

# Improving Performance Of Motor Imagery Systems Using Ensemble Classifier

Dr. Kinda Abo Kassem\*

Dr. Oulfat Jolaha\*\*

Tarek Ali\*\*\*

(Received 22 / 6 / 2023. Accepted 19 / 2 / 2024)

## □ ABSTRACT □

The algorithms and methods employed in the field of brain signal recognition, particularly those based on electroencephalogram (EEG) for motor imagery systems, have exhibited diversity, both in the pre-processing and classification stages. However, these systems currently lack the necessary accuracy for practical implementation. Therefore, it is imperative to enhance the recognition rate across multiple standard datasets to ensure the efficacy of these systems.

The research proposes a hybrid recognition system for brain signal recognition using electroencephalogram (EEG) data. The system utilizes an Ensemble classifier approach, incorporating two ensemble classifiers. The first ensemble classifier consists of four sub-classifiers: Support Vector Machine (SVM), Random Forest, Logistic Regression, and K-Nearest Neighbors (KNN). The second ensemble classifier comprises two sub-classifiers: Random Forest and Logistic Regression. The system also employs Filter Bank Common Spatial Patterns (FBCSP) in the pre-processing stage.

The proposed system was tested on three datasets: IV2a, IV2b, and AlexMI, and achieved recognition rates of 88.69%, 82.71%, and 87.18%, respectively.

**Keywords:** Artificial Intelligence, Brain Computer Interface (BCI), SVM, KNN, Logistic Regression, Random Forest, Electroencephalography (EEG), Filter Bank Common Spatial Pattern (FBCSP).

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. tarekali@gmail.com

## تحسين أداء أنظمة التصور الحركي باستخدام تقنية تجميع المصنفات

د. كندة أبو قاسم\*

د. ألفت جولة\*\*

طارق علي\*\*\*

(تاريخ الإيداع 22 / 6 / 2023. قُبِلَ للنشر في 19 / 2 / 2024)

### □ ملخص □

تتعدد الخوارزميات والطرق المستخدمة في مجال التعرف على الإشارات الدماغية وخاصة أنظمة التصور الحركي المعتمدة على مخطط كهربائية الدماغ، سواء في مرحلة المعالجة الأولية للإشارة أو في مرحلة التصنيف، ولكن لا تزال هذه الأنظمة تفتقر إلى الدقة الكافية لتنفيذها عملياً، لذلك لا بد من تحسين نسبة التعرف وعلى عدة مجموعات بيانات قياسية لضمان فعالية هذه الأنظمة.

يقترح هذه البحث نظام تعرف هجين للتعرف على الإشارات الدماغية بالاعتماد على مخطط كهربائية الدماغ EEG، باستخدام تقنية تجميع المصنفات (Ensemble) حيث تم تصميم مصنفي تجميع، الأول مكون من أربع مصنفات فرعية وهي آلة متجه الدعم (Support Vector Machine) SVM، مصنف الغابة العشوائية Fandom Forest، مصنف الانحدار اللوجستي Logistic Regression ومصنف الجار الأقرب (K Nearest Neighbors) KNN، والمصنف الثاني مكون من مصنفين فرعيين هما الغابة العشوائية والانحدار اللوجستي، واستخدام النمط المكاني المشترك متعدد المرشحات (Filter Bank Common Spatial Pattern) FBCSP في عملية المعالجة المسبقة. تم اختبار النظام المقترح على ثلاث مجموعات بيانات هي IV2a، IV2b و AlexMI والوصول لنسب تعرف 88.69%، 82.71%، و 87.18% على التوالي.

**الكلمات المفتاحية:** الذكاء الاصطناعي، تجميع المصنفات، واجهة الدماغ والحاسوب، مخطط كهربائية الدماغ، النمط المكاني المشترك متعدد الفلاتر، مصنف الغابة العشوائية، آلة متجه الدعم، خوارزمية الجار الأقرب، مصنف الانحدار اللوجستي.

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.  
tarekali@gmail.com

**مقدمة:**

تعتبر أنظمة واجهة الدماغ والحاسوب وخاصةً أنظمة التصور الحركي، أنظمة مهمة جداً لما يمكن أن تقدمه للإنسان من خدمات، فعند تطبيق هذه الأنظمة يمكن تعويض طرف مبتور لشخص ما، فبمجرد أن يتخيل الشخص تحريك الطرف كتخيل تحريك اليد للأعلى يتأين الدماغ بشحنة كهربائية معينة قابلة للقياس، يتم استخدام عدة لواقط أو مستشعرات توضع على فروة الرأس الخارجية ويتم تسجيل هذه الشحنات على شكل إشارة متعددة القنوات تسمى مخطط كهربائية الدماغ (Electroencephalography) EEG، بالتالي عند تصنيف هذه الإشارات يمكن تحديد الحركة المطلوبة من الطرف الصناعي وتنفيذها مباشرةً.

وقد قدمت العديد من الدراسات في هذه المجال ومنها دراسة استخدمت تقنيتين للمعالجة الأولية وهما النمط المكاني المشترك القائم على مرشح التناقض الطبقي (CDFCSP) (Class Discrepancy Filter-Based Common Spatial Pattern) و تقنية التناقض المكاني الزمني (STDF) (Spatio-Temporal Discrepancy Feature) مع مصنف Ensemble مكون من ثلاث مصنفات (Support Vector Machine) SVM فرعية وتم اختبار النتائج على مجموعة البيانات BCI-Competition/IV2a&IV2b والوصول لنسبة تعرف %82.5 [1]، أُجريت دراسة أخرى للتعرف على التصور الحركي باستخدام مصنف (Ensemble Subspace Discriminant) ESD للتعرف على صنفين هما تخيل تحريك اليد اليمنى أو اليسرى، وتم اعتماد خوارزمية (Neighborhood Component Analysis) NCA على مجموعة البيانات BCI-Competition/IV2a&IV2b والوصول لنسبة تعرف %80.04 باستخدام 250 سمة [2].

دراسة أخرى تم فيها مقارنة أداء عدة مصنفات تجميع باستخدام أكثر من خوارزمية معالجة أولية على مجموعة البيانات dataset III of BCI competition II وتم الوصول لأعلى نسبة تعرف عند استخدام تقنية طاقة الحزمة Band Power في المعالجة الأولية و مصنف تجميع (Mix-boost Ensemble) مكون من خمس مصنفات فرعية جميعها من النوع (Adaptive Boosting) Adaboost ولكن لكل منها معاملات مختلفة وتم الوصول باستخدام الخوارزمية المقترحة لنسبة تعرف %85.71 [3].

دراسة أخرى استخدمت مجموعة البيانات IV2a، حيث تم ترشيح الإشارة وفق مرشح تمرير حزمة (7-30Hz)، ثم تطبيق تحويل الموجات وخوارزمية CSP على التوالي في عملية المعالجة الأولية، كما تم استخدام مصنف CNN مكون من ثلاث فروع، وكل فرع مكون من خمس طبقات التفاف وخمس طبقات Max-pooling ثم طبقة تسطيح (Flatten) وأربع طبقات ترابط تام ثم دمج الخرج الناتج عن هذه الطبقات وإدخاله إلى شبكة ترابط تام من طبقتين، تم الوصول باستخدام المصنف المقترح إلى نسبة تعرف %64.75 [4].

قدمت دراسة أخرى عام 2023 للتعرف على التصورات الحركية في الزمن الحقيقي باستخدام 22 قناة تسجيل، شارك في البحث عشر مشتركين وتم التعرف على نوعين من التصورات الحركية (القبض باليد اليمنى - القبض باليد اليسرى)، تم استخدام مرشح تمرير حزمة (8-30Hz) تم تطبيق خوارزمية CSP في المعالجة الأولية للإشارة، وتم الوصول لنسبة تعرف %72.87 باستخدام مصنف تحليل التمييز الخطي (Linear Discriminant) LDA (Analysis) [5].

أجريت دراسة أخرى عام 2023 استخدم فيها تقنيتين لاستخلاص السمات هي CSP للحصول على السمات الترددية و (Power Spectrum Density) PSD 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 [6].

### أهمية البحث وأهدافه:

لاتزال الأبحاث المتعلقة بأنظمة التصور الحركي تفتقر إلى الدقة الكافية لتنفيذها عملياً، كما أن أغلب الدراسات تقوم بقياس دقة التصنيف على قاعدة بيانات قياسية واحدة فقط أو قاعدة بيانات محلية، لذلك فإن زيادة الدقة على عدة مجموعات بيانات تؤدي إلى زيادة فرصة تطبيق هذه الأنظمة على أرض الواقع بشكل فعال وقابل للتعميم. يقدم البحث نظام تعرف باستخدام مصنف تجميع (Ensemble Classifier) لزيادة دقة أنظمة التصور الحركي، واختبار النتائج على ثلاث مجموعات بيانات قياسية لاختبار شمولية وثبات النظام المقترح.

### طرائق البحث ومواده:

يتم في هذا البحث تحميل إشارات EEG المسجلة مسبقاً ومعالجتها ثم تحويلها إلى المجال الطيفي، ثم اختيار المصنفات الفرعية وطريقة تجميع المصنفات للحصول على المصنف المقترح، وتم اختبار النظام المقترح على عدة مجموعات بيانات قياسية وهذه المجموعات هي ( BCI-competition IV2a, BCI-competition IV2b and AlexMI ). أنجز هذا العمل على منصة google colab المجانية 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.

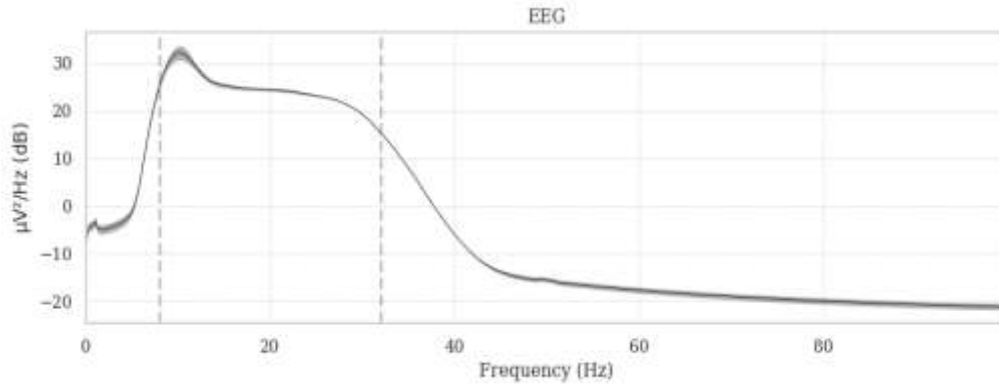
### مجموعات البيانات :

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، حيث تمثل هذه التسجيلات تخطيطات حركية وهي تخطيط تحريك اليد اليسرى (class1)، تخطيط تحريك اليد اليمنى (class2)، تخطيط تحريك كلتا القدمين (class3)، تخطيط تحريك اللسان (class4).

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



الشكل (1) توزيع كثافة الطيف على كامل المجال الترددي

حيث يبين الشكل (1) أن المناطق التي تحوي على أعلى كثافة طيفية هي من 7Hz وحتى 35Hz بينما تكون منخفضة في باقي المجال.




الشكل (2) توزيع كثافة الطيف على الدماغ والأقطاب

تمثل النقاط السوداء في الشكل (2) أماكن توزيع الأقطاب، حيث 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 تخطيطات حركية وهي تخطيط تحريك اليد اليمنى (class1)، تخطيط 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).



الشكل (3) توزيع كثافة الطيف على كامل المجال الترددي

يبين الشكل (3) توزيع الكثافة الطيفية على المجال الترددي كاملاً، ويظهر أن القيم الأعلى موجودة في المجال من 7Hz حتى 35Hz.




الشكل (4) توزيع كثافة الطيف على الدماغ والأقطاب

يبين الشكل (4) توزيع الكثافة الطيفية على الدماغ بعد إجراء متوسط حسابي لكثافة الطيف لكامل مجموعة البيانات، وتوزع الأقطاب الخاصة بمجموعة البيانات.


• 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، حيث تم التسجيل عبر جلستين مختلفتين بفاصل زمني قدره أسبوع وعبر ثلاث أقطاب تسجيل هي (C3,C4,Cz)، تردد التسجيل المستخدم هو (250 Hz) وتم ترشيح الإشارة عبر مرشح تمرير حزمة (0-100 Hz).



الشكل (5) توزيع كثافة الطيف على كامل المجال الترددي

يبين الشكل (5) توزيع الكثافة الطيفية على كامل المجال الترددي لمجموعة البيانات والخطوط المنقطعة تبين المجال من 7Hz حتى 35Hz.



الشكل (6) توزيع كثافة الطيف على الدماغ والأقطاب

يبين الشكل (6) توزيع الكثافة الطيفية على الدماغ حيث تعتمد مجموعة البيانات هذه ثلاث أقطاب فقط. معايير تقييم الأداء:

يتم اختبار أداء أنظمة التصور الحركي باستخدام عدة طرق، فعندما يكون عدد الأصناف 2 فقط يتم قياس الأداء باستخدام معيار المنطقة تحت منحنى خصائص تشغيل جهاز الاستقبال AUC-ROC (Area Under the

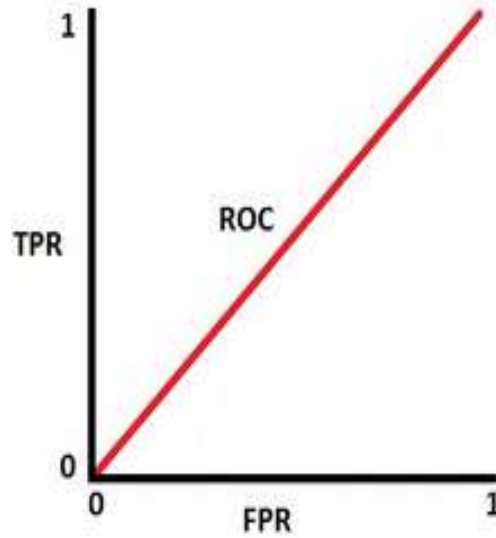
(Receiver Operating Characteristic curve) وفي حال كان عدد الأصناف ثلاثة أو أكثر يتم استخدام الدقة (Accuracy).

لحساب ROC-AUC يتم رسم العلاقة بين معدل الحالات الصحيحة الموجبة (True Positive Rate) TPR ومعدل الحالات الخاطئة الموجبة (False Positive Rate) FPR، ثم حساب المساحة تحت هذا المنحني والشكل يبين مثال لذلك عندما تكون  $ROC-AUC=0.5$ . حيث أن TPR تعطى بالعلاقة (1)[10]:

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

و FPR تعطى بالعلاقة (2)[10]:

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



الشكل (7) المنحني ROC عندما تكون  $AUC=0.5$

ويتم حساب الدقة وفق العلاقة (3)[11]:

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

المعالجة المسبقة:

تتم عملية المعالجة المسبقة على جميع الإشارات الموجودة في مجموعات البيانات الثلاث بنفس الطريقة وتتم بالخطوات الآتية:

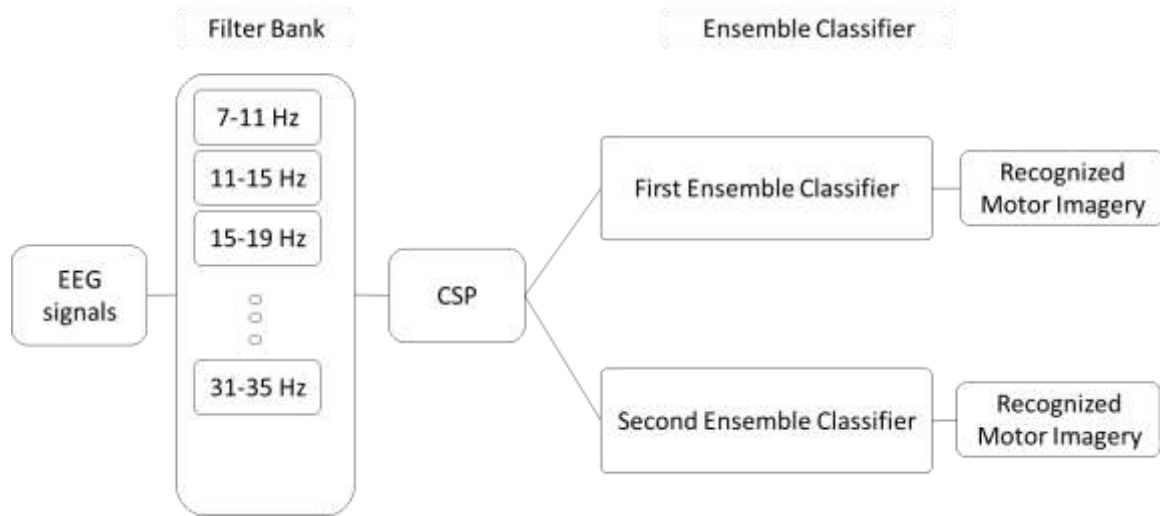
1. تمرير الإشارة عبر مرشح تمرير حزمة (7-35 Hz).
2. تقسيم المجال الترددي إلى 7 حزم ترددية كل منها (4 Hz).

3. تطبيق النمط المكاني المشترك (CSP (Common Spatial Pattern) على كل حزمة ترددية.
4. حساب قوة كثافة الطيف (PSD) لكل قناة.

وبذلك نكون قد حصلنا على السمات المطلوبة لتدخل بعدها إلى المصنف المقترح

#### النظام المقترح لتصنيف التصور الحركي:

تمر الإشارات الدماغية في هذه النظام بعدة مراحل كما يوضح الشكل (8)، حيث يتم ترشيح الإشارات وفق مرشح تمرير حزمة (7-35 Hz)، ويتم تقسيم المجال الترددي إلى حزم ترددية كل منها (4 Hz) ثم تطبيق النمط المكاني المشترك CSP من النوع متعدد المرشحات (FBCSP (Filter Bank CSP)، ثم حساب قوة كثافة الطيف لكل قناة، لتدخل بعد ذلك إلى المصنف المقترح حيث يقوم بالتعرف على الحركة التي تم تخيلها.



الشكل (8) إطار العمل

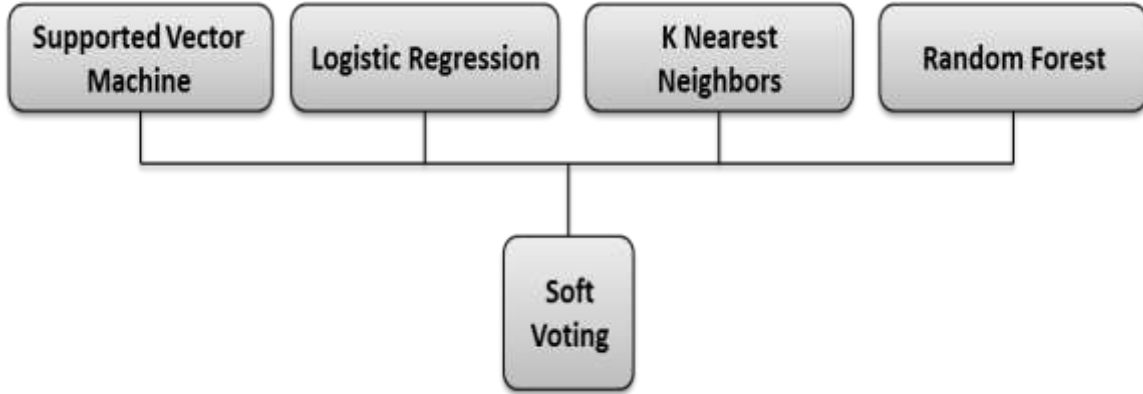
#### التصنيف:

يعتمد المصنف المقترح في هذا البحث على تقنية تجميع المصنفات (Ensemble)، حيث أن مصنف التجميع هو مصنف يستخدم في التعلم الآلي لتحسين أداء التصنيف عن طريق دمج عدة مصنفات فردية (base classifiers) معاً. يتم تدريب كل مصنف فردي على جزء من البيانات ويقوم بإصدار تصنيفه الخاص، ثم يتم استخدام تقنية التجميع لجمع تصنيفات المصنفات الفردية واستخلاص تصنيف نهائي.

هناك عدة أنواع من مصنفات التجميع، ومنها مصنف التصويت الناعم (Soft voting classifier)، في هذا النوع يتم استخدام تقنية التصويت الناعم لاتخاذ القرار النهائي، إذ يتم تعيين وزن لكل مصنف فردي ويتم حساب مجموع الأصوات المرتبطة بكل فئة، ليتم اختيار الفئة التي تحقق أعلى مجموع كتصنيف نهائي.

مصنف التجميع يعتبر استراتيجية فعالة لتحسين أداء نماذج التعلم الآلي عن طريق الاستفادة من قوة وتنوع المصنفات الفردية المختلفة، ويمكن استخدامه في مجموعة متنوعة من المجالات والمشكلات التي تتطلب تصنيف دقيق وموثوق. نقترح في هذا البحث مصنفي تجميع الأول مكون من أربع مصنفات فرعية والثاني مكون من مصنفين فرعيين فقط، والشكل (9) يبين المصنف المقترح الأول.





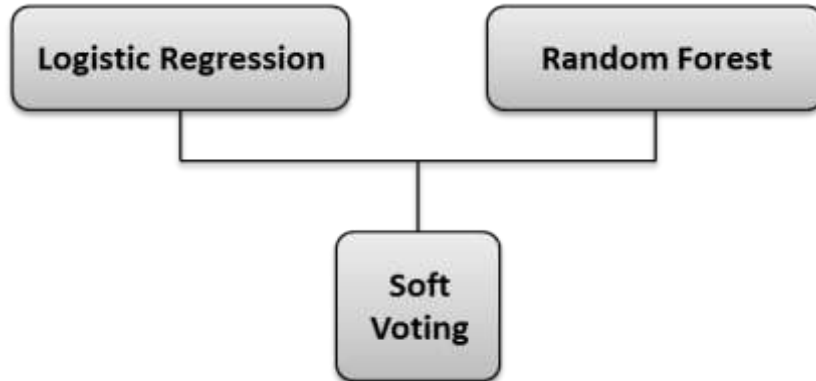
الشكل (9) المصنف المقترح الأول

يتضمن المصنف المقترح الأول أربعة مصنفات فرعية وهي آلة متجه الدعم (Support Vector Machine) SVM والانحدار اللوجستي (Logistic Regression) LR وخوارزمية الجار الأقرب (K Nearest Neighbors) KNN والغابة العشوائية (Random Forest)، ويتم استخدام التابع Soft Voting للحصول على الخرج النهائي، حيث يقوم هذا التابع بحساب متوسط الاحتمالية الناتج عن جميع المصنفات لكل صنف واختيار الصنف ذو الاحتمالية الأعلى وتعطى معادلة التابع Soft Voting بالعلاقة (4)[12]:

$$y = \operatorname{argmax}_i \sum_{j=1}^m w_j p_{ij} \quad (4)$$

حيث  $w_j$  هو وزن المصنف الفرعي رقم  $j$  (ويتم تحديد هذا الوزن خلال مرحلة التدريب)،  $i$  يمثل رقم الصنف،  $p$  تمثل الاحتمالية المتوقعة باستخدام المصنف (أو خرج المصنف)،  $m$  هو عدد المصنفات الفرعية،  $y$  اسم الصنف الناتج. يمكن شرح المعادلة السابقة من خلال الخوارزمية التالية:

- a. من أجل كل صنف  $i$ :
  - a. احسب قيمة التصويت الفردي من خلال ضرب وزن كل مصنف فرعي  $w_{ij}$  بالخرج الناتج عنه  $p_{ij}$ .
  - b. احسب مجموع التصويت الفردي.
  - ii. أرجع قيمة  $i$  التي يقابلها أعلا مجموع تصويت.
  - iii. اطبع اسم الصنف  $y$  التي تقابل رقم الصنف  $i$ .
- أما المصنف المقترح الثاني يتكون من مصنفين فرعيين وهما الغابة العشوائية ومصنف الانحدار اللوجستي كما يبين الشكل (10).



الشكل (10) المصنف المقترح الثاني

**سيناريوهات العمل:**

بعد تحميل قواعد البيانات الثلاث وتصميم النظام المقترح، تتم معالجة كل مجموعة بيانات بشكل مستقل، حيث تمر الإشارات بعملية المعالجة المسبقة والتصنيف، ثم حساب نسبة التعرف لكل مجموعة بيانات على حدة وفق ثلاث سيناريوهات.

يتم في السيناريو الأول حساب نسبة التعرف على التصورات الحركية الموجودة في مجموعة البيانات IV2a باستخدام مصنفات مختلفة وهي آلة متجه الدعم SVM، وخوارزمية الجار الأقرب KNN، الغابة العشوائية RF، الانحدار اللوجستي LR، المصنف المقترح الأول المكون من أربع مصنفات فرعية وهي (SVM، KNN، RF، LR)، والمصنف المقترح الثاني المكون من مصنفين فقط وهما (RF و LR).

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

تم استخدام الدقة (Accuracy) لحساب نسبة التعرف في مجموعتي البيانات IV2a و AlexMI، وتم استخدام المعيار ROC-AUC لحساب نسبة التعرف في مجموعة البيانات IV2b، لنحصل على النتائج المبينة في الجدول (1).

يتم حساب نسبة التعرف على التخييلات الحركية لكل شخص (Subject) على حدة من الشخص الأول (S1) وحتى الأخير (S9) إن وجد ضمن قاعدة البيانات، ثم حساب المتوسط الحسابي (AVG) وبذلك نكون قد حصلنا على متوسط نسبة التعرف لجميع التخييلات الحركية الموجودة في مجموعة البيانات.

**السيناريو الأول:**

عند تطبيق السيناريو الأول وحساب نسب التعرف على مجموعة البيانات IV2a باستخدام المصنفات المذكورة تم الحصول على نسب التعرف المبينة في الجدول (1).

**جدول 1: نسبة التعرف على مجموعة البيانات IV2a**

المصنف	نسبة التعرف									
	AVG	S9	S8	S7	S6	S5	S4	S3	S2	S1
SVM	86.64	85.31	99.19	91.6	73.08	94.9	78.09	98.15	63.95	95.53
KNN	85.89	90.4	99.01	89.15	70.31	93.36	78.84	97.05	61.22	93.72
RF	87.32	91.96	99.09	94.09	64.99	96.32	82.71	98.03	61.24	96.71
LR	88.51	90.21	99.71	93.1	75.84	95.38	85.66	98.55	62.57	95.65
Voting1	87.86	97.02	59.18	99	83.16	96.89	73.23	91.86	99.62	90.78
Voting2	88.69	92.65	99.29	93.5	68.77	96.6	83.33	98.45	67.89	97.8

يُلاحظ من الجدول (1) تفوق مصنف التجميع المقترح الثاني المكون من مصنفين فرعيين على المصنفات المنفردة بنسبة تتراوح من 0.18% وحتى 2.8%، كما يُلاحظ تفوق مصنف الانحدار اللوجستي على مصنف التجميع الأول بمقدار 0.65% علماً أن نسبة الخطأ في هذه الأنظمة قد تزيد عن 1% بالتالي فإن مصنف التجميع الأول قدم أداءً مشابه لمصنف الأداء اللوجستي وتراجع عنه في بعض الحالات بينما تفوق مصنف التجميع الثاني على جميع المصنفات.

**السيناريو الثاني:**

عند تطبيق السيناريو الثاني وحساب نسب التعرف على التصورات الحركية في مجموعة البيانات IV2b باستخدام المصنفات المذكورة تم الحصول على نسب التعرف المبينة في الجدول (2).

**جدول 2: نسبة التعرف على مجموعة البيانات IV2b**

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	<b>SVM</b>
77.42	78.86	82.72	78.86	82.78	89.37	94.02	53.37	55.88	81	<b>KNN</b>
80.49	83.66	81.19	78.96	89.13	91.15	95.46	59.93	59.38	85.62	<b>RF</b>
82.55	86	83.38	85.68	90.13	94.06	97.32	60.26	61.11	85.03	<b>LR</b>
82.64	85.08	84.5	85	90.47	94.12	96.8	59.06	61.05	87.69	<b>Voting1</b>
82.71	84.27	84.64	85.73	91.32	93.38	96.78	60.64	60.17	87.48	<b>Voting2</b>

يُلاحظ من الجدول 2 تفوق المصنف المقترح الأول على المصنفات المنفردة بنسبة تتراوح من 0.09% وحتى 5.22%، كما يُلاحظ تفوق مصنف التجميع الثاني على المصنف المقترح الأول بمقدار (0.07%).

**السيناريو الثالث:**

عند تطبيق هذا السيناريو وحساب نسب التعرف على التصورات الحركية في مجموعة البيانات AlexMI نحصل على النتائج المبينة في الجدول 3.

**جدول 3: نسبة التعرف على مجموعة البيانات AlexMI**

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	<b>SVM</b>
83.67	100	100	62.5	64.38	84.38	86.87	80.62	90.62	<b>KNN</b>
85.15	95	100	61.25	82.5	90	89.38	80	83.13	<b>RF</b>
84.84	97.5	100	65	66.25	97.5	82.5	90	80	<b>LR</b>
86.87	98.75	100	71.25	75	96.25	83.75	85	85	<b>Voting1</b>
87.18	100	100	77.5	81.25	91.25	85	85	77.5	<b>Voting2</b>

يُلاحظ من الجدول 3 تفوق المصنف المقترح الأول على المصنفات المنفردة بنسبة تتراوح من 1% وحتى 3.2%، كما يُلاحظ تفوق مصنف التجميع الثاني على المصنف المقترح الأول بمقدار (1.31%).

**النتائج والمناقشة:**

نلاحظ من النتائج السابقة أن مصنف KNN أعطى أسوأ نسبة تعرف في جميع السيناريوهات، ومصنف الانحدار اللوجستي أعطى وسطياً أفضل أداء بين المصنفات المنفردة.

كما أن استخدام مصنف التجميع المقترح الثاني أدى إلى تحسن نسبة التعرف بنسبة تصل حتى 5.27%، أما مصنف التجميع الأول فقد أعطى نسبة تعرف مماثلة لمصنف الانحدار اللوجستي في إحدى الحالات وأدى إلى تحسن في نسبة التعرف تصل إلى 3.2% في حالات أخرى.

### الاستنتاجات والتوصيات:

إن استخدام مصنفات فرعية ضعيفة الأداء في مصنف التجميع يؤدي إلى تراجع الأداء، بالتالي يجب اختبار كل مصنف منفرد واختيار المصنفات التي تعطي أفضل أداء قبل استخدامها في مصنفات التجميع. ومن المقترحات المستقبلية استخدام مصنف تجميع مكونات من مصنفات تجميع أخرى فرعية ولكن يجب مراعاة زمن التعرف في هذه الحالة، كما يمكن زيادة عمليات المعالجة الأولية على الإشارات الدماغية قبل عملية التصنيف.

### References:

- [1] J. LUO, X. GAO, X. ZHO, B. WANG, N. LU, J. WANG. *Motor imagery EEG classification based on ensemble support vector learning*. ELSEVIER, Computer Methods and Programs in Biomedicine, vol. 193, 2020.
- [2] E. KAYA, I. SARITAS. *Feature Analysis For Motor Imagery EEG Signals With Different Classification Schemes*. Sakarya University Journal of Science, vol. 27, Issue. 2, 2023.
- [3] R. CHATTERJEE, A. DATTA, D. K. SANYAL. *Ensemble Learning Approach to Motor-Imagery EEG Signal Classification*. Science Direct, Pages: 183-208, 2019.
- [27] HUANG G, ZHAO Z, ZHANG S, HU Z, FAN J, FU M, CHEN J, XIAO Y, WANG J AND DAN G (2023) "Discrepancy between inter- and intra-subject variability in EEG-based motor imagery brain-computer interface: Evidence from multiple perspectives". *Front. NEUROSCI*. 17:1122661.
- [5] Wang X, Dai X, Liu Y, Chen X, Hu Q, Hu R and Li M. (2023). "Motor imagery electroencephalogram classification algorithm based on joint features in the spatial and frequency domains and instance transfer". *Front. Hum. NEUROSCI*. 17. 1175399.
- [6] 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. *Review of the BCI competition IV*. Frontiers in Neuroscience, vol. 6, p.55, 2012.
- [7] ZOUCHE, WASSIM & ECHTIQUI, AMIRA. (2022). "EEG Motor Imagery Classification using Fusion Convolutional Neural Network". 10.5220/0010975600003116.
- [8] 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.
- [9] A. BARACHANT. *Commande robuste d'un effecteur par une interface cerveau machine EEG asynchrone*. SEMANTIC SCHOLAR, Corpus ID: 170981156, 2012.
- [10] 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.
- [11] 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.
- [12] A. AGUILETA, R. F. BRENA, E. MOLINO, C. E. GALVAN. *Facial Expression Recognition from Multi-Perspective Visual Inputs and Soft Voting*. Sensors, vol. 22, Issue. 11, 2022.