

نظام هجين:

تضييب شبكة عصبية-جينية لحل بعض مسائل التصنيف

رائدة سالم خضير و شذى فالح هندي

قسم علوم الحاسوب / كلية العلوم / جامعة البصرة

ISSN -1817-2695

(الاستلام 3 تشرين الثاني 2009 ، القبول 28 ذار 2011)

المستخلص

قدم هذا البحث طريقة هجينة تتكون من الأنظمة الذكية الثلاثة الشبكات العصبية الاصطناعية، المنطق المضيّب، الخوارزميات الجينية، إذ تعد هذه الأنظمة فعالة في حل مسائل مختلفة إلا أن كل نظام يعاني من بعض المشكلات التي تقلل كفاءته، لذا تم دمج هذه الأنظمة مع بعض لتعطي نظاماً يستفيد من محسن كل طريقة ويتعدى عن مساوئها. استعملنا في هذا البحث طريقة هجينة ناتجة من الجمع بين المنطق المضيّب والشبكات العصبية، إذ استعمل المنطق المضيّب لتضييب بيانات التدريب والأوزان المستعملة في الشبكة العصبية وتسمى هذه الطريقة **تضييب الشبكات العصبية**، الذي يعطي الشبكة قدرة أكبر على التعلم ويسرع من عملية التقارب، ولكن هذه الطريقة تعاني من مشكلة في تحديد عدد المجاميع المضيّبة والأوزان المضيّبة المثلث، إذ تستعمل أسلوب التجربة لتحديد لها. حل هذه المشكلة استعملت الخوارزمية الجينية لتحديد أفضل عدد من المجاميع المضيّبة وأفضل أوزان مضيّبة من خلال البحث ، مما يجعل الشبكة تترتب بصورة أكفاء.

الكلمات المhogزة: النظام المضيّب ، الشبكات العصبية ، الخوارزمية الجينية ، تضييب الشبكات العصبية.

1. المقدمة

أساس فكرة تضييب الشبكات العصبية هو استعمال مدخلات ومخرجات وأوزان مضيّبة في تدريب الشبكة العصبية، مما يزيد قدرة الشبكة على التعلم بصورة أكفاء. استعملنا لهذا الغرض شبكة عصبية متعددة الطبقات ذات تغذية أمامية، وعملية التعلم تعتمد على خوارزمية التغذية الإرجاعية *back-propagation algorithm*. أما

الخوارزمية الجينية فهي تضمن الحصول على أفضل أوزان وأفضل عدد للمجاميع المضيّبة التي ستستعمل لتضييب المدخلات و المخرجات، وبهذا تزيد من كفاءة الشبكة و تجعلها تقارب أسرع وتقلل الخطأ بين المخرجات الحقيقة و المخرجات المحسوبة.

2. تعريف مستوى الجاميع

مستوى المجاميع للعدد المضيّب \tilde{A} يعرف كما يلي [1,2]:-

$$[\tilde{A}]_h = \{X \setminus \mu_{\tilde{A}}(x) \geq h, X \in R\} \text{ for } 0 < h \leq 1$$

حيث X هي متغير إدخال.

μ دالة الانتماء.

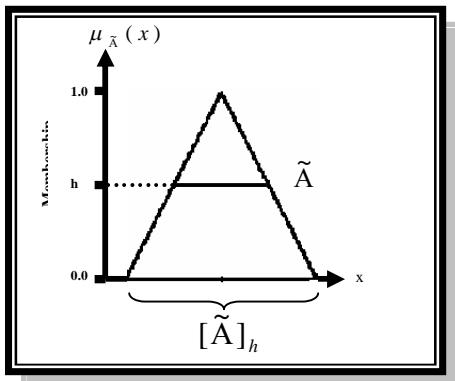
h مستوى المجموعة المضيّبة.

R مجموعة الأعداد الحقيقة.

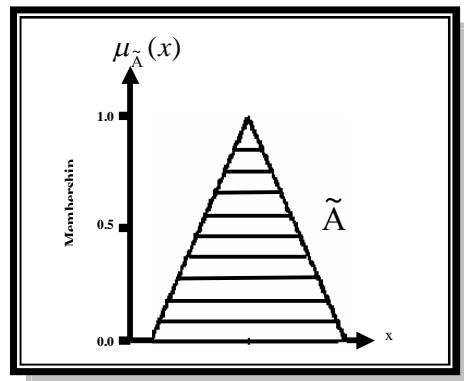
التمثيل التقريري بواسطة عشرة مستويات للمجموعة بحيث:-

$$h = 0.1, 0.2, 0.3, \dots, 1.0$$

يوضح الشكل (1) مستوى المجاميع للعدد المضبب \tilde{A} . والعدد المضبب يمكن أن يمثل تقريباً بواسطة تجمع من مستوى مجامي له قيمة h مختلفة. يوضح الشكل (2)



شكل (1) مستوى المجاميع



شكل (2) التمثيل التقريري لمستوى المجاميع

3. استعمال المدخلات والمخرجات المضببة في تضييب الشبكات العصبية

هنا يتم وصف كيف إن الشبكات العصبية ذات التغذية الأمامية المتعددة الطبقات تستطيع أن تتواسع إلى حالة المدخلات والمخرجات المضببة، التي ربما يحصل عليها من قياسات غير مؤكدة أو معرفة لغوية من الخبرات البشرية متمثلة بقوانين إذا-فأن، ويوضح المثال التالي ذلك [3]:-

لعدد من أنماط التدريب نفرض أن:-
 Large, Medium Large, Medium, Medium Small, Small هي مجامي مضببة. x قيمة الإدخال لنط تدريب معين الذي إخراجها y . تكون قاعدة القوانين الممثلة بقوانين إذا-فأن كالتالي [4]:-

If x is Small Then y is Small or Medium Small
 If x is Medium Then y is Medium Small or Medium
 If x is Large Then y is Medium or Medium Large or Large

هذه الأزواج تستعمل كأنماط تدريب مضببة في تضييب الشبكات العصبية لنط تدريب واحد.

بصورة عامة لعدد من المجامي المضببة يوجد n من المدخلات و c من المخرجات هناك m من أنماط التدريب المضببة، توضح المعادلة التالية ذلك [5]:-

Rule: IF X_1 is A_{P1} and ... and X_n is A_{Pn}
 Then Y_1 is B_{P1} and ... and Y_c is B_{Pc}

$$\begin{aligned} P &= 1, 2, \dots, m \\ i &= 1, 2, \dots, n \\ j &= 1, 2, \dots, c \end{aligned}$$

تتمثل كل قاعدة P كزوج إدخال وإخراج مضبب (A_P, B_P) ، إذ أن A_P هو جزء المقدمة للقانون و B_P هو جزء النتيجة للقانون، من هذه القواعد يمكن الحصول على الأزواج التالية:-

$$\{(A_P, B_P)\} = \{(Small, Small or Medium Small), (Medium, Medium Small or Medium), (Large, Medium or Medium Large or Large)\}$$

حيث P : تشير إلى رقم القاعدة.
 $X_i (X_1, \dots, X_n)$: هو متوجه الإدخال.

A_{Pi} (A_{P1}, \dots, A_{Pn}) هو جزء المقدمة للقانون.

Y_j (Y_1, \dots, Y_c) هو متوجه الخرج.

B_{Pj} (B_{P1}, \dots, B_{Pc}) جزء النتيجة للقانون.

m : هي العدد الكلي للقوابين المعطاة.

n : عدد خلايا الإدخال.

c : عدد خلايا الإخراج.

يستعمل جزء المقدمة للقوابين المضيبة (A_{P1}, \dots, A_{Pn}) من كل قاعدة كمتوجه إدخال مضبب، وجزء النتيجة للقوابين المضيبة يستعمل كمتوجه أخراج مناظر في تعلم الشبكات العصبية، إذ يتم إدخال القيمة اللغوية كنقط

تدريب، وتمثل كل قيمة لغوية بواسطة مجموعة من مستويات مجاميعها أي تقسم القيمة اللغوية إلى مستوياتها على شكل فترات [2].

خلية في الطبقة المخبأة من مجموع المدخلات الموزونة net_j [5].

علاقة الإدخال والإخراج في كل وحدة في تضبيب الشبكات العصبية تعرف بالمعادلات التالية:-

Input units:-

$$net_j = \sum_{i=1}^n w_{ji} \cdot x_i + \theta_{j0} \quad i = 1, 2, \dots, n, \quad j = 1, 2, \dots, n_h$$

Hidden units:-

$$f(net_j) = e^{-net_j} = M_j$$

$$net_k = \sum_{j=1}^c M_j \cdot v_{kj}$$

$$O_k = f(net_k) \quad k = 1, 2, \dots, c$$

4. وصف الشبكة العصبية

الشبكة العصبية المستعملة في هذا البحث هي شبكة ذات تهذية أمامية مكونة من ثلاثة طبقات، طبقة إدخال وطبقة مخبأة وطبقة إخراج. ترسل خلايا طبقة الإدخال قيم المدخلات إلى الطبقة المخبأة إذ يتم حساب قيمة كل

تضبيب الشبكات العصبية لمستوى المجاميع $h\text{-level}$ تعرف بالمعادلات التالية[6]:-

Input units:-

يُمثل متوجه الإدخال لمستوى المجاميع X_{pi} لنطاق التدريب p بالمعادلة:-

$$[O_{pi}]_h = [X_{pi}]_h$$

Hidden units:-

يحسب إخراج كل خلية في هذه الوحدة من المجموع الموزون للمدخلات المضيبة لمستوى المجاميع وتطبق دالة التشبيط عليه، كما في المعادلات التالية :-

$$\begin{aligned} [O_{pj}]_h &= f([net_{pj}]_h) & i = 1, 2, \dots, n_i \\ [net_{pj}]_h &= \sum_{i=1}^{n_i} [W_{ji}]_h \cdot [O_{pi}]_h + [\theta_j]_h & j = 1, 2, \dots, n_h \end{aligned}$$

Output units:-

يمثل كل خرج كل خلية في هذه الوحدة من المجموع الموزون للمخرجات المضببة للطبقة المخبأة

$$\begin{aligned} [O_{pk}]_h &= f([net_{pk}]_h) \\ [net_{pk}]_h &= \sum_{j=1}^{n_h} [v_{kj}]_h \cdot [O_{pj}]_h \quad k = 1, 2, \dots, c \end{aligned}$$

يمثل كل متوجه إدخال لمستوى المجاميع ذلك المتوجه بقيمة عليا (حد أعلى) وقيمة دنيا (حد أدنى) والتي تعتبر حد أعلى وحد أدنى لفترة مغلقة. تكتب العلاقات كالتالي:-

Input units:-

$$[O_{pi}]_h = [[O_{pi}]_l, [O_{pi}]^u]$$

Hidden units:-

ت تكون مخرجات خلايا الطبقة المخبأة من قيمة عليا وقيمة سفلی لمستوى المجاميع نفسه، كما في المعادلة:-

$$\begin{aligned} [O_{pj}]_h &= [[O_{pj}]_l, [O_{pj}]^u] \\ &= [f([net_{pj}]_h)], f([net_{pj}]_h)] \\ [net_{pj}]_h &= \sum_{i=1}^n [w_{ji}]_h \cdot [O_{pi}]_h + \sum_{i=1}^n [w_{ji}]_h \cdot [O_{pi}]^u + [\theta_j]_h \\ [net_{pj}]^u_h &= \sum_{i=1}^n [w_{ji}]_h \cdot [O_{pi}]_h + \sum_{i=1}^n [w_{ji}]_h \cdot [O_{pi}]^u + [\theta_j]^u_h \\ i &= 1, 2, \dots, n \\ j &= 1, 2, \dots, n_h \end{aligned}$$

Output units:-

ت تكون مخرجات الشبكة من قيمة عليا وقيمة سفلی لمستوى المجاميع نفسه، كما في المعادلة:-

$$\begin{aligned} [O_{pk}]_h &= [[O_{pk}]_l, [O_{pk}]^u] \\ &= [f([net_{pk}]_h)], f([net_{pk}]_h)] \\ [net_{pk}]_h &= \sum_{j=1}^{n_h} [v_{kj}]_h \cdot [O_{pj}]_h + \sum_{j=1}^{n_h} [v_{kj}]_h \cdot [O_{pj}]^u \\ [net_{pk}]^u_h &= \sum_{j=1}^{n_h} [v_{kj}]_h \cdot [O_{pj}]_h + \sum_{j=1}^{n_h} [v_{kj}]_h \cdot [O_{pj}]^u \\ j &= 1, 2, \dots, n_h \\ k &= 1, 2, \dots, c \end{aligned}$$

6. التعلم في تضييب الشبكات العصبية

يتطلب التعلم وجود دالة الكلفة *cost function* التي تحسب الفرق بين المخرجات الحقيقة والمحسوبة، هذا فضلاً عن وجود خوارزمية التعلم.

ليكن $T_p = (T_{p1}, T_{p2}, T_{p3}, \dots, T_{pno})$ هو متوجه المخرجات المضببة الحقيقة للشبكة الذي يقابل متوجه

الإدخال المضبب X_p . تعرف دالة الكلفة لمستوى المجاميع للإخراج المضبب المحسوب O_{pk} من وحدة الإخراج k مع ما يقابلها من الإخراج المضبب الحقيقي T_{pk} كما يلي

-:[5]

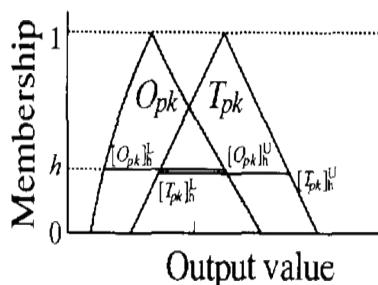
$$\begin{aligned} e_{pkh} &= e_{pkh}^l + e_{pkh}^u \\ e_{pkh}^l &= h \cdot (T_{pk})_h^l - [O_{pk}]_h^l)^2 / 2 \\ e_{pkh}^u &= h \cdot (T_{pk})_h^u - [O_{pk}]_h^u)^2 / 2 \\ h &= 0.1, 0.2, \dots, 1 \end{aligned}$$

من المعادلات السابقة تعرف دالة الكلفة بين متوجه الإخراج المضبب المحسوب O_p ومتوجه الإخراج المضبب الحقيقي T_p لمستوى المجاميع T_p .

$$e_{ph} = \sum_{k=1}^{n_o} e_{pkh}$$

$$e_p = \sum_h e_{ph}$$

يوضح الشكل (3) الإخراجين المضببين الحقيقي والمحسوب.



شكل (3) الإخراج المضبب الحقيقي

7. النظام الهجين المستخدم

العصبية بواسطة خوارزمية التغذية الإرجاعية (BP). فيما يلي يتم وصف العمليات الجينية المستعملة في النظام الهجين المقترن.

طريقة التشفير المستعملة هي التشفير الحقيقي *Real Encoding*, بحيث قيمة كل جين في الكروموسوم هي عبارة عن عدد حقيقي. يشفّر الكروموسوم بطريقة إذ يمثل أول جين عدد المجاميع المضببة *Fuzzy Sets* والجينات التي بعدها تمثل قيم الأوزان المضببة بين طبقة الإدخال والطبقة المخبأة (W), والطبقة المخبأة وطبقة الإخراج (V), وكذلك قيم bias (B)، وكما في الشكل (4).

الخوارزمية الجينية هي خوارزمية بحث تعتمد التكرار، تبدأ بمجتمع من الأفراد يتولد عشوائياً والذي يمثل حلول المسألة المحددة وصولاً إلى الحل الأمثل بواسطة العمليات الجينية في كل دورة جينية، إذ تنتج أطفالاً يكونوا حلولاً جيدة والتي تستبدل مع الحلول السيئة. استعملنا الخوارزمية الجينية بسبب وجود بعض المشاكل في معرفة الأوزان الجيدة وكذلك لم نستطع تحديد أي عدد من المجاميع مناسب لكل مسألة إلا من خلال التجربة. لذلك استعملنا الخوارزمية الجينية للبحث عن الحل الأمثل للمسألة المحددة والذي يمثل الأوزان والمجاميع المضببة والتي ستستعمل في تدريب تضييب الشبكات.

<i>Fuzzy set no.</i>	W_{11}	W_{12}	...	W_{ji}	V_{11}	V_{12}	...	V_{kj}	B_1	B_2	...	b_j
----------------------	----------	----------	-----	----------	----------	----------	-----	----------	-------	-------	-----	-------

شكل(4) تشفير الكروموسوم

بحيث:- i : عدد خلايا طبقة الإدخال.

j : عدد خلايا الطبقة المخبأة.

k : عدد خلايا طبقة الإخراج.

كل جين تتولد عشوائياً وتكون ضمن الفترة [0,1] لتمثيل الأوزان المضببة أما المجاميع المضببة فتكون أعداد أولية صحيحة في الفترة [2,7]. طول الكروموسوم يحدد من خلال عدد خلايا طبقة الإدخال والطبقة المخبأة وطبقة الإخراج، كما في المعادلة التالية:-

يتكون المجتمع من عدد من الكروموسومات (الأفراد) كل كروموسوم يمثل حل للمسألة المعطاة، حجم المجتمع المستعمل في هذا البحث يختلف باختلاف المسألة ولكن دائماً يكون بين [50-100]. استعملنا كروموسومات مكونة من عدد من الجينات قيمة

$$L = 1 + (\text{no-input} * \text{no-hidden} + \text{no-output} * \text{no-hidden}) * 2$$

بمقدار 0.01 ماعدا الجين الأول حيث يضاف إليه القيمة 1 اذا كانت قيمة الجين 2، فيما عدا ذلك يضاف إليه القيمة 2، هذه الأرقام اكتشفناها بالتجربة. احتمالية الطفرة هي $P_m = 0.03$.

يتم اختيار فرد من المجتمع عشوائياً وتقارن قيمة صلاحيته مع قيمة صلاحية الفرد الناتج (الطفل)، فإذا كان الفرد الناتج ذا صلاحية أعلى فيستبدل مع الفرد المختار من المجتمع وبعكسه لا تحصل عملية الاستبدال.

شرط التوقف المستعمل هو عند اتمام الدورات الجينية المفترضة لكل مسالة وتتراوح بين [20,60] دورة جينية، أو في حالة الوصول إلى مجتمع متكرر لأكثر من دورة جينية.

لذلك يمر النظام الهجين بمرحلتين، المرحلة الأولى تستعمل الخوارزمية الجينية للبحث عن عدد المجاميع المضببة والأوزان المضببة، المرحلة الثانية تدريب تضبيب الشبكات العصبية باستعمال المجاميع المضببة والأوزان المضببة الناتجة من المرحلة الأولى.

إذ يعني الرقم 1 موقع الجين الذي يمثل المجاميع المضببة. أما موقع الأوزان فتحسب من عدد خلايا طبقة الإدخال والطبقة المخبأة وطبقة الإخراج. وبما إن لكل متغير قيمة عليا *upper* وقيمة دنيا *lower* تضرب المعادلة في 2.

دالة الصلاحية المستعملة هنا تمثل مقدار الخطأ في الشبكة بين المخرجات المضببة الحقيقية T_p والمخرجات المضببة المحسوبة O_p واعتماداً على دالة الكافنة e_{ph} . تكون دالة الصلاحية عالية كلما كان مقدار الخطأ قليلاً.

الفردان المختاران من المجتمع لكل دورة جينية تجري عليهما عملية تراويخ لإنتاج طفل جديد، في هذا البحث تم تجربة الأنواع الثلاثة من التراويخ وكان أكثرها دقة هو عامل التراويخ المنتظم (UX)، لأنه يوفر تنوع في المجتمع ويمنع حدوث تكرار في الأفراد الناتجة. احتمالية التراويخ كانت $P_c = 0.7$.

استخدم عامل الطفرة لكل فرد من الأفراد الناتجة من عملية التراويخ، إذ يتم إيقاص قيمة جين عشوائياً

8. الاختبارات والنتائج للنظام الهجين

لاختبار النظام الهجين استعملت مجموعة من مسائل التصنيف *Classification Problems* والتي يكون من الصعب تدريبيها في الشبكات العصبية التقليدية، وهذه المسائل هي (*synthetic, iris, Diabetes*)، الجدول التالي يبين مواصفات كل منها.

جدول (1) مواصفات مسائل التصنيف

المسألة	عدد المدخلات	عدد المخرجات	عدد انماط التدريب	عدد انماط الاختبار
Iris	4	3	75	75
Diabetes	7	1	100	100
Synthetic	2	1	125	125

الصحة العالمية. البيانات جمعت بواسطة تعين الأمم المتحدة لمرض السكري وهي :
 Npreg: عدد النساء الحوامل، Glu: تركيز الكلوكوز في نسبة الكلوكوز الفموي المختبر Bp: مقدار ضغط الدم .
 Skin: مقدار سمك جلد العضلة العضدية، Bmi : مواصفات الجسم (الوزن بالكيلوغرام / الطول بالمتر)، Ped: أصل مرض السكري، Age : العمر بالسنوات، Type: نعم / لا .

مسألة Iris تعطي ثلاثة أصناف مختلفة من الأزهار. كل زهرة تقاس بواسطة طول الورقة وعرضها وطول الساق وعرضه. في حين ان مسألة Synthetic تصنف نوعين من البيانات حيث تمتلك قيمتين حقيقيتين كإحداثيات (xs and ys) والصنف يكون xc الذي يكون 0 أو 1. في مسألة Diabetes in Pima Indian النساء اللاتي أعمارهن أقل من 21 سنة من الشعب الهندي يتم فحصهن لمرض السكري اعتماداً على شروط منظمة

والأوزان المضببة التي تستعمل في تدريب تضييب الشبكات العصبية وتسجل النتائج وتقارن مع نتائج المرحلة الأولى، يتم مقارنة نتائج المرحلتين مع الشبكات العصبية التقليدية لمعرف فعالية الطريقة المقترنة.

9. الاختبارات والنتائج

العمل في هذا البحث ينقسم إلى جزأين، الجزء الأول يمثل تدريب تضييب الشبكات العصبية فقط وتسجيل النتائج ويتم مناقشتها. الجزء الثاني تستعمل فيه الخوارزمية الجينية لغرض تحديد المجاميع المضببة

9-1 تضييب الشبكات العصبية

استعملت شبكة عصبية متعددة الطبقات ذات تغذية أمامية، عدد الخلايا في الطبقة المخبأة اختير بالتجربة، معامل التعلم قيمة صغيرة اكتشفت بالتجربة إذ لا تتجاوز 0.9، والأوزان المضببة تتولد عشوائياً تقع ضمن الفترة [0,1] وتم تجربة خمس حالات من الأوزان لمعرفة تأثير تغيير الأوزان على النتائج.

عدد المجاميع المضببة اختبرت ضمن الفترة [2,7]، الذي اكتشف بالتجربة، كما تم تجربة نوعين من مستويات المجاميع، النوع الأول يتكون من خمسة مستويات (1, 0.2, 0.4, 0.6, 0.8)، النوع الثاني ($h=0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, 1$) لمعرفة تأثير ذلك على النتائج.

يتكون من عشرة مستويات ($h=0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, 1$) لمعرفة تأثير ذلك على النتائج.
 تم إجراء مجموعة من التجارب لكل مسألة على أنواع مستويات المجاميع وأعداد المجاميع المضببة للوصول إلى أفضل النتائج التي تجعل خطأ الشبكة قليلاً، نفذت التجارب خمس مرات لكل مسألة، لكل تفاصيل أوزان مختلفة لعدم معرفة الأوزان التي تعطي نتائج جيدة ومعرفة مدى تأثير تغيير الأوزان على النتائج وكانت النتائج مختلفة في كل تفاصيل وكما سيوضح لاحقاً.

أي تجعل خطأ الشبكة أقل، لهذا تم تثبيت المجاميع المضببة بثلاث مجامي (صغير، متوسط، كبير) وعدد الخلايا في الطبقة المخبأة ومعامل التعلم لكل مسألة لمعرفة مدى تأثير تغيير الأوزان على النتائج وحسب التالي :-

جيدة ولكن عملية التدريب تكون بطيئة جداً. الأوزان المضببة التي اختيرت كانت أوزاناً عشوائية موجبة هذه الأوزان اكتشفت بالتجربة. كانت عدد الدورات اللازمة

لمعرفة أفضل مستوى مجامي يمكن أن يستعمل في تدريب الشبكة الذي يجعل الشبكة تقارب بسرعة، تم اختبار نوعين من مستويات المجاميع. نفذ البرنامج لكل مسألة خمس مرات للوصول إلى أوزان تعطي نتائج جيدة مسألة Synthetic

عند تدريب الشبكة العصبية المضببة على هذه المسألة تم اختيار عدد الخلايا في الطبقة المخبأة بالتجربة وكانت 5 خلايا إذ كانت النتائج في هذا العدد جيدة، أما عند زيادة عدد الخلايا في الطبقة المخبأة تكون النتائج

لتدريب هذه المسألة 150 دورة. يوضح الجدول (2) النتائج التي تم التوصل إليها من خلال التجارب الخمسة.

Iris مسألة

المضيبة التي اختيرت كانت أوزاناً عشوائية موجبة هذه الأوزان اكتشفت بالتجربة. كانت عدد الدورات الازمة لتدريب هذه المسألة 150 دورة. يوضح الجدول (3) النتائج التي تم التوصل إليها من خلال التجارب الخمسة.

عند تدريب الشبكة العصبية المضيبة على هذه المسألة تم اختيار عدد الخلايا في الطبقة المخبأة بالتجربة وكانت 9 خلايا إذ كانت النتائج في هذا العدد جيدة، أما عند زيادة عدد الخلايا في الطبقة المخبأة تكون النتائج جيدة ولكن عملية التدريب تكون بطيئة جداً. الأوزان

Diabetes مسألة

المضيبة التي اختيرت كانت أوزاناً عشوائية موجبة هذه الأوزان اكتشفت بالتجربة. كانت عدد الدورات الازمة لتدريب هذه المسألة 60 دورة. يوضح الجدول (4) النتائج التي تم التوصل إليها من خلال التجارب الخمسة.

عند تدريب الشبكة العصبية المضيبة على هذه المسألة تم اختيار عدد الخلايا في الطبقة المخبأة بالتجربة وكانت 15 خلية إذ كانت النتائج في هذا العدد جيدة، أما عند زيادة عدد الخلايا في الطبقة المخبأة تكون النتائج جيدة ولكن عملية التدريب تكون بطيئة جداً. الأوزان

جدول (2) تأثير تغيير مستوى المجاميع في مسألة Synthetic

Run no.	5-level		10-level		
	Net-error	Tr. rate	Net-error	Tr. rate	Generalize rate
Run1	0.00170693	25%	0.00115574	100%	96%
Run2	0.00331597	25%	0.00076027	100%	96%
Run3	0.00142017	25%	0.00099632	100%	96%
Run4	0.00189705	25%	0.00113345	100%	96%
Run5	0.00335053	25%	0.00128224	100%	96%

جدول (3) تأثير تغيير مستوى المجاميع في مسألة Iris

Run no.	5-level		10-level		
	Net-error	Tr. Rate	Net-error	Tr. rate	Generalize rate
Run1	0.00085005	25%	0.00031537	100%	81%
Run2	0.00083197	25%	0.00032268	100%	81%
Run3	0.00042716	25%	0.00032078	100%	81%
Run4	0.00083674	25%	0.00009991	100%	81%
Run5	0.00169150	25%	0.00038149	100%	81%

جدول (4) تأثير تغيير مستوى المجاميع في مسألة Diabetes

Run no.	5-level		10-level	
	Net-error	Training rat	Net-error	Training rat
Run1	0.00054882	24%	0.00049345	96%
Run2	0.00054882	24%	0.00058439	96%
Run3	0.00210129	24%	0.00033590	96%
Run4	0.00229046	24%	0.00050216	96%
Run5	0.00097398	24%	0.00058990	96%

النتائج تكون متقاربة نوعاً ما عند المقارنة على أساس خطأ الشبكة، ولكن يمكن ملاحظة الفرق في نسب التدريب إذ يتضح إن زيادة مستويات المجاميع المضيئة يعطي نتائج أفضل وبنسبة تعليم جيدة وتبين التقارب في كل مسألة.

نلاحظ من الجداول (2) و (3) و (4) أنه في كل تجربة تكون النتائج مختلفة أي إن تغيير الأوزان له تأثير على

النتائج فقد يعطي نتائج جيدة أو غير جيدة. أما بالنسبة لتأثير تغيير مستويات المجاميع فيمكن ملاحظة أن

2. تجربة رقم(2)

توصل إلى النتيجة الجيدة. مستوى المجاميع المستعمل هو عشر مستويات لأنه أعطى نتائج جيدة في التجربة السابقة. معاملات الشبكة لكل مسألة كانت كما في التجربة السابقة وكانت النتائج كما في الجداول (5) و (6) و (7).

لتحديد أي عدد للمجاميع المضيئة يمكن أن يستخدم التدريب كل مسألة وهو يعطي نتائج جيدة، تم اختيار مجموعة من الأعداد لاختبار المسائل.نفذت البرامج خمس مرات لكل مسألة لعدم معرفة الأوزان المضيئة التي

جدول (5) تأثير تغيير أعداد المجاميع المضيئة في مسألة *Synthetic*

<i>set no.</i>	2		3		5		7	
<i>Run no.</i>	<i>Net-error</i>	<i>Tr. rat</i>						
<i>Run1</i>	33.506831	15	0.0052529	100	0.0012661	92	0.0018087	100
<i>Run2</i>	35.516146	15	0.0035334	100	0.0041696	92	0.0012552	100
<i>Run3</i>	33.677898	15	0.0029765	100	0.0036271	92	0.0017975	100
<i>Run4</i>	33.557358	15	0.0031097	100	0.0028159	92	0.0017749	100
<i>Run5</i>	33.570831	15	0.0032163	100	0.002277	92	0.0007510	100

جدول (6) تأثير تغيير أعداد المجاميع المضيئة في مسألة *Iris*

<i>set no.</i>	2		3		5		7	
<i>Run no.</i>	<i>Net-error</i>	<i>Tr. rat</i>						
<i>Run1</i>	0.0009747	98	0.0006946	100	0.0006832	94	0.0005754	100
<i>Run2</i>	0.0007332	98	0.0007127	100	0.0006127	94	0.0005640	100
<i>Run3</i>	0.0010478	98	0.0006823	100	0.0005224	94	0.0005509	100
<i>Run4</i>	0.0009745	98	0.0007818	100	0.0005996	94	0.0005140	100
<i>Run5</i>	0.0008374	98	0.0003742	100	0.0060957	94	0.0004747	100

جدول (7) تأثير تغيير أعداد المجاميع المضيئة في مسألة *Diabetes*

<i>set no.</i>	2		3		5		7	
<i>Run no.</i>	<i>Net-error</i>	<i>Tr. rat</i>						
<i>Run1</i>	0.0008132	97	0.0005899	96	0.0004320	100	0.0001335	100
<i>Run2</i>	0.0045568	97	0.0015677	96	0.0006212	100	0.0002546	100
<i>Run3</i>	0.3566485	97	0.0156784	96	0.0057896	100	0.0015688	100
<i>Run4</i>	0.0254896	97	0.0045685	96	0.0014456	100	0.0006522	100
<i>Run5</i>	0.2003541	97	0.0556315	96	0.0142327	100	0.0044325	100

تحديد عدد المجاميع المضيبة المناسب يعتمد على المسألة ذاتها فيمكن تجربة عدد من المجاميع المضيبة لمعرفة أي منها تعطي نتائج جيدة، وكذلك يعتمد على قيم التقسيمات لكل مجموعة.

في هذا البحث تم اختيار أقصى عدد مجاميع مضيبة بالعدد 7 إذ عند زيادة العدد إلى أكثر من ذلك يكون تنفيذ البرامج بطبيأً "جداً". ولمعرفة نسبة التعميم في الشبكة تم عرض بيانات الاختبار على الشبكة المدربة وكانت النتائج كما في الجداول (8) و (9) و (10):-

يتضح من الجداول (5) و (6) و (7) أنه في كل تنفيذ تختلف النتائج مما يعني أن تغيير الأوزان له تأثير على نتائج الشبكة. نلاحظ في الجدول (5) الزيادة في عدد المجاميع المضيبة تعطي نتائج جيدة، أما في الجدول (6) فيكون الفارق قليلاً وقد تحصل حالات يكون فيها عدد المجاميع القليلة هو الأفضل كما في مسألة Iris في التنفيذ الثالث، كذلك في الجدول (7) يكون في بعض الحالات عدد المجاميع القليلة تعطي نتائج أفضل كما في التنفيذ الأول والثاني. من ملاحظة نسب التدريب نستنتج أن

جدول (8) نسبة التعميم للشبكة المدربة في مسألة Synthetic

set no.	2		3		5		7	
Run no.	Net-error	Ge. rat						
Run1	33.506831	-	0.0052529	90	0.0012661	-	0.0018087	96
Run2	35.516146	-	0.0035334	90	0.0041696	-	0.0012552	96
Run3	33.677898	-	0.0029765	90	0.0036271	-	0.0017975	96
Run4	33.557358	-	0.0031097	90	0.0028159	-	0.0017749	96
Run5	33.570831	-	0.0032163	90	0.002277	-	0.0007510	96

جدول (9) نسبة التعميم للشبكة المدربة في مسألة Iris

set no.	2		3		5		7	
Run no.	Net-error	Ge. rat						
Run1	0.0009747	-	0.0006946	81	0.0006832	-	0.0005754	82
Run2	0.0007332	-	0.0007127	81	0.0006127	-	0.0005640	82
Run3	0.0010478	-	0.0006823	81	0.0005224	-	0.0005509	82
Run4	0.0009745	-	0.0007818	81	0.0005996	-	0.0005140	82
Run5	0.0008374	-	0.0003742	81	0.0060957	-	0.0004747	82

جدول (10) نسبة التعميم للشبكة المدربة في مسألة Diabetes

set no.	2		3		5		7	
Run no.	Net-error	Ge. rat						
Run1	0.0008132	-	0.0005899	-	0.0004320	95	0.0001335	96
Run2	0.0045568	-	0.0015677	-	0.0006212	95	0.0002546	96
Run3	0.3566485	-	0.0156784	-	0.0057896	95	0.0015688	96
Run4	0.0254896	-	0.0045685	-	0.0014456	95	0.0006522	96
Run5	0.2003541	-	0.0556315	-	0.0142327	95	0.0044325	96

9-2 الخوارزميات الجينية مع تضييب الشبكات العصبية

أوزان الشبكة المستعملة هي أوزان موجبة عشوائية، اختير معامل التعلم بالتجربة وكان عدد الخلايا في الطبقة المخبأة كما في تضييب الشبكات العصبية، قسم مستوى المجاميع إلى عشرة مستويات لأنه أعطى نتائج جيدة في التجربة السابقة.

تم إجراء تجربة على عامل التزاوج لمعرفة أي العوامل الثلاثة يعطي نتائج أفضل، إذ تم تجربة كل مسألة على كل العوامل.

يقسم العمل في هذه التجربة إلى ثلاثة مراحل، المرحلة الأولى تجربة عامل التزاوج ($1x$)، المرحلة الثانية تجربة عامل التزاوج ($2x$)، المرحلة الثالثة تجربة عامل التزاوج (ux). حجم المجتمع لكل مسألة اختير بعد تجربة مجموعة من الأحجام. وبعد أن تنتهي الخوارزمية الجينية عملها يؤخذ الفرد الناتج الذي يمثل عدد المجاميع المضببة والأوزان المضببة لتدريب الشبكة العصبية وكانت النتائج كما في الجدول (11).

في عامل التزاوج (ux) حجم المجتمع 20 فرداً يتولد عشوائياً، عدد الدورات الجينية هو 30 دورة جينية.

مسألة Diabetes

في عامل التزاوج ($1x$) حجم المجتمع 10 أفراد تتولد عشوائياً، عدد الدورات الجينية هو 25 دورة جينية.

في عامل التزاوج ($2x$) حجم المجتمع 10 أفراد تتولد عشوائياً، عدد الدورات الجينية هو 30 دورة جينية.

في عامل التزاوج (ux) حجم المجتمع 10 أفراد تتولد عشوائياً، عدد الدورات الجينية هو 25 دورة جينية.

جاءت الحاجة لاستعمال الخوارزمية الجينية من عدم معرفة العدد المناسب للمجاميع المضببة وكذلك من أجل الحصول على أوزان مضببة مثل تساعد الشبكة على إعطاء أفضل النتائج وتخلصنا من إعادة التنفيذ أكثر من مرة، إذ في المرحلة السابقة تم معرفة أفضل أوزان وأفضل عدد للمجاميع المضببة من خلال إجراء العديد من التجارب لكل مسألة وكانت النتائج غالباً متقاربة. الخوارزمية الجينية المستعملة تتكون من عدد من الأفراد (الكروموسومات) كل فرد يتكون من عدد من الجينات بحيث أول جين يمثل عدد المجاميع المضببة وهو يتولد عشوائياً ضمن الفترة [2,7]، والجينات الأخرى تمثل الأوزان المضببة تتولد عشوائياً ضمن الفترة [0,1]. عدد أفراد المجتمع يتراوح بين [10,50] فرد لكل مسألة. يتم توليد المجتمع عشوائياً ويقيم كل فرد اعتماداً على دالة الصلاحية المستعملة وهي مقدار الخطأ بين المخرجات المضببة الحقيقة والمخرجات المضببة المحسوبة. عدد الدورات الجينية يقع ضمن الفترة [20,60] لكل مسألة.

مسألة Synthetic

في عامل التزاوج ($1x$) حجم المجتمع 50 فرداً يتولد عشوائياً، عدد الدورات الجينية هو 60 دورة جينية.

في عامل التزاوج ($2x$) حجم المجتمع 50 فرداً يتولد عشوائياً، عدد الدورات الجينية هو 50 دورة جينية.

في عامل التزاوج (ux) حجم المجتمع 50 فرداً يتولد عشوائياً، عدد الدورات الجينية هو 40 دورة جينية.

مسألة Iris

في عامل التزاوج ($1x$) حجم المجتمع 20 فرداً يتولد عشوائياً، عدد الدورات الجينية هو 60 دورة جينية.

في عامل التزاوج ($2x$) حجم المجتمع 20 فرداً يتولد عشوائياً، عدد الدورات الجينية هو 50 دورة جينية.

جدول (11) تأثير عامل التزاوج على كل المسائل

type	<i>Ix</i>			<i>2x</i>			<i>ux</i>		
	problems	Set no.	Net-error	Tr. rat	Set no.	Net-error	Tr. rat	Set no.	Net-error
<i>Synthetic</i>	3	0.00103017	81	3	0.00194253	81	7	0.00061111	100
<i>Iris</i>	5	0.00030739	94	2	0.00082013	100	5	0.00025971	100
<i>Diabetes</i>	5	0.00667724	80	3	0.00083562	95	5	0.00043201	100

كان عامل التزاوج (ux) الأفضل من حيث أنه وفر تنوع في المجتمع إذ في كل دورة جينية يتكون أفراد جدد أي يمنع تكرار الفرد.

كذلك تم إجراء عملية مقارنة بين نتائج بيانات الاختبار لغرض التأكيد من النتائج.

هذه المسائل من مسائل التصنيف التي من الصعب تربيتها في الشبكات العصبية التقليدية إذ تحتاج إلى الكثير من المحاولات وكما يلي:-

[0.1,0.1] هذه الأوزان اكتشفت بالتجربة. عدد الخلايا في الطبقة المخبأة كان 40 خلية عرف من خلال التجربة أيضاً أي إنها تحتاج إلى هيكل شبيكي كبير. عملية التدريب تتطلب عدد دورات يتجاوز 10000 دورة. وكانت النتائج كما في الجدول (12).

في الطبقة المخبأة كان 5 خلايا عرف من خلال التجربة أيضاً. عملية التدريب تتطلب عدد دورات يتجاوز 10000 دورة. وكانت النتائج كما في الجدول (12).

المضيبة والأوزان المضيبة المناسبة لكل مسألة، لهذا استعمال الخوارزمية الجينية ضمننا لها الوصول إلى خطأ قليل للشبكة بعدد مجاميع مضيبة مناسب وأوزان مضيبة مثل ما يزيد كفاءة الشبكة ويسرع عملية التقارب وأيضاً تخلص من عمليات التكرار في التنفيذ من الجدول (12). إلى نتائج مرغوب بها وهذا ما يلاحظ من نسب تدريب البيانات، بينما المسائل نفسها يكون من الصعب تربيتها في الشبكات العصبية التقليدية إذ تحتاج إلى الكثير من المحاولات والتجارب للوصول إلى نتائج جيدة.

نلاحظ من الجدول (11) لكل مسألة عامل التزاوج (ux) أعطى نتائج أكثر دقة إذ كان تقارب الشبكة عنده أفضل من غيره من العوامل، إلا إنه في عامل التزاوج (2x) يكون التنفيذ أسرع إذ يعطي أقل عدد من المجاميع المضيبة ويمكن ملاحظة ذلك من نسب التدريب.

3-9 المرحلة الأخيرة

في هذه المرحلة تحصل عملية مقارنة للنتائج التي تم الحصول عليها من تدريب المسائل في الشبكات العصبية التقليدية وتضبيب الشبكات العصبية والخوارزميات الجينية مع تضبيب الشبكات العصبية،

Synthetic

عند القيام بعملية تدريب هذه المسألة في الشبكة العصبية التقليدية تم اختيار شبكة عصبية ذات أوزان عشوائية إذ إن الأوزان التي تقع بين طبقة الإدخال والطبقة المخبأة تقع ضمن الفترة [-0.5,0.5] والأوزان التي تقع بين الطبقة المخبأة وطبقة الإخراج تقع ضمن الفترة [-0.8,0.8] والـ *baise* تقع ضمن الفترة [-0.5,0.5]

Iris

عند القيام بعملية تدريب هذه المسألة في الشبكة العصبية التقليدية تم اختيار شبكة عصبية ذات أوزان عشوائية إذ إن جميع الأوزان تقع ضمن الفترة [-0.5,0.5]، هذه الأوزان اكتشفت بالتجربة. عدد الخلايا

Diabetes

عند القيام بعملية تدريب هذه المسألة في الشبكة العصبية التقليدية تم اختيار شبكة عصبية ذات أوزان عشوائية إذ إن جميع الأوزان تقع ضمن الفترة [-0.5,0.5]، هذه الأوزان اكتشفت بالتجربة. عدد الخلايا في الطبقة المخبأة كان 50 خلية عرف من خلال التجربة أيضاً. عملية التدريب تتطلب عدد دورات يتجاوز 10000 دورة. وكانت النتائج كما في الجدول (12).

نلاحظ من الجدول (12) إن استعمال تضبيب الشبكات العصبية يكون كفوء ويعطي نتائج جيدة ولكن بعد إجراء العديد من التجارب لمعرفة عدد المجاميع

جدول (12) مقارنة نتائج الشبكات العصبية وتضبيب الشبكات العصبية والخوارزميات الجينية مع تضبيب الشبكات العصبية

Problem	Fuzzified Neural Networks				Genetic Fuzzified Neural Networks				Neural Networks	
	Set no.	Net-Error	Tr. rate	Ge. rate	Set no.	Net-Error	Tr. rate	Ge. rate	Net-Error	Tr. rate
synthetic	3	0.00097748	100%	90%	7	0.00061111	100%	100%	6.49935723	92%
Iris	3	0.00027085	100%	81%	5	0.00025971	100%	100%	0.00195592	90%
Diabetes	3	0.00058990	96%	-	5	0.00043201	100%	98%	17.20078617	75%

المصادر

1-H. Ishibuchi, K. Kwon & H. Tanaka, "A Learning Algorithm of Fuzzy Neural Networks With Triangular Fuzzy Weights", Department of Industrial Engineering Osaka Prefecture University, E-mail Hisaoi@ie.osakafu-u.ac.jp, 1995.

2-C. T. Leones, "Fuzzy Logic and Expert Systems Applications", Academic Press, 1998.

3-H. Ishibuchi, M. Nii, "Neural Networks for Soft Decision Making", Department of Industrial Engineering Osaka Prefecture University, E-mail Hisaoi@ie.osakafu-u.ac.jp, 2000.

4-H. Ishibuchi & H. Tanaka, "Fuzzy Regression Analysis Neural Networks", Department of Industrial Engineering Osaka

Prefecture University, E-mail Hisaoi@ie.osakafu-u.ac.jp, 1992.

5-Fuzzy If-Then Rules", Department of Industrial Engineering Osaka Prefecture University, E-mail Hisaoi@ie.osakafu-u.ac.jp, 2001.

6-H. Ishibuchi, M. Nii, "Fuzzy Regression Using Asymmetric Fuzzy Coefficients and Fuzzified Neural Networks", Department of Industrial Engineering Osaka Prefecture University, E-mail Hisaoi@ie.osakafu-u.ac.jp, 2001.

7-H. Takagi, "Introduction to Fuzzy Systems, Neural Networks, and Genetic Algorithms", Intelligent Systems: Fuzzy Logic, Neural networks and Genetic Algorithms, Ch1, Pp1-33, 1997.

Hybrid System Geno-Fuzzified Neural Network For Solving Some Classification Problems

Raidah Salim Khaudeyer & Shatha Faleh Hendy

Abstract

This paper presented a hybrid method consisting of three intelligent systems (artificial neural networks, fuzzy logic, genetic algorithms), since these systems are effective in solving different issues but all the system suffers from some problems that reduce efficiency, so it was to integrate these systems with some To give the system benefit from the advantages of each method and encroaches on the disadvantages.

We used in this research method of a hybrid resulting from a combination of fuzzy logic and neural networks, as used fuzzy logic to fuzzified training data and weights used in the neural network, and this method is called **fuzzified neural networks**, which gives the network a greater ability to generalize and accelerate the convergence process, but this method suffers of a problem in determining the number of fuzzy sets and optimal fuzzy weights, as the experiment method used to select it. To resolve this problem, genetic algorithm was used to determine the best number of fuzzy sets and the best fuzzy weights through research, which makes the network more efficiently trained.

Key words: fuzzy system, neural networks, genetic algorithm, fuzzified neural networks .