، كما يبين الشكل(8).



الشكل رقم (8): المتوسط الحسابي لنسب التعرف على مجموعات البيانات الثلاث

نستنتج من الشكل (8) أن أفضل مصنف لتصنيف إشارات EEG الخاصة بالتصور الحركي عند استخدامه كمصنف شامل، هو مصنف التكدس Classifier D بنسبة تعرف 86.69% متفوقاً على بقية المصنفات الفرعية بنسبة تعرف تتراوح بين 1.29% وحتى 4.37%.

بالنسبة لمجموعات البيانات المنفردة فإن أفضل مصنف للتعرف على التصورات الحركية في مجموعة البيانات IV2a هو المصنف الهجين Classifier A بنسبة تعرف 88.70%، وأفضل مصنف للتعرف على التصورات الحركية في مجموعة البيانات IV2b هو المصنف الهجين Classifier B بنسبة تعرف 83.03%، أما بالنسبة لمجموعة البيانات AlexMI فإن أفضل مصنف هو Classifier D بنسبة تعرف 89.37%.

من النتائج السابقة نلاحظ تفوق المصنفات الهجينة على المصنفات المنفردة بنسبة تصل إلى 4.37%، ونلاحظ أن النظام المقترح يعتمد بشكل كبير على مصنف الانحدار اللوجستي الذي يتصف بالسرعة العالية والدقة لتجنب الكلفة الزمنية الناتجة عن عملية التهجين.

مقارنة مع الدراسات المرجعية:

عند المقارنة بين أكثر من نظام تعرف على الإشارات الدماغية يجيب الأخذ بعين الاعتبار مواصفات مجموعة البيانات المستخدمة، كالحجم وعدد أقطاب التسجيل وعدد الأصناف وغيرها، إضافة إلى الكلفة الحسابية الناتجة عن عمليات المعالجة الأولية وعدد المصنفات الفرعية، يبين الجدول (5) مقارنة للنظام المقترح مع مجموعة من الدراسات المرجعية.

الجدول رقم (5): مقارنة مع الدراسات المرجعية

الدراسة	مجموعة البيانات	المعالجة الأولية	المصنف	نسبة التعرف
[2]	BCI competition III-IVa	DWT+CSP	Ensemble ROF+KNN	94.83%
[3]	Local	CC	Ensemble 5 Classifiers	89.57%
[4]	IV2a	CSP+PSD	Ensemble	91.5±4.4%
	IV2b		KMM+adaboost	83.7±6.3%
[5]	IV2a	CSP	Ensemble CNN+AE	69.98±12.15%
النظام المقترح	IV2a	FBCSP	Hybrid	88.70%
	IV2b			83.03%
	AlexMI			89.37%

يُلاحظ من الجدول (4) تفوق النظام المقترح من حيث نسبة التعرف على الدراسات [4][5] التي استخدمت نفس مجموعات البيانات مع الأخذ بعين الاعتبار نسبة الخطأ العالية للدراسة [4].

بالنسبة للدراسة [2] فإنه على الرغم من الوصول لنسبة تعرف عالية إلا أن مجموعة البيانات IVa صغيرة مقارنة بالمجموعات المستخدمة في هذا البحث، إضافةً إلى استخدام أكثر من تقنية في مرحلة المعالجة المسبقة وهذا يزيد من الكلفة الحسابية واستهلاك موارد النظام.

أما في الدراسة [3] فقد تم الوصول لنسبة تعرف جيدة على مجموعة البيانات المحلية التي تستخدم 24 قطب لتسجيل الإشارات الدماغية مقارنة مع بحثنا الذي يستخدم 3 أو 16 أو 22 قطب فقط حسب كل مجموعة بيانات مستخدمة، كما أنه لم يتم تجريب النظام المقترح في تلك الدراسة على مجموعة بيانات عامة بالتالي لا يمكن تعميم نتائجه.

المقترحات المستقبلية:

إن مصنفات التكديس الهجينة تؤدي إلى تحسين نسبة التعرف بشكل ملحوظ لذلك نقترح تجريب مصنفات تكديس تعتمد على مصنفات فرعية أخرى.

كما أن مصنف الانحدار اللوجستي منفرداً أعطى نتائج جيدة جداً لذلك يمكن العمل على تحسين أداء هذا المصنف وإضافة المزيد من عمليات المعالجة المسبقة.

ومن المقترحات التي يمكن أن تزيد نسبة التعرف بشكل كبير هي استخدام تقنيات متعددة في استخلاص السمات ودمج هذه السمات ولكن يجب الأخذ بعين الاعتبار الكلفة الزمنية واجراء المعالجات اللازمة لتقليل هذه الكلفة.

الخاتمة:

تم في هذا المقال اقتراح مجموعة من المصنفات الهجينة كل منها مكون من ثلاث مصنفات فرعية، وتم تجريب البنى المقترحة على ثلاث مجموعات بيانات قياسية والوصول لنسب تعرف عالية باستخدام خوارزمية واحدة في استخلاص السمات وهي خوارزمية CSP، كما أن النظام المقترح أكثر قابلية للتعميم ونسبة الخطأ لا تتجاوز 1%.

المراجع:

- [1]G. R. BERMUDEZ; A. L. BELCHI; A. GIRAULT; (2019): Testing Brain–Computer Interfaces with Airplane Pilots under New Motor Imagery Tasks. International Journal of Computational Intelligence Systems, vol. 12, No. 2.
- [2]A. SUBASI; S. M. CAISAR; (2021): The Ensemble Machine Learning–Based Classification of Motor Imagery Tasks in Brain–Computer Interface. Journal of Healthcare Engineering, Vol. 2021, Article ID 1970769, 12 pages.
- [3]D. H. KRISHNA; I. A. PASHA; T. S. SAVITHRI; (2018): Multiclass classification of motor imagery EEG signals using ensemble classifiers & cross–correlation. International Journal of Engineering & Technology, vol. 7, NO. 2.6.
- [4]X. WANG; X. DAI; Y. LIU; X. CHEN; Q. HU; R. HU; M. LI; (2023): Motor imagery electroencephalogram classification algorithm based on joint features in the spatial and frequency domains and instance transfer. Neurosci, vol. 17:1175399.
- [5]Y. DONG; X. WEN; F.GAO; C. GAO; R. CAO; J. XIANG; R. CAO; (2023): Subject–Independent EEG Classification of Motor Imagery Based on Dual–Branch Feature Fusion. Brain Sciences, vol. 13, Issue 7.
- [6] 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 15, 473–482.
- [7]A. BARACHANT;(2012): Commande robuste d’un effecteur par une interface cerveau machine EEG asynchrone . SEMANTIC SCHOLAR, Corpus ID: 170981156.
- [8]M. TANGERMANN; K.R. MÜLLER; A. AERTSEN; N. BIRBAUMER; C. BRAUN; C. BRUNNER; R. LEEB; C. MEHRING; K.J. MILLER; G. MUELLER–PUTZ; G. NOLTE; (2012): Review of the BCI competition IV. Frontiers in Neuroscience, vol. 6, p.55.
- [9]A. AGUILETA ; R. F. BRENA ; E. MOLINO ; C. E. GALVAN ; (2022):Facial Expression Recognition from Multi–Perspective Visual Inputs and Soft Voting. Sensors, vol. 22, Issue. 11.
- [10] C. SWEENEY; E. ENNIS; M. MULVENNA; R. BOND; S. O’NEILL;(2022): How Machine Learning Classification Accuracy Changes in a Happiness Dataset with Different Demographic Groups. Computers, VOL.11, NO.5.
- [11] 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. arXiv:00556v1.