

Signal Distinction Electroencephalograms (EEG) Using a Back Propagation Neural Network Based On Localized Structural Features Extractions

Najlaa M.I. Safar

*College of Agriculture and Forestry
University of Mosul, Iraq*

Received on: 26/10/2004

Accepted on: 30/05/2005

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.

Keywords: Electroencephalograms (EEG), structural features, back propagation neural network, BFGS Quasi-Newton Back propagation function.

تمييز إشارات تخطيط الدماغ باستخدام شبكة الانتشار العكسي المعتمدة على المميزات الهيكلية

الموضوعية المستخلصة

نجلاء متى اسحق سفر

كلية الزراعة والغابات، جامعة الموصل

تاريخ قبول البحث: 2005/05/30

تاريخ استلام البحث: 2004/10/26

الملخص

تم في هذا البحث استخلاص المميزات الهيكيلية الموضعية بوصفها أساساً لقياس التغيرات الهيكيلية مع الزمن لتصنيف السلسلة الزمنية لإشارات تخطيط الدماغ EEG المستحصلة من أربعة حالات اثنان منها مرضية والأخرى سليمة (مفتوح ومغلق العينين في كل منهما). بعدها تم إدخال المميزات الهيكيلية 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 بعد دورات أقل من باقي الدول الشائعة الاستخدام مع شبكة الانتشار العكسي. وقد أظهرت النتائج لتصنيف المميزات EEG باستخدام شبكة الانتشار العكسي إن مرض الزهايمر يمكن اكتشافه بقوة 100% في العديد من القنوات في حالة اخذ 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 متباعدة في بيانات كل قناة من قنوات EEG إذ تراوحت بين 50 - 100% في حالة التمييز الصحيح في كل من الحالات الأربع (ho, hc, ao, ac). ويمكن الاستقادة من الطريقة المتبعية في هذا البحث في كثير من التطبيقات، من ضمنها تحليل السلسلة الزمنية، ومعالجة الإشارة، وتمييز الكلام.

الكلمات المفتاحية: إشارات تخطيط الدماغ، المميزات الهيكيلية، شبكة العصبية للانتشار العكسي، دالة BFGS Quasi-Newton Back propagation .

1. المقدمة

أصبح تحليل إشارات تخطيط الدماغ EEG وتمييزها Electroencephalograms (EEG) 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 أن 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 تطرق بحوث أخرى إلى تمييز توقع الحركة خلال التخدير[12]، وقدر عميق التخدير[4].

2. إشارات تخطيط الدماغ:

إن الغالب ببحوث إشارات تخطيط الدماغ تهدف إلى فهم ديناميكية المعالجات التي تجري 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) تصنیف إشارات EEG لعدة أنواع من المهام المعروفة لتمييزها،[2,1].
- ج) تصنیف 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 بالزهايمير وشخص سليم باستخدام بيانات لتسعة عشرة قناة، في حالة فتح العينين وغلقهما لكل من الشخصين المريض والسليم.

3. 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 يدوياً وتمييز الحروف المطبوعة ومجالات عديدة في تمييز الصور وتصنيفها.

إن الشبكات العصبية بنوعيها، التي تعمل بإشراف أو من دونه والمكونة من طبقة واحدة أو من عدة طبقات استطاعت وبنجاح تطبيق مختلف التصانيف ومسائل التمييز.

استخدمت الشبكات العصبية الموجة من مفاهيم تنظيمية لدماغ الإنسان، مؤخراً في حقول مختلفة من التطبيقات، مثل تمييز الأنماط، والتعریف، والتصنیف، والكلام، والرؤیة، ومعالجة الإشارات وأنظمة السيطرة. ووُجدت الشبكات العصبية تطبيقها في مساحات متعددة في معالجة الإشارات ومن بينها

إشارات تخطيط الدماغ إذ إنها من الإشارات المعقدة ذات التغيير الكبير وغالباً ما يتطلب تحليلها تحكماً من قبل شخص خبير.

إن للشبكات العصبية القدرة على إيجاد التحويل اللاخطي للنمط لكي يمكن تصنيفها بدقة أكبر، فالإرث في التعقيد للشبكة العصبية يمكن أن ينتج بسبب عدد مرات الحسابات الكبيرة لتدريب الشبكة.
[11]

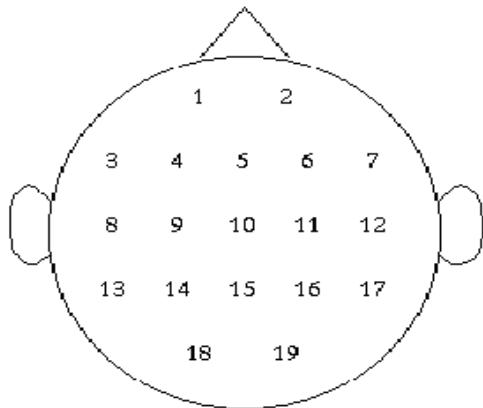
4. بيانات إشارات تخطيط الدماغ : EEG

إن بيانات إشارات تخطيط الدماغ EEG المستخدمة في البحث متوفرة عموماً في جامعة فلوريدا [3]، حيث استخدمت أربع مجتمعات من بيانات إشارات تخطيط الدماغ، كل مجموعة تتكون من 19 عموداً تقابل التسع عشرة قناة المستخدمة. ويوضح الشكل (1) موقع هذه القنوات للحالات المستخدمة في البحث وكما يأتي:

- شاب سليم عيناه مفتوحتان ho
- شاب سليم عيناه مغلقتان hc
- مريض بالزهايمر عيناه مفتوحتان ac
- مريض بالزهايمر عيناه مغلقتان 20

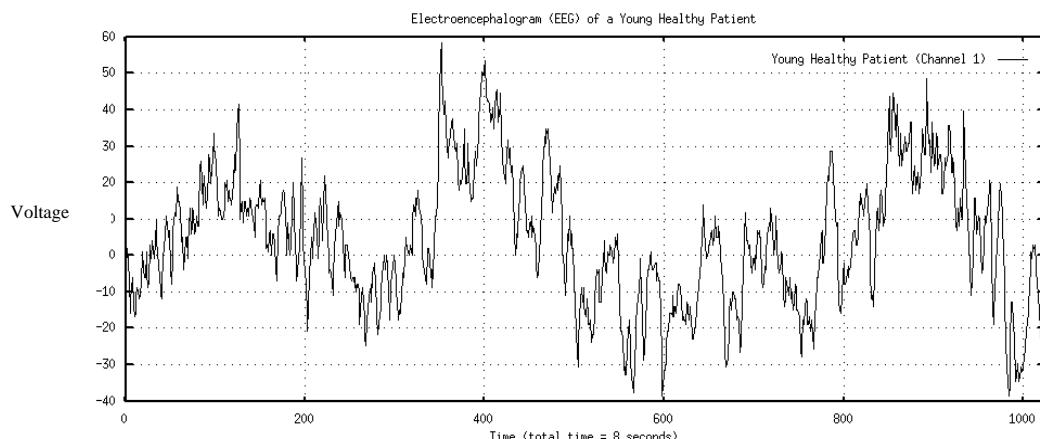
الهدف من البحث هو لتصنيف هذه الحالات الأربع بوصف الاختلاف في بيانات القناة نفسها من كل حالة. تم استقصاء السلوك الزمني للبيانات المجموعة عند نسبة أعيان 128 هرتز لمدة 8 ثوان وقد أنتجت سلسلة زمنية لـ 1024 عينة. أجز التحويل الرقمي للإشارة المقاسة تناوياً باستخدام محول رقمي ذي 8 بت، خضعت الإشارات لتصفية band-pass filter (0.1 Hz to 30Hz، 12dB/octave roll-off). أن النظام المصمم في هذا البحث اعتمد على إشارات دماغ ذات أعيان 128 هرتز تحول إلى إشارة رقمية باستخدام محول رقمي ذي 8 بت، يبين الشكل (2) إشارة تخطيط الدماغ للشخص السليم الملقطة في القناة الأولى خلال 8 ثوان.

إشارات تخطيط الدماغأخذت في 19 قناة مختلفة الموضع لتعطي معلومات حيزية وزمنية



منظر من قمة الرأس نزولا

الشكل (1) موقع القنوات التسعة عشرة في رأس الشخص المعتمدة في البحث [3].



الشكل (2): إشارة تخطيط الدماغ للشخص السليم الملقطة في القناة الأولى خلال 8 ثوان [3].

5. اختيار المميزات الهيكيلية الموضعية:

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

مسافة اعتماداً على حجم مصلعات استخدمها في بحثه). استندت طريقة اختيار المميزات الهيكلية الموضعية إلى المنطق الآتي: للبيانات ذات نوع سلسل 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 مصلع يقيس المميزات الهيكلية لـ P من النقاط، فضلاً عن ذلك، فإن قيم المصلعات لا تتقاطع مع بعضها، تمنح مميزات المصلع فوائد إضافية مهمة، وتعد كتوقيع وحيد ممكن استخدامه في التصنيف المعتمد على المعلومات الزمنية. إن المساحة للمصلع الذي يكون عند اللحظة الزمنية t يمكن حسابها بسهولة حسب المعادلة (1) [13] :

تمثل مساحة المضلع نصف مجموع الفروقات بين المشاهدة 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 الموقعة لكل عينة في القناة والتي هي :

المساحة للمضلع الذي يكون عند اللحظة الزمنية t , \mathcal{A}_t

التغير في المساحة للمضلعات المتتالية عند اللحظة الزمنية الحالية،

$$\Delta\psi_t = \psi_t - \psi_{t-1}$$

البيان للبيانات عند اللحظة الزمنية t , σ_t

$$\Delta\sigma_t = \sigma_t - \sigma_{t-1}, \quad t$$

اتجاه حركة الإشارة φ_t ، التي تكون صفرًا عندما تكون المشاهدة عند

اللحظة الزمنية ($t+1$)

وَلَا تَكُونُ وَاحِدًا.

6. خوارزمية العمل

التطبيق العملي للبحث موضح في الخطوات الآتية:

الخطوة 1: إجراء عملية الفصل لإشارات القنوات.

الخطوة 2: إيجاد المميزات الموقعة لكل عينة في القناة كما ذكرت في جزء اختيار المميزات الهيكيلية.

الخطوة 3: تكوين ملفات التدريب من البيانات المحولة، إذ يحتوي ملف التدريب على ثلث بيانات الإشارة المحولة، أي سيكون 19 ملفاً لكل تجربة من التجارب الأربع المعتمدة في البحث.

الخطوة 4: تكوين ملفات الاختبار من البيانات المحولة، إذ يحتوي ملف الاختبار على ثلثي بيانات الإشارة المحولة، والتي لم توضع في ملفات التدريب، أيضاً سيكون 19 ملفاً لكل تجربة من التجارب الأربع المعتمدة في البحث.

الخطوة 5: تحضير ملفات الهدف (المعلم للشبكة)، والتي تحتوي على بيانات منطقية(صفر، واحد)

الخطوة 6: تدريب الشبكة العصبية ذات الانتشار العكسي، إذ يكون الإدخال ملفات التدريب المهيأة للبيانات المحولة لقناة الأولى في التجارب الأربع.

الخطوة 7: اختبار الشبكة العصبية ذات الانتشار العكسي، باستخدام ملفات الاختبار المهيأة للبيانات المحولة لقناة الأولى في التجارب الأربع.

الخطوة 8: تكرار الخطوتين 6 و 7 لتدريب الشبكة واختبارها على القناة التالية.

7. 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،
$$C^m = (x_1 \dots x_N) , \text{ حيث } N=1024 \text{ و } 1 \leq m \leq 19 .$$
 تتحول البيانات الخام لكل قناة إلى بيانات التحويل باستخدام طريقة استخلاص المميزات الهيكيلية. كل نقطة x_i في قناة معينة تمثل الان بمتجه y_i ذي خمس قيم (كما تم وصفها في جزء اختيار المميزات الهيكيلية)، $y_i = (p_i, q_i, r_i, s_i, t_i)$ لجميع النقاط 1024 للبيانات الأصلية x_i ، سوف نحصل على عدد مساو من قيم y_i . البيانات الأصلية تتتألف من قياسات EEG لشخصين في حالتين مختلفتين (فتح العينين أو غلقهما)، وهذا يعطي 4 فئات للبيانات.

تمأخذ قياسات كل من هذه البيانات في 19 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 تتتألف من 35% من بيانات التحويل الكلية من كل ملف، وتم استخدام بقية البيانات في كل ملف في الاختبار وتتألف من 65% من بيانات التحويل الباقي، أي أن أكثر من نصف بيانات الإشارة في كل حالة، لم تستخدم في التدريب، فالبيانات التي تم استخدامها في الاختبار لم تدرس 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 المتوفرة لدينا لنفس الحالات، والمأخوذة من نفس القنوات لنفس الموضع في رأس الشخص، لذلك يعمد أكثر الباحثين إلى مثل هذا الإجراء.

الشبكة العصبية المستخدمة في البحث ذات تنظيم ضمن طبقتين (إدخال ومحفية وإخراج) وبعد مناسب من وحدات الخلايا، حيث أدخلت قيم المميزات الهيكيلية إلى الشبكة، واحتوت الطبقة المخفية على 50 أو 100 خلية (بعد تجرب التدريب العديدة وبقيم مختلفة إلى أن تم الاستقرار على هذا العدد)، أي تم تدريب الشبكة لجميع القنوات التسع عشرة، مرة باستخدام 50 خلية في الطبقة المخفية وتتدريب آخر باستخدام 100 خلية في الطبقة المخفية، وفي كلتا الحالتين أعطت نتائج جيدة. أما الإخراج فيحتوي على 4 خلايا كل منها يشير إلى أحد 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 تكيف عامل التعلم، دالة انحدار الخطأ/ باستخدام العزم لشبكة الانتشار العكسي، دالة شبه نيوتن للانتشار العكسي، وكانت الأخيرة الأحسن في العمل مع بيانات الشبكة إذ حققت نتائج أفضل عند الاختبار للمميزات الهيكيلية لعينات الإشارات التي لم يتم التدريب عليها كما وإنها وصلت إلى الهدف في التدريب بعد دورات أقل من باقي الدوال والشكل (3-أ و3-ب) يوضح انحدار الخطأ في الشبكة في أثناء التدريب والوصول إلى الهدف بعد دورات يعد قليلاً نسبة إلى صعوبة المسألة وتعقدتها.

وتعتبر طريقة نيوتون بديلاً لطريقتين مشتقة الانحدار وذلك لأجل سرعة الوصول إلى الأمثلية . إن الخطوة الأساسية لطريقة نيوتون هي:

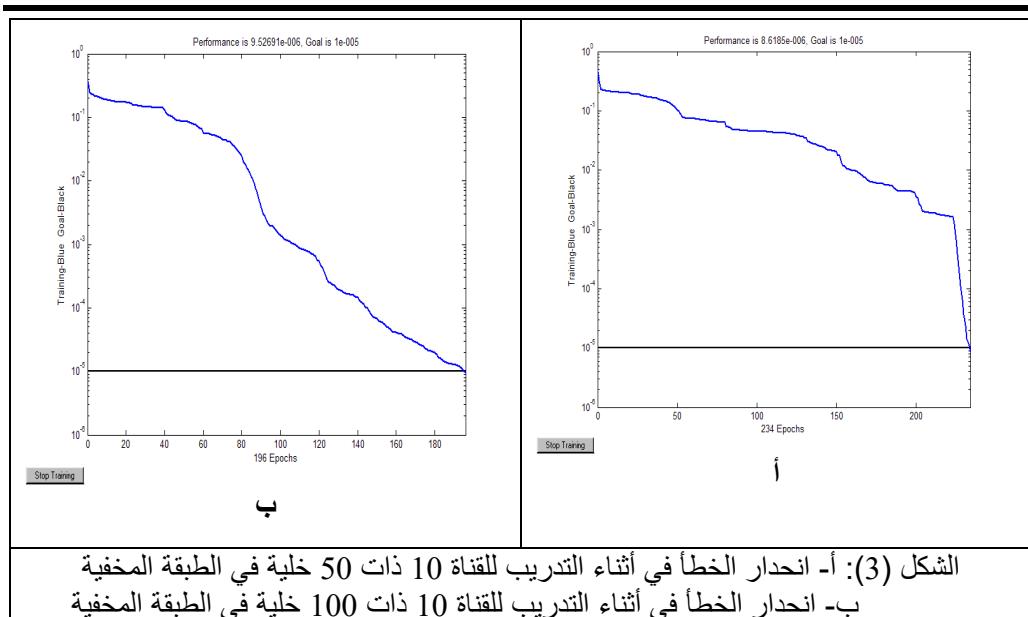
حيث إن:

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

X_k : متجه الأوزان و الانحيازات الحالية.

A_k هي مصفوفة هيسيان (الإشتقات الثانية) من فهرست الأداء في القيم الحالية للأوزان والانحرافات. g_k تمثل الانحدار الحالي.

تقرب طريقة نيوتن غالباً بشكل أسرع من طرائق مشتقة الانحدار . لسوء الحظ، إن حساب مصفوفة هيسيان للغذية الأمامية feed forward للشبكات العصبية يعد معقداً ومكلفاً. هناك نوع من الخوارزميات التي تكون مستندة إلى طريقة نيوتن، لكن لا تتطلب حساب الإشتقاتات الثانية. هذه تدعى طرائق شبه نيوتن (أو secant quasi-Newton). 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].



8. مناقشة النتائج

تزود المميزات الهيكلية الموضعية للإشارة بفائدة معنوية أكثر من استخدام المشاهدات الأصلية عند تصنيف الإشارة كما أثبتت العديد من البحوث، يبين الجدولان (1) و(2) نسبة الاختبار الصحيح لبيانات الإشارة غير المدرب عليها للحالات الأربع (ho, hc, ao, ac) باستخدام 19 قناة عند وجود 50 ، و100 خلية في الطبقة المخفية، على التوالي، ويمكن القول بأن مرض الزهايمر يمكن كشفه بقوة أكبر في حالة غلق العينين للمريض (الجدول 1) إذ تم تمييز 100% في كل من القنوات (4 و 6 و 9 و 10 و 13 و 14 و 15 و 18 و 19)، وبنسبة لانقل عن 96% في باقي القنوات عدا القناتين 3 و 12 ، أما عند حالة فتح العينين للمريض فقد حققت القناة 12 أعلى نسبة تمييز %85 ، وفي حالة الشخص السليم وهو مغلق العينين فقد حققت القناة 15 أعلى نتيجة، وفي حالة الشخص السليم ومفتوح العينين فقد حققت القناة 6 أفضل تمييز 97%. هذا عندما كان عدد الخلايا في الطبقة المخفية 50.

الجدول (1): نسبة الاختبار الصحيح في التجارب الأربع لجميع القنوات عند التدريب باستخدام 50 عقدة في الطبقة المخفية.

التجربة 4 سليم مفتوح العينين %	التجربة 3 سليم مغلق العينين %	التجربة 2 مريض مفتوح العينين %	التجربة 1 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 100 خلية في الطبقة المخفية (الجدول 2)، فنلاحظ أيضاً قوة اكتشاف مرض الزهايمر بنسبة 100% للتمييز الصحيح في القنوات (4 و 5 و 6 و 8 و 9 و 10 و 13 و 14 و 15 و 16 و 17 و 18 و 19)، وبنسبة لانقل عن 95% في باقي القنوات عدا القناتين 1 و 3 . وعند حالة فتح العينين للمريض فقد حققت القناة 12 أعلى نسبة تمييز، وفي حالة الشخص السليم ومغلق العينين فقد حققت القناة 16 أعلى نتيجة وهي 98%， وفي حالة الشخص السليم ومفتوح العينين فقد حققت القناة 6 أفضل تمييز بنسبة 91% .

الجدول (2): نسبة الاختبار الصحيح في التجارب الأربع لجميع القنوات عند التدريب باستخدام 100 عقدة في الطبقة المخفية.

التجربة 4 سليم مفتوح العينين %	التجربة 3 سليم مغلق العينين %	التجربة 2 مريض مفتوح العينين %	التجربة 1 مريض مغلق العينين %	اسم التجربة رقم القناة
69.98	87.19	54.49	87.76	channel11
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] Pfurtscheller,G. (1997), “EEG-based discrimination between imagination of right and left hand movement”, **electroencephalography and Clinical Neurophysiology** 103(6): 642-651.
- [9] Pfurtscheller,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).
- [14] Wahlberg, P. and G. Salomonsson (1996), “Feature extraction and clustering of EEG epileptic spikes”, **Computers and Biomedical Research**, 29(5): 382-394.