

## كشف نوبات الصرع من إشارات الدماغ EEG باستخدام LPC وLS-SVM

د. م. ألفت جولحة\*

م. زينب ددع\*\*

### ملخص

وفقاً لمنظمة الصحة العالمية WHO، مرض الصرع هو أحد الأمراض الأكثر شيوعاً التي تصيب الجهاز العصبي المركزي، ويتميز بحدوث نوبة الصرع بشكل مفاجئ. وإن القدرة على كشف النوبة بشكل سريع ودقيق آلياً سيدفع للحصول على لمساعدة الطبية الفورية ويتفادى الإصابات الناتجة عنها. يستخدم في هذا البحث الترميز التنبؤي الخطي LPC (Linear Predictive Coding) لاستخلاص سمات نوبات الصرع من إشارات الدماغ EEG (Electroencephalogram). ثم يجري تمرير تلك السمات إلى مصنف LS-SVM (Least Square-Support Vector Machine) لكشف وجود نوبة الصرع من عدم وجودها باستخدام برنامج MATLAB. وأظهرت النتائج تحسناً ملحوظاً في دقة كشف نوبات الصرع بنسبة 98.66% بينما كانت أعلى نسبة كشف في الدراسات السابقة هي 97.6%.

الكلمات المفتاحية: كشف نوبة الصرع، الترميز التنبؤي الخطي LPC، LS-SVM.

\*مدرس، قسم هندسة الحاسبات والتحكم الآلي، كلية الهندسة الميكانيكية والكهربائية، جامعة تشرين، اللاذقية، سورية.

\*\*طالبة دراسات عليا (ماجستير)، قسم هندسة الحاسبات والتحكم الآلي، كلية الهندسة الميكانيكية والكهربائية، جامعة تشرين، اللاذقية، سورية.

# Epilepsy Seizures Detection from EEG Signals Using LPC and LS-SVM

Dr. Oulfat Jolaha\*  
Eng. Zeinab Dadaa\*\*

## Abstract

According to World Health Organization (WHO), epilepsy is one of the most common primary diseases of the central nervous system, which characterizes by epileptic seizures. Thus, the ability to automatically detecting epileptic seizure leading to fast medical assistance. In this research, LPC (Linear Predictive Coding) was used for features extraction of epileptic seizures in EEG (Electroencephalography) signals. Then these features were classified using Least Square-Support Vector Machine (LS-SVM) classifier to detect epilepsy seizure. MATLAB was used for modeling the proposed system, results showed a noticeable improvement in detection epilepsy seizures compared with previous studies.

Keywords: Epileptic seizures Detection, LPC, LS- SVM Classifier.

---

\*PhD Doctor, Department of Computer and Automatic Control Engineering, Faculty of Mechanical and Electrical Engineering, Tishreen University, Lattakia, Syria.

\*\*Postgraduate Student, Department of Computer and Automatic Control Engineering, Faculty of Mechanical and Electrical Engineering, Tishreen University, Lattakia, Syria.

## 1- مقدمة

تعتبر إشارة الدماغ Electroencephalogram (EEG) مهمة جداً لتشخيص مرض الصرع، حيث تحتوي تسجيلات EEG لمريض الصرع على كمية كبيرة من البيانات. لذلك يتطلب كشف البؤر الصرعية تحليلاً كاملاً لإشارات الدماغ EEG وغالباً ما تتجزأ من قبل الخبراء [1]. بذلت جهود عديدة ونشرت أبحاث كثيرة للكشف الآلي لنوبات الصرع التي تختلف من مريض لآخر ومن نوبة لأخرى عن طريق تسجيلات إشارات الدماغ EEG و ECOG. ومن الدراسات التي استخدمت طرق تعلم الآلة الدراسة [2] التي صنفت إشارة ECOG إلى إشارات تدل على وجود صرع من عدم وجوده باستخدام آلية شعاع الدعم (Support Vector Machine) SVM وطرق تحليل المكونات PCA (Principal component analysis) و ICA (Independent Component Analysis)، وجد أنها تعطي حساسية 98% ونوعية 80%، ولكنها تستغرق زمن تشغيل كبير لتحليل المكونات. تم تحليل إشارات الدماغ EEG وتصنيفها لاكتشاف مستويات مخاطر الصرع باستخدام مصنفين: الأول مصنف Fuzzy يعمل بالاعتماد على الميزات المستخلصة من إشارات دماغ المريض مثل الطاقة والتباين والحدة في موجات الدماغ، والمصنف الثاني مصنف آلية شعاع الدعم SVM والإنتروبيا النسبية بحدودها الدنيا وذلك لتحقيق الأمثلية وتحسين التصنيف، وتم استخدام بيانات 10 مرضى وكانت الحساسية 97.07% والنوعية 97% [3]. استخدم التعلم العميق لكشف وتصنيف نوبات الصرع باستخدام CNN (Convolution Neural Network) فكانت الدقة 88.6% والنوعية 90% والحساسية 95% [4]. تم كشف تغير معدل نبضات القلب المتعلقة بنوبات الصرع باستخدام مراقب قلبي صالح للارتداء يعمل لاسلكياً وتم الكشف باستخدام WiSARD Neural Network

و DWT (Discrete Wavelet Transform)، فكانت الدقة جيدة ولكن الأجهزة اللاسلكية تستهلك طاقة كبيرة [5]. وكذلك تم استخدام كل من DT (Decision Tree) و SVM و DWT و CWT (Continuous Wavelet Transform) و RF (Random Forest) و ANN (Artificial Neural Network) لاستخلاص السمات وكشف نوبات الصرع فكانت الدقة لكل من خوارزمية SVM و KNN و DT و ANN هي 97.6% و 97% و 97.6% و 97.4%، على التوالي [6]. ووجد أن استخدام DWT متعدد المستويات وبحزم مختلفة وبتطبيق التوابع الإحصائية الآتية: variance و mean و Skewness و MAV و Shannon entropy و (Standard Deviation) SD و (Mean Absolut Value) يستهلك زمناً حسابياً كبيراً [6]. في حين أنه عند استخدام CNN و CWT في كشف نوبة الصرع من إشارات الدماغ EEG كانت دقة التصنيف 93.5% [7]. واستخدم FFT (Fast Fourier Transform) و (short-time Fourier Transform) STFT و WT (Wavelet Transforms) مع CWT و CNN لكشف وتصنيف نوبة الصرع من إشارات الدماغ EEG فكانت الدقة 93.60% [8].

يلاحظ في الدراسات المذكورة أن أعلى دقة كشف تم التوصل إليها هي 97.6% [6]، لذا استخدم في هذا البحث LPC ومصنف LS-SVM من أجل زيادة دقة الكشف بالنسبة للدراسات المرجعية السابقة.

## 2- هدف البحث وأهميته

بناء نظام لتحسين دقة كشف نوبات الصرع باستخدام الترميز التنبؤي الخطي LPC ومصنف LS-SVM. يمكن هذا النظام من حصول المصاب على المساعدة الطبية الفورية مما يقيه من الإصابات الناتجة عن النوبة. كما أن تحليل EEG المنجز بصرياً من قبل الأطباء يستهلك وقتاً، لذلك فإن تقنيات معالجة إشارات الدماغ EEG تساعد في تسريع هذه العملية وتسمح للمستخدمين الطبيين بتمييز حالات الصرع بدقة.

### 3- مواد وطرق البحث

اعتمدت قاعدة بيانات من جامعة Bonn الألمانية [12]، وهي تتألف من 5 مجموعات لإشارات تخطيط دماغ، كل مجموعة منها تتألف من 100 مقطع، مدة كل مقطع 23.6 ثانية أخذت من الأشخاص باستخدام 32 قطب كالاتي [9]:

- المجموعتان F,N: أخذت من أشخاص بحالة Inter Ictal.
- المجموعتان Z,O: أخذت من أشخاص أصحاء.
- المجموعة S: أخذت من أشخاص بحالة Ictal.

استخدم برنامج MATLAB R2014a وحاسب بمعالج @2.00GHz N2810.

مرض الصرع هو اختلال عصبي داخلي ينتج عن اضطرابات الخلايا الكهربية في خلايا المخ والخلل القائم في العملية الكهربية الدماغية، والعرض الأساسي الجامع لكل أشكال الصرع هو فقدان الوعي بالإضافة إلى حدوث تشنجات ونوبات أحياناً [1]. وتقسم النوبة الصرعية إلى المراحل الآتية [1] و[9]:

1. Pre-Ictal: تحدث تماماً قبل 30 إلى 60 دقيقة من بداية نوبة الصرع.
2. Ictal: تعرف كنوبة صرع تستمر من 1 إلى 3 دقائق يضعف خلالها نشاط الدماغ.
3. Inter-Ictal: تحدث بين نوبتي صرع متتاليتين ويمكن أن تميز نشاط دماغي شاذ أو طبيعي.
4. Post-Ictal: هي الحالة التي يتعافى فيها الدماغ من النوبة الصرعية وتتراوح مدتها بين 30 إلى 60 دقيقة بعد النوبة الحقيقية.

إشارة تخطيط الدماغ EEG هي تسجيل للنشاط الكهربائي التلقائي للدماغ خلال فترة من الزمن. تتركز الاستعمالات التشخيصية بشكل عام على المحتوى الطيفي لتخطيط أمواج الدماغ. ويستخدم تخطيط الدماغ بشكل كبير لتشخيص مرض الصرع الذي يسبب أنماطاً

غير طبيعية في قراءات التخطيط الدماغى. إن وجود نشاطات صرع في إشارات EEG يؤكد تشخيص مرض الصرع عند المريض، وهذه النشاطات تشبه إطلاق شرارة spike أو موجات حادة sharp wave، تتراوح مدة الشرارة بين 20-70 ميلي ثانية وتتبعها موجة حادة لمدة 70-200 ميلي ثانية [1] و[9].

### 3-1 نظام كشف نوبات الصرع المقترح

أول مرحلة في نظام كشف نوبات الصرع المقترح هي إزالة الضجيج باستخدام مرشح تمرير منخفض يعمل بتردد قطع  $Cutoff = Fs/8 = 21.7 \text{ Hz}$  حيث  $Fs = 173.6 \text{ Hz}$  وذلك لأن الترددات التي تعطي معلومات مهمة عن نوبات الصرع تقع في المجال الترددي لموجات إلفا ( $\alpha$ ) ودلتا ( $\delta$ ) الدماغية التي تتراوح تردداتها بين [0-4 Hz] لموجات ( $\alpha$ ) و [8-16 Hz] لموجات ودلتا ( $\delta$ ).

وفي المرحلة الثانية يتم تحويل إشارات الدماغ EEG الناتجة إلى المجال الترددي باستخدام تحويل فورييه السريع FFT، وهو تحويل يحسب قيمة تحويل فورييه المتقطع DFT بسرعة، وتعود سرعته لعدم حسابه للأجزاء التي مجموعها يساوي صفر في تحويل فورييه المتقطع [10]. وتبنى فكرة هذا التحويل على تجزئة التابع  $s(n)$  إلى عدد من التتابعات الفرعية الأصغر طولاً حيث  $n$  متغير في المجال الزمني. ولإيضاح مبدأ التقسيم في الزمن نعتبر الحالة الخاصة عندما يكون  $N = 2^M$  حيث  $M$  عدد صحيح موجب أكبر من الواحد وبما أن  $N$  عدد زوجي يمكن تجزئة التابع  $s(n)$  إلى تتابعين فرعيين متساويين كل منهما بطول  $N/2$ ، التابع الأول  $g(n)$  من العينات ذات الترتيب الزوجي  $0, 2, 4, \dots, N-2$  والتتابع الثاني  $h(n)$  من العينات ذات التتابع الفردي  $1, 3, 5, \dots, N-1$  وفق المعادلة الآتية [10]:

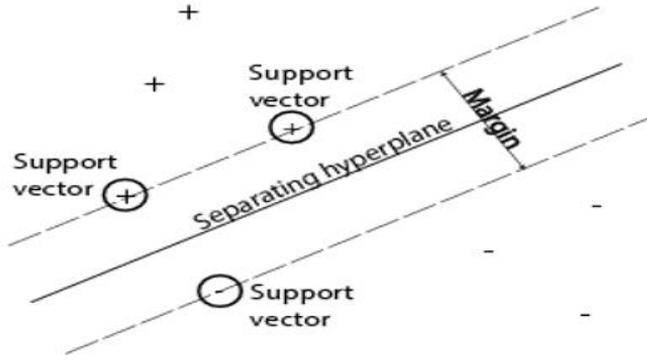
$$s(k) = \sum_{r=0}^{\frac{N}{2}-1} s(2r) W_{N/2}^{rk} + W_N^K \sum_{r=1}^{\frac{N}{2}-1} s(2r+1) W_{N/2}^{rk} \quad (1)$$

$$r = 0, 1, 2, 3, \dots, \frac{N}{2} - 1 \quad \text{و} \quad W_{N/2} = e^{-j\frac{2\pi}{N/2}}$$

وبعد الحصول على الإشارة في المجال الترددي يتم استخلاص السمات باستخدام الترميز التنبؤي الخطي LPC، الذي يعتمد على فكرة أنّ العينة الحالية يمكن أن تكون بشكل تقريبي مجموعة خطية من العينات السابقة توصف رياضياً بالعلاقة [11]:

$$s(n) \approx a_1s(n-1) + a_2s(n-2) + \dots + a_p s(n-p) \quad (2)$$

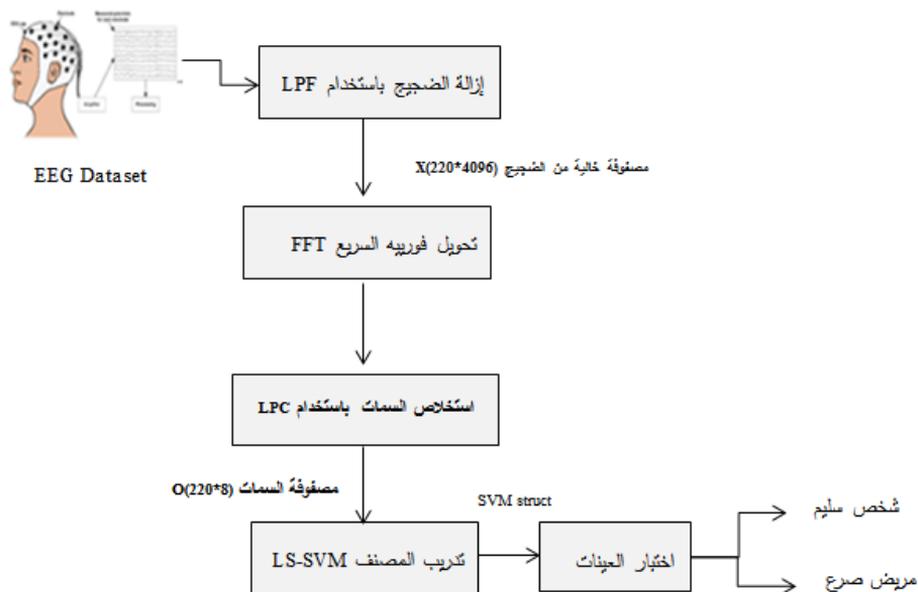
حيث تمثل  $n$  طول السلسلة و  $p$  يمكن أن تكون عدداً ما من 1 إلى  $n-1$  والترميز التنبؤي الخطي يحسب مجموعة المعاملات  $\{a_k\}$  التي تصف التشكيلات الموجية المميزة Formants، وهي تمثل الترددات عند القمم الاهتزازية resonant peaks وتدعى ترددات الموجة المميزة. يتم تخمين مواقع هذه الترددات المميزة في إشارة EEG عن طريق حساب معاملات التنبؤ الخطي  $\{a_k\}$  على طول الإشارة وإيجاد القمم في الطيف الناتج عن مرشح النموذج التنبؤي الخطي. ومن ثم تبدأ مرحلة تدريب المصنف LS-SVM الذي يعمل على تصغير مجموع مربعات الأخطاء للتابع الهدف. يقوم مصنف SVM في حالة التصنيف الثنائي بإيجاد أفضل مستوي يفصل جميع نقاط الصنف الأول عن جميع نقاط الصنف الثاني، وأفضل مستوي حدي هو المستوي الذي يملك أكبر هامش بين الصنفين، ويعني الهامش العرض الأعظمي للكتلة الموازية للمستوي التي ليس لها نقاط بيانات داخلية وموجهات الدعم هي نقاط البيانات الأقرب إلى مستوي الفصل وهذه النقاط على حد الكتلة الموازية لمستوي الفصل، وهذا مبين في الشكل (1) [3]. تستخدم ثلاث طرق في مصنف SVM هي البرمجة الخطية من الدرجة الثانية QP، والتحسين التسلسلي الأدنى SMO وهي خوارزمية لحل مشكلة البرمجة التربيعية التي تنشأ أثناء تدريب المتجهات الداعمة وهي الطريقة الافتراضية للمصنف SVM، ولقد جرى في هذا البحث استخدام طريقة المربعات الصغرى LS-SVM التي يتم فيها تحليل البيانات والتعرف على الأنماط.



الشكل (1) مصنف SVM [3].

### 2-3 مخطط نظام كشف نوبات الصرع المقترح

يبين المخطط في الشكل (2) خطوات كشف نوبات الصرع في النظام المقترح حيث يتم إدخال بيانات إشارات EEG وبعدها يتم إزالة الضجيج منها باستخدام المرشح filterfft وهو مرشح تمرير منخفض LPF الذي ينتج مصفوفة خالية من الضجيج  $X(220*4096)$ ، ومن ثم يتم تحويل الإشارات إلى المجال الترددي باستخدام تحويل فورييه السريع FFT، ليتم استخلاص سمات المصفوفة  $X$  باستخدام الترميز التنبؤي الخطي LPC وتنتج مصفوفة السمات التي تمثل معاملات التنبؤ الخطي  $O(220*8)$  وتستخدم في تدريب المصنف LS-SVM. وبعدها يتم تدريب المصنف واختباره على مجموعة من العينات ليكون خرج الاختبار إما شخص مصاب بالصرع أو شخص سليم. من المهم في إشارة EEG أن تكون الإشارة موصوفة بصيغة رياضية سهلة وبسيطة مع الاحتفاظ بكل خصائص الإشارة لذلك تم استخدام LPC في هذا البحث.

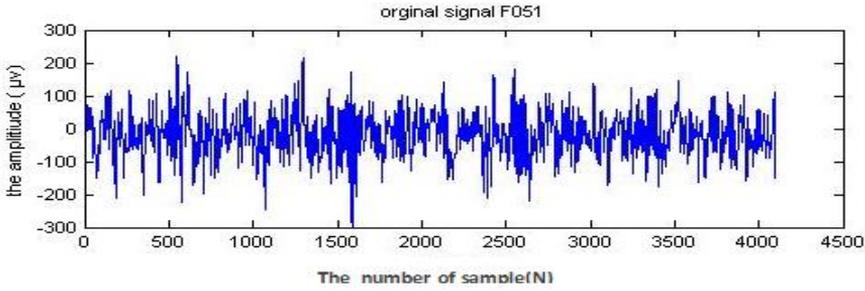


الشكل (2) مخطط نظام كشف نوبات الصرع المقترح.

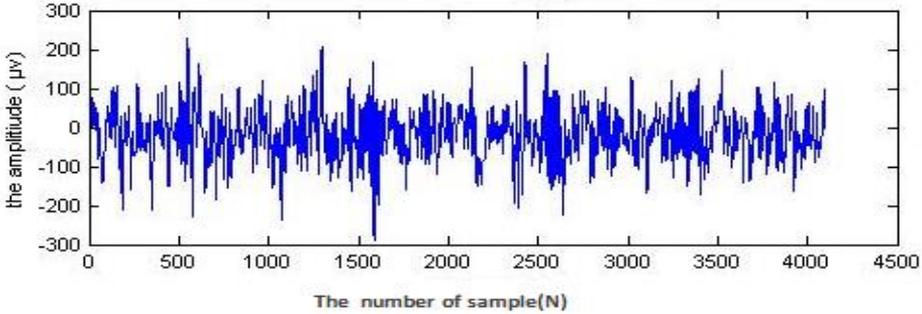
#### 4- النتائج ومناقشتها

جرى إدخال 220 إشارة EEG مأخوذة من قاعدة البيانات لمجموعة أشخاص أصحاء وأشخاص في حالة نوبة الصرع Inter-Ictal و Ictal على نظام كشف نوبات الصرع المقترح، حيث تم إزالة الضجيج من إشارات EEG المدخلة باستخدام مرشح تمرير منخفض LPF، ومن ثم تحويل الإشارات للمجال الترددي باستخدام تحويل فورييه السريع FFT وبعد ذلك تم استخراج السمات باستخدام الترميز التنبؤي الخطي LPC بأكثر من درجة. استخدم برنامج MATLAB في نمذجة نظام كشف نوبات الصرع المقترح، وتم عرض 3 إشارات من إشارات EEG الأصلية فقط كأمثلة مع نتيجة إزالة الضجيج منها وعرض نتائج الترميز التنبؤي الخطي LPC باستخدام درجات مختلفة وذلك في الأشكال من الشكل (3) إلى الشكل (17)، ولوحظ أن الدرجة 8 هي الأنسب فالدرجات الأكبر من هذه الدرجة تعطي تغيرات في الإشارة قليلة جداً ولا تفيد في التصنيف.

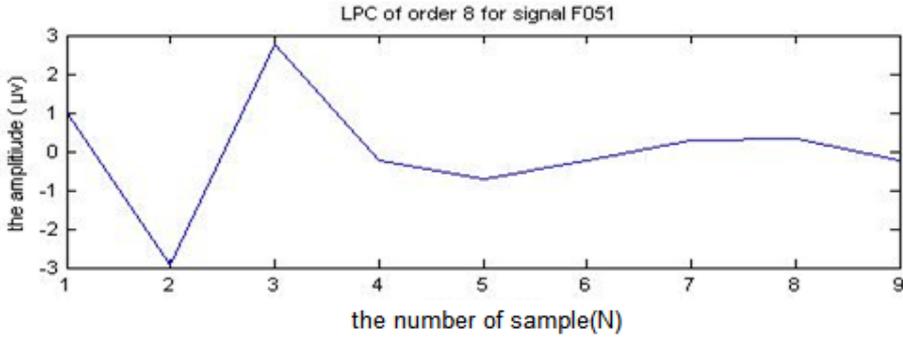
يبين الشكل (3) إشارة EEG الأصلية للإشارة F051 وهي لشخص مريض صرع بحالة النوبة INTER ICTAL. نلاحظ وجود موجات عابرة بشكل شرارات مفردة أو متتالية وموجات حادة أو موجات حادة تتبعها شرارة ولكنها بشكل عابر ولا تظهر على طول التسجيل الكهربائي لإشارة EEG. بينما يبين الشكل (4) الإشارة F051 بعد إزالة الضجيج منها باستخدام مرشح تمرير منخفض LPF بتردد قطع 21.7 Hz. والأشكال (5) و(6) و(7) تبين معاملات التنبؤ الخطي المستخلصة من الإشارة F051 بدرجات تنبؤ مختلفة، التي تمثل قيم تخمينية لمواقع الترددات المميزة عند القمم الاهتزازية في طيف الإشارة.



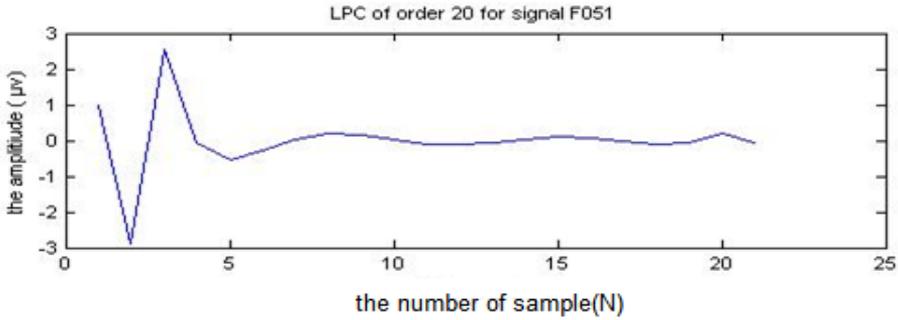
الشكل (3) إشارة EEG الأصلية للإشارة F051.



الشكل (4) إشارة F051 خالية من الضجيج.

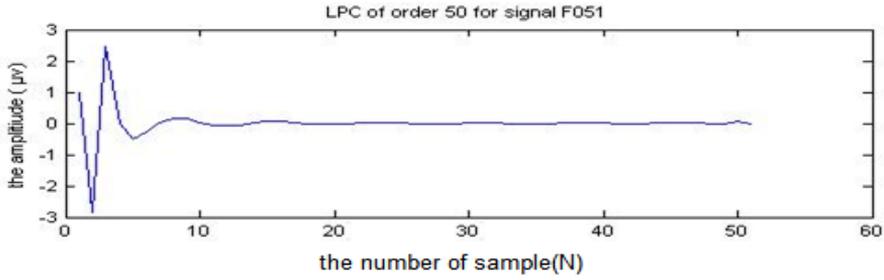


الشكل (5) الترميز التنبؤي الخطي للإشارة F051 من الدرجة 8.

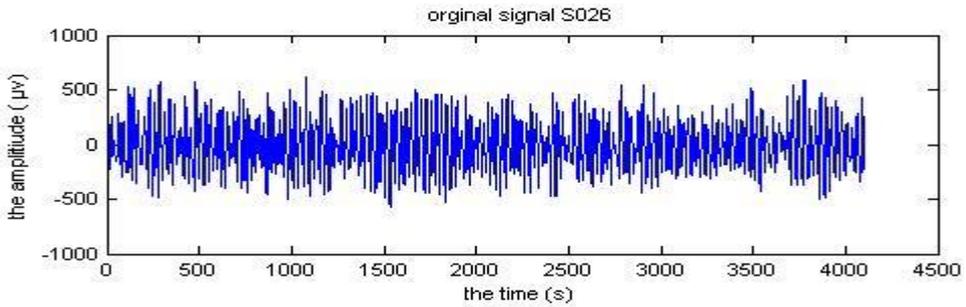


الشكل (6) الترميز التنبؤي الخطي للإشارة F051 من الدرجة 20.

يبين الشكل (8) إشارة EEG الأصلية للإشارة S026 وهي لشخص مريض صرع بحالة النوبة ICTAL. نلاحظ وجود إطلاقات مستمرة من الموجات غير المنتظمة والمطالات والترددات المتغيرة ووجود شرارات تتبعها موجات حادة معقدة ووجود فرط تزامن إيقاعي أو خمول في كهربائية الدماغ أطول من معدلاته خلال حالات InterIctal. والشكل (9) يبين الإشارة S026 بعد إزالة الضجيج منها باستخدام مرشح تمرير منخفض LPF بتردد قطع 21.7 HZ. الأشكال (10) و(11) و(12) تبين معاملات التنبؤ الخطي المستخلصة من الإشارة F051 بدرجات تنبؤ مختلفة، التي تمثل قيم تخمينية لمواقع الترددات المميزة عند القمم الاهتزازية في طيف الإشارة.

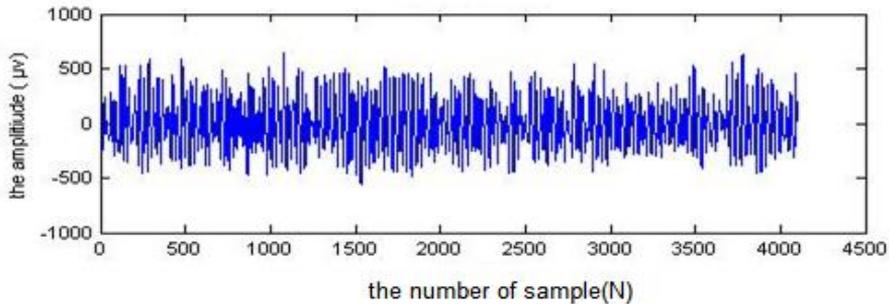


الشكل (7) الترميز التنبؤي الخطي للإشارة F051 من الدرجة 50.

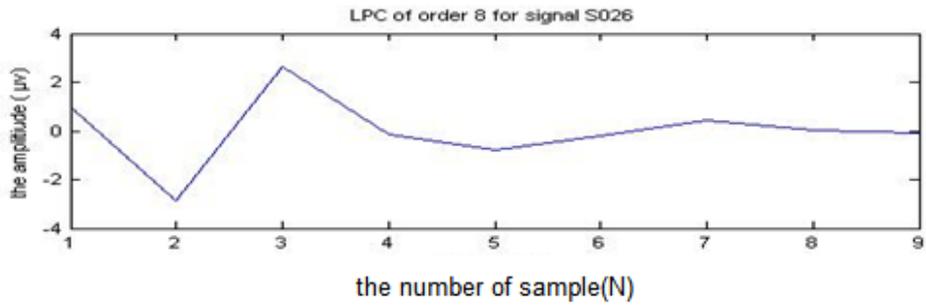


الشكل (8) إشارة EEG الأصلية للإشارة S026.

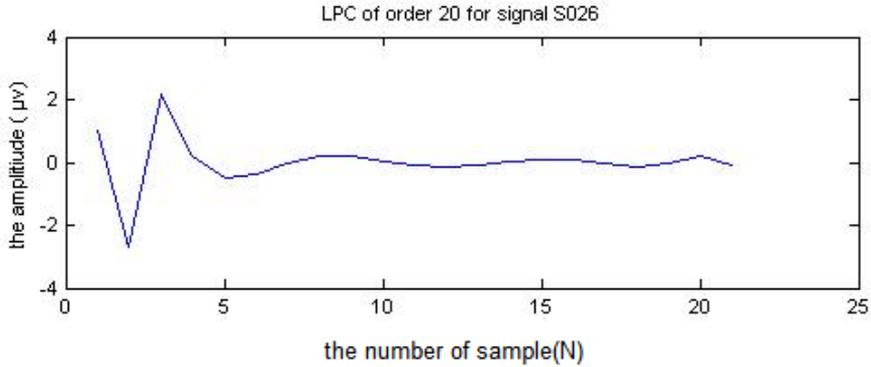
يبين الشكل (13) إشارة EEG الأصلية للإشارة F051 وهي لشخص سليم ونلاحظ أنها إشارة دماغ طبيعية لا يوجد فيه شذوذ أو موجات غير طبيعية. والشكل (14) يبين الإشارة O079 بعد إزالة الضجيج منها باستخدام مرشح تمرير منخفض LPF بتردد قطع  $21.7\text{HZ}$ .



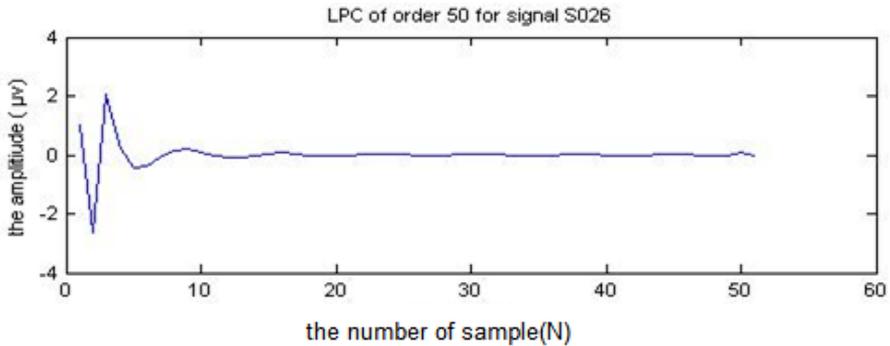
الشكل (9) إشارة S026 خالية من الضجيج.



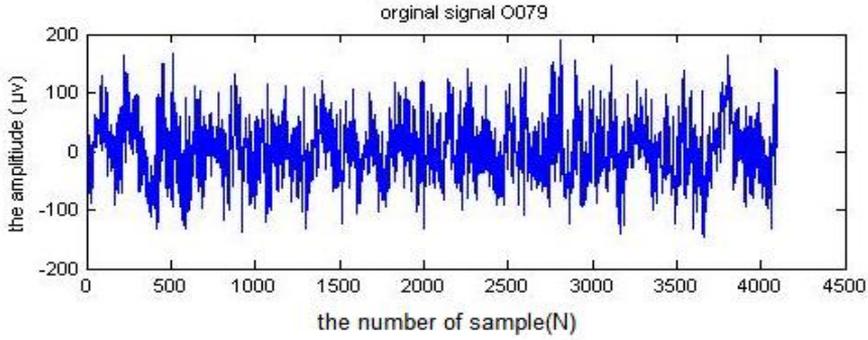
الشكل (10) الترميز التنبؤي الخطي للإشارة S026 من الدرجة 8.



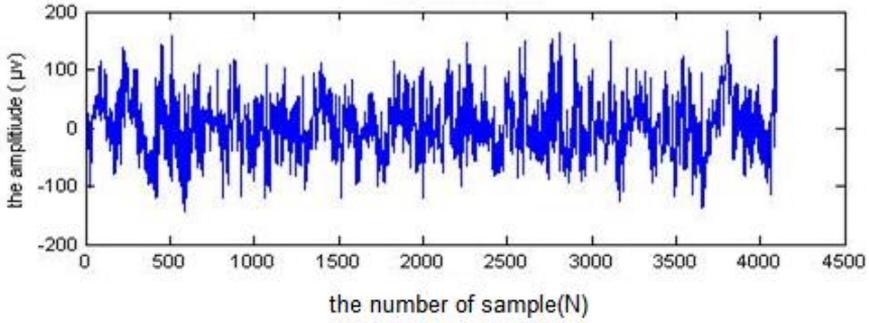
الشكل (11) الترميز التنبؤي الخطي للإشارة S026 من الدرجة 20.



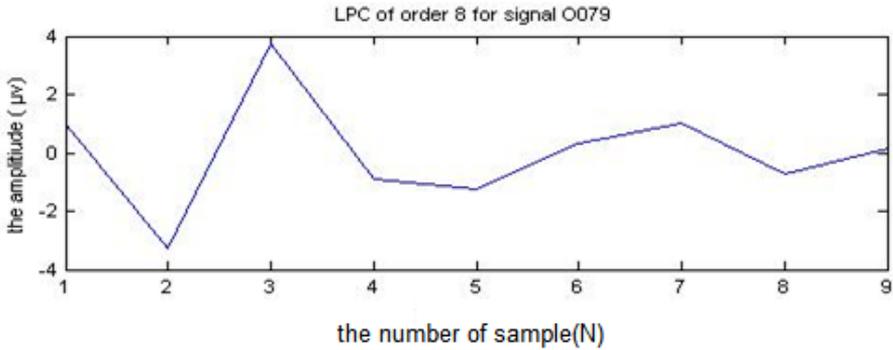
الشكل (12) الترميز التنبؤي الخطي للإشارة S026 من الدرجة 50.



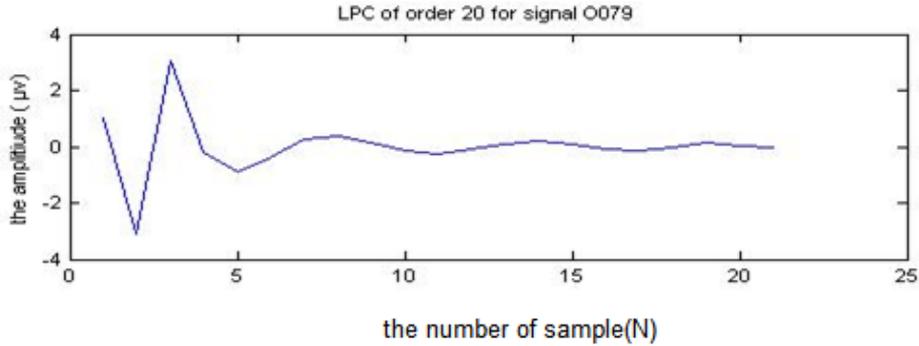
الشكل (13) إشارة EEG الأصلية للإشارة O079.



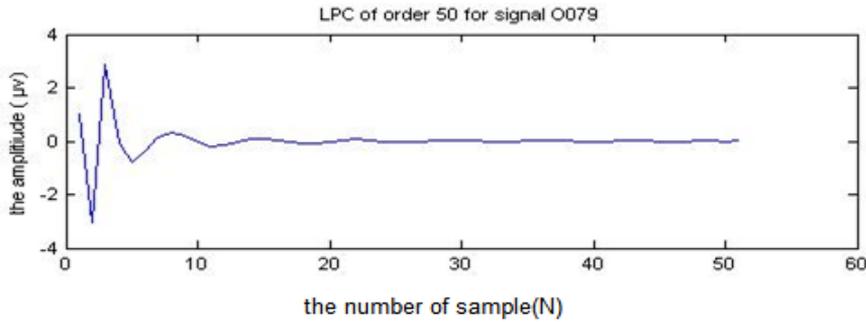
الشكل (14) إزالة الضجيج للإشارة O079.



الشكل (15) الترميز التنبؤي الخطي للإشارة O079 من الدرجة 8.



الشكل (16) الترميز التنبؤي الخطي للإشارة O079 من الدرجة 20.



الشكل (17) الترميز التنبؤي الخطي للإشارة O079 من الدرجة 50.

بينما تبين الأشكال (15) و(16) و (17) معاملات التنبؤ الخطي المستخلصة من الإشارة O079 بدرجات تنبؤ مختلفة، التي تمثل قيم تخمينية لمواقع الترددات المميزة عند القمم الاهتزازية في طيف الإشارة.

تم تدريب المصنف LS-SVM باستخدام 220 عينة تدريب ومن ثم اختباره على 250 عينة من قاعدة البيانات. يبين الجدول (1) نتائج التصنيف لبعض عينات EEG وتوافقه مع التصنيف الحقيقي للإشارة الذي يمثل رأي الخبراء حسب قاعدة البيانات المستخدمة. بينما الجدول (2) يعطي نتائج اختبار المصنف على مجموعات جزئية من قاعدة

البيانات. ولدراسة أداء أي مصنف في مجال التحليل التنبؤي تعد مصفوفة الارتباك (confuse matrix) من أفضل المقاييس. يبين الشكل (18) عناصر مصفوفة الارتباك وهي [13]:

- True Positive (TP) نحصل عليه عندما يكون تصنيف المصنف ايجابي والتصنيف الحقيقي ايجابي بمعنى أن المصنف أصاب 'hit'.
- True Negative (TN) نحصل عليه عندما يكون تصنيف المصنف للعينة سلبى والتصنيف الحقيقي سلبى أي بمعنى الرفض الصحيح correct rejtion .
- False Positive (FP) نحصل عليها عندما يكون تصنيف المصنف للعينة ايجابي والتصنيف الحقيقي سلبى أي خطأ نوع I .
- False Negative (FN) نحصل عليه عندما يكون تصنيف المصنف للعينة سالب والتصنيف الحقيقي موجب أي خطأ من النوع II.

		Ground Truth	
		Positive	Negative
Prediction	Positive	True Positives	False Positives
	Negative	False Negatives	True Negatives

الشكل (18) مصفوفة الارتباك [13].

تعرف حساسية *sensitivity* المصنف بأنها النسبة المئوية للأشخاص المصابين بالمرض وتم تشخيص إصابتهم بالمرض بشكل صحيح من قبل المصنف وتحسب بتطبيق العلاقة [13]:

$$sensitivity = \frac{TP}{TP+FN} * 100\% \quad (3)$$

والنوعية *specifity* هي النسبة المئوية للأشخاص الأصحاء الذين تم تشخيصهم بأنهم غير مصابين بالمرض من قبل المصنف وتحسب بتطبيق العلاقة [13]:

$$specificity = \frac{TN}{TN+FP} * 100\% \quad (4)$$

أما الدقة *precision* فتعبر عن نسبة النواحي الإيجابية المميزة بشكل صحيح وتحسب بتطبيق العلاقة [13]:

$$precision = \frac{TP}{positive\ output} \quad (5)$$

يبين الجدول (1) نتائج التصنيف لبعض عينات EEG المستخدمة في قاعدة البيانات. بينما يقدم الجدول (2) تقيماً لأداء نظام كشف نوبات الصرع المقترح، فمثلاً من أجل المجموعة F+N+O يعطي نظام الكشف المقترح دقة 99% وحساسية 100% ونوعية 98%، وعند اختباره على إشارات من جميع مجموعات قاعدة البيانات F+N+S+Z+O يعطي دقة 98.66% وحساسية 98.66% ونوعية 98%. ومن خلال مقارنة هذه النتائج مع الدراسات السابقة كما في الجدول (3) نلاحظ تحسناً في دقة التصنيف والحساسية والنوعية للمصنف المقترح وذلك لأن استخدام LPC في تحليل السلاسل الزمنية دقيق رياضياً وبسيط في الحساب والتطبيق ويحتفظ بكل خصائص الإشارة.

حيث تم حساب بارامترات الأداء باستخدام معادلات نفذت باستخدام برنامج MATLAB وفق العلاقات (3) و(4) و(5) وذلك بعد الحصول على عناصر مصفوفة الارتباك.

نلاحظ من الجدول (3) أن النظام المقترح تفوق على النظام في الدراسة [2] من ناحية النوعية والحساسية وعلى الأنظمة في الدراسات [3] و[4] و[6] و[8] من ناحية الدقة. ورغم أن الحساسية في النظام [4] هي 100% إلا أن نظام كشف نوبات الصرع المقترح قد حقق نوعية ودقة أكبر وذلك لأن المجموعة الأفضل من معاملات التنبؤ الخطي تقلل مربع متوسط الخطأ التنبؤي في إشارات EEG وطريقة المربعات الصغرى LS المستخدمة في مصنف SVM تعمل على اختيار الخط المستقيم الأفضل الذي يحقق أن مربعات أبعاد النقاط عن هذا الخط أقل ما يمكن.

كشف نوبات الصرع من إشارات الدماغ EEG باستخدام LPC و LS-SVM

الجدول (1) نتائج التصنيف لبعض عينات EEG المستخدمة في قاعدة البيانات.

رقم العينة	رأي الخبراء	نتيجة المصنف	التوافق
F051	مريض صرع	مريض صرع	√
F052	مريض صرع	مريض صرع	√
F053	مريض صرع	مريض صرع	√
F054	مريض صرع	مريض صرع	√
F055	مريض صرع	مريض صرع	√
F060	مريض صرع	مريض صرع	√
N026	مريض صرع	مريض صرع	√
S056	مريض صرع	مريض صرع	√
S058	مريض صرع	مريض صرع	√
S059	مريض صرع	مريض صرع	√
S060	مريض صرع	شخص سليم	×
Z039	شخص سليم	مريض صرع	×
Z040	شخص سليم	شخص سليم	√
Z041	شخص سليم	شخص سليم	√
O060	شخص سليم	شخص سليم	√

الجدول (2) تقييم الأداء لنظام كشف نوبات الصرع المقترح.

مجموعة الاختبار	الدقة	الحساسية	النوعية	Confusion Matrix Parameters
F+N+S	98.3%	98.66%	98%	TP=148 FN=2 TN=98 FB=2
F+N+Z	98.66%	100%	96%	Tp=100 FN=0 FB=2 TN=48
F+N+O	99%	100%	98%	TP=100 FN=0 FB=1 TN=49
F+S+Z	98%	98%	96%	TP=98 FN=2 FB=2 TN=48
F+S+Z+O	98.5%	100%	97%	TP=100 TN=97 FB=3 FN=0

F+N+S+Z+O	98.66%	98.66%	98%	TP=148 TN=98 FB=2 FN=2
-----------	--------	--------	-----	---------------------------

الجدول (3) مقارنة بارامترات أداء نظام كشف نوبات الصرع المقترح مع الدراسات السابقة.

رقم الدراسة	الدقة	الحساسية	النوعية
[2]	-	98%	80%
[3]	-	97.07%	97%
[8]	90%	100%	83.3%
[6]	SVM: 97.6% KNN: 97% DT: 97.6% ANN: 97.4%	-	-
[4]	88.67%	90%	95%
[7]	93.5%	-	-
[8]	93.6%	-	-
الدراسة الحالية	98.66%	98.66%	98%

##### 5- الاستنتاجات

جرى استخلاص سمات إشارات EEG لكشف وجود نوبة صرع ووجد أنه باستخدام الترميز التنبؤي الخطي LPC من الدرجة 8 واستخدام مصنف LS-SVM أمكن الحصول على دقة كشف لنوبة الصرع بنسبة 98.66% وحساسية بنسبة 98.66% ونوعية بنسبة 98% على عينات EEG، وهذه النتائج تدل على قوة النظام المقترح في كشف نوبة الصرع بالمقارنة مع الدراسات السابقة.

##### 6- التوصيات والمقترحات

تعديل المصنف السابق لتصنيف جزئي لحالة Pre-Ictal التي تحدث تماما قبل 30 إلى 60 دقيقة من بداية نوبة الصرع وذلك باستخدام قاعدة بيانات حالة النوبة InterIctal التي تحدث بين نوبتين صرعيتين متتاليتين وذلك في حال عدم توفر قاعدة بيانات لحالة

Pre-Ictal مما يسهم بشكل فعال في التنبؤ بحدوث النوبة بدقة وتقديم العلاج اللازم بسرعة.

#### 7- المراجع

- [1] ZHOU, J., 2014 - **A Study of Automatic Detection and Classification of EEG Epileptiform Transients**. PhD Thesis, Clemson University, 139p.
- [2] BALASUBRAMANIAN, P., 2014 - **Automated Classification of EEG Signals Using Component Analysis and Support Vector Machines**, Master Thesis, Grand Valley State University, 90 p.
- [3] GURUMURTHY, S., and TRIPATHY, B. K., 2015 - Classification and Analysis of EEG Brain Signals for Finding Epilepsy Risk Levels Using SVM. **World Applied Sciences Journal**, Vol. 33 (4), 631-639.

- [4] ACHARYA, U. R., OH, S. L., HAGIWARA, Y., TAN, J. H., and ADELI, H., 2018 - Deep Convolutional Neural Network for the Automated Detection and Diagnosis Of Seizure Using EEG Signals. **Computers in Biology and Medicine**, Vol. 100, 270–278.
- [5] RAO, P.V., AKILAN, S., DHIVAKA, V., and KARTHIKEYAN, D., 2016 - Epilepsy Seizure Detection Using EEG - Curvelet Feature Selection and SVM Classification, **International Journal of Advanced Research in Computer and Communication Engineering (IJARCCE)**, Vol. 5, Issue 3, March.
- [6] AL-QEREM, A., KHARBAT, F., NASHWAN, S., ASHRAF, S., and BLAOU, K. 2020 - General Model for Best Feature Extraction of EEG Using Discrete Wavelet Transform Wavelet Family and Differential Evolution, **International Journal of Distributed Sensor Networks**, Vol. 16 (3).
- [7] ZHAO, W., et. al., 2020 - A Novel Deep Neural Network for Robust Detection of Seizures Using EEG Signals, **Computational and Mathematical Methods in Medicine**, Hindawi, Vol. 2020.
- [8] TÜRK, Ö., and ÖZERDEM, M. S., 2019- Epilepsy Detection by Using Scalogram Based Convolutional Neural Network From EEG Signals, **Brain Sciences**, **MDPI**, Vol. 9, 115.
- [9] PROEKT, A., 2018 - Brief Introduction to Electroencephalograph. **Elsevier Inc.**, **Methods in Enzymology**, Vol. 603, 257-273.
- [10] OBERST, U., 2007 - The Fast Fourier Transform. **SIAM Journal and Control and Optimization**, Vol. 46(2), 496-540.
- [11] SIWALANKERTO, J., et. al., 2015- Speech Recognition Using Linear Predictive Coding and Artificial Neural Network for Controlling Movement of Mobile Robot, **International Conference on Information and Electronics Engineering (IPCSIT)**, Vol. 6, IACSIT Press, Singapore.
12. <http://www.epileptologie-bonn.de>. Accessed Nov. 2017.
13. JU´AREZ-GUERRA, E. and ALARCON-AQUINO, V., and Juárez-Guerra, E., Alarcon-Aquino, V., & Gómez-Gil, P., 2011 - Epilepsy Seizure Detection in EEG Signals Using Wavelet Transforms and Neural Networks. **New Trends in Networking, Virtual International**

**Conference on Computing, E-Learning, Systems Sciences, and Engineering (CSSE), 261–269.**