

# تميز إشارات تخطيط الدماغ باستخدام شبكة الانتشار العكسي المعتمدة على معاملات مرشح التوقع الخطي

## EEG RECOGNITION BY USING BACKPROPAGATION NEURAL NETWORK BASED ON LINEAR PREDICTION FILTER COEFFICIENTS

نجلاء متي اسحق سفر

مدرس

كلية الزراعة والغابات/جامعة الموصل

د. عبدالستار محمد خضر

مدرس

المعهد التقني في الموصل

quantifying changes with time series for Electroencephalograms (EEG) obtained from four states two abnormal and two healthy with eyes open and eyes closed in both. Then it has been submit these linear prediction filter coefficients to the back propagation neural network for the purpose of signal distinction by the intelligent methods. It has been gives a good results at testing to the values of features extractions that they not been training with.

The results for classifying EEG using back propagation neural network shows that Alzheimer sickness can be detected with power 80-100% in many channels in case in taken EEG for the abnormal with eyes closed. The transformed inputs (from the original data of the signal to the features intentional in the research) are ideally suited for effective classification of EEG data. Recognition rates vary for each EEG channel data for correct recognition in the four cases (ho, hc, ao, ac). The follow up method can be useful in several applications including time-series analysis, signal processing and speech recognition.

**Keywords:** Electroencephalograms (EEG), EEG recognition, backpropagation neural network, linear prediction filter coefficients (LPC).

### 1. المقدمة

تعد إشارات تخطيط الدماغ Electroencephalograms (EEG) مصدر مهم للمعلومات لدراسة معالجات الدماغ الضمنية، حيث تمثل هذه الإشارات فعالية الدماغ للشخص وتعطي حالة موضوعية عند تسجيل تحفيزات الدماغ [1]. وإن السلوك الديناميكي المعقد لنشاط الدماغ يعكس عند تسجيل الفعالية الكهربائية في إشارات تخطيط الدماغ [2]. وقد اقترحت العديد من الدراسات بان EEG يمكن إن يستخدم للكشف عن العديد من الأمراض مثل نوبات الصرع والزهايمر والاختلال

### المستخلص

تم في هذا البحث استخلاص معاملات مرشح التوقع الخطي ذات المرتبة (15) linear prediction filter coefficients لإشارات تخطيط الدماغ (EEG) Electroencephalograms لتصنيف السلسلة الزمنية المستحصلة من أربع حالات اثنتان منها مرضية والأخرى سليمة (مفتوح ومغلق العينين في كل منهما). بعدها تم إدخال معاملات التوقع الخطي إلى الشبكة العصبية ذات الانتشار العكسي لغرض تمييز الإشارة بالطرق الذكية. ظهرت نتائج جيدة عند الاختبار لقيم المعاملات المستخلصة التي لم يتم التدريب عليها.

وقد أظهرت النتائج لتصنيف معاملات التوقع الخطي ذات المرتبة 15 لإشارات الدماغ EEG باستخدام شبكة الانتشار العكسي إن مرض الزهايمر يمكن اكتشافه بقوة 80-100% في العديد من القنوات في حالة اخذ إشارات تخطيط الدماغ للمريض عندما يكون مغلق العينين، كما استطاعت الشبكة تمييز خلو الشخص من مرض الزهايمر بقوة 100% في العديد من القنوات في حالة اخذ إشارات تخطيط الدماغ للشخص السليم عندما يكون مغلق العينين. وقد كان الإدخال المتحول (من البيانات الأصلية للإشارة إلى المميزات المعتمدة في البحث) مناسباً بشكل جيد في التصنيف الفعال لبيانات EEG، كانت نسبة التمييز متباينة في بيانات كل قناة من قنوات EEG في حالة التمييز الصحيح في كل من الحالات الأربعة (ho, hc, ao, ac). ويمكن الاستفادة من الطريقة المتبعة في هذا البحث في كثير من التطبيقات، من ضمنها تحليل السلاسل الزمنية، ومعالجة الإشارة، وتمييز الكلام.

### ABSTRACT

In this research, It has been used linear prediction filter coefficients method as base of

إن للشبكات العصبية القدرة على إيجاد التحويل اللاخطي للنمط لكي يمكن تصنيفها بدقة أكبر، فالازدياد في التعقيد للشبكة العصبية يمكن أن ينتج بسبب عدد مرات الحسابات الكبيرة لتدريب الشبكة. [13]


## 2. المواد وطرائق العمل

إن بيانات إشارات تخطيط الدماغ EEG المستخدمة في البحث متوفرة عموماً في جامعة فلوريدا [14] ، حيث استخدمت أربع مجاميع من بيانات إشارات تخطيط الدماغ، كل مجموعة تتألف من 19 عمود تقابل التسعة عشر قناة المستخدمة. ويوضح الشكل (1) مواقع هذه القنوات للحالات المستخدمة في البحث وكما يأتي:

- شاب سليم عينية مفتوحتين ho
- شاب سليم عينية مغلقتين hc
- مريض بالزهايمر عينية مفتوحتين ao
- مريض بالزهايمر عينية مغلقتين ac

الهدف من البحث هو تصنيف هذه الحالات الأربعة بتميز الاختلاف في بيانات القناة نفسها من كل حالة. تم استقصاء السلوك الزمني للبيانات المجمعة عند نسبة أعتيان 128 هرتز لمدة 8 ثوان وقد أنتجت سلسلة زمنية لـ 1024 عينة. أنجز التحويل الرقمي للإشارة المقاسة تماثلها باستخدام محول تماثلي رقمي ذات 8 مراتب.

إشارات تخطيط الدماغ أخذت في 19 قناة مختلفة المواقع لتعطي معلومات حيزية وزمانية



منظر من قمة الرأس نزولاً

شكل (1) مواقع القنوات التسعة عشر في رأس الشخص المعتمدة في البحث [14].

العقلي وانفصام الشخصية، بالإضافة إلى العديد من البحوث التي تطرقت إلى الكشف عن بعض الحركات الإرادية مثل تحريك الذراع وغلغ وفتح العين [3] و[4] والتميز بين حركة أصابع اليد أصابع القدم واللسان [5] و[6]. كما تطرقت بحوث أخرى إلى تمييز توقع الحركة خلال التخدير [7]، وتقدير عمق التخدير [8].

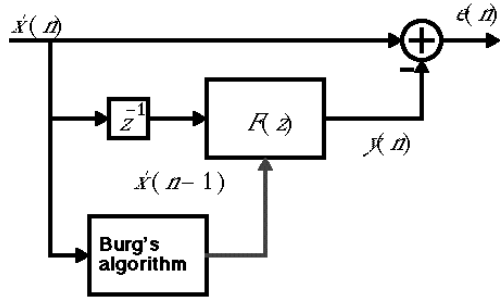
إن اغلب بحوث إشارات تخطيط الدماغ تهدف إلى فهم ديناميكية المعالجات التي تجرى في الدماغ، والتي تكون بمثابة الأساس للسلوك الفيزيائي والذهني [2]. ينجز تحليل وتميز بيانات EEG، بصورة عامة، إما لأجل التوقع أو لتصنيف الإشارة. وقد وجدت عدة أصناف من التحليلات في EEG. (أ) تخمين إشارات EEG لتوقع حركة جسم خاصة (مثل تحريك الأصابع) أو توقع نوبات الصرع. (ب) تصنيف إشارات EEG لعدة أنواع من المهام المعروفة لتمييزها، [9] و [10]. (ج) تصنيف إشارات EEG مأخوذة من شخصين أو عدة أشخاص يقومون بإنجاز المهام نفسها. (د) تجميع وتحليل عناصر مستقلة من بيانات القناة باستخدام الطرق الحيزية أو الطيفية [11] و [12].

في هذا البحث تم التركيز بشكل أساسي على تمييز EEG لشخصين مريض بالزهايمر و اخر سليم باستخدام بيانات لتسعة عشر قناة، في حالة فتح وغلغ العينين لكل من الشخصين المريض والسليم. وهذا العمل يتعلق بصورة رئيسية باستخدام الشبكة العصبية ذات الانتشار العكسي لغرض تمييز إشارات الدماغ.

استخدمت الشبكات العصبية الموحاة من مفاهيم تنظيمية لدماغ الإنسان، مؤخرًا في حقول مختلفة من التطبيقات، مثل تمييز الأنماط والتعرف والتصنيف والكلام والرؤية ومعالجة الإشارات وأنظمة السيطرة. ووجدت الشبكات العصبية تطبقها في مساحات متعددة في معالجة الإشارات ومن بينها إشارات تخطيط الدماغ حيث إنها من الإشارات المعقدة ذات التغيير الكبير وغالبا ما يتطلب تحليلها تحكيم من قبل شخص خبير [13].

تستخدم الشبكات العصبية الاصطناعية في تمييز الأنماط، التي هي العملية التي تتم على البيانات للحصول على معلومات مرتبة لتصنيف هذه البيانات. إن تمييز الأنماط يستخدم لعدة تطبيقات مثل تمييز الأرقام وتميز الحروف المكتوبة يدويا وتميز الحروف المطبعية ومجالات عديدة في تمييز وتصنيف الصور [13].

إن الشبكات العصبية بنوعها، التي تعمل بإشراف أو بدون إشراف والمتكونة من طبقة واحدة أو من عدة طبقات استطاعت وبنجاح تطبيق مختلف التصنيفات ومسائل التمييز [13].




شكل (3) مخطط يوضح مرشح التوقع الخطي [16]

في هذا العمل تم تقسيم كل إشارة من إشارات الدماغ، بعد فصلها عن إشارات القنوات الأخرى، إلى مقاطع متداخلة وكل مقطع تم تحليله لتجهيز معاملات مرشح التوقع الخطي التي تم استخدامها كإدخالات إلى الشبكة العصبية ذات الانتشار العكسي لغرض تمييزها.

التطبيق العملي للبحث موضح في خطوات الخوارزمية الآتية:  
الخطوة 1: إجراء عملية الفصل لإشارات القنوات التسعة عشر كلاً على حدة وذلك لتسهيل التعامل معها داخل النظام .

الخطوة 2: كما ذكرنا اعلاه ان كل إشارة انتجت في كل قناة تتكون من سلسلة زمنية لـ 1024 عينة، استخدم نصفها في عملية التدريب ونصفها الاخر في عملية الاختبار للشبكة العصبية. وكل نصف تم اجراء التقطيع المتداخل عليه من خلال تقسيمه إلى إشارات متجزئة كل منها تكون متداخلة مع مايجاورها من إشارات مقطعة، كذلك كل من هذه الإشارات المقطعة تعتبر نمط إشارة جديدة منفصلة بحد ذاتها، يحتوي كل مقطع على 200 عينة، ويكون المقطع متداخلاً بمقدار 20 عينة مع المقطع الذي يسبقه و 20 عينة مع المقطع الذي يليه، لذلك فالإدخال للشبكة العصبية يكون من تقسيم كل إشارة آتية من إحدى القنوات التسعة عشر لإشارات تخطيط الدماغ إلى كتل أحادية البعد متساوية الحجم.

الخطوة 3: إيجاد معاملات مرشح التوقع الخطي لخمسة عشر مرتبة لكل مقطع متداخل في الإشارة.



شكل (2): إشارة تخطيط الدماغ للشخص السليم الملتقطة في القناة الأولى خلال 8 ثوان [14].

بعد مرشح التوقع الخطي واحداً من أهم الأساليب المستخدمة في معالجة الإشارة، يحدد هذا المرشح المعاملات للتوقع الخطي المتقدم عن طريق تقليل خطأ التوقع في المربعات الصغرى المحسوسة للمرتبة p والذي يتوقع القيمة الحالية لعينات السلسلة الزمنية الحقيقية x بالاعتماد على العينات المسبقة، وله تطبيقات في تصميم المرشحات وفي ترميز الكلام speech coding .

$$\hat{x}(n) = -a(2)x(n-1) - a(3)x(n-2) - \dots - a(p+1)x(n-p)$$

حيث إن p تمثل مرتبة التوقع لمرشح متعدد الحدود،  $a = [1 \ a(2) \ \dots \ a(p+1)]$  يستخدم مرشح التوقع الخطي لوصف علاقة إخراج واحد أو متغير في النظام إلى واحد أو أكثر من الإدخالات التي تعد محددات لوصف النظام تحكم بمعادلات تفاضلية اعتيادية [15] و [16] و [17].

تستخدم طريقة التوقع الخطي مشاهدات الإشارة لمحاولة تكهن العينة التالية إلى مابعد العينات التي يمكن مشاهدتها، كما موضح في الشكل (3). الصندوق المعنون "Burg's algorithm" في المخطط التوضيحي، يدل على استخدام واحدة من عدة طرق لحساب معاملات التوقع الخطي لكل إشارة مقطعة. يحصل تأخير لإشارة الإدخال  $x'(n)$  بمقدار عينة واحدة بالكتلة المعنونة  $z^{-1}$ ، والكتلة  $F(z)$  هي المرشح الذي إخرجه  $y(n)$  يكون تكهنًا للقيمة الحالية  $x'(n)$ ، وخطأ التوقع  $e(n)$  هو الفرق بين ما تم استنتاجه وما هو متوقع [16].

الخطوة 4: تكوين ملفات التدريب من البيانات المستخلصة، بحيث يحتوي كل ملف تدريب على نصف البيانات الكلية من كل قناة، فيكون لدينا (19) ملف تدريب ، كل ملف يمثل البيانات المستخلصة من الإشارات المقطعة المتداخلة لإحدى القنوات التسعة عشر لكل تجربة من التجارب الأربعة المعتمدة في البحث.

الخطوة 5: تكوين ملفات الاختبار من البيانات المستخلصة، حيث يحتوي ملف الاختبار على النصف الآخر من البيانات، التي لم تستعمل في ملفات التدريب، أيضاً سيكون لدينا (19) ملف لكل تجربة من التجارب الأربعة المعتمدة في البحث.

الخطوة 6: تكوين ملفات الهدف (معلم الشبكة)، حيث تحتوي على بيانات منطقية (صفر، واحد).

الخطوة 7: تدريب الشبكة العصبية ذات الانتشار العكسي، حيث يكون الإدخال فيها ملفات التدريب المهيأة للبيانات المستخلصة للقناة الأولى في التجارب الأربعة.

الخطوة 8: اختبار الشبكة العصبية ذات الانتشار العكسي، باستخدام ملفات الاختبار المهيأة للبيانات المستخلصة للقناة الأولى في التجارب الأربعة.

الخطوة 9: تكرار الخطوات 7 و 8 لتدريب الشبكة واختبارها لكل من القنوات التسعة عشر.



ان تشخيص إشارات تخطيط الدماغ مسألة معقدة في مجال تمييز الأنماط، وبيانات إشارات EEG تكون متغيرة بشكل كبير وذات طبيعة ديناميكية.

في هذا البحث تم تعريف البيانات لإحدى القنوات كمصفوفة أحادية الأبعاد من الأرقام تمثل قياس التحفيز الكهربائي، حيث  $N=1024$  و  $\mathbf{C}^m = (X_1 \cdots X_N)$  ،  $1 \leq m \leq 19$  . تقطع الإشارة إلى مقاطع متداخلة، فالإدخال للشبكة العصبية يتمثل من تقسيم كل إشارة أتية من كل قناة من القنوات لإشارات EEG إلى كتل أحادية البعد متساوية الحجم. تُحوّل البيانات الخام لكل مقطع متداخل في كل قناة إلى بيانات التحويل باستخدام مرشح معاملات التوقع الخطي ذات المرتبة 15 كطريقة لاستخلاص المميزات.

البيانات الأصلية تتألف من قياسات EEG لشخصين في حالتين مختلفتين (فتح العينين و غلقهما)، وهذا يعطي أربع قنوات للبيانات. كل من هذه البيانات تم اخذ قيمها للتسعة عشر قناة. تم إجراء التصنيف في تجارب منفصلة لكل قناة مفردة أي جمع البيانات المستخلصة للقناة الأولى لجميع الحالات في تجربة، والبيانات المستخلصة للقناة الثانية لجميع الحالات في تجربة أخرى وهكذا للبيانات المستخلصة لباقي القنوات الأخرى.

الشبكة العصبية ذات الانتشار العكسي المستخدمة في البحث تتكون من ثلاث طبقات (إدخال وطبقتين مخفية وإخراج)، احتوت طبقة الإدخال على خمسة عشر خلية وهي تمثل مرتبة التوقع لمرشح متعدد الحدود التي تم استخدامها في هذا البحث، واحتوت الطبقة المخفية الأولى على خمس خلايا، واحتوت الطبقة المخفية الثانية على أربع خلايا (بعد تجارب التدريب العديدة وقيم مختلفة من الخلايا إلى أن تم الاستقرار على تلك الأعداد)، أما الإخراج فقد احتوى على أربع خلايا كل منها يشير إلى احد أنواع التجارب الداخلة في عملية التدريب (أي ان التدريب على أربع تجارب لكل قناة على انفراد) كما موضح في الشكل (4). وتم استخدام عدة أنواع من دوال التدريب مع شبكة الانتشار العكسي وهي دالة انحدار الخطأ/باستخدام تكييف عامل التعلم (traingd)، وعامل معدل التعلم هو ثابت يستخدم في التعلم الخطأ في الشبكة العصبية backpropagation وغيرها من الشبكات العصبية الاصطناعية اذ تعلم وتؤثر في الخوارزميات للشبكات على سرعة التعلم. وعلى سبيل المثال تستند في معادلات شبكة backpropagation ، على التغييرات/الصغيرة التي يجري إدخالها على الأوزان في كل خطوة : إذا كانت التغييرات التي أجريت على أوزان كبيرة جدا ، الخوارزمية قد "ترتد حول" سطح خطأ في انماط مضادة للإنتاجية. في هذه الحالة ، لا بد من تخفيض معدل التعلم. من ناحية أخرى ، فإن نسبة صغيرة التعلم ، والمزيد من الخطوات التي تتخذ للوصول الى وقف المعيار ودالة انحدار الخطأ/باستخدام العزم لشبكة الانتشار العكسي (traingdx)، ودالة شبه نيوتن للانتشار العكسي (trainbfg)، وكانت الأخيرة الأفضل حيث حققت نتائج جيدة عند الاختبار لمميزات الإشارات التي لم يتم التدريب عليها، كما إنها وصلت إلى الهدف في التدريب بعدد دورات اقل من باقي الدوال والشكل (4-أ و 4-ب و 4-ج) يوضح انحدار الخطأ في الشبكة أثناء التدريب.

الثانية. وهذه الطريقة تدعى ( شبه نيوتن quasi-Newton ). حيث تُجدد مصفوفة هيسيان في كل تكرار للخوارزمية. إن التجديد يحسب كوظيفة للميل. هذه الخوارزمية طبقت باستخدام الدالة المكتيبة (trainbfg) في برمجيات MATLAB V7.0 [18].



الشكل (4) يوضح هيئة الشبكة العصبية ذات الانتشار العكسي المستخدمة في البحث

ان معيار التوقف في الشبكة العصبية The Backpropagation stopping learning criteria ان توقف عمل الشبكة العصبية في تعلم الخطأ يعتمد على المعايير الآتية:

- وصول مجموع الخطأ الكلي في الشبكة الى قيمة ادنى من قيمة محددة مسبقاً predetermined level.
- اكتمال عدد معين من الدورات epochs .

وتعد طريقة نيوتن كبديل لطرق مشتقة الانحدار وذلك لأجل سرعة الوصول إلى الأمثلية . إن الخطوة الأساسية لطريقة نيوتن هي:

$$X_{k+1} = X_k - A_k^{-1} g_k \dots \dots \dots (2)$$

حيث إن:

$X_{k+1}$  : متجه الأوزان والانحيازات الجديدة.

$X_k$  : متجه الأوزان والانحيازات الحالية.

$A_k$  هي مصفوفة هيسيان (الإشتقاقات الثانية) من فهرس الاداء في القيم الحالية للأوزان والانحياز.

$g_k$  تمثل الانحدار الحالي.

غالباً ما تقترب طريقة نيوتن بشكل أسرع من بقية طرق مشتقات الانحدار. هناك نوع من الخوارزميات التي تكون مستندة على طريقة نيوتن، لكن لا تتطلب حساب الإشتقاقات

### 3. النتائج والمناقشة

يزود مرشح معاملات التوقع الخطي للإشارة بفائدة معنوية أكبر من استخدام المشاهدات الأصلية عند تصنيف الإشارة، كما أثبتت العديد من البحوث، تم استخدام النصف الثاني من الإشارة (غير مستخدم في عملية التدريب للشبكة العصبية)، وتطبيق خطوات الخوارزمية للبحث (5،3،2،1) المذكورة اعلاه، وتم تم تزويد ملفات الاختبار للشبكة لعمل محاكاة والحصول على نتائج الاختبار ويبين الجدول (1) نسبة الاختبار الصحيح لبيانات مقاطع الإشارات غير المدرب عليها للحالات الأربعة (ho, hc, ao, ac) لجميع القنوات التسعة عشر.

جدول (1): نسب الاختبار الصحيح في التجارب الأربعة لجميع

القنوات لمقاطع الإشارات غير المدرب عليها

اسم التجربة	التجربة 1	التجربة 2	التجربة 3	التجربة 4
رقم القناة	مريض مغلق العينين %	مريض مفتوح العينين %	سليم مغلق العينين %	سليم مفتوح العينين %
channel1	45.45	18.18	86.36	77.27
channel2	13.64	27.27	100	86.36
channel3	95.45	31.82	100	77.27
channel4	72.73	31.82	72.73	72.73
channel5	100.00	45.45	100	50.00
channel6	86.36	18.18	86.36	36.36
channel7	59.09	22.73	100	45.45
channel8	59.09	45.45	100	63.64
channel9	90.91	18.18	100	77.27
channel10	86.36	22.73	95.45	54.55
channel11	13.64	31.82	95.45	95.45
channel12	36.36	22.73	72.73	90.91
channel13	63.64	22.73	86.36	77.27
channel14	86.36	18.18	86.36	36.36
channel15	81.82	36.36	95.45	31.82
channel16	59.09	36.36	100.0	63.64
channel17	90.91	36.36	95.45	81.82
channel18	13.64	45.45	90.91	90.91
channel19	22.73	22.73	86.36	59.09

ويمكن القول بأن مرض الزهايمر يمكن كشفه بنسبة أعلى في حالة غلق العينين للمريض حيث تم تمييزه بنسبة نجاح تقترب من 80-100% في كل من القنوات (3 و 5 و 6 و 9 و 10 و 14 و 15 و 17)، واما نتائج كشف المرض في حالة الشخص المريض والمفتوح العينين فقد حققت 45% كأعلى نسبة تمييز في القناتين (5 و 18) ، وفي حالة الشخص السليم ومغلق

العينين فقد حققت جميع القنوات نتائج جيدة في وصف سلامة الشخص اذ حققت اغلب القنوات نسب عالية في التمييز الصحيح، وأخيرا في حالة الشخص السليم ومفتوح العينين فقد حققت القنوات (2 و 11 و 12 و 17 و 18) أفضل تمييز لعدم وجود المرض تفاوتت بين 81%-95%، عليه يمكن اعتماد هذه البرنامج في الكشف عن مرض الزهايمر بوثوقية عالية بأخذ اشارات للمريض وهو مغلق العينين والتركيز على القنوات القنات (3 و 5 و 6 و 9 و 10 و 14 و 15 و 17) في تقرير وجود المرض من عدمه.

### المصادر REFERENCES

- [1] Pradhan, N. and P.K. Sadasivan, and S. Chatterji, and D.D. Narayana, "Patterns of attractor dimensions of sleep EEG", *Comput. Biol. Med.* . 25(5): 455-462 , 1995.
- [2] Pfurtsheller,G., "EEG-based discrimination between imagination of right and left hand movement", *Electroencephalography and Clinical Neurophysiology*, 103(6):642-651, 1997.
- [3] Pfurtsheller,G. and D. Flotzinger and P. Neuper, "Differentiation between finger, toe and tongue movement in man based 40 Hz EEG" , *Electroencephalography and Clinical Neurophysiology*, 90(5) pp 456-460 , 1994.
- [4] Sharma,A. and R.J. Roy, "Design of a recognition system to predict movement during anesthesia", *IEEE Transactions on Biomedical engineering*, 44(6):505-511 , 1997.
- [5] Huang, J.W. L.Ying-Ying,A. Nayak, R.J.Roy,"Depth of anesthesia estimation and control", *IEEE Transaction on Biomedical Engineering*, 46(1): 71-81 , 1999.
- [6] Anderson, C.W. and E.A. Stolz and S. Shamsunder, "Multivariate autoregressive models for classification of spontaneous Electroencephalogram during mental tasks", *IEEE Transactions on Biomedical Engineering*, 45(3): 277-286 , 1998.
- [7] Anderson, C.W. and Z Sijercic, "Classification of EEG signals from four subjects during five mental tasks", In *Solving Engineering problems with neural networks, Proceedings of the Conference on Engineering Applications in Neural Networks (EANN'96)*,A.B. Bulsari, S. Kallio and D. Tsaptsinos, pp. 407-414 , 1996.
- [8] Lowe, D., "An approach to dynamic modeling and topographic feature extraction of wake EEG", *Proceedings of the International Conference on Advances in Pattern Recognition (ICAPR'98)*, pp. 145-153 , 1998.

- [9] Wahlberg, P. and G. Salomonsson, "Feature extraction and clustering of EEG epileptic spikes", *Computers and Biomedical Research*, 29(5): 382-394 , 1996.
- [10] Khidhir, A.M., *Investigation of using electroencephalography signals in human-machine communication system*, Ph.D. Thesis, Department of electrical engineering, College of engineering, University of Mosul, Iraq , 2000.
- [11] Safar, N.M., *EEG recognition by using neural network*, M.Sc. Thesis, Department of Computer Sciences, College of Computers and Mathematics Sciences, University of Mosul,Iraq , 2001.
- [12] Singh, S. EEG data classification with localized structural information, (from author via e-mail: [s.singh@exter.ac.uk](mailto:s.singh@exter.ac.uk)).
- [13] Wassermann, P.D.,(1989), *Neural computing theory and practice*, Van Nostrand Reinhold; New York.
- [14] Electroencephalogram (EEG) Data via internet from URL <http://www.scri.fsu.edu/~nayak/chaos/data.html> .
- [15] Brien, P.O.(2000), ESS265, Chapter 9."Linear Prediction Filters and Neural Networks" via internet from URL [http://www-ssc.igpp.ucla.edu/personnel/russell/ESS265/Ch9/linear\\_predict/](http://www-ssc.igpp.ucla.edu/personnel/russell/ESS265/Ch9/linear_predict/)
- [16] Speech Processing Using Linear Prediction via internet from URL <http://ptolemy.eecs.berkeley.edu/eecs20/speech/lp.html>
- [17] Signal Processing Toolbox 6, User's Guide ,2010, The MathWorks, Inc.
- [18] Howard Demuth, Mark Beale, Martin Hagan, "Neural Networks Toolbox 6" , 2010, The MathWorks, Inc.
- [19] The Machine Learning Dictionary for COMP9414 , Copyright © Bill Wilson, 1998, 2003, Last updated on: 22 April 2008 from internet via <http://www.cse.unsw.edu.au/~billw/mldict.html>