

تميز إشارات تخطيط الدماغ باستخدام شبكة الانتشار العكسي المعتمدة على المميزات الهيكلية  
الموضعية المستخلصة

نجلاء متي اسحق سفر  
كلية الزراعة والغابات  
جامعة الموصل

تاريخ قبول البحث: ٢٠٠٥/٥/٣٠

تاريخ استلام البحث: ٢٠٠٤/١٠/٢٦

### ABSTRACT

In this research, it localized structural feature selection method has been used as a base of quantifying structural changes with time for Electroencephalograms (EEG) obtained from four states two patient and two healthy with eyes open and eyes closed in both. Then these structural characteristics have been submitted to the back propagation neural network for the purpose of signal distinction by the intelligent methods. BFGS Quasi-Newton Back propagation function has been used with the data of the network. It gives good results at testing to the values of features extractions that they have not been training with, and it has been reached to the goal with minimum iteration from other common function that is used with back propagation neural network.

The results for classifying EEG using back propagation neural network show that Alzheimer sick can be detected hardly 100% in many channels in case in taken EEG for the patient 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 between 50-100% correct recognition in the four cases. The follow up method can be useful in several applications including time-series analysis, signal processing and speech recognition.

## الملخص

تم في هذا البحث استخلاص المميزات الهيكلية الموضعية بوصفها أساساً لقياس التغيرات الهيكلية مع الزمن لتصنيف السلسلة الزمنية لإشارات تخطيط الدماغ EEG المستحصلة من أربعة حالات اثنتان منها مرضية والأخرى سليمة (مفتوح ومغلق العينين في كل منهما). بعدها تم إدخال المميزات الهيكلية الموضعية إلى الشبكة العصبية ذات الانتشار العكسي لغرض تمييز الإشارة بالطرق الذكية. واستخدمت الدالة BFGS Quasi-Newton Back propagation مع بيانات الشبكة إذ حققت نتائج جيدة عند الاختبار لقيم المميزات المستخلصة التي لم يتم التدريب عليها، كما إنها وصلت إلى الهدف في التدريب بعدد دورات أقل من باقي الدوال الشائعة الاستخدام مع شبكة الانتشار العكسي.

وقد أظهرت النتائج لتصنيف المميزات EEG باستخدام شبكة الانتشار العكسي إن مرض الزهايمر يمكن اكتشافه بقوة ١٠٠% في العديد من القنوات في حالة أخذ إشارات تخطيط الدماغ للمريض عندما يكون مغلق العينين. وقد كان الإدخال المتحول (من البيانات الأصلية للإشارة إلى المميزات المعتمدة في البحث) مناسباً بشكل مثالي في التصنيف الفعال لبيانات EEG، كانت نسبة التمييز متباينة في بيانات كل قناة من قنوات EEG إذ تراوحت بين ٥٠ - ١٠٠% 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.

## ١ . المقدمة

أصبح تحليل إشارات تخطيط الدماغ (Electroencephalograms (EEG وتمييزها الموضوع للعديد من الدراسات. إذ تمثل هذه الإشارات فعالية الدماغ للشخص وتعطي حالة موضوعية عند تسجيل تحفيزات الدماغ [13]. إذ إن السلوك الديناميكي المعقد لنشاط الدماغ ينعكس عند تسجيل الفعالية الكهربائية في إشارات تخطيط الدماغ [10]. وقد اقترحت العديد من الدراسات بان EEG يمكن إن يستخدم للكشف عن العديد من الأمراض مثل نوبات الصرع، والزهايمر، والاختلال العقلي، وانفصام الشخصية، فضلاً عن العديد من البحوث التي تطرقت إلى الكشف عن بعض الحركات الإرادية مثل تحريك الذراع، وغلق العين وفتحها [5] و [11] والتمييز بين حركة أصابع اليد،

وأصابع القدم، واللسان [9]. كما تطرقت بحوث أخرى إلى تمييز توقع الحركة خلال التخدير [12]، وتقدير عمق التخدير [4].

## ٢. إشارات تخطيط الدماغ:

إن أغلب بحوث إشارات تخطيط الدماغ تهدف إلى فهم ديناميكية المعالجات التي تجرى في الدماغ، والتي تكون بمثابة الأساس للسلوك الفيزيائي والذهني [10]. ينجز تحليل وتمييز 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، [2,1].

ج) تصنيف إشارات EEG مأخوذة من شخصين أو عدة أشخاص يقومون بإنجاز المهام نفسها.

د) تجميع وتحليل عناصر مستقلة من بيانات القناة باستخدام طرق الحيزية أو الطيفية [14,6].

في هذا البحث تم التركيز بشكل أساسي على تمييز EEG لشخص مريض بالزهايمر وشخص سليم باستخدام بيانات لتسع عشرة قناة، في حالة فتح العينين وغلقهما لكل من الشخصين المريض والسليم.

## ٣. تمييز إشارات الدماغ باستخدام الشبكات العصبية:

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 وتمييز الحروف المكتوبة يدويا وتمييز الحروف المطبعية ومجالات عديدة في تمييز الصور وتصنيفها.

إن الشبكات العصبية بنوعها، التي تعمل بإشراف أو من دونها والمتكونة من طبقة واحدة أو من عدة طبقات استطاعت وبجاح تطبيق مختلف التصانيف ومسائل التمييز.

استخدمت الشبكات العصبية الموحاة من مفاهيم تنظيمية لدماغ الإنسان، مؤخرا في حقول مختلفة من التطبيقات، مثل تمييز الأنماط، والتعريف، والتصنيف، والكلام، والرؤية، ومعالجة

الإشارات وأنظمة السيطرة. ووجدت الشبكات العصبية تطبيقها في مساحات متعددة في معالجة الإشارات ومن بينها إشارات تخطيط الدماغ إذ إنها من الإشارات المعقدة ذات التغيير الكبير وغالبا ما يتطلب تحليلها تحكيماً من قبل شخص خبير .  
 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. [11]

#### ٤ . بيانات إشارات تخطيط الدماغ EEG :

إن بيانات إشارات تخطيط الدماغ EEG المستخدمة في البحث متوافرة عموماً في جامعة فلوريدا [3]، حيث استخدمت أربع مجاميع من بيانات إشارات تخطيط الدماغ، كل مجموعة تتألف من ١٩ عموداً تقابل التسع عشرة قناة المستخدمة. ويوضح الشكل (١) مواقع هذه القنوات للحالات المستخدمة في البحث وكما يأتي:

شاب سليم عيناه مفتوحتان ho


شاب سليم عيناه مغلقتان hc

مريض بالزهايمر عيناه مفتوحتان ao

مريض بالزهايمر عيناه مغلقتان ac


الهدف من البحث هو لتصنيف هذه الحالات الأربعة بوصف الاختلاف في بيانات القناة نفسها من كل حالة. تم استقصاء السلوك الزمني للبيانات المجمعة عند نسبة أعتيان ١٢٨ هرتز لمدة ٨ ثوان وقد أنتجت سلسلة زمنية لـ ١٠٢٤ عينة. أنجز التحويل الرقمي للإشارة المقاسة تناظرياً باستخدام محول رقمي ذي ٨ بت، خضعت الإشارات لتصفية (band-pass filter ، 0.1 Hz to 30Hz, 12dB/octave roll-off). أن النظام المصمم في هذا البحث اعتمد على إشارات دماغ ذات أعتيان ١٢٨ هرتز تحول إلى إشارة رقمية باستخدام محول رقمي ذي ٨ بت، يبين الشكل (٢) إشارة تخطيط الدماغ للشخص السليم الملتقطة في القناة الأولى خلال ٨ ثوان.

إشارات تخطيط الدماغ أخذت في ١٩ قناة مختلفة المواقع لتعطي معلومات حيزية وزمنية



منظر من قمة الرأس نزولاً

الشكل (١) مواقع القنوات التسع عشرة في رأس الشخص المعتمدة في البحث [3].



الشكل (٢): إشارة تخطيط الدماغ للشخص السليم الملتقطة في القناة الأولى خلال ٨ ثوان [3].

##### ٥. اختيار المميزات الهيكلية الموضعية:

اعتمدت طريقة اختيار المميزات الهيكلية الموضعية في البحث وحسب ما جاء في [13] ،  
(الذي استخدم فضلاً عن العوامل أدناه عوامل أخرى مع معادلات في مجال تمييز الأنماط لإيجاد

اقصر مسافة اعتمادا على حجم مزلعات استخدمها في بحثه). استندت طريقة اختيار المميزات الهيكلية الموضوعية إلى المنطق الأتي: للبيانات ذات نوع سلاسل زمنية، التغيرات الهيكلية مع الزمن للبيانات المأخوذة من المصدر نفسه تكون ذات توقيع وحيد لبيانات المصدر، وتسمح بتمييزها بنجاح في حالة وجود عدة إشارات مأخوذة من عدة أشخاص في حالات مختلفة إذا تم استخلاص مميزات كافية لتمثيلهم.

وبالإمكان رياضيا تعريف بيانات المصدر S كمصدر اختلافات غير مستقرة والتي تولد المشاهدات  $(x_0 \dots x_N)$ . كل مزلع يقيس المميزات الهيكلية لـ P من النقاط، فضلاً عن ذلك، فإن قمم المزلعات لا تتقاطع مع بعضها، تمنح مميزات المزلع فوائد إضافية مهمة، وتعد كتوقيع وحيد ممكن استخدامه في التصنيف المعتمد على المعلومات الزمنية. إن المساحة للمزلع الذي يكون عند اللحظة الزمنية t يمكن حسابها بسهولة حسب المعادلة (1) [13]:

$$Area = \frac{1}{2} \sum_{i=0}^{N-1} t_i x_{i+1} - t_{i+1} x_i \text{ KKKKKKKKKKKK (1)}$$

تمثل مساحة المزلع نصف مجموع الفروقات بين المشاهدات التالية  $x_{i+1}$  للحظة الزمنية الحالية  $t_i$  والمشاهدة الحالية  $x_i$  للحظة الزمنية التالية  $t_{i+1}$  في الإشارة لكل فترة زمنية. تم إيجاد المميزات الموقعية لكل عينة في القناة والتي هي:

المساحة للمزلع الذي يكون عند اللحظة الزمنية t،  $y_t$

التغير في المساحة للمزلعات المتتالية عند اللحظة الزمنية الحالية،

$$\Delta y_t = y_t - y_{t-1}$$

التباين للبيانات عند اللحظة الزمنية t،  $s_t$

التغير في التباين عند اللحظة الزمنية t،  $\Delta s_t = s_t - s_{t-1}$

اتجاه حركة الإشارة  $j_t$ ، التي تكون صفراً عندما تكون المشاهدة عند

اللحظة الزمنية (t+1) أقل من مرتبة المشاهدة عند اللحظة الزمنية (t)،

وإلا تكون واحداً.

## ٦. خوارزمية العمل

التطبيق العملي للبحث موضح في الخطوات الآتية:

- الخطوة ١: إجراء عملية الفصل لإشارات القنوات.
- الخطوة ٢: إيجاد المميزات الموقعية لكل عينة في القناة كما ذكرت في جزء اختيار المميزات الهيكلية.
- الخطوة ٣: تكوين ملفات التدريب من البيانات المحولة، إذ يحتوي ملف التدريب على ثلاث بيانات الإشارة المحولة، أي سيكون ١٩ ملفاً لكل تجربة من التجارب الأربع المعتمدة في البحث.
- الخطوة ٤: تكوين ملفات الاختبار من البيانات المحولة، إذ يحتوي ملف الاختبار على ثلاثي بيانات الإشارة المحولة، والتي لم توضع في ملفات التدريب، أيضاً سيكون ١٩ ملفاً لكل تجربة من التجارب الأربع المعتمدة في البحث.
- الخطوة ٥: تحضير ملفات الهدف (المعلم للشبكة)، والتي تحتوي على بيانات منطقية (صفر، واحد).
- الخطوة ٦: تدريب الشبكة العصبية ذات الانتشار العكسي، إذ يكون الإدخال ملفات التدريب المهيأة للبيانات المحولة للقناة الأولى في التجارب الأربع.
- الخطوة ٧: اختبار الشبكة العصبية ذات الانتشار العكسي، باستخدام ملفات الاختبار المهيأة للبيانات المحولة للقناة الأولى في التجارب الأربع.
- الخطوة ٨: تكرار الخطوتين ٦ و ٧ لتدريب الشبكة واختبارها على القناة التالية.

## ٧. التطبيق العملي

يعد تمييز إشارات تخطيط الدماغ مسألة معقدة في مجال تمييز الأنماط، والبيانات لإشارات EEG تكون متغيرة بشكل كبير وذات طبيعة ديناميكية، في هذا البحث تم تعريف البيانات لإحدى القنوات C بوصفها مصفوفة أحادية الأبعاد من الأرقام تمثل قياس التحفيز الكهربائي،  $C^m = (x_1 \mathbf{L} x_N)$  ، حيث  $N=1024$  و  $1 \leq m \leq 19$  . تُحوّل البيانات الخام لكل قناة إلى بيانات التحويل باستخدام طريقة استخلاص المميزات الهيكلية. كل نقطة xi في قناة معينة تمثل الآن بمتجه yi ذي خمس قيم (كما تم وصفها في جزء اختيار المميزات الهيكلية)،  $yi = (pi, qi, ri, si)$  ، لجميع النقاط ١٠٢٤ للبيانات الأصلية xi ، سوف نحصل على عدد مساو من قيم yi . البيانات

الأصلية تتألف من قياسات EEG لشخصين في حالتين مختلفتين (فتح العينين أو غلقهما)، وهذا يعطي ٤ فئات للبيانات.

تم أخذ قياسات كل من هذه البيانات في ١٩ قناة. تم إجراء تصنيف البيانات في تجارب منفصلة لكل قناة مفردة أي جمع بيانات التحويل للقناة الأولى لجميع الحالات في تجربة وبيانات التحويل للقناة الثانية لجميع الحالات في تجربة أخرى وهكذا لباقي بيانات القنوات الأخرى. ولاختبار أداء الشبكة في التصنيف للميزات المستخلصة، فقد تم تقسيم بيانات التحويل (المميزات المستخلصة) إلى جزأين استخدم الجزء الأول في التدريب، أما الجزء الثاني فقد تم استخدامه في الاختبار، أي إن بيانات التدريب تتألف من ٣٥% من بيانات التحويل الكلية من كل ملف، وتم استخدام بقية البيانات في كل ملف في الاختبار وتتألف من ٦٥% من بيانات التحويل الباقية، أي أن أكثر من نصف بيانات الإشارة في كل حالة، لم تستخدم في التدريب، فالبيانات التي تم استخدامها في الاختبار لم تدرب الشبكة عليها، وهي تعود لأربعة أشخاص، ويعود السبب في استخدام نفس إشارات الأشخاص بعد تجزئتها إلى جزأين في التدريب والاختبار إلى قلة بيانات إشارات الدماغ المتوافرة لدينا لنفس الحالات، والمأخوذة من نفس القنوات لنفس المواقع في رأس الشخص، لذلك يعتمد أكثر الباحثين إلى مثل هذا الإجراء.

الشبكة العصبية المستخدمة في البحث ذات تنظيم ضمن طبقتين (إدخال ومخفية وإخراج) وبعدها مناسب من وحدات الخلايا، حيث أدخلت قيم المميزات الهيكلية إلى الشبكة، واحتوت الطبقة المخفية على ٥٠ أو ١٠٠ خلية (بعد تجارب التدريب العديدة وبقيم مختلفة إلى أن تم الاستقرار على هذا العدد)، أي تم تدريب الشبكة لجميع القنوات التسع عشرة، مرة باستخدام ٥٠ خلية في الطبقة المخفية وتدريب آخر باستخدام ١٠٠ خلية في الطبقة المخفية، وفي كلتا الحالتين أعطت نتائج جيدة. أما الإخراج فيحتوي على 4 خلايا كل منها يشير إلى احد أنواع التجارب الداخلة في عملية التدريب (أي تم التدريب على أربع تجارب لكل قناة على انفراد). وتم استخدام عدة أنواع من دوال التدريب المستخدمة مع شبكة الانتشار العكسي مثل دالة انحدار الخطأ لشبكة الانتشار العكسي، دالة انحدار الخطأ باستخدام تكييف عامل التعلم، ودالة انحدار الخطأ باستخدام العزم لشبكة الانتشار العكسي، ودالة شبه نيوتن للانتشار العكسي، وكانت الأخيرة الأحسن في العمل مع بيانات الشبكة إذ حققت نتائج أفضل عند الاختبار للمميزات الهيكلية لعينات الإشارات التي لم يتم التدريب عليها كما وإنها وصلت



إلى الهدف في التدريب بعدد دورات أقل من باقي الدوال والشكل (3-أ و 3-ب) يوضح انحدار الخطأ في الشبكة في أثناء التدريب والوصول إلى الهدف بعدد دورات يعد قليلاً نسبة إلى صعوبة المسألة وتعتها.

وتعد طريقة نيوتن بديلاً لطرائق مشتقة الانحدار وذلك لأجل سرعة الوصول إلى الامتثية .  
إن الخطوة الأساسية لطريقة نيوتن هي:

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

حيث إن:

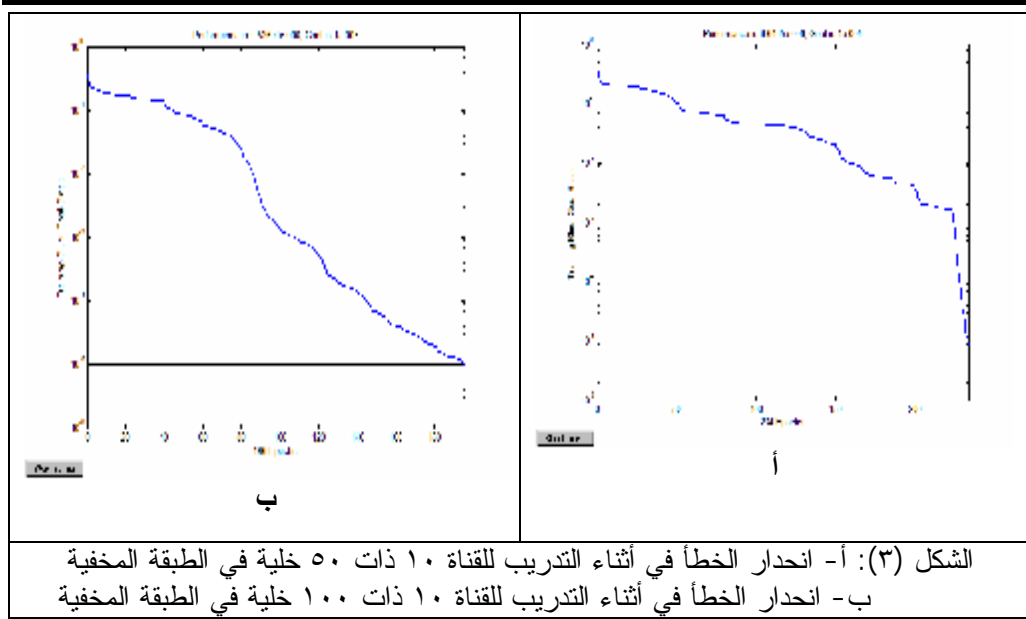
$X_{k+1}$ : متجه الأوزان و الانحيازات الجديدة.

$X_k$ : متجه الأوزان و الانحيازات الحالية.

$A_k$  هي مصفوفة هيسيان ( الإشتقاق الثانية ) من فهرست الأداء في القيم الحالية للأوزان والانحياز.

$g_k$  تمثل الانحدار الحالي.

تقترب طريقة نيوتن غالباً بشكل أسرع من طرائق مشتقة الانحدار . لسوء الحظ، إن حساب مصفوفة هيسيان للتغذية الأمامية feed forward للشبكات العصبية يعد معقداً ومكلفاً. هناك نوع من الخوارزميات التي تكون مستندة إلى طريقة نيوتن، لكن لا تتطلب حساب الإشتقاق الثانية. هذه تدعى طرائق شبه نيوتن quasi-Newton ( أو secant ). حيث تُجدد مصفوفة هيسيان في كل تكرار للخوارزمية. إن التجديد يحسب بوصفه وظيفة للميل. هذه الخوارزمية طبقت في الدالة المكتوبة (trainbfg) في برمجيات MATLAB V6.5 [9] .



#### ٨. مناقشة النتائج

تزود المميزات الهيكلية الموضوعية للإشارة بفائدة معنوية أكثر من استخدام المشاهدات الأصلية عند تصنيف الإشارة كما أثبتت العديد من البحوث، يبين الجدولان (١) و(٢) نسبة الاختبار الصحيح لبيانات الإشارة غير المدرب عليها للحالات الأربع (ho, hc, ao, ac) باستخدام ١٩ قناة عند وجود ٥٠، و ١٠٠ خلية في الطبقة المخفية، على التوالي، ويمكن القول بأن مرض الزهايمر يمكن كشفه بقوة اكبر في حالة غلق العينين للمريض (الجدول ١) إذ تم تمييزه ١٠٠% في كل من القنوات (٤ و ٦ و ٩ و ١٠ و ١٣ و ١٤ و ١٥ و ١٨ و ١٩)، وبنسبة لا تقل عن ٩٦% في باقي القنوات عدا القناتين ٣ و ١٢، أما عند حالة فتح العينين للمريض فقد حققت القناة ١٢ أعلى نسبة تمييز ٨٥%، وفي حالة الشخص السليم وهو مغلق العينين فقد حققت القناة ١٥ أعلى نتيجة، وفي حالة الشخص السليم ومفتوح العينين فقد حققت القناة ٦ أفضل تمييز ٩٧%. هذا عندما كان عدد الخلايا في الطبقة المخفية ٥٠.

الجدول (١): نسبة الاختبار الصحيح في التجارب الأربع لجميع القنوات عند التدريب باستخدام ٥٠ عقدة في الطبقة المخفية.

التجربة ٤ سليم مفتوح العينين %	التجربة ٣ سليم مغلق العينين %	التجربة ٢ مريض مفتوح العينين %	التجربة ١ مريض مغلق العينين %	اسم التجربة رقم القناة
62.91	84.32	54.11	99.62	channel1
58.37	92.54	50.34	99.43	channel2
79.16	90.06	54.30	74.38	channel3
77.44	89.10	57.93	100.00	channel4
65.20	90.25	50.03	97.51	channel5
91.97	83.94	56.27	100.00	channel6
54.30	78.97	59.46	96.18	channel7
52.07	60.42	58.32	99.81	channel8
88.53	88.15	59.08	100.00	channel9
71.89	94.07	50.40	100.00	channel10
90.63	96.18	63.29	98.09	channel11
66.92	50.86	85.47	88.15	channel12
84.51	91.20	55.64	100.00	channel13
78.39	89.48	50.73	100.00	channel14
75.33	97.32	51.22	100.00	channel15
83.56	93.50	66.16	99.62	channel16
66.73	92.35	67.88	99.81	channel17
86.81	95.03	63.48	100.00	channel18
64.63	94.46	81.07	100.00	channel19

أما في حالة وجود ١٠٠ خلية في الطبقة المخفية (الجدول ٢)، فنلاحظ أيضا قوة اكتشاف مرض الزهايمر بنسبة ١٠٠% للتمييز الصحيح في القنوات (٤ و ٥ و ٦ و ٨ و ٩ و ١٠ و ١٣ و ١٤ و ١٥ و ١٦ و ١٧ و ١٨ و ١٩)، وبنسبة لا تقل عن ٩٥% في باقي القنوات عدا القناتين ١ و ٣ . وعند حالة فتح العينين للمريض فقد حققت القناة ١٢ أعلى نسبة تمييز، وفي حالة الشخص السليم ومغلق العينين فقد حققت القناة ١٦ أعلى نتيجة وهي ٩٨%، وفي حالة الشخص السليم ومفتوح العينين فقد حققت القناة ٦ أفضل تمييز بنسبة ٩١% .

الجدول (٢): نسبة الاختبار الصحيح في التجارب الأربع لجميع القنوات عند التدريب باستخدام ١٠٠ عقدة في الطبقة المخفية.

التجربة ٤ سليم مفتوح العينين %	التجربة ٣ سليم مغلق العينين %	التجربة ٢ مريض مفتوح العينين %	التجربة ١ مريض مغلق العينين %	اسم التجربة رقم القناة
69.98	87.19	54.49	87.76	channel1
51.05	91.40	52.12	99.81	channel2
76.67	90.63	54.49	70.17	channel3
80.50	91.01	56.02	100.00	channel4
62.72	91.01	50.33	100.00	channel5
92.54	90.44	59.08	100.00	channel6
52.39	83.75	56.98	95.22	channel7
56.65	75.14	50.43	100.00	channel8
89.87	88.34	56.41	100.00	channel9
86.42	91.40	50.53	100.00	channel10
89.10	96.18	63.10	97.51	channel11
77.44	60.61	74.19	97.90	channel12
84.13	96.37	62.91	100.00	channel13
90.44	96.56	53.40	100.00	channel14
83.56	93.50	14.91	100.00	channel15
73.42	98.66	55.45	100.00	channel16
81.07	93.31	72.85	100.00	channel17
88.91	95.98	51.17	100.00	channel18
81.07	94.84	72.66	100.00	channel19

المصادر

- [1] Anderson, C.W. and Z Sijercic (1996), “**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.
- [2] Anderson, C.W. and E.A. Stolz and S. Shamsunder (1998), “Multivariate autoregressive models for classification of spontaneous Electroencephalogram during mental tasks”, **IEEE Transactions on Biomedical Engineering**, 45(3): 277-286.
- [3] Electroencephalogram(EEG) Data (2000) via <http://www.scri.fsu.edu/~nayak/chaos/data.html> .
- [4] Huang, J.W. L.Ying-Ying,A. Nayak, R.J.Roy (1999), “Depth of anesthesia estimation and control”, **IEEE Transaction on Biomedical Engineering**, 46(1): 71-81.
- [5] Khidhir, A.M. (2000), “**Investigation of using electroencephalography signals in human-machine communication system**”, Ph.D. Thesis, Department of electrical engineering, College of engineering, University of Mosul, Iraq.
- [6] Lowe, D. (1998), “**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.
- [7] **Neural Network toolbox for Matlab V6.5**. Copyright 1984-2002, The Math Works, Inc.
- [8] Pfurtsheller,G. (1997), “EEG-based discrimination between imagination of right and left hand movement”, **electroencephalography and Clinical Neurophysiology** 103(6): 642-651.
- [9] Pfurtsheller,G. and D. Flotzinger and P. Neuper (1994), “Differentiation between finger”, toe and tongue movement in man based 40 Hz EEG,

- electroencephalography and Clinical Neurophysiology** 90 pp 456-460.
- [10] Pradhan, N. and P.K.Sadasivan, and S. Chatterji, and D.D.Narayana (1995), "Patterns of attractor dimensions of sleep EEG", **Comput. Biol. Med.** . 25(5): 455-462.
- [11] Safar, N.M. (2001), "**EEG recognition by using neural network**", M.Sc. Thesis, Department of Computer Sciences, College of Computers and Mathematics Sciences, University of Mosul,Iraq.
- [12] Sharma,A. and R.J. Roy (1997), "Design of a recognition system to predict movement during anesthesia", **IEEE Transactions on Biomedical engineering**, 44(6):505-511.
- [13] Singh, S. (2000), "**EEG data classification with localized structural information**", (from author via e-mail: [s.singh@exter.ac.uk](mailto:s.singh@exter.ac.uk)).
- [14] Wahlberg, P. and G. Salomonsson (1996), "Feature extraction and clustering of EEG epileptic spikes", **Computers and Biomedical Research**, 29(5): 382-394.