

Hybridization of a hidden Markov model using Elman neural network with application

Omar S. Qasim

omar.saber@uomosul.edu.iq

College of Computer Science and Mathematics

University of Mosul, Mosul, Iraq

Received on: 22/10/2012

Accepted on: 30 /01/2013

ABSTRACT

This research aims to improve the performance of the work of hidden Markov model, which is limited to the positive integers as input, and through the use of Elman artificial neural network that have the ability to accept all types of data in the input space. The proposed model has proved that it is highly efficient in the classification of osteoporosis data compared with Elman artificial neural network on the one hand and the hidden Markov model on the other.

Keywords: pattern recognition; Elman neural network; hidden Markov model.

تهجين أنموذج ماركوف المخفي باستخدام شبكة ايلمان العصبية الاصطناعية مع التطبيق

عمر صابر قاسم

كلية علوم الحاسوب والرياضيات، جامعة الموصل

تاريخ قبول البحث : 2013\1\30

تاريخ استلام البحث : 2012\10\22

المخلص

يهدف هذا البحث إلى تطوير أداء عمل أنموذج ماركوف المخفي والذي يقتصر على فضاء الإدخال من نوع الأعداد الصحيحة الموجبة، وذلك من خلال استخدام شبكة ايلمان العصبية الاصطناعية التي لها القابلية على تقبل جميع أنواع البيانات في فضاء الإدخال. حيث اثبت الأنموذج المقترح كفاءة عالية في تصنيف بيانات هشاشة العظام مقارنة مع شبكة ايلمان العصبية الاصطناعية من جهة وأنموذج ماركوف المخفي من جهة أخرى. **الكلمات المفتاحية:** تمييز الأنماط; الشبكة العصبية الاصطناعية; نموذج ماركوف المخفي .

1. المقدمة

لقد أولى الباحثون في السنوات الأخيرة اهتماماً بالغاً في تصنيف الأنماط الطبية المختلفة ومن ضمنها مرض هشاشة العظام والذي يعد من الأمراض الصامتة التي تتشأ بدون ألم [8] , لذلك فإنه من الضروري جداً أن نحافظ عليها مع تقدم العمر. كما أن التشخيص المبكر يمكننا من التعرف على أعراض الإصابة من اجل اتخاذ الخطوات اللازمة لمنع تفاقم هذا المرض.

إن التشخيص الدقيق للبيانات يحتاج إلى اختيار متقن للنماذج المستخدمة في التعرف على الأنماط المختلفة, وعملية الاختيار لا بد من أن تكون ضمن دراسة للسلوك الرياضي لهذه النماذج لمعرفة مدى ملائمة كل من فضاء المجال (Domain) والمدى (Range) مع نوعية بيانات الإدخال (Input) والإخراج (Output). وعلى هذا الأساس تم اختيار شبكة ايلمان العصبية كمرحلة أولى في عملية معالجة البيانات, كونها تتقبل في فضاء المجال (الإدخال) جميع أنواع البيانات سواء أكانت صحيحة أم حقيقية وكذلك موجبة أو سالبة, في حين تتم المعالجة الثانية من خلال أنموذج ماركوف المخفي الذي يكون متلائماً مع طبيعة سلوك الإخراج للشبكة والذي يعطي نتائج أكثر دقة من خلال المعالجة المزدوجة.

2. وصف المشاهدات


تم اخذ مجموعة من المشاهدات المختلفة بحجم (344) عينة، وتتكون كل عينة من (17) ميزة (متغير مستقل)، بحيث تتضمن هذه العينات أنواع أمراض هشاشة والتمثلة بالإصابة في المرحلة الأولى من المرض وتدعى (Osteopenia) والثانية الإصابة في المرحلة المتأخرة من المرض وتدعى (Osteoporosis) في حين تكون الحالة الثالثة هي الحالة السليمة (Normal) [12]، كما أن البيانات التي تم استخدامها في التعرف على أمراض هشاشة العظام عبارة عن قيم عددية ووصفية تم الحصول عليها بمساعدة أساتذة في كلية التمريض في جامعة الموصل وتمثل معلومات ضمن قاعدة بيانات (Data Base) لأشخاص تم إجراء عملية الفحص عليهم داخل العراق وتحديداً في محافظة نينوى .

إن التشخيص المتقن والتعرف الدقيق على الأنماط يعد من أهم المسائل التي تحتاج إلى اختيار دقيق لتقنيات التشخيص، وقد تم في هذا البحث دراسة سلوك كل من تقنيتي شبكة ايلمان العصبية (Elman Network) وأنموذج ماركوف المخفي (Hidden Markov) من الناحية الرياضية والتركيز على فضاءات الإدخال والإخراج والدوال الرياضية المستخدمة في عملية تحويل البيانات.

3. أنموذج ماركوف المخفي [2],[7]

يعد أنموذج ماركوف المخفي تعميماً لنماذج ماركوف الاعتيادية وتطويراً للعمليات الماركوفية، حيث أن الحالات في أنموذج ماركوف الاعتيادي تكون مرئية بشكل مباشر إلى المشاهد أو المراقب، ولهذا تكون احتمالية انتقال الحالة مؤشرة ومعلومة، في حين أن أنموذج ماركوف المخفي تكون الحالة غير مرئية والنتيجة تعتمد على الحالة، وكل حالة لها توزيع احتمالي يعتمد على الإخراج. إن سلسلة الرموز المتولدة بأنموذج ماركوف المخفي تعطي بعض المعلومات حول سلسلة الحالات.

يعود الفضل إلى اكتشاف هذا الأنموذج إلى الباحث (Leonard E. Baum) وآخرون عندما نشروا مجموعة من المقالات الإحصائية بهذا الخصوص في النصف الثاني من ستينيات القرن العشرين. أما أول تطبيق لأنموذج ماركوف المخفي فكان في مجال تمييز الصوت (Speech Recognition) وذلك في منتصف سبعينيات القرن العشرين. وفي النصف الثاني من ثمانينيات القرن العشرين بدأ استخدام أنموذج ماركوف المخفي في تحليل المتتابعات الحياتية (Biological Sequences)، خصوصاً DNA، ومنذ ذلك الوقت فرض أنموذج ماركوف المخفي وجوده في مجال المعلوماتية الحياتية (Bioinformatics). يستخدم أنموذج ماركوف المخفي بشكل خاص في تمييز الأنماط مثل الكلام والكتابة وكذلك في تطبيقات المعلوماتية وغيرها.



الشكل (1) يمثل المعطيات الاحتمالية في أنموذج ماركوف المخفي

في الشكل أعلاه يمكن تمثيل المعلمات بالشكل الآتي :

x : تمثل الحالات (states).

y : تمثل المشاهدات الممكنة.

a : احتمالات انتقال الحالة.

b : احتمالات الإخراج.

1.3. المسائل الأساسية لنماذج ماركوف المخفية

هناك ثلاث مسائل أساسية لنماذج ماركوف المخفية وهي [3]:

1. مسألة التقييم Evaluation Problem :

تتطلب هذه المسألة حساب $P(O|\lambda)$ عندما يكون المعطى هو الأنموذج $\lambda=(A,B,\pi)$ ومتتابة المشاهدات O.

2. مسألة حل الشفرة Decoding Problem :

إذا كان المعطى هو الأنموذج $\lambda=(A,B,\pi)$ ومتتابة المشاهدات O، فكيف يمكننا حساب متتابة الحالة المثلى (Optimal) (الأكثر احتمالا).

3. مسألة التدريب Training Problem :

وتتناول هذه المسألة كيفية تعديل معلمات الأنموذج $\lambda = (A, B, \pi)$ لتعظيم $P(O|\lambda)$.

2.3. خوارزمية فيتربي [6],[3]

تعمل خوارزمية (Viterbi) على إيجاد أفضل متتابة حالة عندما يكون المعطى الأنموذج $\lambda = (A, B, \pi)$ وعدد الحالات هو (N) ومتتابة المشاهدات $O = \{O_1, O_2, \dots, O_T\}$. وتكون هذه الخوارزمية مشابهة للخوارزمية الأمامية إلا أنها تأخذ أعلى احتمالية للمسار على احتمال المسارات السابقة، في حين أن الخوارزمية الأمامية تأخذ المجموع (Sum). كذلك فان خوارزمية فيتربي لها مؤشرات تراجعية (Back-Pointers) لاتملكها الخوارزميات الأساسية، إذ يتم حساب أفضل تسلسل للحالة عن طريق الاحتفاظ بمسار الحالات المخفية التي تقود لكل حالة، ثم تتبع أفضل مسار (Back Trace) إلى البداية.

لكي يتم إيجاد متتابة الحالة المثلى لمتتابة المشاهدات $O = \{O_1, O_2, \dots, O_T\}$ يجد النظام متتابة الحالة ذات الطول T من الحالة الابتدائية إلى الحالة النهائية. كما أن هناك بعض المتغيرات الأساسية لهذه الخوارزمية وكالاتي [3]:

1. المتغير $V_t(i)$: يمثل أعلى احتمالية على طول المسار الوحيد في الحالة i عند الزمن t والذي يساوي احتمالية متتابة الحالة الجزئية الأكثر احتمالاً بالنسبة لمتتابة المشاهدات المنتهية في الحالة i ويمكن التعبير عنه رياضياً كالاتي :

$$V_t(j) = \max_{i=1}^N v_{t-1}(i) a_{ij} b_j(O_t) \quad , j=1,2,\dots,N \quad , t=1,2,\dots,T \quad \dots\dots\dots(1)$$

a_{ij} : احتمالية الانتقال من الحالة السابقة q_i الى الحالة الحالية q_j .

$b_j(O_t)$: احتمالية المشاهدة للرمز O_t الذي تُعطيه الحالة الحالية q_j .

$\psi_t(j)$: يعمل هذا المتغير على حفظ تتابع الأثر (Keep Track) للمسار الفعلي.

أما خطوات خوارزمية فيتربي فهي كما يأتي :

2. البداية Initialization

$$V_1(j)=(2) \dots \dots \dots j = 1,2,\dots, N ; \pi_i b_i (O_1)$$

$$\psi_1(j) = O \dots \dots \dots (3)$$

3. التعاقب Recursion

$$V_t(j) = \max_{i=1}^N [v_{t-1}(i).a_{ij}] b_j (O_t) ; j = 1,2,\dots, N$$

$$t = 2,3,\dots, T \dots \dots \dots (4)$$

$$\psi_1(j) = \arg \max_{i=1}^N [v_{t-1}(i).a_{ij}] ; j = 1,2,\dots, N$$

$$t = 2,3,\dots, T \dots \dots \dots (5)$$

4. النهاية Termination

$$P^* = \max_{i=1}^N [v_T(i)] \dots \dots \dots (6)$$

$$q_T^* = \arg \max_{i=1}^N [v_T(i)] \dots \dots \dots (7)$$

5. التعاقب المعاكس (Back tracking)

$$q_t^* = \psi_{t+1}(q_{t+1}^*) ; t=T-1, T-2, \dots, 2, 1 \dots \dots \dots (8)$$

4. شبكة ايلمان العصبية الاصطناعية

تعد شبكة ايلمان العصبية من اشهر الشبكات التكرارية التي ابتكرت من قبل العالم (Jeffrey L. Elman) في العام (1990)، وهي بشكل عام نوع خاص من شبكات التغذية الخلفية التي تتكون من طبقتين تسري من خلالهما المعالجة من طبقة الإدخال إلى طبقة الإخراج بعملية التغذية الأمامية. إذ إن الاتصال المتكرر يسمح لشبكة ايلمان العصبية الاصطناعية أن تلاحظ وتولد أنماطاً مختلفة في الوقت (Time-Varying)، كما أن النمذجة الرياضية لهذه الشبكة يمكن أن يتم صياغتها بالشكل الآتي [5] [9]:

$$O_k(t) = \sum_{j=1}^q w_{kj} H_j(t) \dots \dots \dots (9)$$

$$H_j(t) = g(V_j(t)) \dots \dots \dots (10)$$

$$V_j(t) = \sum_{a=1}^q w_{ja} H_{ja}(t-1) + \sum_{i=1}^p w_{ji} I_i(t) \dots \dots \dots (11)$$

p : عدد الوحدات العصبية في طبقة الإدخال.

q : عدد الوحدات العصبية في الطبقة المخفية (Hidden).

$H_j(t)$: يمثل إخراج وحدات الطبقة المخفية.

$H_{ja}(t-1)$: يمثل إخراج وحدات الطبقة المخفية متأخرة بمقدار وحدة زمنية واحدة.

$V_j(t)$: مجموع ادخال وحدات الطبقة المخفية.

$I_i(t)$: وحدات الإدخال (Input) في الشبكة العصبية.


$O_k(t)$: يمثل ناتج إخراج الطبقة الأخيرة (Output).

w_{kj} : تمثل وزن الارتباط بين الطبقة المخفية (Hidden) وطبقة الإخراج (Output).

w_{ja} : تمثل وزن الارتباط بين طبقة (Context) والطبقة المخفية.

w_{ji} : تمثل وزن الارتباط بين طبقة الإدخال والطبقة المخفية.

$g(.)$: دالة التنشيط وعادة ماتكون غير خطية.



الشكل (2) يمثل معمارية شبكة ايلمان العصبية الاصطناعية

تتكون شبكة ايلمان العصبية من دالة التفعيل من النوع (tansig) في الطبقة المخفية ومن دالة التفعيل من النوع (purelin) في طبقة الإخراج, كما أن الطبقة المخفية تتطلب عدداً كافياً من وحدات المعالجة أو العقد يتناسب مع تعقيد المسألة المراد معالجتها, وقد تم استخدام (50) وحدة معالجة في بحثنا هذا, كما تتميز شبكة ايلمان العصبية الاصطناعية عن بقية الشبكات الاعتيادية ذات الطبقتين كون أن الطبقة الأولى فيها تمتلك اتصالاً متكرراً (Recurrent Connection), كما أن التأخير في الاتصال يخزن القيم من الخطوة السابقة والتي يمكن أن تستخدم في الخطوة الحالية [10] [11].

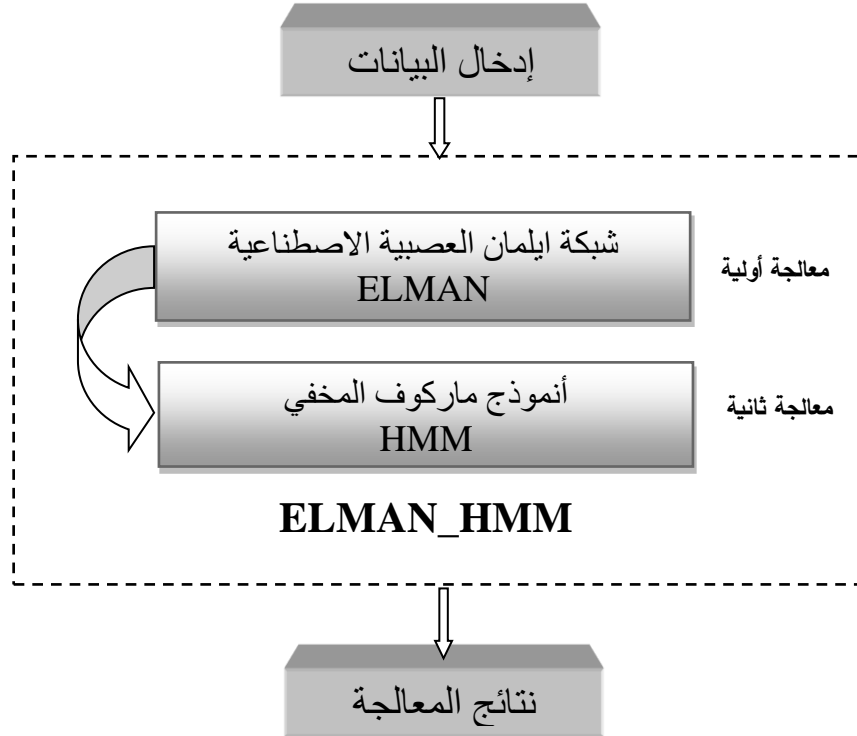
1.4. آلية المعالجة في شبكة ايلمان العصبية الاصطناعية :

تتكون شبكة ايلمان العصبية الاصطناعية من طبقة الإدخال وطبقة الإخراج بالإضافة إلى الطبقة المخفية, وتتميز بوجود وحدات معالجة ملحقة تدعى (Context) يكون عددها مساوياً لعدد وحدات المعالجة في الطبقة المخفية وتعطى لها قيمة صفرية في بداية المعالجة كما تعطى الأوزان المقابلة لها قيمة واحدة ثم تعدل أثناء التدريب وتقوم بخزن قيم الإخراج السابقة للطبقة المخفية, كما أن إعادة إخراج الطبقة المخفية إلى طبقة الإدخال يعطي إمكانية بناء ذاكرة قصيرة الأمد تستعمل لتسريع عمل وتدريب الشبكة من خلال ضبط الأوزان [13] [1]. إن الإدخال إلى الطبقة المخفية هو ناتج حاصل ضرب الإدخال في الأوزان مضافاً إليها قيمة التحيز, كما تعدل الأوزان عن طريق تكرار الانتشار الخلفي للخطأ لإعطاء الشبكة إمكانية معالجة الأنماط من خلال مراحل تكرارية مختلفة [4].

2. الأنموذج المقترح (ايلمان_ماركوف المخفي) (ELMAN_HM):

تم اقتراح خوارزمية مهجنة بين شبكة ايلمان (Elman) العصبية الاصطناعية وأنموذج ماركوف المخفي (HMM), وذلك من خلال إجراء تكامل في عملية المعالجة لبيانات الهشاشة والتي تنتمي إلى فضاء الأعداد الحقيقية ولايستطيع أنموذج ماركوف المخفي لوحده معالجتها كونه يقبل إدخالاً تنتمي إلى فضاء الأعداد الصحيحة الموجبة, حيث تم تهجين هذا الأنموذج باستخدام شبكة ايلمان العصبية الاصطناعية ذات القدرات

الرياضية العالية في آلية معالجة البيانات، بالإضافة إلى كونها تتقبل البيانات التي تنتمي إلى فضاءات الأعداد الحقيقية، حيث تم تسمية الأنموذج المقترح باسم أنموذج (إيلمان_ماركوف المخفي) نسبة إلى كل من أنموذج شبكة إيلمان وأنموذج ماركوف المخفي، حيث يتألف الأنموذج المقترح من مرحلتين أساسيتين من مراحل معالجة البيانات، تتمثل المرحلة الأولى من خلال بناء شبكة إيلمان العصبية الاصطناعية والتي يتم من خلالها استقبال البيانات في طبقة الإدخال والقيام باليات المعالجة المتوازية من خلال معمارية الشبكة، والبيانات المخرجة في الطبقة الأخيرة تعد إدخالاً للمرحلة الثانية والتي تتم من خلال أنموذج ماركوف المخفي ويتم من خلالها تقدير معلمات الأنموذج ويصبح قادراً على تقبل البيانات الجديدة وتصنيفها.



الشكل (3) مخطط عام يوضح مراحل المعالجة في الخوارزمية المقترحة (ELMAN_HMM).

1.5. تطبيق أنموذج إيلمان_ماركوف المخفي على بيانات هشاشة العظام

لقد تم استخدام وتطبيق أنموذج إيلمان_ماركوف المخفي على بيانات الهشاشة بوصفه إحدى النماذج الذكائية التي لاتعتمد على نوع محدد من بيانات الإدخال كما في أنموذج ماركوف المخفي الاعتيادي الذي يتطلب بيانات عددية صحيحة موجبة، حيث أن الأنموذج المقترح لديه إمكانية أوسع لمعالجة البيانات فضلا عن الدقة الكبيرة في تصنيف الحالات المرضية مقارنة مع أنموذج ماركوف المخفي الاعتيادي والذي عجز عن معالجة بيانات هشاشة العظام كونها تحتوي على قيم تنتمي إلى فضاء الأعداد الحقيقية (Real Number) والتي لاتلائم فضاء الإدخال لهذا الأنموذج، وقد تم تقسيم بيانات هشاشة العظام إلى بيانات سليمة (Normal) ومصابة بالهشاشة من النوع (Osteopenia) ومصابة بالهشاشة من النوع (Osteoporosis)، كما تم تقسيم إدخالات أنموذج إيلمان_ماركوف المخفي إلى :

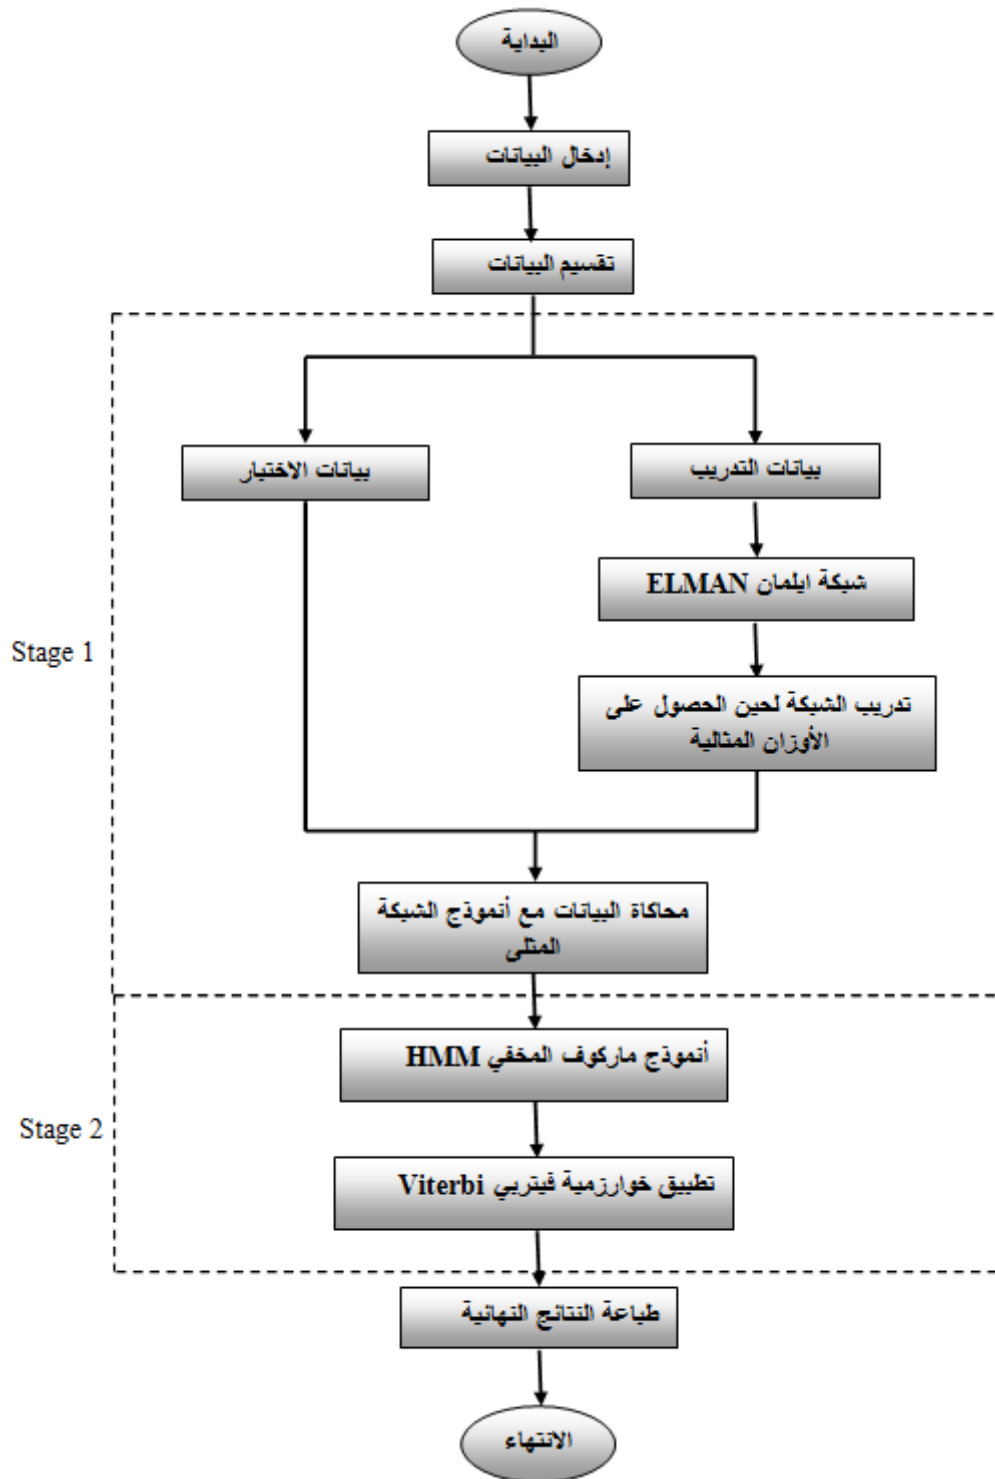
1. بيانات التدريب Training Data : حيث تتكون من (300) حالة منها (86) حالة من نوع (Normal) و (116) حالة من نوع (Osteopenia) و (98) حالة من نوع (Osteoporosis).
2. بيانات الاختبار Testing Data : حيث تتكون من (44) حالة منها (14) حالة من نوع (Normal) و (15) حالة من نوع (Osteopenia) و (15) حالة من نوع (Osteoporosis).

إن الاختيار المناسب لمعاملات شبكة ايلمان العصبية الاصطناعية يعد من المسائل المهمة والمؤثرة في تصميم أنموذج ايلمان_ماركوف المخفي, وكل هذه الاختيارات يجب أن تتم قبل بداية التدريب, وبدون شك سيعطي الاختيار الموفق لمعاملات الشبكة نتائج أفضل للأنموذج المقترح. لقد تم اختيار معمارية الشبكة المثلة من خلال التجربة لحين إعطاء أفضل النتائج الممكنة بالنسبة لبيانات الإدخال. حيث تتكون معمارية هذه الشبكة من وحدات الإدخال والتي تمثل قراءات لحالات مرض هشاشة العظام المستخدمة في تدريب أنموذج الشبكة وعددها (17) قراءة و(400) حالة مرضية وسليمة, كما تم اعتماد طبقة مخفية واحدة في معمارية الشبكة, في حين أن عدد العقد (Nodes) التي تم اعتمادها في هذه الطبقة المخفية هو (50) وحدة معالجة تحوي كل منها على دالة تنشيط من نوع (Hyperbolic Tangent Sigmoid), كما تم اعتماد الدالة الخطية (Linear Function) كدالة تنشيط في طبقة الإخراج.

3. الخوارزمية المقترحة في تصنيف بيانات هشاشة العظام:

إن الخطوات الرئيسية لتصنيف حالات أمراض هشاشة العظام باستخدام أنموذج ايلمان_ماركوف المخفي (ELMAN_HHM), والتي يتم من خلالها استخدام الخوارزمية المقترحة, لها القدرة على التعامل مع جميع أنواع البيانات في فضاءات الأعداد, دون الاقتصار على البيانات العددية في فضاء الأعداد الصحيحة, وهذه ميزة تمتلكها الخوارزمية المقترحة ولايملكها أنموذج ماركوف المخفي , كما أن الخوارزمية المقترحة لها القدرة على تصنيف البيانات بأقل خطأ ممكن, وهذه ميزة ثانية للخوارزمية المقترحة, لاتملكها شبكة ايلمان العصبية الاصطناعية, حيث أن الخطوات الرئيسية للخوارزمية المقترحة تكون على النحو الآتي :

1. تهيئة مصفوفة بيانات الإدخال, ولتكن (X), صفوفها تمثل الأنماط القياسية للحالات المرضية التي تم قياسها وأعمدها تمثل الحالات المرضية المتنوعة.
2. تقسيم بيانات الإدخال إلى مجموعتين (X1) و (X2) حيث تمثل الأولى بيانات التدريب في حين تمثل الثانية الحالات المستخدمة في اختبار الأنموذج.
3. إدخال بيانات التدريب على شبكة ايلمان العصبية الاصطناعية ومن ثم تدريب هذه البيانات من خلال محاكاتها مع الشبكة المدربة للحصول على الإخراج الحقيقي. بينما في بيانات الاختبار لا يتم تدريب الشبكة أثناء المعالجة, إذ يتم الاكتفاء بعملية المحاكاة على أنموذج الشبكة المدربة من خلال بيانات التدريب.
4. تطبيق أنموذج ماركوف المخفي وذلك من خلال خوارزمية فيتربي على الإخراج الحقيقي لشبكة ايلمان العصبية الاصطناعية.
5. مقارنة النتائج المستحصلة من الأنموذج المهجن (ايلمان_ماركوف المخفي) في كل من بيانات التدريب والاختبار مع النتائج الحقيقية للحالات المرضية.



الشكل (4) مخطط انسيابي عام يوضح آلية عمل الخوارزمية المقترحة (ELMAN_HMM)


4.مقارنة النتائج بين الخوارزمية المهجنة (ELMAN_HHM) والنماذج القياسية من خلال تصنيف أمراض هشاشة العظام

لقد تمت مقارنة الخوارزمية المقترحة (ELMAN_HHM) والتي يتم من خلالها تهجين شبكة ايلمان العصبية الاصطناعية و أنموذج ماركوف المخفي, مع كل من شبكة ايلمان العصبية الاصطناعية القياسية من جهة, وأنموذج ماركوف المخفي من جهة أخرى, وقد أثبتت النتائج أن التقنية المهجنة أو المقترحة (ELMAN_HHM) هي الأفضل من ناحية دقة النتائج المطلوبة التي يستدل عليها من خلال مقياس معدل مربع الخطأ (MSE) بالنسبة لبيانات الاختبار والتدريب. والجدول (1) يوضح نتائج هذه المقارنة :

الجدول (1) مقارنة بين التقنية المهجنة (ELMAN_HHM) مع كل من شبكة ايلمان العصبية وأنموذج ماركوف المخفي

معدل مربع الخطأ لبيانات الاختبار (MSE_Testing)	معدل مربع الخطأ لبيانات التدريب (MSE_Training)	تقبل فضاء الإدخال (Input Space)	نوع التقنية الذكائية المستخدمة (Type of Technique)
0.0682	0.05	نعم	التقنية المهجنة (ELMAN_HHM)
0.2307	0.2107	نعم	شبكة ايلمان العصبية (ELMAN)
-----	-----	لا يمكن	أنموذج ماركوف المخفي (HHM)

إن نتائج التهجين المبينة في الجدول (1) والمتمثلة بتقنية (ELMAN_HHM) أثبتت أنها هي الأفضل من خلال مقياس (MSE), من شبكة ايلمان العصبية الاصطناعي ومن خلال بيانات الاختبار والتدريب فضلاً عن إمكانيتها على إجراء عملية محاكاة لفضاءات الإدخال للبيانات والتي عجز عنها أنموذج ماركوف المخفي حيث أن هذا الأنموذج لا يستطيع معالجة بيانات الهشاشة كونها تنتمي إلى فضاء الأعداد الحقيقية, لذا لا يمكن استخدامه في تصنيف أمراض الهشاشة, وبهذا تكون الخوارزمية المهجنة المقترحة (ELMAN_HHM) أفضل من كل من تقنيتي شبكة ايلمان العصبية وأنموذج ماركوف المخفي. كما يبين الشكل (4) مقارنة لعدد الحالات المصنفة بشكل صحيح في كل من تقنيتي شبكة ايلمان العصبية (ELMAN) والتقنية المهجنة (ELMAN_HHM) بالنسبة لبيانات الاختبار والتي عددها (44) حالة :



الشكل (4) يبين مقارنة بين عدد حالات الاختبار المصنفة بشكل صحيح في كل من تقنية (ELMAN) والتقنية المهجنة (ELMAN_HMM)

5. الاستنتاجات والتوصيات

من خلال النتائج في الجدول (1) نستنتج ما يأتي :

1. لقد اثبت الأنموذج المهجن المقترح (ELMAN_HMM) في الجدول (1) إمكانية عالية في تصنيف بيانات الهشاشة وذلك من خلال مقياس (MSE) مقارنة مع شبكة ايلمان العصبية الاصطناعية وفي كل من بيانات التدريب والاختبار.

2. إمكانية الأنموذج المقترح (ELMAN_HMM) التعامل مع جميع أنواع المدخلات في فضاء الإدخال (Input Space), مما يعطيه شمولية كبيرة في التعامل مع التطبيقات المختلفة, وهذه ميزة لايمتلكها أنموذج ماركوف المخفي القياسي.

3. أثبتت شبكة ايلمان العصبية الاصطناعية أنها أكثر عمومية من أنموذج ماركوف المخفي في التعامل مع التطبيقات كونها تتقبل جميع أنواع الفضاءات التي تنتمي إليها البيانات.

كما نوصي بالآتي:

1. نوصي باستخدام تهجين بين أنموذج ماركوف المخفي وشبكات عصبية أخرى لها إمكانيات في معالجة البيانات المختلفة مثل شبكة التراجع الخلفي للخطأ (Backpropagation).

2. نوصي بتوظيف الطريقة المقترحة كنظام مساعد للطبيب في المراكز الطبية المختلفة واستخدامها على بيانات تنتمي إلى فضاءات متعددة.

المصادر

- [1] جبريني, مصون نبهان حمصي ،(2010)، "نظام تفاعلي ذكي من اجل التعليم على الشبكة العنكبوتية"، أطروحة دكتوراه غير منشورة، كلية العلوم، جامعة حلب، سوريا.
- [2] الخياط, باسل يونس،(2010)، "النمذجة الماركوفية مع تطبيقات عملية"، الجزء الثاني، دار الكتب للطباعة والنشر-الموصل، العراق.
- [3] زمزوم, فاطمة محمود حسن،(2010)، "استخدام النمذجة الماركوفية في المعلوماتية الحياتية"، رسالة ماجستير غير منشورة، كلية علوم الحاسوب والرياضيات، جامعة الموصل، العراق.
- [4] عيسى، علام زكي ،(2000)، "الشبكات العصبية، البنية الهندسية-الخوارزميات-التطبيقات"، الطبعة الأولى، شعاع للنشر والعلوم، حلب، سوريا.
- [5] محمد, سوزان حسن ،(2011)، " تأثير استخدام مرشحات كشف الحواف على أداء وكفاءة شبكة ايلمان العصبية الاصطناعية" ، كلية علوم الحاسبات والرياضيات، جامعة الموصل ، العراق.
- [6] Batzoglou,S، (2010)، "Hidden Markov Models and the Viterbi algorithm" Scribed by John C.Mu .
- [7] Fonzo, V. , Aluffi-Pentini, F., and Parisi, V، (2007) ، " Hidden Markov Models in Bioinformatics", Vol. 2, No. 1, Euro. Bio. Park, University di Roma, Roma, Italy.
- [8] <http://en.wikipedia.org/wiki/Osteoporosis>.
- [9] Medsker L.R. & Jain L.C.,(2001)," RECURRENT NEURAL NETWORKS: Design and Applications", CRC Press Boca Raton London New York Washington, D.C.
- [10] Ramadevi R., Sheela R. B. & Prakash V. ,(2012), "Role of Hidden Neurons in an Elman Recurrent Neural Network in Classification of Cavitation Signals", International Journal of Computer Applications (0975 – 8887), Volume 37– No.7.
- [11] Ramo R.M. & Ramo F.M. ,(2011),"Face Detection Using Neural Networks", The Fourth Scientific Conference of the College of Computer Science & Mathematics pp [336-350].
- [12] Wolfram U., Schwen L.O. & Simon U. ,(2009) ," Statistical Osteoporosis Models Using Composite Finite Elements: A Parameter Study",Submitted to Journal of Biomechanics.
- [13] Zeng Z., (2012),"Multi-step Predictions Based on TD-DBP ELMAN Neural Network for Wave Compensating Platform", Advances in CSIE, Vol. 2, AISC 169, pp. 431–436. © Springer-Verlag Berlin Heidelberg.

ملحق (1) يمثل بيانات الاختبار لمرض هشاشة العظام المستخدمة في البحث

y	X1	X2	X3	X4	X5	X6	X7	X8	X9	X10	X11	X12	X13	X14	X15	X16	X17
3	1	1	1	1	1	0	0	0.5	0.333333	0	1	0.344828	1	0.2	0	1	0.75
3	1	1	1	1	0	1	1	0	0.333333	0	1	0.275862	1	0.4	0	1	0.75
3	1	0.5	1	1	1	0	0	0.5	0.666667	0	1	0.344828	1	0	0	1	0.75
3	1	0	1	1	1	1	0	0.5	0.666667	0	0.5	0.275862	1	0	0	1	0.5
3	1	0	1	1	1	1	1	0.5	0.666667	0	1	0.206897	1	0	0	0	0.75
3	1	1	1	1	1	1	0	0.5	0.333333	1	1	0.586207	1	1	0	1	0.75
3	1	0	1	1	1	0	1	0.5	0.333333	0	1	0.275862	1	0	0	1	1
3	1	0	1	1	1	1	1	0.5	1	0	1	0.37931	0	1	1	1	0.5
3	1	1	1	1	1	0	1	0	0.666667	0	1	0.103448	1	0.4	1	1	0.75
3	1	1	1	1	0	1	0	1	0.333333	1	1	0.241379	0	1	1	1	0.5
3	1	0	1	1	1	0	1	0	0.666667	0	1	0.275862	1	0.4	1	1	0.5
3	1	0.5	1	1	1	1	1	0.5	0.666667	1	1	0.413793	1	0	1	1	0.75
3	1	1	1	1	1	1	0	0.5	0.666667	0	1	0.448276	1	0.4	1	1	0.75
3	1	0	1	1	1	0	0	0.5	0.666667	0	0.5	0.241379	1	0	1	1	0.75
3	1	0	1	1	1	1	1	0	0.666667	0	1	0.241379	1	0	1	1	0.5
1	0	1	1	1	1	1	1	1	0	0	1	0.206897	0	1	1	1	0
1	0	1	1	1	1	1	0	0	0.333333	0	1	0.517241	1	0	1	1	0.75
1	0	1	1	1	1	1	1	0	0.666667	0	1	0.448276	1	0	1	0	0.25
1	0	1	0	1	1	1	1	1	0.333333	0	1	0.689655	0	1	1	1	0.25
1	0	0	1	1	1	1	1	0.5	0.666667	0	1	0.275862	1	0	1	1	0.5
1	0	1	1	1	1	1	0	0.5	0.666667	0	1	0.551724	1	0.6	1	0	0.5
1	0	0	1	1	1	1	1	0	0.333333	0	1	0.448276	1	0.2	1	1	0.5
1	0	1	1	1	1	1	1	0	0.333333	0	1	0.310345	1	0.4	1	0	0.5
1	0	1	1	1	1	1	1	1	0.333333	0	1	0.344828	1	0.8	1	1	0.25
1	0	1	1	1	1	1	1	0	0.666667	1	1	0.655172	1	0	1	1	0.75
1	0	1	0.5	1	1	1	1	1	0.333333	0	1	0.37931	0	1	1	1	0.25
1	0	1	1	1	1	1	1	1	1	0	1	0.275862	0	1	1	1	0.5
1	0	1	1	1	1	1	1	0	1	0	1	0.689655	1	0	0.5	0	0.75
1	0	1	1	1	1	1	0.5	1	0.666667	1	1	0.517241	1	0.4	1	1	0.25
2	0	1	1	1	1	1	1	0	1	0	1	0.172414	0	1	1	1	0.5
2	0	1	1	1	1	1	0	0.5	0.666667	0	1	0.758621	1	0.4	1	1	0.75
2	0	1	1	1	1	1	0	1	0	0	1	0.206897	1	0	1	1	0
2	0	1	1	1	1	1	1	0	0.333333	0	1	0.758621	1	1	1	1	0.75
2	0	1	1	1	1	1	1	0	0.333333	0	1	0.310345	0	1	1	1	0.25
2	0	1	1	1	1	1	1	0.5	0.666667	0	1	0.37931	1	0	1	1	0.5
2	0	1	1	1	1	1	1	0	0.333333	0	1	0.275862	1	0.6	1	1	0.75
2	0	1	1	1	1	1	0	0.5	0.666667	0	1	0.310345	1	0	1	1	0.5
2	0	1	1	1	1	1	1	0.5	0.666667	0	1	0.344828	1	0.2	1	1	1
2	0	0	1	1	1	0	1	0.5	0.666667	0	1	0.482759	1	0	1	1	0.75
2	0	1	1	1	1	1	1	0.5	1	1	1	0.413793	1	0.2	1	1	0.5
2	0	1	1	1	1	1	0	0	0.666667	0	1	0.275862	1	0.4	1	1	0.25
2	0	1	1	1	1	1	1	0	0.666667	1	1	0.896552	1	0	1	1	0.5
2	0	1	1	1	1	1	1	0.5	0.666667	0	1	0.448276	1	0	1	0	1
2	0	1	1	1	1	1	1	1	0.666667	0	1	0.344828	1	0.4	1	0	0.25

ملحق (2) يمثل بيانات التدريب لمرض هشاشة العظام المستخدمة في البحث

y	X1	X2	X3	X4	X5	X6	X7	X8	X9	X10	X11	X12	X13	X14	X15	X16	X17
3	1	0	1	1	1	1	1	0.5	0.333333	1	1	0.551724	1	0	1	1	1
3	1	0	1	1	1	0	1	0.5	0.666667	0	1	0.103448	1	0.4	1	1	0.75
3	1	0	1	1	1	0	1	0	0.666667	0	1	0.137931	1	0	1	1	0.75
3	1	0	0	1	1	1	1	0.5	0.666667	1	1	0.275862	1	0	1	1	0.75
3	1	1	1	0	1	1	1	0	0.666667	1	1	0.344828	1	0	1	1	1
3	1	0.5	1	0	1	1	1	0	0.666667	0	0.5	0.241379	1	0	1	1	0.75
3	1	1	1	1	1	1	1	0	0.666667	0	1	0.448276	1	0.2	1	1	0.25
3	1	1	1	1	0	0	1	0	1	1	1	0.068966	0	1	0.5	1	0.5
3	1	0.5	1	1	1	0	1	0	0.666667	0	1	0.344828	1	0.4	1	1	0.5
3	1	1	0	1	1	1	1	0	0	0	1	0.241379	0	1	1	1	0.25
3	1	1	1	1	1	1	1	0	0.666667	0	0.5	0.448276	1	0	1	1	0.25
3	1	0	1	1	1	0	1	0	0	0	1	0.275862	1	0.4	1	1	0.5
3	1	1	1	0	1	0	1	0	0.666667	0	1	0	1	0	1	1	0.5
3	1	0.5	1	1	1	0	0	0	0.333333	0	1	0.310345	0	1	1	1	0.75
3	1	0	1	0	1	1	1	0	0.333333	0	1	0.448276	1	1	1	1	0.75
3	1	0	1	1	1	1	1	0	0.666667	0	1	0.448276	1	0	1	1	0.75
3	1	1	1	1	1	1	1	0	0.666667	1	1	0.241379	1	0	1	1	0.75
3	1	1	1	1	1	1	1	0	0.666667	1	1	0.517241	1	0	1	1	0.5
3	1	1	1	1	1	1	1	0	0.666667	0	0.5	0.517241	1	0	1	1	0.75
3	1	0	1	1	1	1	1	0	0.666667	0	1	0.482759	1	0	1	1	0.5
3	1	0	1	1	1	1	1	0	0.666667	1	1	0.517241	1	0	1	1	0.75
3	1	1	1	1	1	0	1	0	0	1	1	0.275862	0	1	1	1	0.5
3	1	1	1	1	1	1	1	0.5	0.666667	0	1	0.482759	1	0.2	1	1	0.5
3	1	1	1	1	1	0	1	0.5	0.333333	0	1	0.551724	1	1	1	1	0.75
3	1	0.5	1	0	1	0	1	0.5	0.666667	0	1	0.034483	1	0	1	1	1
3	1	0	1	1	1	0	1	0	1	1	1	0.172414	0	1	0.5	1	0.5
3	1	0.5	0	1	1	1	1	0.5	0.666667	1	1	0.448276	1	0	1	1	1
3	1	1	1	1	1	1	1	0	0.666667	0	0.5	0.448276	1	0	1	0	0.5
3	1	1	0	1	1	0	1	0	0.333333	0	1	0.241379	1	0.4	1	1	0.75
3	1	1	1	1	1	1	1	0.5	0.666667	0	1	0.344828	1	0	1	1	0.5
3	1	1	1	1	1	1	1	0.5	0.666667	0	1	0.413793	1	0	1	1	0.5
3	1	1	1	1	1	0	1	0.5	0.666667	1	1	0.482759	1	0	1	1	0.75
3	1	1	1	1	1	1	1	0	1	0	0.5	0.37931	1	0.4	1	1	0.5
3	1	1	1	1	1	1	0	0.5	0.666667	1	1	0.517241	0	1	1	1	0.75
3	1	1	0	0	1	0	1	0.5	0.666667	1	1	0.241379	1	0	1	1	1
3	1	0	1	1	1	1	1	0	0.666667	0	1	0.241379	1	0	1	1	0.75
3	1	1	1	1	1	1	0	0.5	0.666667	0	1	0.172414	1	0	1	1	0.75
3	1	1	1	1	1	1	1	0	0.666667	1	0.5	0.172414	1	0	1	1	0.75
3	1	1	1	1	1	1	0	0.5	0.666667	0	1	0.517241	1	0	1	1	0.75
3	1	1	1	1	1	1	1	0	0.666667	1	1	0.344828	1	0	1	0	0.75
3	1	0	1	1	1	1	0	0.5	0.666667	1	1	0.310345	1	0	1	1	0.5
3	1	1	1	1	1	1	1	0.5	0.666667	0	1	0.344828	1	0	1	0	0.5
3	1	0	1	1	1	1	1	0.5	0.666667	0	1	0.37931	1	0	1	1	0.75

3	1	1	1	1	1	0	1	1	0.666667	1	1	0.137931	1	0.4	1	1	0
3	1	0.5	1	1	1	1	1	0.5	0.666667	0	0	0.241379	1	0	1	0	0.75
3	1	1	0	1	1	0	0.5	0	0	1	1	0.344828	1	0.4	1	1	0.5
3	1	0	0	1	1	0	1	0	0.666667	1	1	0.103448	1	0	1	1	0.75
3	1	1	1	1	1	1	1	0.5	0.666667	1	1	0.37931	1	0	1	1	0.75
3	1	1	1	1	1	1	1	0	0.333333	0	1	0.172414	1	0	1	1	0.25
3	1	1	1	1	1	1	1	0.5	1	0	1	0.310345	1	1	0.5	1	1
3	1	0.5	1	1	1	0	0	0.5	0.333333	1	1	0.586207	1	0.4	1	1	0.75
3	1	1	1	1	1	1	1	0	0.666667	1	0.5	0.344828	1	0	1	1	1
3	1	0	1	1	1	1	1	0	1	0	1	0.310345	1	0	0.5	1	0.5
3	1	0	1	0	1	1	0	0	0.333333	1	1	0.37931	1	0	1	1	0.5
3	1	1	1	1	1	1	1	0	0.666667	1	1	0.413793	1	0.6	1	1	0.5
3	1	1	1	1	1	1	1	0	0.666667	1	1	0.413793	1	0	1	1	0.75
3	1	1	1	0	1	0	1	0.5	0	1	1	0.310345	1	0.6	0.5	1	0.5
3	1	1	1	1	1	1	1	0.5	0.666667	0	1	0.310345	1	0	1	1	0.5
3	1	1	1	1	1	1	1	0	0.333333	0	1	0.482759	1	0	1	1	0.75
3	1	1	1	1	1	1	1	1	0.666667	0	1	0.37931	1	0.4	1	0	0
3	1	1	1	1	1	1	0	0	0.666667	0	1	0.448276	1	0.2	1	1	0.5
3	1	1	0	1	1	1	1	0	0.666667	0	1	0.758621	1	0	1	0	0.5
3	1	1	1	1	1	0	1	0.5	0.666667	0	1	0.241379	1	0	1	1	1
3	1	0	1	1	1	0	1	0.5	0.666667	0	1	0.448276	1	0	1	0	1
3	1	1	1	1	1	1	1	0	1	1	1	0.206897	1	0.8	0.5	1	0.75
3	1	1	0	1	1	1	0	0.5	0.666667	0	1	0.310345	1	0.4	1	1	0.75
3	1	1	1	1	1	0	1	0.5	0.666667	0	1	0.517241	1	0.2	1	1	0.75
3	1	1	1	1	1	1	0	0.5	0.333333	0	0.5	0.37931	1	0	1	1	0.75
3	1	1	1	1	1	1	1	0.5	0.666667	0	1	0.37931	1	0	1	1	1
3	1	1	1	1	1	1	1	0	1	0	1	0.586207	1	0.2	0.5	1	0.75
3	1	1	1	1	1	1	1	0	0.666667	0	1	0.103448	1	0	1	1	0.5
3	1	1	1	1	1	1	1	0	0	1	1	0.206897	0	1	1	1	0.5
3	1	1	1	1	1	0	0	1	0.333333	0	1	0.586207	1	0.2	1	1	0.5
3	1	1	1	1	1	0	1	0.5	0.666667	1	1	0.344828	1	0	1	1	0.75
3	1	1	1	1	1	0	0	0.5	0.333333	1	1	0.241379	1	0.6	1	1	0.75
3	1	1	1	1	1	0	1	0	0.666667	0	1	0.344828	1	0	1	1	1
3	1	0.5	1	1	1	0	1	0	0	0	1	0.206897	0	1	1	1	0.5
3	1	1	1	1	0	0	0	0.5	0.666667	0	1	0.482759	1	0.4	1	1	0.75
3	1	0.5	1	1	1	1	0	0	0.666667	0	1	0.310345	1	0.2	1	1	0.5
3	1	1	1	1	0	1	0	0	0.333333	0	1	0.448276	1	0.4	1	1	0.5
3	1	1	1	1	1	0	1	0.5	0.666667	0	1	0.448276	1	1	1	1	0.75
3	1	1	1	1	1	0	0	0	0.666667	1	1	0.310345	1	0.2	1	1	1
3	1	0	1	1	1	0	1	0	0	1	1	0.482759	1	0.4	1	1	0.75
3	1	0.5	1	1	1	1	1	0	1	1	1	0.37931	1	0	0.5	1	0.5
3	1	1	1	1	1	1	1	0.5	0.333333	1	1	0.068966	1	0	1	1	1
3	1	1	1	1	1	1	0	0	0.666667	1	1	0.310345	1	0	1	1	0.75
3	1	1	1	1	0	1	1	0.5	0.666667	0	0.5	0.344828	1	0	1	1	0.5
3	1	1	1	1	1	1	1	0.5	0.666667	0	1	0.586207	1	0	1	1	0.75

3	1	0.5	1	1	1	1	1	0.5	0.666667	0	0.5	0.62069	1	0	1	1	0.75
3	1	1	1	1	1	0	1	0.5	0	0	0.5	0.551724	1	0	1	1	1
3	1	1	1	1	1	1	1	0.5	0.666667	0	1	0.482759	1	0.4	1	1	0.5
3	1	0	1	0	1	0	1	0.5	0	0	1	0.241379	1	1	1	1	0.5
3	1	0.5	1	0	1	0	1	0.5	0.666667	1	1	0.344828	1	0	1	1	0.5
3	1	0	1	1	1	1	1	0	0.333333	1	1	0.241379	1	0.2	1	1	0.5
3	1	1	1	1	1	0	0	0.5	0.666667	0	1	0.206897	1	0.2	1	1	0.75
3	1	1	1	1	1	1	1	0	0.333333	1	1	0.37931	1	1	1	1	0.75
3	1	1	1	0	1	1	1	0.5	0.666667	1	1	0.482759	1	0	1	1	0.5
3	1	1	1	0	1	1	1	0	0.666667	0	1	0.344828	1	0	1	0	0.5
1	0	1	1	1	1	1	0	0.5	0.666667	0	1	0.37931	1	0.4	1	0	0.75
1	0	0	1	1	1	1	0	0	0.333333	0	1	0.758621	1	0.4	1	1	0.5
1	0	1	1	0	1	1	1	0	0.333333	0	1	0.655172	1	0.4	1	1	0.75
1	0	1	1	1	1	1	1	0.5	0	0	1	0.793103	1	0	1	0	0.5
1	0	1	1	1	0	1	1	0.5	0.333333	0	1	0.344828	1	0.6	1	1	0.75
1	0	1	1	0	0	1	0.5	0.5	0.666667	0	1	0.655172	1	0.4	1	1	0.5
1	0	1	1	1	1	1	0.5	1	0	1	1	0.344828	0	1	1	1	0.25
1	0	1	1	1	1	1	1	0	0.333333	0	1	0.275862	0	0.8	1	1	0.5
1	0	0	1	1	1	1	1	1	0.333333	0	1	0.37931	1	0.4	1	1	0
1	0	1	1	1	1	1	1	1	0.333333	0	1	0.413793	1	1	1	1	0.5
1	0	1	1	1	1	1	1	1	0.333333	0	1	0.275862	1	0.4	1	1	0.25
1	0	1	1	1	1	1	1	0.5	0.666667	0	1	0.275862	1	0	1	1	0.75
1	0	1	0	1	1	1	0	0	0.333333	0	1	0.724138	1	0.4	1	1	0.75
1	0	1	1	1	1	1	1	0.5	0.666667	0	1	0.862069	1	0.2	1	1	0.75
1	0	1	1	1	1	1	1	1	0.666667	0	1	0.275862	1	0	1	1	0.25
1	0	1	1	1	1	1	0	1	0.333333	0	1	0.448276	1	0.6	1	1	0.25
1	0	0	1	1	1	1	1	1	0.666667	0	1	0.827586	1	0.2	1	1	0.5
1	0	1	1	1	1	1	0	0.5	0.666667	0	1	0.275862	1	0.2	1	1	0.75
1	0	1	1	0	1	1	1	1	0.333333	0	1	0.586207	1	0.4	1	1	0.5
1	0	1	1	1	1	1	0	1	0.333333	0	1	0.37931	1	0.2	1	1	0.25
1	0	0	1	1	1	1	1	0	0.666667	0	0.5	0.206897	1	0	1	0	0.25
1	0	1	0	1	1	1	1	1	0.666667	0	1	0.275862	1	0.4	1	1	0.5
1	0	1	1	1	1	1	0	1	0.333333	0	1	0.206897	1	0.4	1	1	0.5
1	0	1	1	1	1	1	1	1	1	0	1	0.206897	0	1	0.5	1	0.5
1	0	1	1	1	1	1	1	1	1	0	1	0.206897	0	1	0.5	1	0.25
1	0	0	1	0	1	1	1	1	0.666667	1	1	0.551724	1	1	1	1	0
1	0	1	1	1	1	1	1	0.5	0.333333	0	1	0.310345	1	0.6	1	1	0.5
1	0	1	0	1	1	1	0	1	0.333333	0	1	0.310345	1	0.6	1	1	0
1	0	1	1	1	1	1	0	0.5	0.666667	1	1	0.517241	1	0.4	1	1	0.5
1	0	1	1	1	1	1	0	0	0.666667	1	1	0.62069	1	0	1	1	0.5
1	0	1	1	1	1	1	1	0.5	0.333333	1	1	0.37931	1	0	1	1	0.5
1	0	1	0	1	1	1	1	1	0.666667	0	1	0.517241	1	0.6	1	1	0.25
1	0	1	1	0	1	1	0	1	0.333333	0	1	0.344828	1	0.6	1	1	0
1	0	1	1	1	1	0	1	1	0.666667	0	1	0.275862	1	0	1	1	0.25
1	0	1	1	1	1	1	1	1	1	0	1	0.206897	1	0.8	0.5	1	0.25

1	0	1	1	1	1	1	1	1	0.666667	1	1	0.689655	1	0	1	1	0.25
1	0	1	1	1	1	0	1	0	0.666667	0	1	0.862069	1	0.2	1	1	0.5
1	0	1	0	1	1	1	1	0	1	1	1	0.206897	1	0.6	1	1	1
1	0	1	1	1	1	1	1	0	0.666667	0	1	0.344828	1	0.4	1	0	0.5
1	0	1	1	1	1	0	0	0	0.333333	0	1	0.275862	1	0.4	1	1	0.75
1	0	1	0	1	1	1	1	0.5	0.333333	1	1	0.413793	1	0.2	1	1	0.75
1	0	1	0	1	1	1	1	0.5	1	0	1	0.655172	1	0	1	1	0.5
1	0	1	1	1	1	1	1	1	0.666667	0	1	0.206897	1	0.2	1	1	0.5
1	0	1	1	1	1	1	1	0.5	0.666667	0	1	0.655172	1	0.2	1	1	0.5
1	0	1	1	1	1	1	0	0	0.666667	0	1	0.344828	1	0.2	1	1	0.5
1	0	1	1	1	1	1	1	1	0.666667	0	1	0.344828	1	0	1	1	0.5
1	0	1	1	1	1	1	1	0.5	0.333333	0	1	0.310345	1	0.4	1	1	0.5
1	0	1	1	1	1	1	1	1	0.333333	0	1	0.241379	1	1	1	1	0
1	0	1	1	1	1	1	1	0.5	0.666667	0	1	0.413793	1	0	1	1	0.5
1	0	1	0.5	1	1	1	1	0	0.333333	0	1	0.551724	1	0.8	1	1	1
1	0	1	0	1	1	1	0	0.5	0.666667	0	1	0.37931	1	0.4	1	1	0.75
1	0	1	1	1	1	1	1	0.5	0.666667	1	1	0.275862	1	0	1	1	0.5
1	0	1	1	1	1	1	1	0.5	0.333333	0	1	0.62069	1	0.6	1	1	0.5
1	0	0	1	1	1	1	0	1	0.333333	0	0	0.344828	1	0.4	1	1	0.25
1	0	0.5	1	1	1	1	1	0	0.666667	0	1	0.413793	1	0	1	1	0.5
1	0	1	1	1	1	1	1	0	0.666667	0	1	0.448276	1	0.2	1	1	0.5
1	0	1	1	1	1	1	1	1	0.666667	0	1	0.689655	1	0.6	1	1	0.25
1	0	1	0.5	1	1	1	1	1	0	0	1	0.482759	1	0.8	1	1	0
1	0	1	1	1	1	1	0	0.5	0.666667	0	1	0.344828	1	0	1	1	0.5
1	0	1	0	1	1	1	1	1	0	0	1	0.206897	0	1	1	1	0
1	0	1	1	1	1	1	0	1	0.333333	0	1	0.206897	1	0.2	1	1	0
1	0	1	1	1	1	1	1	0.5	0.666667	0	1	0.37931	1	0	1	1	0.5
1	0	1	1	1	1	1	1	0.5	0.333333	1	1	0.172414	1	0.2	1	1	0.75
1	0	1	1	1	1	1	0	1	0.666667	0	1	0.275862	1	0	1	1	0.5
1	0	1	1	1	1	1	1	1	0.333333	0	1	0.241379	1	0.8	1	1	0
1	0	1	1	1	1	1	1	1	0.333333	0	1	0.310345	1	0.4	1	1	0.25
1	0	1	1	1	1	1	1	1	0.333333	0	1	0.275862	1	0.8	1	1	0
1	0	1	1	1	1	1	1	1	0	0	1	0.62069	1	0.8	1	1	0
1	0	0	1	1	1	1	1	1	0.666667	1	1	0.551724	1	0.6	1	1	0.25
1	0	1	1	1	1	1	1	0	0.333333	0	1	0.62069	1	0.6	1	1	0.25
1	0	1	1	1	1	1	1	1	0	0	1	0.62069	1	0.6	1	1	0.5
1	0	1	1	1	1	1	1	0.5	0.666667	0	1	0.344828	1	0.4	1	1	0.5
1	0	1	1	1	1	1	1	0.5	0.666667	0	1	0.344828	1	0	1	1	0.5
1	0	1	1	1	1	1	1	0.5	0	0	1	0.206897	0	1	1	1	0.5
1	0	0	1	1	0	1	1	1	0.333333	0	1	0.310345	1	0.6	1	1	0.5
1	0	1	1	1	1	0	1	1	1	0	1	0.551724	1	0.4	1	1	0.5
1	0	1	0	1	1	1	1	1	1	0	1	0.724138	1	0.2	0.5	0	0
1	0	1	1	1	1	1	1	1	0.666667	0	1	0.689655	1	0	1	0	0.25
1	0	1	1	1	1	1	1	0.5	0.666667	0	1	0.586207	1	0	1	1	1
1	0	1	1	1	1	1	1	1	0.333333	0	1	0.241379	0	1	1	1	0.25

1	0	1	1	1	1	1	1	1	0.333333	0	1	0.758621	1	0	1	1	0.25
1	0	1	1	1	1	1	1	0.5	0.666667	0	1	0.241379	1	0	1	1	0.75
1	0	1	1	1	1	1	0	1	0.333333	1	1	0.793103	1	0.4	1	1	0.25
1	0	1	1	1	1	1	1	1	0.666667	0	1	0.275862	1	0.2	1	1	0.25
1	0	1	1	1	1	1	0	0.5	0.666667	0	1	0.344828	1	0	1	1	0.5
1	0	1	1	1	1	0	0.5	1	0.666667	0	1	0.62069	1	0.4	1	1	0.5
2	0	1	1	1	1	1	1	1	0	0	1	0.344828	1	0.6	1	1	0.25
2	0	1	1	1	1	1	1	0.5	0.666667	0	1	0.517241	1	0	1	1	0.5
2	0	1	0	1	1	1	0	0	0.333333	1	1	0.344828	1	1	1	1	0.75
2	0	1	1	1	1	1	1	0.5	0.666667	0	1	0.62069	1	0.4	1	1	0.75
2	0	0	1	1	1	1	1	1	0	0	1	0.034483	0	1	1	1	0
2	0	0	1	1	1	1	0	0	0.333333	1	1	0.275862	1	1	1	1	0.75
2	0	1	1	1	0	0	1	0.5	0	0	1	0.413793	1	0.4	1	1	0.75
2	0	0	0	1	1	1	0	0.5	0.333333	0	1	0.275862	1	0.4	1	1	0.75
2	0	1	1	1	1	1	1	0.5	0.333333	0	1	0.724138	1	0	1	1	0.5
2	0	1	1	1	1	1	0	1	0.333333	0	1	0.413793	1	0.4	1	1	0.25
2	0	1	1	1	1	1	1	0	0.666667	0	1	0.275862	1	0	1	0	0.5
2	0	1	0	1	1	1	1	0.5	0.666667	0	1	0.413793	1	0.4	1	1	1
2	0	1	1	1	1	0	0	0.5	0.666667	0	1	0.689655	1	0.4	1	1	0.75
2	0	1	1	1	1	1	1	1	0.666667	0	1	0.37931	1	0	1	1	0.25
2	0	1	1	1	1	1	1	0.5	0.333333	0	1	0.551724	1	0.4	1	1	0.5
2	0	1	1	1	1	1	1	1	0.666667	0	1	0.37931	1	0	1	1	0.5
2	0	0	1	1	1	1	1	1	0.666667	0	1	0.551724	1	0.4	1	1	0.25
2	0	1	1	1	1	0	1	0.5	0	0	1	0.241379	1	0.2	1	1	0.5
2	0	1	1	1	1	1	1	0.5	0.666667	0	1	0.689655	1	0	1	1	0.75
2	0	0	1	1	1	1	1	0	0.666667	0	1	0.586207	1	0	1	0	0.5
2	0	1	1	1	1	1	1	0	0.666667	0	1	0.206897	1	0	1	1	0.5
2	0	1	1	1	1	1	1	0.5	0.666667	0	1	0.413793	1	0.4	1	1	0.5
2	0	1	1	1	1	1	1	1	0.666667	0	1	0.482759	1	0.4	1	1	0.5
2	0	1	1	1	1	1	1	0.5	0.666667	0	1	0.275862	1	0	1	1	0.75
2	0	1	1	1	1	1	0	0.5	0.666667	1	1	0.724138	1	0.2	1	1	0.75
2	0	1	1	1	1	1	1	0.5	0.666667	0	1	0.37931	1	0.2	1	1	0.5
2	0	1	1	1	1	0	0	0.5	0.666667	1	1	0.344828	1	0.2	1	1	0.75
2	0	1	1	1	1	1	1	0.5	0.333333	0	1	0.310345	1	1	1	1	0.75
2	0	1	1	1	1	1	1	0.5	0.666667	0	1	1	1	0	1	0	0.75
2	0	1	1	1	1	1	0	0.5	0.333333	0	1	0.275862	1	0.2	1	1	0.75
2	0	1	1	1	1	1	1	0.5	0.666667	0	1	0.586207	1	0	1	1	1
2	0	1	1	1	1	1	1	0.5	0.666667	0	1	0.793103	1	0.2	1	1	0.5
2	0	1	1	1	1	1	1	0.5	0.333333	0	1	0.241379	0	1	1	1	0.5
2	0	1	0	1	1	0	0	0.5	0.666667	0	1	0.310345	1	1	1	1	0.75
2	0	1	0	1	1	1	0	0	0.666667	0	1	0.37931	1	0	1	1	0.75
2	0	0.5	1	1	1	1	0	0.5	0.333333	0	1	0.310345	1	0.2	1	1	0.5
2	0	1	1	1	1	1	0	0.5	0.333333	0	1	0.413793	1	0	1	1	0.75
2	0	1	0.5	1	1	0	1	0	0.666667	0	1	0.344828	0	1	1	1	0.5
2	0	1	1	1	1	1	1	0.5	0.666667	1	1	0.310345	1	0	1	1	0.5

2	0	1	1	1	1	1	1	0.5	0.333333	0	1	0.310345	1	0.8	1	1	0.5
2	0	1	1	1	1	1	0	0.5	0.333333	0	1	0.206897	1	1	1	1	1
2	0	1	1	1	1	1	1	0.5	0.666667	0	1	0.37931	1	0	1	1	0.75
2	0	1	0	1	1	1	1	0.5	0	0	1	0.103448	0	1	1	1	0.5
2	0	0	1	1	1	1	1	0.5	0.333333	0	1	0.655172	1	0.2	1	0	0.5
2	0	1	1	1	1	1	0	0.5	0.333333	0	1	0.310345	1	0.6	1	1	0.5
2	0	1	0	1	1	1	0.5	0.5	0.666667	0	1	0.275862	1	0.4	1	1	1
2	0	1	1	0	1	1	0	0.5	0.333333	0	1	0.206897	0	1	1	1	0.5
2	0	1	0	1	1	1	1	0	0.666667	0	1	0.310345	0	1	1	1	0.25
2	0	1	1	1	1	1	0	0.5	0.666667	0	1	0.344828	1	0.4	1	1	0.5
2	0	0.5	1	1	1	1	1	0	0.333333	0	0.5	0.413793	1	0	1	1	0.75
2	0	1	1	1	1	1	0	0	0.333333	1	1	0.517241	1	0.2	1	1	0.25
2	0	1	1	1	1	1	1	0.5	0.333333	0	1	0.413793	1	0.8	1	1	0.75
2	0	1	1	1	1	1	0	0.5	0.666667	0	1	0.448276	1	0.2	1	1	0.5
2	0	1	1	0	1	1	0	1	0.666667	0	1	0.275862	1	0.4	1	1	0.5
2	0	1	1	1	1	1	0	0.5	0.666667	1	1	0.344828	1	0	1	1	0.75
2	0	1	1	1	1	1	1	1	0.333333	0	1	0.310345	1	0	1	1	0.25
2	0	1	1	1	1	1	1	0	0.666667	0	1	0.413793	1	0.4	1	1	0.5
2	0	1	1	1	1	1	1	0	0.666667	0	1	0.448276	1	0	1	1	0.25
2	0	0	1	1	0	1	0.5	0	0.333333	0	1	0.517241	1	0.6	1	1	0.5
2	0	0	1	1	1	1	1	0.5	0.666667	0	1	0.310345	1	0	1	1	0.5
2	0	1	1	1	1	1	1	0	0	0	1	0.482759	1	1	1	1	0.5
2	0	1	1	1	1	1	0	0.5	0.333333	0	1	0.448276	1	0.4	1	1	0.75
2	0	1	1	1	1	1	1	0.5	0.666667	0	1	0.517241	1	0.2	1	1	0.75
2	0	1	0	1	1	1	0	0	0.666667	0	1	0.448276	1	0.2	1	1	0.75
2	0	1	1	1	1	1	1	0	0.666667	0	1	0.655172	1	0	1	1	0.5
2	0	1	1	1	1	1	1	0	0.666667	1	1	0.758621	1	0	1	1	0.25
2	0	1	1	1	1	1	1	0.5	0.666667	0	1	0.827586	1	0.8	1	1	0.75
2	0	1	1	1	1	1	0	0	0.333333	0	1	0.344828	1	1	1	1	0.75
2	0	1	1	1	1	0	1	0.5	0.666667	1	1	0.310345	1	0	1	1	0.5
2	0	1	0	1	1	1	1	1	0.333333	0	1	0.344828	0	1	1	1	0.25
2	0	1	1	1	1	1	0	0	0.666667	0	1	0.551724	1	0.2	1	1	0.5
2	0	1	1	1	1	1	0	1	0.666667	0	1	0.206897	1	0.2	1	1	0.5