

## دمج الشبكات العصبية والمنطق الضبابي: استخدام توابع العضوية كأوزان للشبكة العصبية

م. حسين بيدوح\*

إشراف: د. مهند رجب

### الملخص

يلعب المنطق الضبابي الذي يدعم الاستدلال الاستقرائي والسببية الرمزية، دوراً مركزياً في النظم المعرفية البشرية الحديثة، مثلاً في مهمات تصنيف الأنماط، والتفكير النوعي، والتفكير التناظري، والنمذجة العصبية، وغيرها من المجالات. وتعد شبكات بيرسيبترون (Perceptron) إحدى أبسط أنواع الشبكات العصبونية أمامية التغذية Feed-Forward، حيث لا يحتوي على طبقة عصبونات خفية بل تنتقل المعلومات المدخلة من الطبقة الأمامية إلى النهائية مباشرة وبسبب القيود الكبيرة على هذه الشبكات، سرعان ما ظهرت الأنظمة الخبيرة لتحل محلها كفرع رئيسي للذكاء الاصطناعي مما وفر حافزاً قوياً لتطوير منهجيات التحليل السببي خصوصاً بعد وضع نظرية المجموعات الضبابية الأولى وتوزيعات الاحتمال المرتبطة بها. ومنذ ذلك الحين، أظهرت الأنظمة الخبيرة بعض نقاط الضعف، على سبيل المثال في عملية استخلاص المعرفة من مصادر الخبرة (مصادر المعلومات)، أو في قدرتها على التعلم وفي بعض الأحيان فإنها حققت نتائج سيئة في حدود مجال خبرة النظام نفسه. بينما تقدم الشبكات العصبية مساهمات ملحوظة للأنظمة الخبيرة، على سبيل المثال في مجال التدريب باستخدام الأمثلة الجاهزة، والتعديل الديناميكي للتغيرات في البيئة، والتعميم، والتعامل مع شذوذ البيانات واكتشاف علاقات جديدة بين المتغيرات. سنطرح خلال هذه البحث فكرة لدمج الشبكات العصبية مع أنظمة المنطق الضبابي ونقدم أمثلة تطبيقية على ذلك.

الكلمات المفتاحية: ذكاء اصطناعي، شبكة عصبية اصطناعية، منطق ضبابي

\* طالب دراسات عليا في قسم هندسة البرمجيات - كلية الهندسة المعلوماتية - جامعة البعث

# **Fusion of Neural Networks and Fuzzy Logic: Using Membership Functions as Weights for Neural Network**

Eng. Hussain Biedouh\*

Supervisor: Dr. Mouhannad Rajab

## **Abstract**

Fuzzy logic that supports inductive reasoning and symbolic causation plays a central role in modern human cognitive systems, for example in tasks of pattern classification, qualitative thinking, analog reasoning, neural modeling, and other areas. Perceptron networks are one of the simplest types of feed-forward neural networks, as they do not contain a hidden layer of neurons. A major for artificial intelligence, which provided a strong incentive to develop methodologies for causal analysis, especially after developing the theory of the first fuzzy groups and the associated probability distributions. Since then, expert systems have shown some weaknesses, for example in the process of extracting knowledge from sources of expertise (information sources), or in their ability to learn and in some cases, they have achieved poor results within the limits of the system's own field of expertise. While neural networks make remarkable contributions to expert systems, for example in the field of training using ready examples, dynamic modification of changes in the environment, generalization, dealing with data anomalies and discovering new relationships between variables. During this research, we will present an idea to integrate neural networks with fuzzy logic systems and provide practical examples of that.

**Keywords:** Artificial Intelligence, Artificial Neural Network, Fuzzy Logic

---

\* Post graduate student in Software engineering department – Information Technology faculty – AL Baath University

## 1- مقدمة

الرموز او الأشكال الرمزية هي عبارة عن انماط بصرية، على سبيل المثال، حرف أو سلسلة من الحروف المتتالية. وتكون هذه الأنماط البصرية تتطوي على معنى مضمن فيها بحيث يشير هذا الرمز إلى شيء اخر قد يكون غرض موجود فيزيائياً أو فكرة أو حدث ما [11] ، مثلاً نحن نستخدم الرمز X للدلالة على كمية مجهولة القيمة في معادلة رياضية، او كلمة (تفاحة) للدلالة على مادة عضوية شبه كروية الشكل ذات لون احمر ويمكن أكلها. وبالتالي يمكن القول ان الرموز تضغط وتختصر كميات كبيرة من المعلومات بشكل يمكن للعقل البشري التعامل معه بسهولة. يمكن ان تستخدم الرموز بطريقة مركبة للمساهمة في نقل كميات كبيرة من المعلومات بشكل مختصر (ضغط المعلومات) والتعامل مع هذه الرموز يكون عن طريق وضع قواعد تربطها ببعضها ونتائج تطبيق هذه القواعد هي أيضاً رموز تشير إلى نتائج حقيقية في العالم الفعلي. نقوم في معظم حالات الاستخدام بتجميع عدد من الرموز لإظهار العلاقات الداخلية بينها وهذا ما نسميه بال (السببية الرمزية). والسببية الرمزية تطلق على اي نوع من التراكيب الرمزية التي تظهر علاقة بين الرموز سواء بالطريقة المجردة البحتة كالمعادلات الرياضية أو بالكلام العادي على سبيل المثال إذا قلنا (كل الأشجار خضراء، السرو شجرة، السرو اخضر).

تسمى التطبيقات التي تعتمد على السببية الرمزية بمحركات القواعد أو الأنظمة الخبيرة أو الرسوم البيانية المعرفية. ومن أشهر التطبيقات الحالية لهذه الانظمة هي الاجوبة التي تقدمها غوغل مباشرة تحت نتيجة البحث، مثلاً عند البحث عن ( what are the names of Uranus moons ) يظهر الجواب بشكل مباشر قبل نتائج البحث في الويب [4].

الفرق الأساسي بين تعلم الآلة والسببية الرمزية يكمن في طريقة التعلم [6]. حيث انه في تعلم الآلة والتعلم العميق الخوارزميات تتعلم القواعد وهي في طور تأسيس علاقات بين

الدخل والخرج. بينما في السببية الرمزية، فيتم وضع القواعد من قبل المبرمج بحيث أننا عند بناء نظام سببية رمزية على المبرمج أولاً تحديد القواعد التي تربط ظاهرتين على الأقل معاً وثم التعبير عن هذه القواعد برمجياً بشكل ثابت (hard-coded) [14]. هذه الطريقة تعتمد على تشكيل تصور مسبق عن العلاقات وهي فعالة في نطاقات عمل واختبار ضمن نطاق محدد معروف مسبقاً، أما التعلم العميق والشبكات العصبية فتتضمن بنية مختلفة لتشكيل التصورات وبناء الافتراضات بحيث تكون القواعد المسبقة فيها هي عن كيفية تعلمها وبناء قواعدها الخاصة بدلاً عن ماهية النتيجة المطلوب التوصل إليها [6].

باستخدام تقنيات المنطق الضبابي، يمكن دمج الشبكات العصبية مع السببية الرمزية والهدف من ذلك حل مشاكل أكثر تعقيداً في العالم الحقيقي، مثل مسائل التعرف على الأنماط أو الانحدار أو تقدير الكثافة وذلك عند استخدام بيانات ذات احجام كبيرة أو أبعاد متعددة، على سبيل المثال لا الحصر، يتم استخدام الشبكات العصبية في أنظمة الملاحة الرقمية، وتحتاج عمليات اتخاذ القرار في هذه الأنظمة الى معالجة عدد كبير من الاحتمالات الحتمية (Cirsp) في فترة زمنية ضيقة جداً، فيمكن تحويل هذا العدد الكبير من الاحتمالات الحتمية إلى مجال ضبابي، يكون أكثر مرونة عند معالجته، مع تعديل الية عمل الشبكة العصبية بحيث تكون قادرة على التعامل مع الدخل الضبابي لتوليد نتائج حتمية. فعند النظر إلى الشبكات العصبية والأنظمة الخبيرة والمنطق الضبابي، من منظور السببية الرمزية، نجد أنها تشترك بالكثير من الميزات الداخلية والتقنيات الحسابية. سيتم تقدم نموذج يعتمد على المنطق الضبابي، حيث تم تصميم شبكة عصبية اصطناعية من أجل بناء قاعدة المعرفة الخاصة بالنظام الخبير عن طريق امثلة التدريب.

في الشبكات العصبية، يرتبط نوعان من الأوزان بالوصلات المشبكية في بنية AND-OR: الأوزان اللغوية الأولية، التي يتم تفسيرها على أنها تسميات للمجموعات الضبابية، والأوزان العددية الثانوية. يتم حساب القيمة التي يتم عندها تنشيط الخلية من خلال

معادلات الاوزان الضبابية min-max. تقوم عملية التعلم على إيجاد الأوزان (العديدية) وتحديد مسارات الشبكة، وقد تم بدايةً تسمية هذه الشبكات بالشبكات ذات التغذية الأمامية، وأول مجالات استخدامها في التطبيقات التي تساعد في التشخيص الطبي [10].

سنقوم تالياً بتطبيق الطريقة لتوضيح كيف يمكننا استخدامها للتعرف على الكتابة بخط اليد. حيث انه في الخلية العصبية الضبابية التي تصف رقماً على سبيل المثال، تمثل الأوزان اللغوية مجموعات ضبابية على خطوط كشف التقاطعات والأوزان الرقمية تعكس أهمية الروابط بين خطوط كشف التقاطعات والأحرف.

## 2- الدراسة المرجعية: Reference Study

يوجد عدد من الابحاث التي قامت بدراسة أنظمة تتضمن المنطق الضبابي والشبكات العصبية معاً، ففي عام 2007 نشر الباحثان شيتول وزهران بحثاً بعنوان Combining fuzzy logic and neural networks in classification of weld defects using ultrasonic time-of-flight diffraction [9] درسا فيه أعطاب الالتحام باستخدام الأمواج فوق الصوتية، في هذا البحث تم ادخال مجموعة بيانات التدريب الى الشبكات العصبية مع تحديد عدد كبير من احتمالات الخرج (الصفوف)، بحيث يكون خرج الشبكة العصبية هو مجال (شعاع) يحوي صفوف العطب الأكثر احتمالاً، ليتم تمرير هذا الشعاع على نظام ضبابي يحوله لقيمة حتمية (صف واحد). وفي عام 2019 نجد دراسة بعنوان Hybrid model based on neural networks, type-1 and type-2 fuzzy systems for 2-lead cardiac arrhythmia classification [3] للباحثين ي. راميريز، ب. ميلين، و ج. ارشيغا. تم في هذه الدراسة بناء نموذج هجين لتصنيف أنواع اضطرابات ضربات القلب، وهو عبارة عن نظام منطق ضبابي يستخدم الشبكات العصبية كمرحلة معالجة أولية

لمجموعة البيانات المؤلفة من قراءات لنتائج تخطيط القلب لمجموعة مكونة من 5233 شخص. ونجد بحثاً آخر للباحثين ب. غونزاليز و ب. ميلين، نشر عام 2015 بعنوان "Fuzzy logic in the gravitational search algorithm for the optimization of modular neural networks in pattern recognition [8]" يصف طريقة استخدام المنطق الضبابي ضمن خوارزمية البحث الجاذبية (GSA) بهدف تحسين نتائج الوحدات العصبية المسؤولة عن تمييز الأنماط، والوحدات العصبية هي عبارة عن عدة شبكات عصبية صغيرة نسبياً تعمل بشكل منفصل ويتم تجميع نتائجها باستخدام طرق رياضية محددة، حيث تم التنبؤ بمتوسط القيمة الخاصة بكل نمط باستخدام المنطق الضبابي ومقارنة هذه القيمة مع نتائج كل وحدة من الوحدات العصبية.

### 3- هدف البحث: Aim of research

نجد أن أغلب محاولات الدمج بين الشبكات العصبية والمنطق الضبابي كانت على مستوى البيانات ومعالجتها، ولكن بمقارنة المنهجيات المتبعة في بناء الأنظمة الخبيرة، نجد أن الشبكات العصبية والمنطق الضبابي تشترك في عدد من الميزات والتقنيات، على سبيل المثال لا الحصر، بنية مجموعات البيانات، والمعادلات والطرق الرياضية. ويمكن أن يؤدي الجمع بين المنطق الضبابي والشبكات العصبية على المستوى الرياضي والبنوي (Structural)، إلى تعزيز قدرة الأنظمة الذكية على التعلم من التجربة والتكيف مع التغييرات في بيئة ذات معلومات نوعية أو غير دقيقة أو غير مؤكدة أو غير كاملة أو تحوي أي شكل من أشكال شذوذ البيانات.

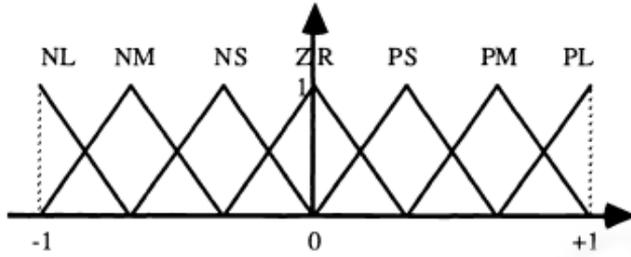
ويمكن تحقيق ذلك عن طريق الوصول لطريقة تحدد الية تشكيل بنية هجينة تربط فيها الشبكات العصبية والأنظمة الخبيرة بحيث يشكل احدهما مرحلة معالجة أولية للآخر، حيث يمكن للشبكة العصبية أن تعمل كمعالج أولي يقوم بمعالجة المعلومات منخفضة المستوى، أو كنظام فرعي داخلي لمهام التعلم أو التعميم والتصنيف. مثلاً يمكن استخدام

الشبكات العصبية لتولد قواعد باستخدام بيانات التدريب ثم تقديم هذه القواعد ليتم استخدامها من قبل نظام ضبابي لإعطاء النتائج النهائية.

### 3- البيانات والطرق المستخدمة Data and Methods

#### 3-1- المنطق الضبابي والشبكات العصبية

في الشبكات العصبية، تعكس الأوزان سلوك النظام. في الأنظمة الضبابية، يتم التعبير عن المعلومات عادةً باستخدام مصطلحات لغوية بعد تحويلها إلى مجموعات ضبابية، وبالتالي للاستفادة من الشكلين، سنقدم أوزان لغوية بشكل نموذج عصبي ضبابي [5]. نعتبر الأوزان نوعين: أوزان أولية، تليها أوزان ثانوية. تعبر الأوزان الأولية عن المعلومات الرئيسية للمعرفة، ولها شكل لغوي ويتم تفسيرها على أنها تسميات لمجموعات ضبابية، وبهذا نعطيها قيم كالتالي (زيادة، نقصان، زيادة كبيرة، قيمة عادية، مستقرة، إلخ..). ويختلف ذلك حسب الغاية التطبيق، يتم تعريف هذه المجموعات الضبابية بالاعتماد على مجموعة من المصطلحات المتعلقة بطبيعة خلايا الإدخال أو كما هو الحال في وحدات التحكم المنطقي الضبابي، يمكن أن تكون قيم من المجال  $[-1, +1]$ ، مع تابع عضوية يمكن ان نعطيها التسميات التالية: كبير سلبي (NL)، متوسط سلبي (NM)، صغير سلبي (NS)، مقارب للصفر (ZR)، إيجابي صغير (PS)، متوسط إيجابي (PM)، إيجابي كبير (PL)، وبالقيام باختصار القيم السابقة يمكننا الإبقاء على التالي منها (انخفاض، استقرار، ازدياد) في قسم مكون من 3 مجموعات ضبابية. ونرى في (الشكل 1) المخطط المقابل لتابع عضوية مثلثي يحوي التسميات السابقة.



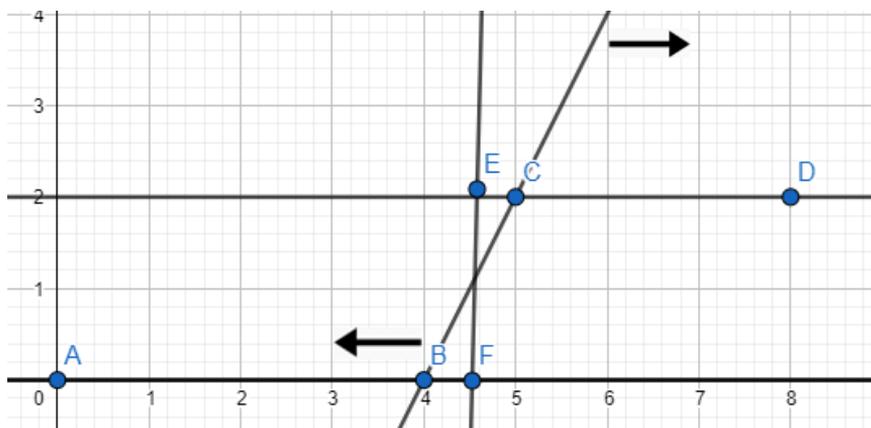
الشكل (1)

الأوزان الثانوية هي أرقام ضمن المجال  $[0,1]$ ، وتعكس درجة ضعف الاتصال المقابل لها (كلما كان الاتصال أضعف، كلما اقترب وزنه من 1) ولا يتم ربطها بالضرورة بالوصلات ولكن عند فعل ذلك، فإنها تتبع الوزن الأولي الذي يتم دمجهما معه.

النظام العصبي الضبابي هو عبارة عن شبكة تغذية امامية بدون قيم عتبة وذلك لأن المجموعات الضبابية لا تحوي عتبات بل يتم اخذ مجموعة من التحولات المتدرجة من حالة إلى أخرى. وفي هذا النظام لا توجد دورات تكرارية، بحيث دورة واحدة تكون كافية للوصول الى نتيجة الاستدلال. ولا يتم في مرحلة التدريب استخدام طرق تتضمن مجاميع مرجحة للمدخلات بل من المعادلات الضبابية الحاوية على قيم (أدنى) و (أعلى). تتكون هذه المرحلة من إيجاد الأوزان العددية من أمثلة التدريب ولا يوجد ضرورة لتحديد توابع العضوية للأوزان الأولية في هذه المرحلة حيث من المفترض أن يكون لدى الخبير البشري فكرة تقريبية عن الأشكال وعليه يمكنه ضبط المنحنيات وفقاً للمعلومات المقدمة من أمثلة المدخلات والمخرجات.

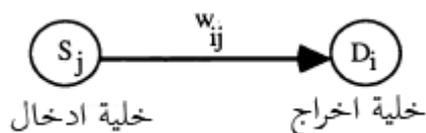
يتكون التعلم بشكل أساسي من إيجاد الأوزان الثانوية العددية وبنية التوصيلات للشبكة، فالأوزان العددية (الثانوية) القريبة من "1" ستشير إلى عدم وجود الوزن الأساسي المقابل، في حين أن الأوزان العددية (الثانوية) القريبة من "0" لن تؤثر على الإطلاق على الوزن

الأساسي المقابل. ويمكن دوماً تعديل الأوزان اللغوية الأساسية عند الحاجة عن طريق تغيير المنحنيات كما في (الشكل 2) في المنطقة الضبابية (تختلف درجات العضوية عن 0 و 1).



الشكل (2)

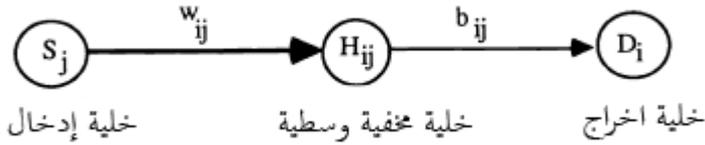
تتكون الشبكة العصبية الضبابية من اتصالات بين خلايا الإدخال ( $S_j$ ) وخلايا الإخراج ( $D_i$ ) (الشكل 3) ويمكن ان تحتوي على خلايا مخفية ( $H_{ij}$ ). أما الأوزان الأولية ( $w_{ij}$ ) فهي تسميات لغوية للمجموعات الضبابية تميز اختلافات خلايا الإدخال وعلاقتها بخلايا الإخراج [10].



الشكل (3)

نفترض أن  $w_{ij}$  يعبر عن وزن لغوي (أو المجموعة الضبابية المرتبطة بهذا الوزن).

والأوزان الثانوية ( $b_j$ ) هي أرقام من ضمن مجال القيم. في الشبكة العصبية، تحتوي خلايا الإدخال على اتصالات تشير إما إلى الخلايا المخفية وتتبعها اتصالات نحو خلايا الإخراج (الشكل 4)، أو وصلات مباشرة من خلايا الإدخال إلى خلايا الإخراج (تتوافق هذه الحالة مع وزن رقمي يساوي 0)، ولكن ليس بالضرورة وجود اتصال مع جميع خلايا الإخراج (عدم وجود اتصال على الإطلاق يتوافق مع وزن عددي يساوي 1) [2]. بمجرد إصدار تنبيه من خلية إدخال، يتم تحديد وزن لغوي ولا يوجد بالضرورة وزن رقمي في حالة عدم وجود خلية مخفية. وتحتوي الخلايا المخفية على أوزان عددية فقط مرتبطة بالوصلات نحو خلايا الإخراج [1].



الشكل (4)

يمكن أن تأخذ خلايا الدخل قيماً عددية أو أرقاماً ضبابية (مجالات)، نستخدم  $S_j$  للإشارة إلى القيمة العددية (الضبابية) المخصصة لتلك الخلية. عندما يتم تعيين خلايا الإدخال  $S_j$ ، يتم إضافة مجموعة من الأوزان التي تستخدم للاستدلال من أجل حساب خلايا الإخراج  $D_i$ ، وفقاً للصيغة التالية:

$$D_i = \min_j [b_{ij} \vee \mu_{w_{ij}}(S_j)] \dots\dots\dots(1) \text{العادلة}$$

$$D_i = \min_j [b_{ij} \vee \pi(w_{ij}, S_j)]$$

حيث  $\mu_{w_{ij}}(S_j)$  هو تابع درجة عضوية  $S_j$  في  $W_{ij}$  و  $S_j$  رقم ضبابي (مجال)

الضبابية  $W_{ij}$  و  $S_j$  . حيث نلاحظ انه عندما نعطي  $S_j$  قيمة ثابتة غير ضبابية  $\pi(W_{ij}, S_j)$  تصبح قيمته  $\mu_{W_{ij}}(S_j)$ .

في المعادلة (1) نفترض أن  $W_{ij}$  معروف كقيمة تقريبية، وتكون القيم غير المعروفة هي قيم  $b_{ij}$ ، يمكن حل هذه المعادلات حسب طريقة برويريان حيث نضع مجموعة قيم  $x$  بحيث تحتوي  $a \vee x \geq b$  على عنصر أصغري ويقع في المجال  $[0,1]$  في حال عدم الوصول لحلول بنسبة نجاح عالية، يمكن تعديل توابع العضوية في  $W_{ij}$  عن طريق تغيير المنحدرات أو إعادة ضبطها. وفي حال كنا لا نعرف قيم  $W_{ij}$  ولا  $b_{ij}$  في المعادلة الأولى، لكن نعلم أن  $W_{ij}$ 's تقع ضمن مجال ضبابي منتهي محدد من  $[-1, +1]$  كما في الشكل 1. أيضاً عندها يمكن حل المعادلة (1) من اجل كل  $W_{ij}$  من المجال الضبابي المذكور.

### 3-2- التطبيق على الطفرات والكروموسومات المسببة لها:

سيتم الآن تمثيل شبكة الاتصال الضبابية بين مجموعة من الكروموسومات والطفرات حيث تكون الكروموسومات كالتالي:  $X_1, X_2, X_3, X_4, X_5$  ويقابلها أربع طفرات جينية  $M_1, M_2, M_3, M_4$

يوضح (الشكل 5) العلاقة، حيث تتوافق الكروموسومات الخمسة مع خلايا الإدخال  $X_i$ ، والمجموعات الأربع لخلايا الإخراج  $M_i, \dots, M_4$ . هناك سبع خلايا مخفية مرتبطة بأوزان عددية. الأوزان اللغوية لها المعنى التالي:

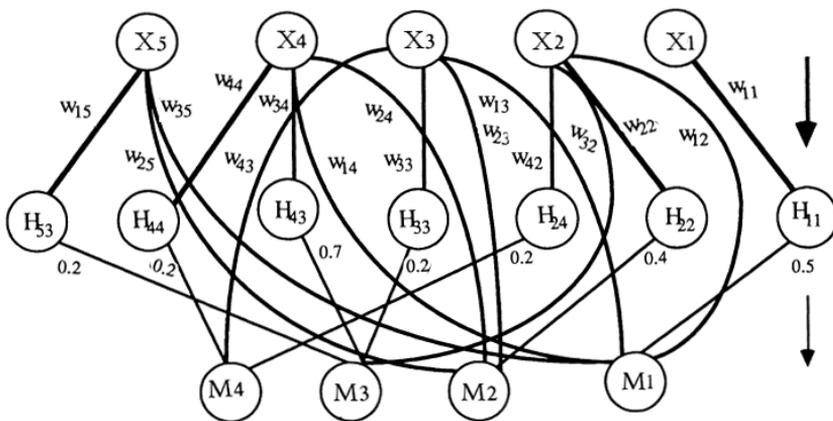
$w_{11}$ : متوسط.

$w_{12}$ : متوسط ،  $w_{22}$ : مرتفع،  $w_{32}$ : منخفض أو عادي،  $w_{42}$ : منخفض أو متوسط.

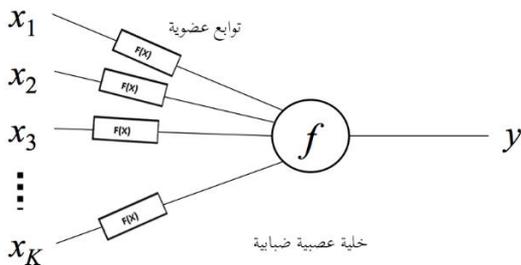
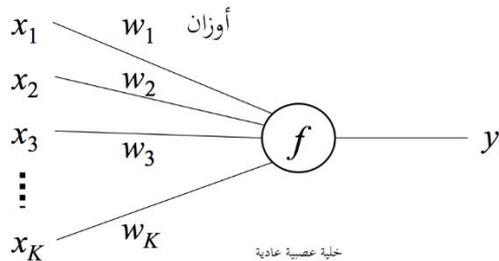
$w_{13}$ : متوسط ،  $w_{23}$ : مرتفع ،  $w_{33}$ : مرتفع ،  $w_{43}$ : منخفض أو متوسط.

$w_{14}$ : متوسط ،  $w_{24}$ : مرتفع ،  $w_{34}$ : مرتفع كثيراً ،  $w_{44}$ : مرتفع أو مرتفع قليلاً.

$w_{15}$ : متوسط ،  $w_{25}$ : مرتفع كثيراً،  $w_{35}$ : مرتفع كثيراً.



الشكل (5)



الشكل (6)

لنأخذ الطفرة (M3) كمثال:

- ترتبط الطفرة (M3) بالكروموسوم (X2) وفق الاتصال (w32) ذي الوزن اللغوي (منخفض أو عادي) حسب ما وضحنا سابقاً.
- ترتبط الطفرة (M3) بالكروموسوم (X3): وفق الاتصال (w33) ذو الوزن اللغوي (مرتفع) والقيمة الوزنية 0.2.
- ترتبط الطفرة (M3) بالكروموسوم (X4) وفق الاتصال (w34) ذو الوزن اللغوي (مرتفع كثيراً) والقيمة الوزنية 0.7.
- ترتبط الطفرة (M3) بالكروموسوم (X5) وفق الاتصال (w35) ذو الوزن اللغوي (مرتفع كثيراً) والقيمة الوزنية 0.2.

### 3-3- تحويل خط اليد الى نص

تم تقديم النموذج الأولي لتمييز خط اليد باستخدام الشبكات العصبية الضبابية من قبل الباحث تاكيشي ياماكاوا [12] [13] وفق التالي:

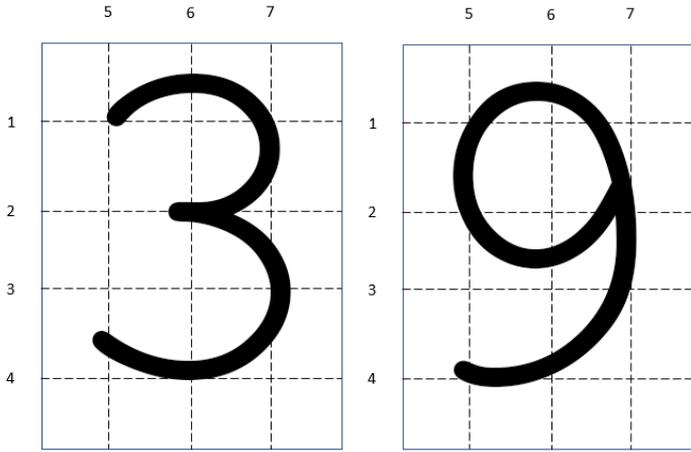
- 1- يتم استبدال عوامل الترجيح بوظائف العضوية.
- 2- يتم تمثيل الاتصالات المحفزة من خلال عمليات MIN والتوصيلات المثبطة بواسطة المتممات المنطقية الضبابية متبوعة بعمليات MIN.
- 3- لا يتم تعيين مستوى عتبة

سنحاول تطبيق الطريقة السابقة بشكل مشابه للنهج الذي اتبعناه في اكتشاف الطفرات انطلاقاً من الكروموسومات.

حيث أن الأحرف المكتوبة بخط اليد (Ci) تحل محل الطفرات، ويتم كتابة الحرف ضمن مساحة محددة الابعاد ومعروفة مسبقاً، يتم وضع مجموعة من الخطوط المرجعية ضمن

هذه المساحة ويمكن ان تكون هذه الخطوط متقاطعة ويتم تحديد شكل الحرف اعتماداً على الأوزان العددية التي ستربط مع الخطوط المرجعية [7].

نحدد مجموعات  $W_{ij}$  وهي مجموعات ضبابية في خطوط التقاطع المرجعية. تحدد مناطق التقاطع، اي تحدد المناطق الضبابية في الخطوط المرجعية حيث يجب أن تتقاطع المحارف، والمناطق المحظورة، حيث لا يجب أن تتقاطع المحارف، تظهر هذه الخطوط في (الشكل 7)



الشكل (7)

مثلاً تسمح المنطقة الضبابية عند الخط 5 بتمييز الرقم 9 عن الرقم 3

وتكون معادلة حساب الخرج كالتالي

$$\mu_{C_i} = \min_j [b_{ij} \vee CDL_j]$$

حيث  $C_i$  هي حرف (على سبيل المثال "9")،  $CDL_j$  هي درجة للخبط المرجعي رقم  $j$ ، و  $b_{ij}$  هي أوزان رقمية ذات أهمية نسبية للخبط المرجعي  $j$  في التعرف على  $C_i$ :

$b_{ji}=1$  يعني أن الخبط المرجعي  $j$  ليس له فائدة في  $C_j$

$b_{ij}=0$  يعني أنه ليست هناك حاجة لوزن الخبط المرجعي  $j$  في  $C_i$

$b_{ij} \in [0,1]$  تعكس الأهمية النسبية للخبط المرجعي المتقاطع  $j$  في  $C_i$

كلما ارتفع  $b_{ij}$ ، كلما كان الخبط المرجعي المقابل اقل تأثيراً.

باتباع التعلم الخاضع للإشراف يمكن إيجاد قيم  $b_{ij}$  عن طريق حل معادلات min-max الضبابية. تسمح التفسيرات أعلاه لـ  $b_{ij}$  بتعديل عدد الخطوط المرجعية في نمط ما، ويمكن تعديل أهميتها النسبية فيما يتعلق بـ  $C_i$  عن طريق  $b_{ij}$  نفسه.

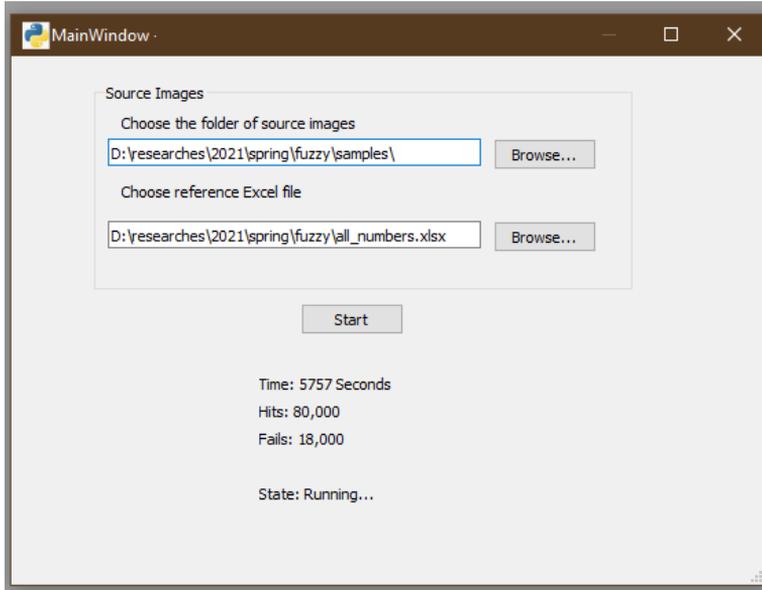
#### 4- التطبيق العملي:

باستخدام لغة البرمجة Python وبالاعتماد على المكتبات التالية:

1- Fuzzylogic 1.0.1

2- PyLearn2

3- PyTesseract



الشكل (8)

تم بناء تطبيق (الشكل 8) يعتمد على المعادلات السابقة وإجراء اختبارات لتمييز مجموعة من الأرقام بعد تدريبه على مجموعة بيانات تم صنعها خصيصاً لهذا الغرض باستخدام دالة توليد الأرقام العشوائية في برنامج Microsoft Excel وباستخدام خط قريب لخط اليد العادي واسمه Segoe Print ومن ثم قمنا باستخدام نفس الطريقة لتحديد مجموعة من الأرقام العشوائية المأخوذة من المجال [0,9] وتحويل كل خلية التي صورة بحيث يكون اسم الملف هو نفس رقم السطر في ملف Excel ومن ثم يقوم التطبيق بمحاولة الكشف عن الرقم في الصورة ومقارنة النتيجة مع السطر الخاص بالصورة في ملف Excel لمعرفة النتائج الصائبة والنتائج الخاطئة، وبعد 50 ألف محاولة كانت نسبة الأجوبة الصحيحة 68.2%، وبعد 100000 محاولة كانت نسبة الأجوبة الصحيحة 72.2%، وبعد 200000 محاولة كانت نسبة الأجوبة الصحيحة 71.9%.

عدد عينات التجربة	نسبة الإجابات الصحيحة	الوقت المستغرق للإتمام
50,000	70.2%	2000 ثانية
100,000	72.2%	4550 ثانية
200,000	71.9%	9000 ثانية

### 5- النتائج والمناقشة:

تم تصميم شبكة عصبية ضبابية لبناء قاعدة معرفية لنظام تصنيف باستخدام أمثلة التدريب. اثنان من خصائصه الرئيسية هي:

1- استخدام الأوزان اللغوية.

2- تفعيل الخلايا العصبية هو مسألة درجة، وفقاً لحد أدنى مرجح. ويمكن

استخدام هذا النموذج لتوصيف القواعد في المنطقي الضبابي.

وتبين لدينا انه يمكن الاعتماد على المنطق الضبابي لتوليد مجموعات تدريب تكون دخلاً للشبكات العصبية المستخدمة في أنظمة الذكاء الاصطناعي والتعلم العميق بحيث تكون قيم بيانات التدريب هذه مشابهة لقيم بيانات تدريب مأخوذة من العالم الحقيقي كونها ليست قيم حتمية بل قيم ضبابية ضمن مجال يحوي جميع احتمالات قيمة الخاصية الهدف. وتم اختبار هذه الطريقة في التعرف على الأرقام المكتوبة بخط اليد وتحويلها الى نص رقمي، وأعطت نتائج جيدة جداً حيث انه عند 100,000 عينة اختبار، حصلنا على 72.2% من حالات الخرج الصحيح.

إلا أن استخدام المنطق الضبابي لتوليد بيانات تدريب للشبكات العصبونية يحتاج مزيداً من البحث والتطبيق على حالات دراسة أخرى للتأكد من فعاليته في جميع الحالات، حيث أنه قد نجد حالات لا يمكن فيها استخدام القيم الضبابية حتى، او حالات يجب ان تكون

فيها النتائج دقيقة جداً حتى باستخدام المنطق الضبابي، مثل التطبيقات الطبية أو الحالات التي تحتاج تقديم معلومات دقيقة جداً وبسرعة عالية جداً، مثل تطبيقات الملاحة والخرائط. وهذه جميعها حالات يجب دراستها بشكل مخصص من حيث إمكانية توليد بيانات تدريب للشبكات العصبية الخاصة بها عن طريق المنطق الضبابي.

## 6-الاستنتاجات

من خلال هذا البحث الذي تمت فيه دراسة سبل استخدام المنطق الضبابي والشبكات العصبية معاً، توصلنا الى الاستنتاجات العلمية الآتية:

- يمكن استخدام الشبكات العصبية والمنطق الضبابي بشكل متداخل على المستوى البنوي (بنية الشبكة العصبية أو بنية النظام الضبابي).
- يمكن توليد قواعد المنطق الضبابي لنظام ضبابي ما، باستخدام الشبكات العصبية الاصطناعية.
- غالباً ما يحتاج خرج الشبكة العصبية الى عملية تعديل (باستخدام تعديل المنحدرات) قبل استخدامه في توابع العضوية في المنطق الضبابي.
- عند بناء نظام عصبي ضبابي يجب الاستغناء عن قيم العتبة لأن المجموعات الضبابية لا تحوي عتبات بل يتم اخذ مجموعة من التحولات المترتبة ويتم التعبير عنها كمجال عددي.
- جعل اوزان الشبكة العصبية تأخذ مجالاً ضبابياً، يمكن تمييز الأرقام المكتوبة بخط اليد حسب قواعد الخطوط المرجعية بنسبة نجاح مرتفعة تخطت 70%.
- يمكن في حالات معينة توليد بيانات التدريب الخاصة بالشبكات العصبية عن طريق المنطق الضبابي.

## 7- المراجع العلمية:

- [1] AGGARWAL C, 2018 - Neural networks and deep learning. SPRINGER Vol. 10/2018. 903 – 978.
- [2] GAMA F, ISUFI E, 2020 - Graphs, convolutions, and neural networks. IEEE Signal Processing Magazine, Vol. 37. 128 – 138.
- [3] GONZALEZ B, MELIN P, 2015 - Hybrid model based on neural networks, type-1 and type-2 fuzzy systems for 2-lead cardiac arrhythmia classification. Expert Systems with Applications. Vol. 126. 295 – 307.
- [4] HASIBUAN N, 2017 - Expert systems with genetics probability. International Journal of Research In Science & Engineering, Vol. 3. 42 – 54.
- [5] NAITZAT G, ZHITNIKOV A, 2020 - Topology of deep neural networks. J. Mach. Learn. Res. Vol. 184. 1 – 40.
- [6] PRENTZAS N, 2019 - Integrating machine learning with symbolic reasoning to build an explainable AI model for stroke prediction, IEEE Bioinformatics and Bioengineering (BIBE), Vol. 19. 817 - 821.
- [7] RACHMAWANTO E, ANARQI G, SARI C - 2018 Handwriting Recognition Using Eccentricity and Metric Feature Extraction Based on K-Nearest Neighbors. Application for Technology of Information and Communication. Vol.18. 411 – 416.
- [8] RAMIREZ E, MELIN P, PRADO-ARECHIGA G, 2019 - Fuzzy logic in the gravitational search algorithm for the optimization of modular neural networks in pattern recognition. Expert Systems with Applications. Vol. 42(14). 5839 – 5847.
- [9] SHITOLE C, 2007 - Combining fuzzy logic and neural networks in classification of weld defects using ultrasonic time-of-flight diffraction. Insight-Non-Destructive Testing and Condition Monitoring. Vol. 49. 79 – 89.
- [10] VAN GERVEN M, 2017 - Artificial neural networks as models of neural information processing, Frontiers in Computational Neuroscience, Vol. 11.

114 – 121.

- [11] XIAOYAN W, 2019 - The Study of Visual Symbols in Digital Media Technology. Semantics Scholar, 30 – 47.
- [12] YAMAKAWA T, 1991 - A fuzzy neuron and its application to pattern recognition. IEEE International Sympoisum on Circuits and Systems, Vol.91. 1369 – 1372.
- [13] YAMAKAWA T, 1993 - A fuzzy inference engine in nonlinear analog mode and its application to a fuzzy logic control. *IEEE transactions on Neural Networks* , 496– 522.