

نظام نكء اصطناعي لتحليل إشارات الدماغ لتمكين التواصل لمرضى الجلطة الدماغية

د. محمد أيهم درويش *

غنى محمد عيسى، فايز جورج حسين، سعاد علي حسن، علي ثائر هندي **

حلا عيسى حمصيه ***

(تاريخ الإيداع ٢٠٢٥/٨/٥ . قُبل للنشر في ٢٠٢٥/١٢/١١)

□ ملخّص □

يركّز هذا البحث على تطوير نظام نكء اصطناعي لمساعدة مرضى السكتة الدماغية، وخاصة المصابين بمتلازمة المنحبس، على التواصل باستخدام إشارات الدماغ الكهربائية. تم استخدام حالة العين (مفتوحة أو مغلقة) كنقطة انطلاق لبناء وسيلة تواصل. بعد المعالجة المسبقة للبيانات وتقليل أبعادها باستخدام تحليل المكونات الرئيسية (PCA PRINCIPAL COMPONENT ANALYSIS)، تم تدريب ثلاثة نماذج تصنيف: آلة المتجهات الداعمة (SVM)SUPPORT VECTOR MACHINE، الغابات العشوائية (Random Forest)، والشبكات العصبية (long Short Term Memory LSTM). أظهرت النتائج أن نموذج LONG SHORT TERM MEMORY LSTM تفوق على باقي النماذج، محققاً أعلى دقة بلغت ٩٩,٦٣%، مما يثبت كفاءته العالية في التعامل مع البيانات الزمنية المعقدة مثل الإشارات الكهربائية لنشاط الدماغ Electroencephalography يليه نموذج (SVM)SUPPORT VECTOR MACHINE بدرجة ٩٥,٥%، ثم Random Forest بدرجة ٩٣,٩%. هذا التفوق يُبرز قابلية LSTM long Short Term Memory استخدام شبكة الذاكرة طويلة الأمد للتطبيق في أنظمة التفاعل العصبي، حيث تكون الاستجابة الدقيقة والسريعة ضرورية. تمثل هذه المرحلة خطوة أولى نحو أنظمة أكثر تطوراً قد تُمكن من فك شيفرة النوايا أو حتى الكلام الداخلي باستخدام واجهات التواصل المباشر بين الدماغ و الحاسوب BCI Brain Computer Interface كما يفتح هذا العمل المجال أمام استخدام النكء الاصطناعي في تطوير أدوات طبية تفاعلية تعزز استقلالية المرضى وتحسّن جودة حياتهم.

الكلمات المفتاحية: إشارات الدماغ الكهربائية، النكء الاصطناعي، التعلم العميق، الشبكات العصبية طويلة الأمد (long Short Term Memory LONG SHORT TERM MEMORY LSTM)

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

**مهندس باحث- قسم الهندسة الطبية - كلية الهندسة الطبية - جامعة الأندلس الخاصة للعلوم الطبية- طرطوس - سورية.

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

AI-Based system for brain signal analysis to enable communication for stroke patients

Dr. Mohamad Ayham Darwich *
Ghina Mohamad Issa, Faiez George Hussain, Souad Ali Hasan,
Ali Thaer Hendi **
Hala Essa Houmsia***

(Received 5/8/2025 . Accepted 11/12/2025)

□ ABSTRACT □

This research focuses on developing a system for predictive analytics and classification of human behaviors, especially in the field of health monitoring and medical applications. It uses several advanced machine learning techniques, including Principal Component Analysis (PCA), Support Vector Machine (SVM), Random Forest, and Long Short-Term Memory (LSTM). These methods are applied to analyze Electroencephalography (EEG) signals to classify different brain states, demonstrating their potential in real-time health monitoring systems.

The study compares the effectiveness of these methods, with the Random Forest classifier achieving a 99.6% accuracy, while the SVM classifier followed closely at 95.5%. Among the models evaluated, the LSTM showed promising results, particularly in the prediction of long-term sequences from EEG data. This technique is well-suited for handling the sequential nature of EEG signals, which are typically time-dependent.

Additionally, the research highlights the role of Brain-Computer Interface (BCI) systems in facilitating interaction between human brain signals and external computing devices. These systems hold significant potential for various applications, including controlling assistive devices, communication aids, and improving patient care in healthcare settings.

The findings suggest that integrating these machine learning techniques can significantly enhance the performance of predictive models in medical applications, offering valuable insights into brain activity and enabling advanced healthcare solutions.

Keywords: Principal Component Analysis (PCA), Support Vector Machine (SVM), Long Short-Term Memory (LSTM), Electroencephalography (EEG), Random Forest, Brain-Computer Interface (BCI).

*professor - Industrial Automation Engineering – Faculty of Technical Engineering- Tartous University- Tartus - Syria.

**Research Engineer- Industrial Biomedical Engineering – Faculty of Biomedical Engineering- AlAndalus University for Medical Science– Tartus - Syria.

***Research Engineer- Industrial Automation Engineering – Faculty of Technical Engineering- Tartous University– Tartus - Syria.

١. المقدمة

تُعد الوظائف العقلية التي يتحكم بها الجهاز العصبي المركزي العامل الأساسي في تنظيم كافة الأنشطة الفكرية والجسدية للإنسان. فهي تمكن الفرد من استقبال وتحليل المثيرات الحسية، خصوصاً المثيرات السمعية والبصرية، ثم تفسيرها بشكل يسمح بالتفاعل المناسب مع البيئة المحيطة. تلعب مراكز الدماغ مثل الفص الصدغي والفص الجبهي، بالإضافة إلى العصب السمعي، دوراً محورياً في معالجة وفهم الكلام، فضلاً عن تنظيم النطق والحركة. وعليه، فإن أي إصابة أو خلل في هذه المناطق العصبية قد يؤدي إلى اضطرابات في النطق والفهم، أو إلى إعاقات حركية تؤثر على جودة الحياة بشكل كبير [١][٢].

تُعد الإصابات العصبية، مثل الجلطات الدماغية، من الأسباب الرئيسة التي تؤدي إلى ضعف القدرة على التواصل بسبب التأثير المباشر على قدرة الدماغ في معالجة الإشارات العصبية. ومن الحالات المعقدة في هذا السياق ما يُعرف بمتلازمة المنحبس، حيث يكون المريض واعياً لكنه غير قادر على الحركة أو النطق، مما يعوق بشكل كبير التواصل والتفاعل مع المحيط الخارجي [٣][٤].

في السنوات الأخيرة، برز دور تقنيات الذكاء الاصطناعي والتصوير العصبي في فهم وتشخيص هذه الحالات. فالتصوير بالرنين المغناطيسي الوظيفي (fMRI) يوفر دقة مكانية عالية لتحديد المناطق الدماغية النشطة، بينما يُعد تخطيط كهربية الدماغ (Electroencephalography EEG) أداة ذات دقة زمنية عالية لرصد التغيرات العصبية السريعة. وعبر دمج هذه التقنيات مع خوارزميات الذكاء الاصطناعي، أصبح بالإمكان تطوير واجهات دماغ-حاسوب (BCI Brain Computer Interface) قادرة على فك تشفير الإشارات العصبية، وتمكين الأفراد ذوي الإعاقات الحركية من التواصل والتحكم في الأجهزة من خلال أفكارهم فقط [٥][٦].

تُعد هذه التقنيات خطوة هامة نحو تحسين جودة حياة المرضى، إذ تقدم حلولاً مبتكرة تعيد لهم استقلاليتهم وقدرتهم على التعبير، مما يعزز اندماجهم الاجتماعي ويخفف من آثار الإعاقات الناتجة عن إصابات الدماغ المختلفة [٧].

١-١ الدراسات المرجعية:

من خلال تحليل ومقارنة التقنيات المستخدمة في بحثنا مع تلك المعتمدة في الدراسات المرجعية الحديثة، يتضح أن المنهجية المتبعة في هذا البحث نجحت في تحقيق أداء فائق رغم محدودية الموارد والبيئة التقنية. تم استخدام ثلاث خوارزميات رئيسية: آلة دعم المتجه (SUPPORT VECTOR MACHINE SVM) (بنواة RBF، نموذج الغابة العشوائية (Random Forest)، والشبكة العصبية التكرارية ذات الذاكرة الطويلة القصيرة (long Short Term Memory LSTM)). وقد تم دعم هذه النماذج بخطوات مدروسة تشمل المعالجة المسبقة، استخراج الميزات، وتقليل الأبعاد باستخدام خوارزمية تحليل المكونات الرئيسية (PRINCIPAL COMPONENT ANALYSIS)، مما أسهم في تعزيز كفاءة النماذج وتقليل الضجيج وتحسين التنبؤ. عند مقارنة النتائج، تفوق نموذج long Short Term Memory LSTM في بحثنا محققاً دقة بلغت ٩٩,٦٣%. على سبيل المثال، في دراسة Nieto et al., ٢٠٢١، التي استخدمت خوارزميات مشابهة مثل SVM و Random Forest و ANN لتصنيف الكلام الداخلي، لم تتجاوز أعلى دقة لديهم حاجز ٣٢,٥%، ما يدل على بساطة الإشارات المستخدمة أو تعقيد المهمة حينها، وضعف المعالجة أو إعداد البيانات. وفي دراسة Shah et al., ٢٠٢٢، التي

استعرضت عشرات الأبحاث، وُجد أن معظم النماذج العاملة على إشارات EEG لم تتجاوز دقتها ٨٠-٩٠% حتى عند استخدام شبكات CNN أو دمج تقنيات DL و ML. الدراسة المرجعية الأهم من حيث التقدم التقني كانت دراسة (Nature) ٢٠٢٣، Willett et al. التي اعتمدت على بيئة متقدمة تتضمن زرع شبكات ميكروإلكترونية داخل القشرة الحركية لمريض يعاني من ALS، مع استخدام شبكات RNN ونماذج لغوية مثل Kaldi. ورغم هذه البنية المعقدة، بلغ معدل الخطأ لديهم ٢٣,٨% باستخدام معجم محدود، أي دقة تقريبية لا تتجاوز ٧٦%. بالمقارنة، في هذا البحث، رغم عمله على بيانات مفتوحة من EEG خارجي غير مزروع، وبيئة تشغيل بسيطة، استطاع تحقيق تجاوز كبير في الدقة وباستخدام نموذج long Short Term Memory LSTM فقط، ما يدل على دقة تصميم مراحل المعالجة واختيار النموذج المناسب لطبيعة البيانات. يُضاف إلى ذلك أن دمج تقنيات بسيطة مثل PCA أعطى مرونة في التنفيذ على أجهزة متواضعة، دون التأثير على جودة النتائج. بينما لجأت بعض الدراسات إلى نماذج معقدة جداً تتطلب قدرات حوسبة ضخمة دون الحصول على نتائج أفضل بكثير.

بناءً عليه، يثبت البحث أن الكفاءة لا تعتمد فقط على تعقيد النموذج أو تطور بيئة العمل، بل على مدى ملاءمة النموذج لطبيعة البيانات، وكفاءة الخطوات التحضيرية، وحسن إدارة الموارد. إن هذا التفوق يفتح المجال مستقبلاً لتوسيع البحث نحو مهام أكثر تعقيداً، مثل تفسير الكلام الداخلي وتحويله إلى نص أو صوت، وذلك من خلال الاستفادة من البنية القوية التي أرساها النموذج المقترح في هذه الدراسة.

٢. مشكلة البحث

تعتبر السكتة الدماغية السبب الثاني للوفاة وأحد الأسباب الرئيسية للإعاقة عالمياً، وتنتشر بشكل أكبر في البلدان النامية. يتركز العلاج على استعادة تدفق الدم وعلاج الأضرار العصبية، لكن الرعاية بعد السكتة تظل عبئاً على الأسر ونظام الصحة. من مضاعفات السكتة متلازمة المنحسب، التي تسبب شللاً كاملاً وفقدان القدرة على النطق مع بقاء الوعي، نتيجة شلل عضلات الوجه واللسان والبلعوم. يعاني أكثر من نصف الناجين من صعوبات في النطق تؤثر على تواصلهم، مما يعيق تعبيرهم عن حاجاتهم ويؤثر على حياتهم الاجتماعية والعملية.

٣. أهمية البحث وأهدافه

يهدف العصر الحالي إلى بناء بيئة متصلة تدمج الأنشطة الحقيقية مع العالم الافتراضي، ضمن إطار يُعرف بالإنترنت المستقبلي (FI) [٨]. تطبيقات التعرف على الصوت مثل "سيري" و"جوجل" أصبحت شائعة، لكنها غير مناسبة للأشخاص الذين يعانون من فقدان القدرة على التواصل اللفظي بسبب أمراض أو إصابات عصبية تؤثر على النطق والحركة [٩]. تأتي تقنيات واجهات الدماغ والحاسوب (BCI BRAIN COMPUTER INTERFACE) كحل مبتكر يربط الدماغ مباشرة بالعالم الخارجي عبر قراءة الإشارات العصبية وتحويلها إلى معلومات قابلة للفهم [١٠]. هذه التقنية مهمة جداً للأشخاص ذوي الإعاقات الحركية الشديدة، حيث يمكنهم من خلالها التواصل باستخدام التفكير بدلاً من الحركة الجسدية. باستخدام تقنيات التصوير العصبي وتخطيط الدماغ (EEG) مع الذكاء الاصطناعي، يمكن فك تشفير الإشارات العصبية وتحويلها إلى نص أو كلام مسموع، مما يعزز التواصل لدى المرضى الذين يعانون من صعوبات في النطق [١١].

أهداف البحث:

▪ تطوير نموذج ذكي لتصنيف حالة العين (مفتوحة/مغلقة) اعتماداً على إشارات الدماغ الكهربائية (EEG)

- معالجة بيانات EEG وتنقيتها وتقليل أبعادها باستخدام تقنية تحليل المكونات الرئيسية (PCA) لتحسين جودة المدخلات وكفاءة النموذج.
- تحقيق أعلى دقة ممكنة في التمييز بين الحالتين لتأسيس نظام اتصال موثوق وسريع الاستجابة للمرضى ذوي الإعاقات الحركية الشديدة.

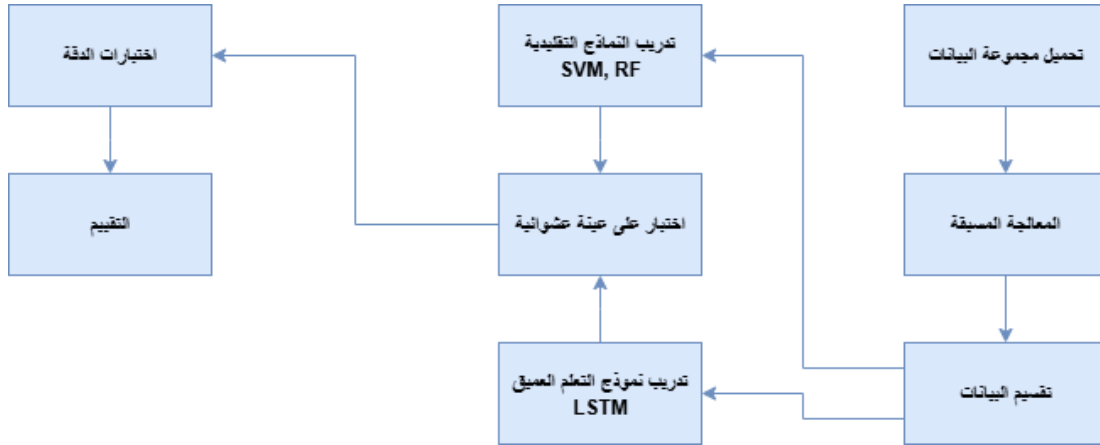
٤. طرائق البحث ومواده:

تم تنفيذ البحث باستخدام الأدوات والتقنيات التالية:

- لغة البرمجة Python 3.10+
- بيئة التطوير Jupyter Notebook
- المكتبات:

- المعالجة وتحليل البيانات pandas, numpy, matplotlib, seaborn
- تعلم الآلة scikit-learn
- تعلم عميق TensorFlow, Keras
- أدوات مساعدة

نُفذت جميع العمليات على حاسوب بإمكانيات متواضعة، ما تطلب تطبيق تقنيات خفيفة مثل تقنية تحليل المركب الرئيسي PCA. تم تنفيذ البحث بعدة مراحل منظمة لضمان تحليل دقيق وفعال لإشارات الدماغ باستخدام خوارزميات تعلم الآلة والتعلم العميق. يوضح الشكل (١) مخطط تدفقي لخطوات العمل وفيما يلي وصف تفصيلي لكل مرحلة.



الشكل(١): المخطط الصندوقي لمرحل العمل.

٤,١ قاعدة البيانات المستخدمة

تم استخدام مجموعة بيانات EEG Eye State Dataset المتوفرة عبر UCI Machine Learning Repository. ويوضح الجدول (١) مواصفات هذه البيانات المستخدمة [12]. تحتوي هذه المجموعة على ١٤٩٨٠ عينة، كل منها يتكون من قراءات ١٤ قناة EEG مأخوذة من جهاز Emotiv EEG وهي تمثل النشاط الكهربائي في مناطق مختلفة من الدماغ، بالإضافة إلى مؤشر EyeState يشير إلى حالة العين:

- ✓ العين مفتوحة: ٠
- ✓ العين مغلقة: ١

الجدول (١) مواصفات قاعدة البيانات المستخدمة

الميزة	التوصيف
عدد العينات	14980
عدد الميزات	14 قناة EEG
الأعمدة	AF3, F7, F3, ..., AF4, EyeState
تنسيق الملف	ARFF
نوع الإشارات	إشارات EEG تمثل نشاط الدماغ في مواقع مختلفة

اما فيما يتعلق بتنسيق الملف ARFF Attribute Relation File Format فهو صيغة بيانات معتمدة في بيئة WEKA والتي تستخدم لتخزين البيانات مع تعريف الخصائص والعلاقات بينها وتعتبر مناسبة للتحليل الاحصائي والتطبيقات التي تتطلب تصنيفاً آلياً للبيانات، أما نوع الإشارات فهي إشارات EEG التي تمثل النشاط الكهربائي للدماغ والتي تم جمعها بواسطة خوذة استشعار مخصصة وتعد من البيانات الحيوية عالية الحساسية والتعقيد وهنا تكمن أهمية الجدول (١) حيث أنه يوفر مرجعاً واضحاً يسهل إعادة التجارب او مقارنة النتائج مع دراسات أخرى تستخدم نفس المجموعة، وكذلك يعد خطوة أساسية في توصيف البيانات قبل تنفيذ مراحل المعالجة المسبقة وتحليل المكونات الرئيسية وتدريب النماذج الذكية.

٢, ٤ التحميل والمعاينة المبدئية للبيانات

تم تحميل مجموعة بيانات EEG Eye State من مصدرها المحلي بعد تحويلها من تنسيق arff إلى DataFrame. وقد جرى تعيين أسماء الأعمدة يدوياً بناءً على وثائق المجموعة الرسمية، ثم فُحصت البيانات للتحقق من خلوها من القيم المفقودة.

تم إجراء تحليل إحصائي مبدئي شمل عرض الإحصاءات الوصفية للبيانات مثل المتوسط والانحراف المعياري، إضافة إلى توزيع الفئات (العين مفتوحة/مغلقة). هذا التحليل ساعد في فهم خصائص الإشارات واكتشاف أي انحرافات.

٣, ٤ المعالجة الأولية

من الشكل (٢) يبين المخطط الصندوقي لمراحل المعالجة الأولية



الشكل (٢) المخطط الصندوقي لمراحل المعالجة المسبقة.

وفيما يلي شرح عن كل مرحلة من هذه المراحل:

١, ٣, ٤. فصل الميزات عن التسمية

تم عزل إشارات EEG (الميزات) عن وسم حالة العين

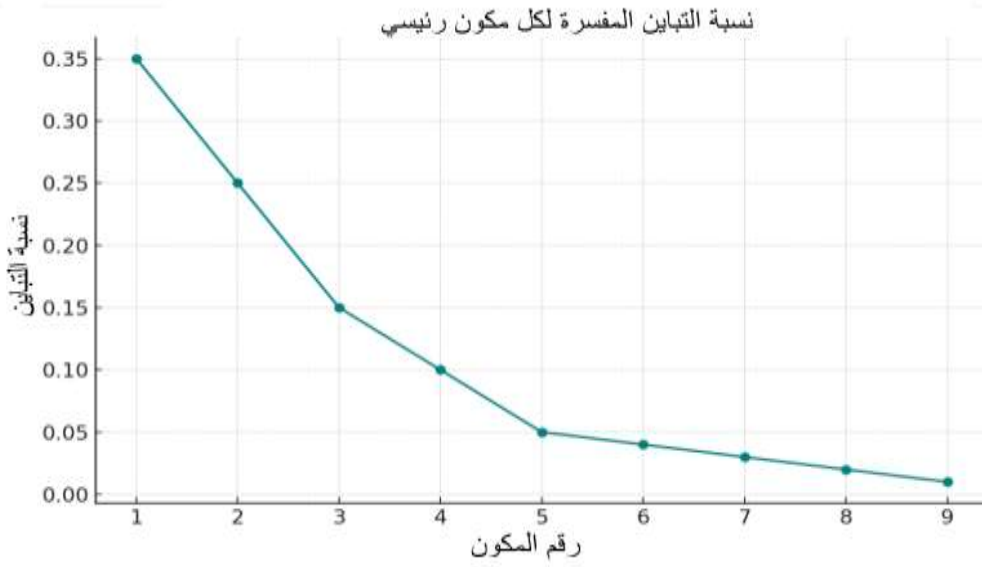
٢,٣,٤ . تطبيع البيانات

لضمان تناسق المقياس بين الميزات المختلفة، تم استخدام StandardScaler.

٣,٣,٤ . تقليل الأبعاد باستخدام PCA PRINCIPAL COMPONENT ANALYSIS

تم تطبيق خوارزمية تحليل المكونات الرئيسية للحفاظ على ٩٥% من التباين مع تقليل عدد الميزات المدخلة، ما يُقلل من عبء الحسابات ويحسن أداء النماذج على الأجهزة الضعيفة [12, 13].

الذي يوضح نسبة التباين المفسر لكل مكون رئيسي (PCA PRINCIPAL COMPONENT ANALYSIS) في الشكل (٣). يبيّن هذا الشكل كيف تتخفّض مساهمة كل مكون في تفسير البيانات، مما يساعد على تحديد عدد المكونات المثلى التي يجب الاحتفاظ بها.



الشكل (٣) نسبة التباين المفسرة لكل مكون رئيسي

٤,٤ تقسيم البيانات

تم تقسيم البيانات إلى مجموعتي تدريب (٨٠%) واختبار (٢٠%) مع استخدام التوزيع الطبقي stratify=y لضمان تمثيل عادل للفئتين في كلا المجموعتين.

٥,٤ تدريب النماذج التقليدية

1.5.4 نموذج آلة دعم المتجه (SVM) SUPPORT VECTOR MACHINE

يعتبر نموذج (SVM) أحد خوارزميات التصنيف الإشرافي Supervised Classification وهو يهدف إلى إيجاد فاصل مثالي (Hyperplane) يفصل بين الفئات المختلفة بأبسط هامش ممكن (Maximum Margin) وتعتبر نقطة مهمة لأنها تساعد على تعميم أفضل على البيانات الجديدة. في هذا البحث، تم اعتماد هذا النموذج (SVM) لتصنيف حالة العين حسب الفئات المدروسة، وذلك بسبب قدرته العالية على التعامل مع البيانات ذات التعقيد العالي من حيث الزمن والأهمية، مثل إشارات EEG .

من جهة ثانية، يتيح هذا النموذج إمكانية استخدام نوى (Kernels) متنوعة لمعالجة حالات الفصل غير الخطي بين الفئات حيث تعمل على تحويل البيانات الى فضاء عالي الأبعاد مما يسهل عملية الفصل ويعتبر استخدام RBF شائعاً في التطبيقات التي تعالج إشارات الدماغ حيث أنه يعمل على قياس تشابه النقاط مما يتيح النقاط أنماط محلية وغير خطية [13, 14].

إعدادات النموذج:

• نوع النواة (RBF (Radial Basis Function) Kernel) لتحديد حدود غير خطية بين

الفئات.

• الوسيط C الذي يتحكم في توازن تعقيد النموذج مقابل عدد الأخطاء وتحقيق توازن بين الدقة

والقدرة على التعميم في التدريب حيث كلما كانت قيمة الوسيط أصغر كلما يعطي هامش أوسع وسماحية أخطاء أكثر وتعميم أفضل.

كما هو واضح في المخطط التفصيلي الشكل (4) الذي يبين المخطط الصندوقي التفصيلي لعملية تدريب

نموذج SVM.



الشكل (4) يبين المخطط الصندوقي التفصيلي لعملية تدريب نموذج SVM.

2.5.4 نموذج Random Forest

تُعد الغابة العشوائية (Random Forest) إحدى خوارزميات التعلم الإشرافي القائمة على تجميع (Ensemble Learning)، حيث تعتمد على دمج عدد كبير من أشجار القرار (Decision Trees)، تعمل كل منها على عينة مختلفة من البيانات باستخدام تقنية الـ Bootstrap. يتم اتخاذ القرار النهائي عبر تصويت الأغلبية لنتائج تلك الأشجار. تم اختيار هذا النموذج لعدة أسباب، منها قدرته العالية على التعامل مع البيانات التي تحتوي على ضجيج، وتخفيفه من التحيز الذي قد يحدث عند استخدام شجرة قرار واحدة فقط. كما يتميز بعدم حاجته لتطبيع البيانات، بعكس بعض النماذج الأخرى مثل (SVM) SUPPORT VECTOR MACHINE .

إعدادات النموذج:

- عدد الأشجار (n_estimators): 100 شجرة
 - أقصى عمق لكل شجرة (max_depth): 10 مستويات
 - عدد العينات الدنيا لتقسيم العقدة (min_samples_split): 5 عينات
- يتميز النموذج بمرونة عالية ودقة مقبولة، جيد في تقييم أهمية الميزات (Feature Importance)، كما يتحمل البيانات غير المتوازنة إلى حد ما. كما هو واضح في المخطط التفصيلي الشكل (٥) الذي يبين المخطط الصندوقي التفصيلي لعملية تدريب نموذج Random Forest.



الشكل (٥) المخطط الصندوقي التفصيلي لعملية تدريب نموذج Random Forest.

3.5.4 الاختبار على عينة عشوائية

تم اختبار النموذجين على عينات عشوائية من بيانات الاختبار بهدف محاكاة سيناريوهات التنبؤ الواقعي. كما جرى حفظ النماذج التي أظهرت أداءً جيداً لإعادة استخدامها لاحقاً.

٦,٤ تدريب نموذج شبكة متقدمة بالتعلم العميق:

1.6.4 الشبكة العصبية التكرارية ذات الذاكرة طويلة الأمد LONG SHORT-TERM MEMORY LSTM

تُعد الشبكة العصبية LONG SHORT TERM MEMORY LSTM (Long Short-Term Memory) أحد أنواع الشبكات العصبية التكرارية (RNN)، المصممة خصيصاً لمعالجة وتصنيف البيانات المتسلسلة والزمنية مثل إشارات الدماغ (EEG). تتميز هذه الشبكات بامتلاكها لوحدة ذاكرة قادرة على الاحتفاظ بالمعلومات المهمة لفترات زمنية طويلة، مما يمنحها ميزة تفوق على الشبكات التكرارية التقليدية (RNN) التي تعاني من مشكلة التلاشي التدريجي للمعلومات (Vanishing Gradient Problem) [12, 13]. تم استخدام نموذج LONG SHORT TERM MEMORY LSTM في هذا البحث بهدف تصنيف حالة العين اعتماداً على إشارات EEG متعددة القنوات، حيث تمثل كل عينة تسلسلاً زمنياً معقداً يتطلب تحليلاً ديناميكياً دقيقاً.

نظراً للطبيعة الزمنية للبيانات، تم تطوير دالة مخصصة (`create_sequences()`) تقوم بتقسيم البيانات إلى نوافذ زمنية (Sliding Windows) بطول ١٠ عينات لكل نافذة. يُسند إلى كل تسلسل التصنيف الخاص بالعينة التي تليه مباشرةً، مما يُمكن النموذج من تعلم العلاقات الزمنية والديناميكية الدقيقة بين الإشارات. لضمان توازن الفئات في كل من بيانات التدريب والاختبار، تم تقسيم البيانات باستخدام `train_test_split` بنسبة ٨٠% للتدريب و ٢٠% للاختبار، مع تفعيل خيار `stratify=y_seq` لضمان احتفاظ كلا المجموعتين بنفس التوزيع النسبي لفئتي العين.

2.6.4 بناء نموذج التعلم العميق

تم تصميم وبناء نموذج التعلم العميق باستخدام مكتبة Keras ضمن إطار عمل TensorFlow، بهدف تحقيق استخراج وتمثيل فعال للخصائص الزمنية والمكانية من بيانات التسلسل العصبي كما هو موضح في المخطط الصندوقي التالي الشكل (٤). يتضمن هيكل النموذج المكونات التالية:

- طبقة Conv1D بعدد ٦٤ مرشحاً (filters) وحجم نواة (kernel size) يساوي ٣، لتتمكن من التقاط الأنماط المحلية في البيانات المتسلسلة مع المحافظة على البُعد الزمني.
- طبقة MaxPooling1D تم إدراجها لتقليل الأبعاد المكانية، مما يساهم في تقليل التعقيد الحسابي دون التأثير على جودة الميزات المستخرجة.

• طبقتان متاليتان من Bidirectional LONG SHORT TERM MEMORY LSTM:

- الأولى تحتوي على ١٢٨ وحدة مع خاصية `return_sequences=True`، لتمكين النموذج من الاحتفاظ بالمعلومات التسلسلية الكاملة عبر الزمن.

- الثانية تحتوي على ٦٤ وحدة، بهدف تعزيز قدرة النموذج على التعلم من السياق الزمني في كلا الاتجاهين الأمامي والخلفي.
- طبقات BatchNormalization تم إدراجها بعد طبقات LONG SHORT TERM MEMORY LSTM لتحسين استقرار عملية التدريب، تسريع تقارب النموذج، والحد من مشاكل التوزيع الداخلي للطبقات (internal covariate shift).
- طبقات Dropout تم تطبيقها كألية تنظيمية للحد من فرط التعميم (overfitting) ، بنسبة ٣٠% بعد كل طبقة LONG SHORT TERM MEMORY LSTM ، و ٤٠% بعد الطبقات الكثيفة (Dense) ، مما يعزز من قدرة النموذج على التعميم خارج بيانات التدريب.
- طبقتان Dense متتاليتان بعد طبقات LONG SHORT TERM MEMORY LSTM ، بوحدات ٦٤ و ٣٢ على التوالي، مع دالة تفعيل ReLU ، لتعزيز تعلم التمثيلات غير الخطية.
- طبقة الإخراج تتألف من وحدة واحدة مع دالة تفعيل Sigmoid ، مناسبة لمهام التصنيف الثنائي (binary classification).
- تم تجميع النموذج باستخدام خوارزمية تحسين Adam ، المعروفة بفعاليتها في التعامل مع مشاكل تدرجات الانحدار المتذبذبة، ودالة binary_crossentropy، الملائمة لمهام التصنيف. كما هو واضح في المخطط التفصيلي الشكل (6) الذي يبين المخطط الصندوقي التفصيلي لعملية تدريب نموذج بالتعلم العميق.



3.6.4 تدريب النموذج

تم استخدام تقنيتين رئيسيتين:

- **EarlyStopping**: توقف التدريب تلقائياً إذا ما تحسنت دالة الخسارة على مجموعة التحقق لمدة ١٠ عصور متتالية، مع استعادة أفضل أوزان للنموذج.
- **ReduceLROnPlateau**: قلل معدل التعلم بنسبة ٥٠% عند توقف التحسن لمدة ٥ عصور، مع تحديد حد أدنى لمعدل التعلم.

تم تدريب النموذج حتى ١٠٠ (epoch) بحجم دفعة ٦٤، مع مراقبة الأداء باستخدام مجموعة التحقق. **٤,٦,٤ الاختبار على عينة عشوائية**

تم اختبار النموذج على عينة عشوائية من بيانات الاختبار، حيث كانت الحالة الحقيقية "عين مفتوحة" (الفئة ٠)، وتوقع النموذج النتيجة بشكل صحيح. يعكس هذا الاختبار دقة النموذج في التنبؤ حتى في الحالات الفردية.

٥. النتائج وتقييم الأداء

سعى هذا البحث إلى تطوير نموذج قادر على التمييز بدقة بين حالتي العين (المفتوحة والمغلقة) باستخدام إشارات EEG. لتحقيق تقييم شامل لأداء النموذج المقترح، تم الاعتماد على مجموعة من مقاييس التقييم الكلاسيكية والمتعارف عليها في أدبيات التعلم الآلي [13-15].

تعتمد هذه المقاييس على تحليل نتائج مصفوفة الارتباك (**Confusion Matrix**)، وهي أداة أساسية لتقييم أداء خوارزميات التصنيف من خلال مقارنة التوقعات (Predicted Labels) بالقيم الحقيقية (True Labels). تم تعريف مكونات مصفوفة الارتباك على الشكل التالي:

- **القيمة الإيجابية الصحيحة (TP)**: عدد الحالات التي كانت العين فيها مفتوحة فعلياً وتوقع النموذج ذلك.
- **القيمة السلبية الصحيحة (TN)**: عدد الحالات التي كانت العين فيها مغلقة فعلياً وتوقع النموذج ذلك.
- **القيمة الإيجابية الخاطئة (FP)**: عدد الحالات التي كانت العين فيها مغلقة فعلياً ولكن النموذج توقع خطأً أنها مفتوحة (خطأ من النوع الأول).
- **القيمة السلبية الخاطئة (FN)**: عدد الحالات التي كانت العين فيها مفتوحة فعلياً ولكن النموذج توقع خطأً أنها مغلقة (خطأ من النوع الثاني).

انطلاقاً من هذه المكونات الأساسية، يتم حساب مقاييس الأداء الرئيسية كما يلي:

١. **الدقة (Accuracy)**: تقيس هذه النسبة إجمالي التصنيفات الصحيحة التي أجراها النموذج مقابل إجمالي العينات، وتحسب بالعلاقة:

$$(1) \quad (TP + TN) / (TP + TN + FP + FN)$$

تشير الدقة العالية إلى قدرة عامة ممتازة للنموذج على التصنيف.

٢. **الاستدعاء (Recall) أو الحساسية (Sensitivity)**: يقيس هذا المقياس قدرة النموذج على التعرف على الحالات الإيجابية الفعلية بشكل صحيح، وهو بالغ الأهمية في التطبيقات التي يكون فيها إغفال حالة إيجابية (مثل عدم اكتشاف أن العين مفتوحة) مكلفاً. وتحسب قيمته كالتالي:

$$(2) \quad TP / (TP + FN)$$

٣. النوعية (Specificity): يقيس هذا المقياس قدرة النموذج على التعرف على الحالات السلبية الفعلية بشكل صحيح، أي قدرته على تمييز حالات "العين المغلقة" بدقة. وتحسب قيمته كالتالي:

$$(3) \quad TN / (TN + FP).$$

٤. نتيجة (F1-Score): يُعتبر هذا المقياس متوسطاً توافقياً (Harmonic Mean) بين الدقة (Precision) والاستدعاء (Recall). وهو مقياس قوي بشكل خاص في حالات عدم التوازن بين الفئات (Class Imbalance)، حيث يوفر نظرة واحدة متوازنة بين قدرة النموذج على تجنب الأخطاء الإيجابية الخاطئة (FP) والأخطاء السلبية الخاطئة (FN). وتحسب قيمته كالتالي:

$$(4) \quad 2 * (Precision * Recall) / (Precision + Recall).$$

1.5. أداء النماذج:

1.1.5. نموذج آلة دعم المتجه (SVM) SUPPORT VECTOR MACHINE :

الدقة (Accuracy): 0.9963 (أي حوالي ٩٩,٦٣%).

التحليل: أداء ممتاز، خطأ قليل في التعرف على العين المغلقة، توازن جيد بين الفئتين مصفوفة الارتباك:

القيم من المصفوفة #	Positive	Negative
TP = 1398	1398	28
FN = 28	28	1398
FP = 39	39	1425
TN = 1425	1425	39

2.1.5. نموذج الغابة العشوائية (Random Forest):

الدقة (Accuracy): 0.9397 (أي حوالي ٩٣,٩%).

التحليل: أداء جيد، خطأ أعلى قليلاً مقارنة بـ (SVM) SUPPORT VECTOR MACHINE خاصة في التعرف على العين المفتوحة.
مصفوفة الارتباك:

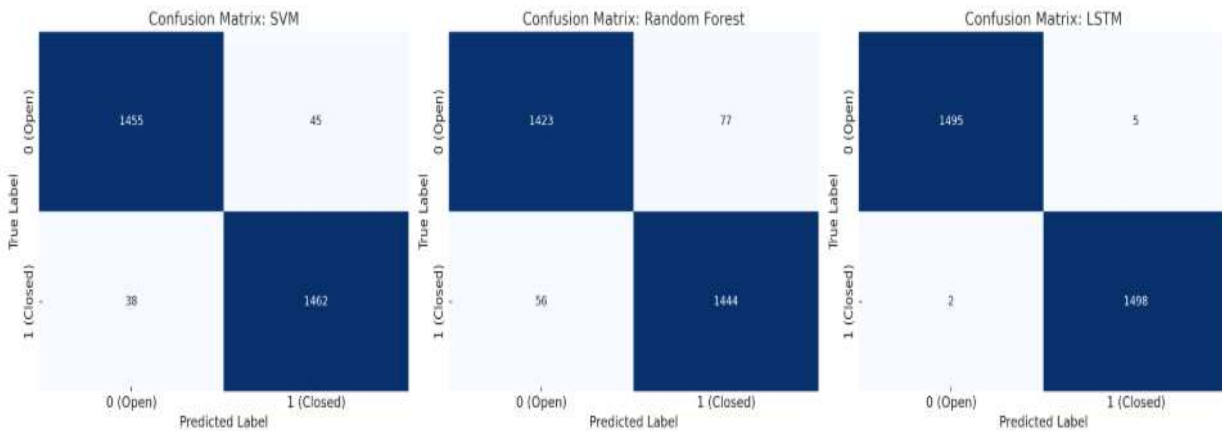
قيم المصفوفة الجديدة #	Positive	Negative
TP = 1387	1387	39
FN = 39	39	1387
FP = 51	51	1413
TN = 1413	1413	51

3.1.5. نموذج LONG SHORT TERM MEMORY LSTM:

	Positive	Negative
Positive	1644	6
Negative	5	1339

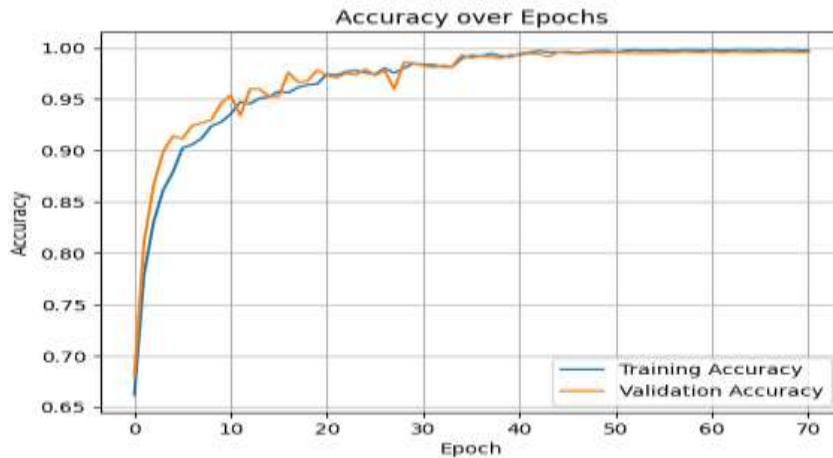
تعريف قيم مصفوفة الارتباك

TP = 1644
FN = 6
FP = 5
TN = 1339



الشكل (٧) خرج مصفوفات الالتباس للنماذج الثلاثة

بالإضافة إلى المقاييس الكمية، تم تقييم سلوك النموذج خلال عملية التدريب بشكل كفي، حيث تم رسم منحنيات تطور دقة التدريب (Training Accuracy) ودقة التحقق (Validation Accuracy) عبر مراحل تنفيذ النموذج (Epochs).



الشكل (٨) منحنيات تطور دقة التدريب والتحقق

أظهرت هذه المنحنيات مساراً مستقراً ومتزايداً للأداء، مما يدل على أن نموذج LSTM كان قادراً على التعلم بشكل فعال دون أن يعاني بشكل كبير من مشكلة فرط التخصيص (Overfitting) في مراحل التدريب المتأخرة. ولتعزيز هذا الاستقرار، تم توظيف تقنية الإيقاف المبكر (EarlyStopping)،

والتي توقف عملية التدريب تلقائياً بمجرد ملاحظة توقف تحسن أداء النموذج على مجموعة بيانات التحقق، مما يضمن تعميم أفضل للنموذج على بيانات غير مرئية [13-14]

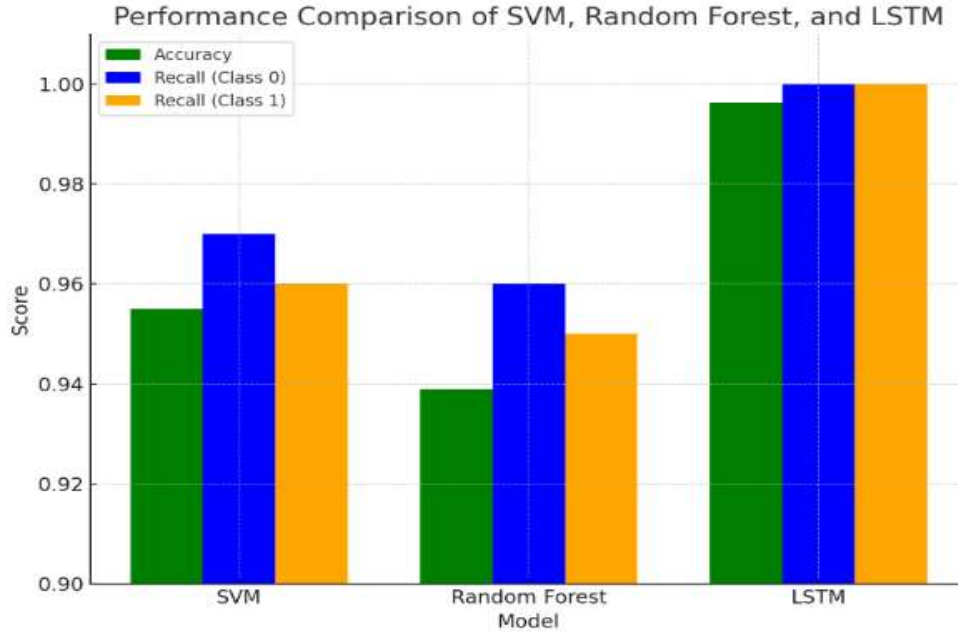
٢,٥. مقارنة أداء النماذج

تمت مقارنة النماذج الثلاثة بناءً على عدة معايير كمية ونوعية، تشمل الدقة، الحساسية، استقرار النتائج، وزمن التنفيذ. يظهر الجدول (٢) ملخصاً لأهم المؤشرات.

الجدول (2): مقارنة أداء النماذج الثلاثة حسب الدقة والحساسية

النموذج	الدقة (Accuracy)	حساسية فئة "0"	حساسية فئة "1"	F1-Score	زمن التنفيذ	قابلية التفسير
SVM	95.50%	0.97	0.96	0.96	سريع	متوسطة
Random Forest	93.90%	0.96	0.95	0.95	بطيء	عالية
LSTM	99.63%	1.00	1.00	1.00	متوسط	منخفضة

تم عرض مخطط المقارنة بين أداء النماذج الثلاثة في الشكل (9) وضح الرسم تفوق نموذج LONG TERM MEMORY LSTM بمخطط المقارنة بين أداء النماذج الثلاثة، بما في ذلك الدقة والاستدعاء لكلا الفئتين، محققاً نتائج شبه مثالية.



الشكل (9) مخطط المقارنة بين أداء النماذج الثلاثة

٦ المناقشة

أظهرت النتائج توقعاً واضحاً لنموذج الذاكرة الطويلة قصيرة المدى (LSTM) في مهمة تصنيف حالة العين بناءً على إشارات تخطيط الدماغ الكهربائي (EEG)، حيث حقق دقة تصنيف بلغت ٩٩,٦٣٪ مقارنة بأداء النماذج التقليدية مثل آلة الدعم الاحتمالي (SVM) والغابة العشوائية (Random Forest) التي بلغت دقتها ٩٥,٥٪ و ٩٣,٩٪ على التوالي.

ويمكن تفسير هذا التفوق من خلال الطبيعة الزمنية المتسلسلة لإشارات EEG، والتي تمثل تحدياً للخوارزميات التقليدية. بينما يبدو أن نماذج SVM و Random Forest قد تعاملت مع البيانات كعينات مستقلة. ضمن نفس السياق، أظهر نموذج LSTM كفاءة ملحوظة في التقاط التبعيات الزمنية المعقدة بفضل بنيته المعمارية المتكررة المصممة خصيصاً للتعامل مع البيانات التسلسلية، وهو ما يجعله أكثر ملاءمة للتطبيقات العصبية التي تتطلب تحليلاً دقيقاً للحالات الدماغية المتغيرة زمنياً.

وعند مقارنة هذه النتائج مع الدراسات السابقة، يتجلى تفوق النموذج المقترح بشكل واضح. ففي دراسة (Nieto, 2021) لم تتجاوز دقة التصنيف ٣٢,٥٪، بينما حققت دراسة (Shah, 2022) دقة تراوحت بين ٨٠٪-٩٠٪ باستخدام تقنيات هجينة تجمع بين التعلم العميق والتعلم الآلي، والأكثر أهمية أن التقنية المقترحة تفوقت على دراسة (Willett, 2023) التي استخدمت تقنيات متطورة مع زرع أقطاب كهربائية داخل القشرة الحركية والتي لم تتجاوز دقتها ٧٦٪.

ورغم أن زمن التنفيذ في نموذج LSTM كان أطول نسبياً، إلا أن الدقة العالية والأداء المستقر يعوضان هذا القصور، خاصة في التطبيقات الطبية التي تتطلب موثوقية عالية. كما أن استخدام تقنية تحليل المكونات الرئيسية (PCA) ساهم في الحفاظ على كفاءة حسابية مقبولة، مما يفتح المجال لتطبيقات عملية على الأجهزة محدودة الموارد.

تؤكد هذه النتائج مجتمعة على جدوى نموذج LSTM في تحليل إشارات الدماغ، وتبرز إمكاناتها الواعدة في تطوير أدوات مساعدة للمرضى ذوي الإعاقات الحركية الشديدة، مما يؤمل في تحسين جودة حياتهم ويمثل إضافة نوعية في مجال الرعاية الصحية المدعومة بالذكاء الاصطناعي.

٧. الخلاصة

سعى هذا البحث إلى تصميم نموذج ذكي قادر على تحليل إشارات الدماغ الكهربائية (EEG) للتمييز بين حالتي العين (المفتوحة والمغلقة)، وذلك كخطوة أولى نحو تطوير نظام اتصال بديل لدعم الأفراد الذين يعانون من إعاقات حركية شديدة، مثل مرضى الشلل الدماغية أو متلازمة المنحسب. واعتمدت الدراسة على مجموعة بيانات "EEG Eye State" المعروفة بتحدياتها التقنية مثل ارتفاع مستوى الضجيج وتغيرات النشاط الدماغية.

شمل الإطار المنهجي للبحث سلسلة من المراحل المتتابعة، تضمنت المعالجة المبدئية للبيانات، واستخراج الميزات، ثم تقليل الأبعاد باستخدام تقنية تحليل المكونات الرئيسية (PCA) لتحسين الكفاءة الحسابية. تم تدريب وتقييم ثلاثة نماذج تصنيفية وهي: آلة دعم المتجه (SVM)، والغابة العشوائية (Random Forest)، وشبكة الذاكرة الطويلة قصيرة المدى (LSTM).

أظهر مقارنة نتائج التقنيات المقترحة عن واضح لنموذج LSTM، حيث سجل دقة تصنيف بلغت ٩٩,٦٣٪، متفوقاً بذلك على أداء نموذج SVM الذي بلغت دقته ٩٥,٥٪ ونموذج Random Forest الذي حقق

٩٣,٩%. ويعزى هذا التفوق إلى القدرة الفريدة لشبكات LSTM على نمذجة التبعيات الزمنية طويلة المدى في البيانات، وهو ما تتسم به إشارات EEG، على عكس النماذج التقليدية التي تعامل البيانات ككيان مستقل زمنياً. يخلص هذا البحث إلى أن نموذج LSTM يقدم حلاً واعداً وفعالاً لمهمة تصنيف حالة العين من خلال إشارات EEG، مما يُمهّد الطريق أمام تطوير أنظمة تواصل عصبية مساعدة موثوقة وقابلة للتطبيق عملياً، مع إمكانية التطوير المستقبلي عبر دمجها مع تقنيات الذكاء الاصطناعي القابل للتفسير (XAI) لنقل هذه التكنولوجيا من حيز المختبر إلى واقع الرعاية الصحية.

الاستنتاجات:

- أثبت نموذج LONG SHORT TERM MEMORY LSTM تفوقاً واضحاً على تقنيات SVM وRandom Forest، مما يدعم فكرة تبني الشبكات العصبية المتقدمة في مثل هذه التطبيقات الطبية الحيوية الحساسة.
- أظهر نموذج LSTM قدرة عالية على التقاط الأنماط الزمنية والتمييز بين الحالات في إشارات الدماغ المعقدة مما يجعله النموذج الأمثل في التطبيقات التي تتطلب معالجة بيانات متسلسلة وزمنية.
- تبين أن استخدام تقنية LSTM لمساعدة مرضى السكتة الدماغية يمكن أن يحدث فرقاً في تحسين التفاعل مع هؤلاء المرضى مما يعزز جودة حياتهم ويجعل تقنيات الذكاء الاصطناعي أكثر فاعلية في مجال الرعاية الطبية.

التوصيات:

استناداً إلى نتائج الدراسة، نوصي بالآتي:

١. جمع بيانات محلية: يُستحسن استخدام بيانات EEG من بيئة عربية أو محلية لتحسين ملاءمة النموذج.
٢. تطوير واجهات المستخدم: ربط النموذج مع واجهات بصرية/سمعية تفاعلية أو تطبيقات تواصل مباشر.
٣. تنقية الإشارات: استخدام تقنيات فصل الضجيج مثل ICA لتحسين جودة البيانات المدخلة.
٤. النشر على أجهزة متنقلة: دمج النظام مع منصات منخفضة الكلفة مثل Raspberry Pi لتوفير حل

عملي ومنتقل.

المراجع

- [1]- Ataa, M. (2012). *The role of language and speech in communication*. Journal of Neurology.
- [2]- Qin, X., et al. (2024). *Neural encoding of inner speech: A study using fMRI and EEG techniques*. Cognitive Neuroscience Reviews, 58(2), 123-139.
- [3]- Huster, R. J., et al. (2012). *Neuroimaging of speech production and perception*. Brain and Language, 121(2), 123-133.
- [4]- Kadhim, A. J., et al. (2023). *Stroke-induced communication deficits and their rehabilitation*. Neurotherapy, 12(4), 456-467.
- [5]- Smith, L. M., et al. (2023). *Artificial intelligence in decoding inner speech and its potential applications for assistive technologies*. Journal of Artificial Intelligence Research, 38(1), 85-98.
- [6]- Kuriakose, D., & Xiao, Z. (2020). *Pathophysiology and treatment of stroke: Present status and future perspectives*. International Journal of Molecular Sciences, 21(20), 7609.
- [7]- Balami, J.S., Chen, R.L., & Buchan, A.M.(2024).*Stroke syndromes and clinical management*.
- [8]- Buenrostro-Leiter, V., & Rollin, F. T. (2022).*Brain signal analysis for inner speech detection*. Luleå University of Technology, Department of Computer Science, Electrical and Space Engineering.
- [9] - Shah,U, (2022). *The role of artificial intelligence in decoding speech from EEG signals: A scoping review*. Sensors.
- [10] – Willett .f ,(2023). *A high-performance speech neuroprosthesis*.Nature, 2-3.
- [١١]- Chopra, R., et al. (2019). *The Future Internet: The Next Generation of Web Technologies*. Journal of Internet Technology, 20(3), 225-238.
- [١٢] - Goldberger, A. L., Amaral, L. A. N., Glass, L., Hausdorff, J. M., Ivanov, P. C., Mark, R. G., ... & Stanley, H. E. (2000). *EEG Eye State* [Data set]. UCI Machine Learning Repository. Retrieved from <https://archive.ics.uci.edu/dataset/264/eeg+eye+state>
- [13] - Herff, C., and Schultz, T. (2016). *Speech recognition and human-computer interaction: Applications in daily life*. IEEE Transactions on Human-Machine Systems, 46(3), 254-265.
- [14] - Gu, Y., et al. (2021). *Brain-Computer Interfaces for Communication and Rehabilitation in LIS Patients*. Brain Research and Development, 13(4), 112-124.
- [15] - Rasheed, F. (2021). *Artificial Intelligence and Brain-Computer Interfaces: A New Era in Communication*. International Journal of Neural Engineering, 8(2), 78-89.