

نموذج شبكة عصبونية صناعية ضبابية لحل مسائل التصنيف الثنائية

كامل باشا*

(تاريخ الإيداع 2022 /4/13 – تاريخ النشر 2022 /9/15)

□ ملخص □

يقدم هذا البحث طريقة جديدة لحل مسائل التصنيف الثنائية باستخدام الشبكات العصبونية الصناعية المعتمدة على قواعد المنطق الضبابي ، قمنا باقتراح نموذج شبكة عصبونية صناعية ضبابية حيث تم استخدام خوارزمية المتوسطات (FCM) في عملية تضبيب مدخلات الشبكة و تشكيل توابع تنشيط عصبونات الطبقة الأولى كما استخدمنا آلة التعلم القصوى (ELM) في تدريب الشبكة العصبونية ومن ثم استخدام معامل ارتباط ماثيو (Matthew coefficient) لتحسين بنية الشبكة من خلال استبعاد العصبونات الأقل تأثيراً على عمل الشبكة، قمنا باختبار النموذج في مسألة تصنيف الأورام الدماغية و مقارنة النتائج مع خوارزمتي Pruning Fuzzy Neural Network و Regularized Fuzzy Neural Network حيث أعطى نتائج أفضل من حيث دقة التصنيف و الزمن اللازم للتدريب والاختبار .

الكلمات المفتاحية : الشبكات العصبونية الصناعية ، المنطق الضبابي ، FCM، ELM، معامل ارتباط ماثيو، تصنيف البيانات.

*ماجستير في الرياضيات التطبيقية، كلية العلوم، جامعة تشرين .

Fuzzy neural network model for classification of brain tumors

Kamel basha*

(Received 13/4/2022.Accepted 15/9/2022)

□ABSTRACT □

This paper presents a new method to solve binary classification problems using artificial neural networks based on fuzzy logic, a fuzzy neural network model was proposed where (Fcm) was used for input fuzzification and forming neurons activation function in the first class, and We also used the ELM in the training of the neural network, then we used Matthew correlation coefficient to improve the network structure by excluding neurons that have less impact on the network, The model was tested in the classification of brain tumors and results compared with the Pruning Fuzzy Neural Network and the Fuzzy Neural Network algorithms, which gave better results in terms of classification accuracy and time for training and testing .

Keywords: artificial neural networks, fuzzy logic, FCM, ELM, Matthew coefficient .

*Master d in Applied Mathematics Branch, Faculty of Science, Tishreen University

مقدمة:

تعد عملية تصنيف البيانات (Data Classification) أحد أهم أساليب التعليم الموجه (Supervised Learning) حيث يتم تجميع البيانات في مجموعات منفصلة بناءً على الخصائص المشتركة فيما بينها وفقاً لنماذج (دخل _ خرج) معدة مسبقاً، ويتم تقسيم البيانات إلى عينتين: عينة التدريب (Training set) و عينة اختبار (Testing set) [1].

تحظى الشبكات العصبونية الصناعية باهتمام لدى الباحثين في هذا المجال نظراً للقدرة العالية التي تتيها حيث يتم الاستفادة من خصائص الشبكات العصبونية الصناعية كالقدرة الحسابية و التعميم و الأنظمة الضبابية التي تحاكي عمليات التفكير البشري في طريقة عملها [2].

مشكلة البحث:

إن النتائج الجيدة التي أعطتها تقنيات و أساليب الذكاء الصناعي المختلفة دفعت الباحثين لدمج هذه التقنيات والوصول لنتائج أفضل من حيث الدقة و الموثوقية في العمل إضافة للسرعة في أداء المهام المطلوبة و لذلك قدمنا في هذا البحث نموذجاً يجمع بين الشبكات العصبونية الصناعية و المنطق الضبابي و معامل ارتباط ماثيو، يعالج هذا النموذج مشكلة الاستخدام العشوائي للعصبونات في الطبقة الخفية .

أهمية البحث و أهدافه:

تكثر في حياتنا اليومية تطبيقات مسائل التصنيف الثنائية فنجد الكثير من الاستخدامات لها في المجالات الطبية والعسكرية والأمنية و الاقتصادية وغيرها. يتركز عملنا حول تصنيف الأورام الدماغية و من هنا تكمن أهمية هذا البحث في تقديم طريقة فعالة و سريعة و غير مكلفة لاستخدامها في تصنيف تلك الأورام إلى حميدة و خبيثة، وقد أثبتت الدراسات السابقة النتائج الدقيقة والفعالية الكبيرة التي تقدمها الأنظمة الذكية في مجال الخدمات الطبية.

طرائق البحث و مواده:

نعرض فيما يلي التقنيات و الخوارزميات المستخدمة في البحث :

آلة التعلم القصوى (Extreme learning machine):

إن آلة التعلم القصوى التي نشير إليها (ELM) تم اقتراحها من قبل Huang في العام 2006 [3]. وهي خوارزمية لتدريب الشبكات العصبونية الصناعية أمامية التغذية وحيدة الطبقة الخفية (Single Hidden layer Feed-Forward Neural Networks) والتي نشير إليها اختصاراً (SLFNs) والموضحة في الشكل (1).

يصف النموذج الرياضي الآتي آلة التعلم القصوى :

لتكن العينة (X_i, t_i) حيث $i = 1 \dots N$ و $X_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n$ و $t_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \in R^m$ عندئذ يمكن وصف خوارزمية ELM بالنموذج الرياضي الآتي :


$$\sum_{i=1}^L \beta_i \cdot g_i(x_j) = \sum_{i=1}^L \beta_i \cdot g_i(w_i \cdot x_j + b_i) = t_j$$

حيث: X_i شعاع المدخلات، t_i شعاع الخرج الموافق و $j = 1 \dots N$.

$w_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T$ هو شعاع الأوزان الذي يصل عصبونات طبقة الدخل بالعصبون الخفي رقم i .

$\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$ هو شعاع الأوزان الذي يربط العصبون الخفي رقم i بعصبونات طبقة الخرج.

هو تابع تنشيط العصبونات ، L هو عدد عصبونات الطبقة الخفية . $g_i(x_j)$



الشكل (1): نموذج شبكة عصبونية صناعية من النوع SLFNs

تهذيب آلة التعلم القصوى (Pruning ELM):

إن استخدام عدد عشوائي من العصبونات في الطبقة الخفية قد يؤدي إلى مشكلة في استقرار النموذج، لذا اقترح Rong في عام 2008 تعديلاً على عمل خوارزمية ELM يتم من خلاله استبعاد العصبونات التي لها تأثيراً ضعيفاً على عمل الشبكة العصبونية [4] مما فتح المجال أمام تطوير العديد من النماذج المعتمدة على شبكات SLFNs .. كما استخدم Souza في عام 2018 ، [5] خوارزمية LARS لتهذيب ELM في نموذج لحل مسائل التصنيف الثنائية .

و فيما يلي نقدم خوارزمية المتوسطات FCM المستخدمة في الطبقة الأولى من النموذج المقترح.

خوارزمية FCM:

تعتبر خوارزمية FCM من أهم الخوارزميات الضبابية المستخدمة في عنقدة البيانات .. و قدمت هذه الخوارزمية من قبل الباحث Dunn في عام 1973 [6] ثم قام الباحث Bezdek بتحسينها في عام 1981 [7]. تستخدم هذه الخوارزمية لتقسيم مجموعة من النقاط $N = \{x_1, x_2, \dots, x_n\}$ إلى c عنقود بحيث تنتمي كل نقطة إلى جميع

العناقيد بنفس الوقت و بدرجات انتماء مختلفة و هذا الفرق بينها و بين خوارزمية k_means التي تنتمي فيها كل نقطة إلى عنقود واحد فقط، الفكرة الأساسية للخوارزمية هي تصغير دالة الكلفة (دالة الهدف) J المعطاة بالعلاقة :

$$J(u, v) = \sum_{i=1}^c \sum_{k=1}^n u_{ik}^m |x_k - v_i|^2$$

حيث:

- n عدد نقاط العينة ، c عدد العناقيد .
- x_1, x_2, \dots, x_n تمثل النقاط العينة المدروسة .
- $V = \{v_1, v_2, \dots, v_c\}$ مراكز العناقيد (المجموعات الضبابية) .
- $U = \{u_{ik}\}$ مصفوفة العضوية حيث تمثل القيمة u_{ik} درجة انتماء النقطة x_k إلى العنقود c_i .
- m معامل التضبيب و يأخذ عادة القيمة 2 (و ذلك وفقا للباحث Kaufman [8]) .

خطوات الخوارزمية:

الخطوة الأولى: أدخل البيانات التالية :

- $c \geq 2$ (إدخال عدد العناقيد).
- $V^0 = \{v_1^0, v_2^0, \dots, v_c^0\}$ (مراكز العناقيد الابتدائية نختارها بشكل عشوائي) .
- $U^0 = \{u_{ik}^0\}$ (القيم الابتدائية لدالة العضوية نختارها بشكل عشوائي) .
- $m = 2$ (إسناد القيمة 2 لمعامل التضبيب) .
- $t = 1$ (تمثل التكرار الأول) .
- ε (عدد صغير موجب) .

الخطوة الثانية: حساب مراكز العناقيد V^t (في التكرار رقم t) من العلاقة :

$$v_i = \frac{\sum_{k=1}^n u_{ik}^m x_k}{\sum_{k=1}^n u_{ik}^m}, \quad i = 1, 2, \dots, c$$

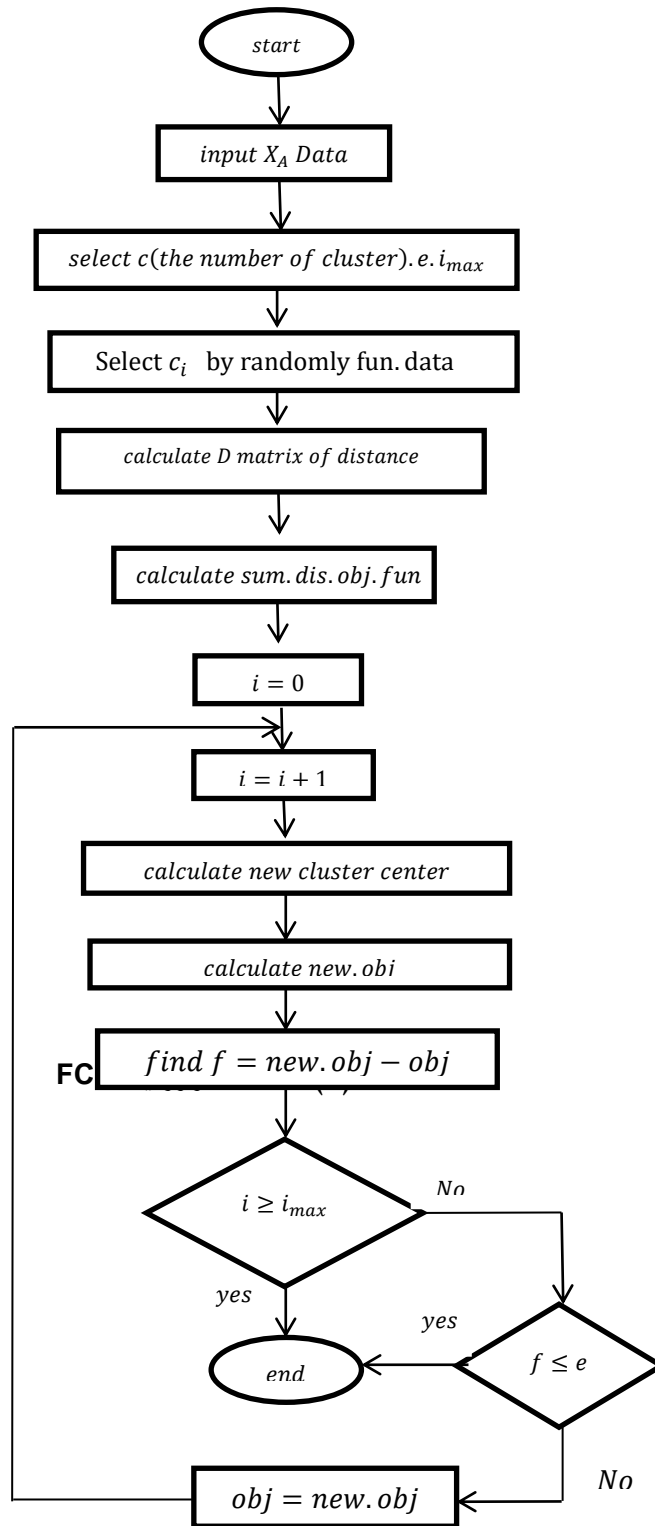
الخطوة الثالثة: حساب قيم دالة العضوية u^{t+1} من العلاقة :

$$u_{ik} = \frac{\left[\frac{1}{(x_k - v_j)^2} \right]^{\frac{1}{m-1}}}{\sum_{j=1}^c \left[\frac{1}{(x_k - v_j)^2} \right]^{\frac{1}{m-1}}}, \quad i = 1, 2, \dots, c, \quad k = 1, 2, \dots, n .$$

الخطوة الرابعة: اختبار الشرط $|u_{ik}^{(t+1)} - u_{ik}^t| \leq \varepsilon$ التوقف في حال تحقق الشرط .

الخطوة الخامسة: $t = t + 1$ ، العودة للخطوة الثانية . ويوضح المخطط في الشكل (2) خطوات خوارزمية

:FCM



الشكل (2): مخطط خوارزمية FCM

معامل ارتباط ماثيو (Matthew coefficient correlation):

يستخدم معامل ارتباط ماثيو (MCC) في مجال التعلم الآلي كمقياس لجودة التصنيفات الثنائية . يعيد معامل الارتباط قيمة من المجال $[-1, +1]$ حيث تمثل القيمة 1 ارتباطاً تاماً (مثالياً) بين العينة و النتيجة المطلوبة ، فيما تمثل القيمة -1 وجود ارتباط غير تام بينهما، أما القيمة 0 فتعني أن النتيجة ليست أفضل من التوقع العشوائي (لا يوجد ارتباط) [9].

إن حساب معامل ارتباط ماثيو يتطلب ايجاد مصفوفة الارتباك (confusion matrix) و هي مصفوفة بأربع مجموعات مختلفة من قيم حقيقية و قيم متوقعة حيث توزع البيانات على أربع مجموعات كالآتي :

- صحيحة موجبة (True Positive)
- صحيحة سالبة (True Negative)
- خاطئة موجبة (False Positive)
- خاطئة سالبة (False Negative)

نضعها في الجدول الآتي:

		قيم حقيقية	
		Positive	Negative
قيم متوقعة	Positive	TP	FP
	Negative	FN	TN

جدول (1): مصفوفة الارتباك

و يتم حساب قيمة معامل ماثيو باستخدام العلاقة التالية :

$$MCC = \frac{TP * TN - FP * FN}{\sqrt{(TP+FP)(TP + FN)(TN + FP)(TN + FN)}} .$$

النموذج المقترح (الشبكة العصبونية الصناعية المضببة والمعدلة باستخدام معامل ارتباط ماثيو

: (Regularized Fuzzy Neural Network – Coefficient Mattiew)

تم اقتراح نموذج لشبكة عصبونية صناعية ضبابية من النوع SLFNS لحل مسائل التصنيف الثنائية بشكل عام و تتألف من ثلاث طبقات:

• الطبقة الأولى: طبقة المدخلات و فيها يُقسم فضاء المدخلات إلى عدد محدد من المجموعات الضبابية باستخدام خوارزمية Fcm .

• الطبقة الثانية: طبقة العصبونات الخفية و تضم عصبونات ضبابية (fuzzy neurons) من النوع

and–neuron و or–neuron وهي عناصر حسابية قادرة على أداء عمليات غير خطية على الفضاء

$[0,1] \rightarrow [0,1]^N$ حيث N هي عدد المدخلات [10] ، كما هو موضح في الشكل (3) .

إن العصبون من النوع or-neuron يؤدي عملية جمع المدخلات مع الأوزان باستخدام العملية t-norm ومن ثم نطبق العملية s-norm على الناتج. وبشكل مشابه يؤدي العصبون and-neuron عملية جمع باستخدام العملية s-norm لجمع المدخلات والأوزان فيما نطبق العملية t-norm على الناتج. العمليتين t-norm و s-norm معرفتين بالشكل:

$$h = or(a, w) = S_{i=1}^n(a_i t w_i)$$


$$h = and(a, w) = T_{i=1}^n(a_i s w_i)$$

حيث h هو خرج العصبون في الطبقة الخفية.

• الطبقة الثالثة: وهي طبقة الخرج و تحوي عصبوناً وحيداً من نوع بيرسبترون بسيط ويكون :

$$y = \sum_{i=0}^L h_i v_i$$

حيث L هو عدد عصبونات الطبقة الخفية.



الشكل (3) : أنموذجي and-neuron و or-neuron


الجانب التطبيقي و النتائج:

تركز الجانب التطبيقي للبحث في مجال تصنيف الأورام الدماغية حيث تم استخدام قاعدة بيانات مؤلفة من 390 عينة مختلفة لأورام دماغية تمثل 9 صفات هي سماكة الكتلة المستهدفة، شكل الخلية، حجم الخلية، النوى الطبيعية للخلايا، النوى العارية، الالتصاق المركزي، الالتصاق الهامشي، الانقسام الفتيلي والكروماتين، تبين الصورة في الشكل (4) نوعين من الأورام أحدهما حميد (benign) والآخر خبيث (malignant) حيث نلاحظ اختلاف بعض الصفات السابقة بين الورمين، تم تخصيص 70% من قاعدة البيانات لتدريب النموذج المقترح و30% منها لاختباره .


تم استخدام برنامج Matlab (R2015a) لبناء النموذج واستخدمنا 10 مجموعات ضبابية لتقسيم فضاء المدخلات باستخدام خوارزمية Fcm كما اعتمدنا معامل ارتباط ماثيو في عملية التهذيب (pruning)، يبين الشكل (5) تصنيف الأورام إلى نوعين حميدة وخبيثة، و حصلنا على النتائج الآتية:

- نسبة الدقة في تصنيف عينة التدريب 86.43% .
- نسبة الدقة في تصنيف عينة الاختبار 88.30% .
- نتيجة تهذيب الشبكة العصبونية الصناعية المستخدمة: تخفيض عدد العصبونات في الطبقة الخفية من 10 عصبونات إلى 6 عصبونات .

و بالتالي فإن النموذج المقترح أعطى نتائج جيدة من حيث دقة التصنيف و الوقت اللازم للقيام بعملية التصنيف مقارنة مع نتائج أبحاث سابقة و طرق قياسية مخصصة لهذا المجال نعرضها في الجدول (2).



الشكل(4): صورة لنوعين مختلفين الأورام



الشكل(5): شكل الإنتشار للأورام في مجموعتين مختلفتين.

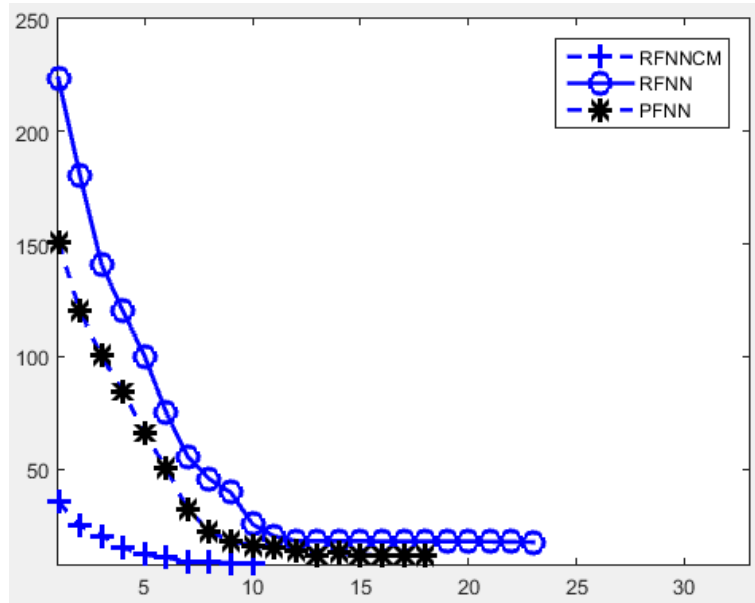
و فيما يلي الجدول (2) نوضح فيه مقارنة النتائج التي توصلنا إليها مع نتائج خوارزميتي Pruning Fuzzy Neural Network والتي نشير إليها اختصارا (PFNN) و Regularized Fuzzy Neural Network أو (RFNN) فيما نشير للنموذج المقترح من قبلنا (RFNNCM).

	Training Accuracy	Training time	Test Accuracy	Test time
RFNNCM	86.43%	2.4sec	88.30%	0.36sec
RFNN	60.30%	204.09sec	61.40%	28.18sec
PFNN	85.9%	123.91sec	86.54%	54.71sec

جدول(2): مقارنة بين نتائج كل من النماذج RFNNCM و PFNN و RFNN .

كما يوضح المخطط في الشكل (6) العلاقة بين عدد التكرارات و دالة الهدف لكل من RFNNCM ،

RFNN و PFNN .



الشكل (6): العلاقة بين عدد التكرارات و دالة الهدف

التوصيات:

- إن استخدام خوارزمية ELM قد لا تعطي نتائج أفضل في جميع المسائل وذلك يعود لطبيعة البيانات المستخدمة، أي أن طبيعة كل مسألة تلعب دوراً هاماً في اختيار نموذج الحل، لذلك نوصي بما يلي:
- اختيار خوارزمية تدريب مختلفة عن خوارزمية ELM بحيث تكون ملائمة للنموذج المقترح للمسألة المدروسة.
- استخدام توابع انتماء ضبابية مختلفة تكون أكثر ملائمة للبيانات المستخدمة في المسألة المدروسة.
- استخدام صيغ مختلفة للعصبونات الضبابية وعمليتي s-norm و t-norm .

المراجع:

- [1]. SHARMA,P.;KAUR,M.(2013),"classification in pattern recognition: AReview".International Journal Of Advanced Research In Computer Science And Software Engineering.
- [2]. Lin, Chin-Teng and Lee, George. (1991). "Neural-network-based fuzzy logic control and decision system". [IEEE Transactions on Computers](#), 40 (12), 1320-1336.
- [3]. Huang, Guang-Bin; Zhu Qin-Yu; Siew Chee-Kheong. (2006). "Extreme learning machine: Theory and applications". *Neurocomputing*, 70 (1-3), 489-501.
- [4]. Rong, HAI-JUN; ONG, YEW-SOON; TAN, AH-HWEE; ZHU, ZEXUAN.(2008)" A fast pruned-extreme learning machine for classification problem". *Neurocomputing*, 72 (1-3), 359-366.
- [5]. SOUZA,P.(2018)."Regularized fuzzy neural networks".International Journal of Applied Engineering Research ISSN,0973-4562,Volume13,Number 5.
- [6]. Dunn,J,C.(1973): "A Fuzzy Relative of the ISODATA Process and Its Use in Detecting Compact Well-Separated Clusters", *Journal of Cybernetics* 3: 32-57
- [7]. BEZDEK,J,C (1981): "Pattern Recognition with Fuzzy Objective Function Algorithms", Plenum Press, New York.
- [8]. KAUFMAN,L.; ROUSSEEUW,P.(2010)." Finding Groups in Data: an Introduction to Cluster Analysis". John Wiley & Sons, Inc,P170.
- [9] MATTHEWS; BRAINS. (1975). "Comparison of the predicted and observed secondary structure of T4 phage lysozyme". [Biochimica et Biophysica Acta \(BBA\) - Protein Structure](#). 405 (2). 442-451.
- [10]. GUPTA,M;RAO,D(1994)."On Principles of Fuzzy neural networks".Intelligent Systems Research Laboratory,University of Saskatchewan,Canada,S7N,OWO.