

## Neutrosophic Weighted Support Vector Machine for Autism Spectrum Disorder Detection in Children

Rania Lutfi

Micheline Alsabea

Faculty of Computer Engineering || Al-Baath University || Syria

**Abstract:** Introduction: Many studies have been introduced in data analysis and machine learning algorithms, especially in the medical and healthcare field, such as Autism Spectrum Disorder (ASD). Aim of Study: The study aimed to find an effective way to classify children with autism spectrum disorder based on the concept of Neutrosophic sets that fits the nature of real data, which may be incomplete or with noise. The proposed method calculates a set of values of weights based on the concept of Neutrosophic membership using Neutrosophic clustering by kernel method, these weights are passed to the Neutrosophic Support Vector Machine to find the optimal hyperplane. Research Methods: The proposed method was evaluated using the UCI Machine Learning Repository data set containing 292 cases and 21 attributes, and it has noise and is incomplete by up to 15%. We compared the proposed method with the Fuzzy Neutrosophic Support Vector Machine (FNSVM) and Support Vector Machine (SVM) methods, conducted using a python programming language. Experimental results: confirm the outperform of the proposed method with an accuracy of 99.98%. In addition, the result of classification accuracy of this method applied to raw data was compared with other methods such as CNN, ANN, and Stochastic GSS by using the same data but after application of initial processing of missing values and selection of features. Discussion: The comparison results prove the superiority of our method, which is based on Neutrosophic theory.

**Keywords:** Neutrosophic Support Vector Machine, Kernel NC-Means clustering, Classification, Autism Spectrum Disorder.

## آلة ناقلات الدعم الموزونة النتروسوفيكية للكشف عن اضطراب طيف التوحد عند الأطفال

رانيا لطفي

ميشلين السبع

كلية الهندسة المعلوماتية || جامعة البعث || سوريا

**المستخلص:** ظهرت العديد من الدراسات التي تناولت تحليل البيانات وخوارزميات التعلم الآلي وخاصة في المجال الطبي والرعاية الصحية، ولا سيما اضطراب طيف التوحد. الهدف من الدراسة: تهدف إلى إيجاد طريقة فعالة لتصنيف أطفال اضطراب طيف التوحد بالاستناد إلى مفهوم المجموعات النتروسوفيكية وتلائم طبيعة المعطيات ضمن العالم الحقيقي، والتي قد تكون ناقصة أو مشوبة بالضجيج. تحسب الطريقة المقترحة مجموعة من قيم الأوزان استناداً إلى مفهوم الانتماء النتروسوفيكى وذلك باستخدام العنقدة النتروسوفيكية بطريقة النواة، هذه الأوزان تمرر إلى آلة ناقلات الدعم ل يتم إيجاد الحل الفاصل الأمثل. مواد البحث وطرائقه: تم تقييم الطريقة المقترحة باستخدام مجموعة المعطيات من UCI Machine Learning Repository. وهي تحتوي على 292 حالة و21 خاصية، كما أن هذه المعطيات فيها ضجيج وناقصة بنسبة تصل إلى 15%. عملنا على مقارنة الطريقة المقترحة مع كل من طريقي آلة ناقلات الدعم

النتروسوفيكية الضبابية وآلة ناقلات الدعم، تم إجراء العمل باستخدام لغة البرمجة بايثون. النتائج التجريبية: تؤكد تفوق الطريقة المقترحة وبدقة 99.98%. بالإضافة إلى ذلك، تمت مقارنة نتيجة دقة التصنيف لهذه الطريقة والنتيجة من تطبيقها على المعطيات الخام بدون تحضير مع طرق أخرى مثل CNN، ANN و Stochastic GSS وذلك باستخدام نفس المعطيات ولكن بعد تطبيق المعالجة المبدئية للقيم الناقصة واختيار الميزات. المناقشة: ناتج المقارنة يثبت تفوق طريقتنا والتي تستند إلى النظرية النتروسوفيكية.

الكلمات المفتاحية: آلة ناقلات الدعم النتروسوفيكية، عنقدة نتروسوفيكية مع نواة، تصنيف، اضطراب طيف التوحد.

## 1- المقدمة.

تعتبر عملية الفحص الدقيق وتقييم التوحد في مرحلة الطفولة مسألة صعبة في اتخاذ القرار، ويعتبر التوحد من أبرز الاضطرابات التي يمكن أن تصيب الأطفال في سن مبكرة. كما أنه تقليدياً يمكن لبعض المختصين الذين يتمتعون بخبرة جيدة أن يحددوا حالة الشخص إن كان مصاب أم لا. ولكن بشكل عام يرجع السبب في صعوبة التشخيص إلى أن اضطراب التوحد يشبه طبيعته بعض الأمراض العصبية، بالإضافة إلى قلة الوعي بالاضطراب وبأعراضه، كما تتضمن عادة طرق التقييم التقليدية قوائم تحتوي على أعراض التوحد في مرحلة الطفولة (Levy et al., 2017; Prata & Kanimazhiselvi, 2014)، وهذه البيانات وفي الكثير من الحالات يتم تجميعها من قبل أشخاص غير خبراء بالمجال المدروس، وهذا ما يجعل البيانات الحقيقية غير محددة، ناقصة أو فيها ضجيج. مما جعل الحاجة إلى نظام مساعد يمكن أن يحسن من دقة إجراء التشخيص الحالي، بحيث يمكن أن يؤكد قرارات الأطباء وبالتالي استخدامه كمساعد في اكتشاف الإصابة بالتوحد.

على الرغم من أن عدد الأبحاث التي تعمل على تطبيق تقنيات (soft computing) لتطوير أنظمة تعمل في هذا المجال كبير، إلا أنه يبقى محدود مقارنة بعدد أطفال مرضى التوحد في العالم، كما أن المعطيات الغير محددة بالعالم الحقيقي دفعت الباحثين إلى تطوير دراسات جديدة تعكس الرؤية لهذه المعطيات من خلال مفهوم النيتروسوفيكية، حيث عمم فلورنتس سماراندكة عام 95 مفهوم المنطق الضبابي إلى النيتروسوفيكي. كما قدم كل من سلامة وسماراندكة نظرية الفئات النتروسوفيكية الكلاسيكية (Salama & Samarandache, 2015) ثم ظهرت نظريات وعمليات جديدة على مفهوم المجموعات والفئات النيتروسوفيكية (Salama & Alblowi, 2012; Broumi et al., 2021) بما فيها في مجال التعلم الآلي واتخاذ القرار (Elhassouny et al., 2019)، وهذا ما دفعنا إلى التركيز في هذا البحث على استخدام تقنيات التعلم الآلي ونظرية النيتروسوفيكية وبخاصة مسألة التصنيف، لبناء نظام مساعد في تحديد الأطفال المصابين بالتوحد.

في السنوات الماضية، اكتسبت دراسات التنبؤ باضطراب طيف التوحد اهتمام العلماء والباحثين من أجل تلبية الاحتياجات المتزايدة للتقنيات التي تساعد في اكتشاف الإصابة باضطراب طيف التوحد. يتضمن المسح التالي دراسات مختلفة تتعلق بأهداف البحث الذي يسعى لإيجاد طريقة مساعدة في تشخيص إصابة الأطفال بالتوحد وتلائم المعطيات الحقيقية التي قد تكون ناقصة أو مشوبة بالضجيج: في احد الأبحاث، اقترح المؤلفون تقنية هجينة تعتمد على الشبكات العصبية والأنظمة الضبابية، والنموذج الذي تم تجربته على مجموعة بيانات تم إنشاؤه من خلال الأجهزة المحمولة لبناء قواعد تساعد في اكتشاف العلاقات والسمات المرتبطة بوجود التوحد لدى الأشخاص، وأظهرت النتائج أن النهج الهجين المقترح يتفوق على الطرق الأخرى (MLP، C4.5، الأشجار العشوائية RNT) بدقة تصل إلى 97.73% و 94.32% و 97.28% للأطفال والمراهقين والبالغين على التوالي (Souza et al., 2021). في بحث آخر، تم اقتراح تقنية تصنيف ثنائي لتحديد ما إذا كان الطفل عرضة لمرحلة التوحد المبكرة، حيث تم تطبيق نماذج التعلم الآلي مثل (KNN, LR, NB, RF, SVM) على مجموعة بيانات مع المعالجة المسبقة وهندسة الميزات، وتم بناء

نموذج تنبؤي لدراسة حالات الاختبار. أظهرت النتائج التجريبية أن طريقة LR تعطي أعلى دقة تصل إلى 97.51٪ لقاعدة البيانات المدروسة (Vakadkar et al., 2021). في دراسة أخرى اقترح الباحثون تصنيف ثنائي لمرضى التوحد في مجموعة بيانات AQ-10 عبر المعلومات العمرية والديموغرافية، تم تجهيز البيانات وهندسة الميزات، ومن ثم دراسة تحليلية لثلاثة مصنفات (KNN، RF، الشبكة العصبية للتغذية الأمامية)، وأظهرت النتائج التجريبية أن الطريقة المقترحة تعمل بشكل أفضل على اكتشاف اضطراب طيف التوحد لدى الأطفال والمراهقين والبالغين (Jannat & Canavan, 2021).

هناك القليل من الدراسات التي تناولت موضوع تشخيص الإصابة بالتوحد باستخدام مفهوم النيتروسوفيكية، نجد دراسة أجريت على 42 حالة لمرضى من عمر 18 شهر إلى 4 سنوات بغرض تحديد العناصر الرئيسية التي تعرض لها الأطفال والتي يمكن أن تسبب الإصابة بالتوحد، وذلك لإنشاء مجموعة مشتركة من العوامل المسببة للتوحد باستخدام مفهوم النيتروسوفيكية، وليس بهدف التصنيف (Salgado et al., 2021). إلا أنه بالمقابل نجد العديد من الأبحاث التي تناولت خوارزميات التعلم الآلي مع النيتروسوفيكية وذلك من أجل التصنيف أو العنقدة وغيره (Elhassouny et al., 2019).

تركز معظم الدراسات الذي تمت مناقشتها في الأعلى على التصنيف باستخدام خوارزميات التعلم الآلي وذلك بعد معالجة المعطيات وهندسة الميزات، ولكن يعد توفير طريقة لتحسين نتيجة التصنيف استناداً إلى النظرية النيتروسوفيكية عمل بالغ الأهمية لأنه يوائم طبيعة المعطيات ضمن العالم الحقيقي وهذا ما نسعى إليه في هذا البحث.

## 2- مشكلة البحث:

يعد الفحص الدقيق وتقييم التوحد في مرحلة الطفولة من المشكلات الصعبة في اتخاذ القرار والسبب في ذلك يرجع إلى أن التوحد يشبه بطبيعته بعض الأمراض العصبية، بالإضافة إلى أن المعطيات الحقيقية التي تخص مرضى التوحد قد تكون ناقصة أو فيها ضجيج، حيث يشير الباحثون في دراساتهم إلى طرق مختلفة لتصنيف أطفال التوحد باستخدام التعلم الآلي، والتي تفيد في دعم وتأكيد قرارات الخبراء بالمجال، لكن جميعها تستند إلى معالجة مبدئية للمعطيات واختيار الميزات، وبالتالي فهي لا تقدم طريقة قياسية لتصنيف أطفال التوحد. يسعى البحث إلى الاستفادة من النظرية النيتروسوفيكية لإيجاد طريقة تساعد في تحديد إصابة الأطفال بمرض التوحد انطلاقاً من معطيات قد تكون ناقصة ومشوبة بالضجيج، لتكون أداة مساعدة للاختصاصيين في تشخيص الأطفال المصابين بالتوحد.

## 3- مواد البحث وطرائقه.

### 1-3- آلة ناقلات الدعم الضبابية (Lin & Wang, 2002):

يتم في هذه الطريقة ومن أجل كل إدخال  $(x_i, y_i)$ ،  $i = 1, 2, \dots, N$ ، إسناد قيمة  $\delta_i$  تمثل الانتماء الضبابي لهذه النقطة إلى صف معين، بحيث تكون  $0 < \delta_i < 1$  و  $e_i$  تمثل خطأ آلة ناقلات الدعم SVM، فيكون الجداء  $\delta_i e_i$  يمثل مقياس الخطأ مع اختلاف الأوزان. تهدف آلة ناقلات الدعم إلى إيجاد الحل الأمثل والذي يكافئ جعل  $w$  أصغري أي يمكن في هذه الحالة إيجاد الفاصل الهامش الأمثل (hyperplane) كما يلي:

$$\text{Minimum} \left( \frac{1}{2} w^2 + C \sum_{i=1}^N e_i \delta_i \right)$$

والذي يخضع لمعالجة تبعاً للعلاقة:

$$y_i(w.z_i + b) \geq 1 - \delta_i \quad i = 1, 2, \dots, N$$

بحيث  $C$  عبارة عن ثابت. من الملاحظ أن أصغر قيمة للخطأ  $e_i$  يمكن أن يقلل من تأثير البارامتر  $\delta_i$  بشكل يجعل قيمة المعطيات التي تقابل  $x_i$  هي الأقل أهمية.

2-3- العنقدة بطريقة النواة النيتروسوفيكية:

#### (Kernel Neutrosophic C-Means) KNC-Means

تستند هذه الطريقة إلى خوارزمية العنقدة النيتروسوفيكية (NCM) (Neutrosophic C-Means) (Guo & Sengur, 2015)، حيث تطبق عليها تابع نواة، ليصبح التابع الهدف المستخدم في حساب العنقدة معطى بالعلاقة:

$$J_{KNCM}(T, I, F, c) = \sum_{i=1}^N \sum_{j=1}^c 2(\bar{w}_1 T_{ij})^m (1 - K(x_i, c_j)) + \sum_{i=1}^N 2(\bar{w}_2 I_i)^m (1 - K(x_i, \bar{c}_{imax})) + \delta^2 \sum_{i=1}^N (\bar{w}_3 F_i)^m$$

ويتم تعريف قيم الانتماء النيتروسوفيكية كمايلي:

$T_{ij}$  وهي تمثل الانتماء الصحيح لعنصر إلى عنقود معين،  $I_i$  والتي تمثل عدم تحديد الانتماء و  $F_i$  وهي تعبر

عن الانتماء الخاطئ:

$$T_{ij} = \frac{\bar{w}_2 \bar{w}_3 K(x_i, c_j)^{-\left(\frac{2}{m-1}\right)}}{\sum_{j=1}^c K(x_i, c_j)^{-\left(\frac{2}{m-1}\right)} + K(x_i, \bar{c}_{imax})^{-\left(\frac{2}{m-1}\right)} + \delta^{-\left(\frac{2}{m-1}\right)}}$$

$$I_i = \frac{\bar{w}_1 \bar{w}_3 K(x_i, \bar{c}_{imax})^{-\left(\frac{2}{m-1}\right)}}{\sum_{j=1}^c K(x_i, c_j)^{-\left(\frac{2}{m-1}\right)} + K(x_i, \bar{c}_{imax})^{-\left(\frac{2}{m-1}\right)} + \delta^{-\left(\frac{2}{m-1}\right)}}$$

$$F_i = \frac{\bar{w}_1 \bar{w}_2 (\delta)^{-\left(\frac{2}{m-1}\right)}}{\sum_{j=1}^c K(x_i, c_j)^{-\left(\frac{2}{m-1}\right)} + K(x_i, \bar{c}_{imax})^{-\left(\frac{2}{m-1}\right)} + \delta^{-\left(\frac{2}{m-1}\right)}}$$

حيث يعطى مركز العنقود بالعلاقة:

$$c_j = \frac{\sum_{i=1}^N (\bar{w}_1, T_{ij})^m K(x_i, x_i)}{\sum_{i=1}^N (\bar{w}_1, T_{ij})^m}$$

من أجل كل عنصر  $i$  يتم حساب قيمة  $\bar{c}_{imax}$  باستخدام مراكز العناقيد مع أخذ أول وثاني أكبر قيمتين

من  $T_{ij}$  كمايلي:

$$\bar{c}_{imax} = \frac{c_{pi} - c_{qi}}{2}$$

$$p_i = \operatorname{argmax}_{j=1,2,\dots,c} (T_{ij})$$

$$q_i = \operatorname{argmax}_{j \neq p_i \cap 1,2,\dots,c} (T_{ij})$$

m عبارة عن ثابت.  $p_i$  و  $q_i$  عبارة عن عدد العناقيد مع أكبر أول قيمتين من  $T$ . في هذه الطريقة يتم الفصل بين العناقيد من خلال عملية تكرارية وصولاً إلى قيمة أمثلية لتابع الهدف وذلك من خلال تعديل كل من قيم الانتماء النيتروسوفيكية، المركز  $C_j$  و قيمة  $\bar{C}_{imax}$  عند كل تكرار، التعديل يتم وفقاً للمعادلات المعرفة أعلاه. يتم توقف العمل التكراري عند الوصول إلى  $\varepsilon$ ، حيث  $\left| T_{ij}^{(k+1)} - T_{ij}^{(k)} \right| < \varepsilon$ ، حيث  $\varepsilon$  يمثل شرط التوقف وهو عبارة عن قيمة بين 0 و 1، بينما يمثل المتحول  $k$  خطوة التكرار.

### 3-3- آلة ناقلات الدعم النيتروسوفيكية (Elhassouny et al., 2019):

#### Neutrosophic Support Vector Machine (NSVM)

بفرض لدينا  $N$  عبارة عن مجموعة من بيانات التدريب  $(x_i, y_i)_{i=1}^N$ ، بحيث  $x_i$  عبارة عن شعاع متعدد الأبعاد و  $y_i \in \{-1, 1\}$  عبارة عن الصف المقابل للعنصر  $x_i$ . نعرف مفهوم آلة ناقلات الدعم النيتروسوفيكية بالاستناد إلى تعريف آلة ناقلات الدعم (Han et al., 2011).

إن آلة ناقلات الدعم عبارة عن نموذج يسعى لإيجاد الحل الأمثل من خلال جعل قيمة الهامش الفاصل عظمية، وبالتالي عندما تكون مجموعة معطيات الإدخال لا خطية، يمكن أن نحصل على الهامش الفاصل بتعريف مجموعة  $N$  من المتحولات الغير سالبة ونرمزها  $\rho = (\rho_1, \rho_2, \dots, \rho_N)$  بحيث يكون لدينا من أجل كل عنصر  $x_i$ :

$$y_i(w\phi(x_i) + b) \geq 1 - \rho_i, \quad i=1,2,\dots,N$$

### 4- الطريقة المقترحة: آلة ناقلات الدعم النيتروسوفيكية الموزونة.

#### Weighted Kernel Neutrosophic Support Vector Machine(W-KNSVM)

تستخدم الطريقة المقترحة مجموعة النيتروسوفيكية وآلة ناقلات الدعم النيتروسوفيكية لإيجاد طريقة تصنيف فعالة لأطفال اضطراب طيف التوحد، حيث تم استخدام العقدة بطريقة النواة النيتروسوفيكية الموضحة ضمن فقرة (2-3) لتحديد الانتماء وإيجاد الأوزان انطلاقاً من الانتماء النيتروسوفيكي، ومن ثم تمرير هذه الأوزان إلى آلة ناقلات الدعم النيتروسوفيكية.

في الطريقة المقترحة، نعرف تابع وزن جديد  $h$  بالاستناد إلى مجموعة قيم الانتماء النيتروسوفيكية كمايلي:

$$h_i = T_{ij} \cdot I_i - F_i$$

باستخدام تابع الوزن المعرف، يكون الحل الأمثل لإيجاد الفاصل هو عبارة عن إيجاد القيمة الأصغرية

لتابع التكلفة:

$$\text{minimize } h_i = \frac{1}{2} w^2 \sum_{i=1}^N h_i \rho_i$$

يمكن أن نلخص خطوات الخوارزمية المقترحة فيمايلي:

الدخل: مجموعة معطيات التدريب

1- تهيئة مراكز العناقيد باستخدام خوارزمية العقدة بطريقة النواة النيتروسوفيكية وذلك لتحديد مجموعة قيم الانتماء النيتروسوفيكية.

2- إيجاد الفاصل الهامشي الأمثلي بحساب تابع الوزن  $h_i$

3- تصغير تابع التكلفة وبالتالي تحسين آلة ناقلات الدعم النيتروسوفيكية والذي يعطي تصغير للوزن بحسب العلاقة:

$$\text{minimize } h_i = \frac{1}{2} w^2 \sum_{i=1}^N h_i \rho_i$$

الخرج: الصف الذي تم التنبؤ به

##### 5- الاختبارات التجريبية والنتائج:

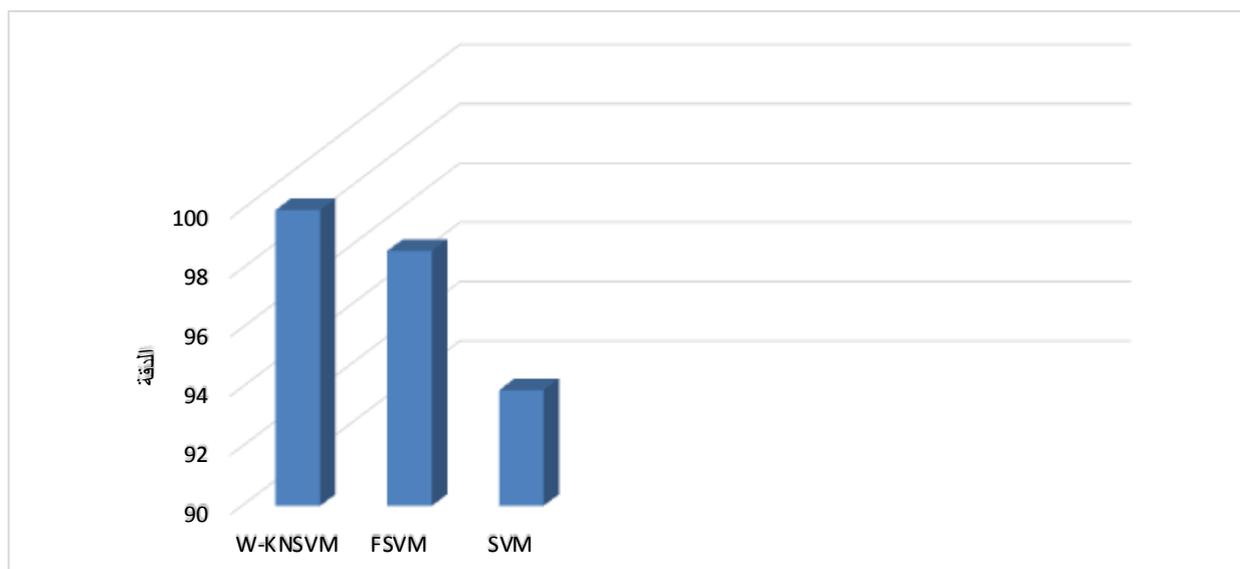
تم في هذا البحث إجراء الاختبارات التجريبية على مجموعة معطيات من UCI Machine Learning Repository (Thabtah, 2017)، وذلك بهدف مقارنة فعالية الطريقة المقترحة مع طريقتي آلة ناقلات الدعم SVM وآلة ناقلات الدعم الضبابية (Fuzzy Support Vector Machine) FSVM، تتألف مجموعة المعطيات هذه من 292 عينة و 21 ميزة تستخدم في عملية التنبؤ. كما تتميز بوجود ضجيج وقيم ناقصة. لقد قمنا بتنفيذ كل من خوارزميات آلة ناقلات الدعم SVM، آلة ناقلات الدعم الضبابية FSVM وآلة ناقلات الدعم النيتروسوفيكية الموزونة W-KNSVM تحت نفس الشروط، حيث لم نطبق أي عمليات معالجة مبدئية واستخدمنا نفس قيم البارامترات، كما تم اعتماد تابع النواة Radial Base Function (RBF) والذي تم إيجاده بطريقة مجال البحث (interval search method)، وهو يعطى بالعلاقة (Akbulut et al., 2017):

$$k_{RBF}(x, x_i) = e^{-\frac{\|x-x_i\|^2}{\sigma^2}}$$

تم العمل على جهاز كمبيوتر انتل Core i7-4810 وسعة الذاكرة 32 غيغابايت. في عملية تقييم الطرق المختلفة، طبقنا five-fold cross-validation، وقسمنا كامل المجموعة إلى جزأين بنسبة 80:20، 80% للتدريب و 20% للاختبار. كما أجرينا تقييم النتيجة باستخدام مقياس الدقة الذي يعطى بالعلاقة التالية (Tohka & Gils, 2021):

$$\text{Accuracy} = \frac{TP+TN}{TP+FP+TN+FN}$$

حيث حصلنا على قيم البارامترات بالتجربة، فكانت قيمة  $\epsilon = 10^{-3}$ ، حجم الخطوة بقيمة  $10^{-1}$ ، بالإضافة إلى بارامترات الوزن  $w_1 = 0.7$ ،  $w_2 = 0.125$  و  $w_3 = 0.125$ ،  $\sigma = 0.05$ ،  $\delta = 7$ . لقد أعطت طريقتنا المقترحة (شكل 1) أعلى دقة تصل إلى 99.98%، تليها طريقة FSVM وبدقة 98.60% في حين تعطي طريقة SVM أقل دقة بقيمة 93.90%.



الشكل (1) مقارنة النتائج

نعرض النتائج التجريبية للطريقة المقترحة والمطبقة على مجموعة المعطيات باستخدام كل الميزات في الجدول (1)، حيث قارنا نتيجة الطريقة المقترحة مع كل من طريقي FSVM و SVM، كما هو واضح من الجدول، أعطت الطريقة المقترحة أعلى دقة.

جدول (1) مقارنة نتائج الطريقة المقترحة مع كل من طريقي FSVM و SVM

الطريقة	الطريقة المقترحة W-KNSVM	FSVM	SVM
الدقة	99.98	98.60	93.90

#### 1-5- المناقشة

ضمن مجموعة المعطيات المدروسة هناك بعض قيم الميزات ناقصة بنسبة تصل تقريبا إلى 15%، بالإضافة إلى وجود ضجيج، وهذا ما يؤثر على نوعية النموذج المستخدم في عملية التصنيف مثل SVM الذي يتأثر بالضجيج. لكن مع استخدام تابع النواة بطريقة النيتروسوفيكية المقترحة تم تحسين فعالية SVM وأعطى أفضل نتيجة مقارنة مع كل من SVM و FSVM وذلك باستخدام نفس تابع النواة RBF، وهذا يعود إلى توابع الانتماء التي تم إيجادها في طريقة العنقدة باستخدام النواة النيتروسوفيكية، بالإضافة إلى تابع الوزن الجديد الذي تم تعريفه بالاستناد إلى معلومات الانتماء والذي أعطى نتائج جيدة على معطيات تحوي ضجيج أو قيم ناقصة.

قمنا بمقارنة الطريقة المقترحة مع دراسات أخرى حديثة (Raj & Masood, 2020; Sujatha et al., 2021) تناولت نفس قاعدة المعطيات، في الدراسة الموضحة ضمن (Raj & Masood, 2020) تم معالجة القيم الناقصة أي المعالجة المبدئية للمعطيات بطريقة (impuration) وكانت نتيجة طريقتنا المقترحة أفضل من نتيجة تطبيق كل من طرق SVM و ANN و CNN على نفس قاعدة المعطيات، حيث أعطت الطريقة المقترحة أعلى دقة تصل إلى 99.98%. كما أن الطريقة المقترحة وبمقارنتها مع العمل الموضح ضمن (Sujatha et al., 2021) والذي يتناول مسألة اختيار بعض الميزات، أعطت أفضل نتيجة مقارنة مع كل من SVM، CNN، و Stochastic SGD.

يوضح الجدول (2) نتيجة مقارنة الطريقة المقترحة مع الطرق المدروسة ضمن (Raj & Masood, 2020; Sujatha et al., 2020) وذلك على نفس مجموعة المعطيات.

جدول (2) مقارنة الطريقة المقترحة مع طرق أخرى باستخدام نفس مجموعة المعطيات

النموذج	الدقة بعد معالجة القيم الناقصة (Raj & Masood, 2020)	الدقة بعد المعالجة المبدئية واختيار الميزات (jatha et al., 2021)
CNN	98.30	97.5
ANN	98.30	---
SVM	98.30	94.1
Stochastic SGD	---	99.6
الطريقة المقترحة W-KNSVM	الدقة باستخدام المعطيات وبدون معالجة أو تحضير أو اختيار ميزات: 99.98	

نستنتج من الجدول السابق أن الطريقة المقترحة والتي تستند إلى تابع النواة النيتروسوفيكية والموزونة حسنت نتيجة التصنيف وذلك من أجل معطيات ناقصة وفيها ضجيج.

## 6- الخاتمة والتوصيات:

في هذا البحث، استخدمنا نظرية النيتروسوفيكية وكل من طريقي آلة ناقلات الدعم النيتروسوفيكية والعنقدة بطريقة النواة النيتروسوفيكية وذلك لإيجاد طريقة فعالة موزونة في التصنيف تدعى W-KNSVM، حيث استخدمناها في عملية تصنيف الأطفال وتحديد إصابتهم باضطراب طيف التوحد. تستند الطريقة المقترحة إلى تحديد مجموعة من الأوزان انطلاقاً من مفهوم الانتماء النيتروسوفيكي وباستخدام العنقدة بطريقة النواة، ومن ثم يتم تمرير الأوزان إلى آلة ناقلات الدعم النيتروسوفيكية وذلك لإيجاد الفاصل الهامشي الأمثلي. عملنا على مقارنة الطريقة المقترحة مع كل من طريقي آلة ناقلات الدعم الضبابية FSVM وآلة ناقلات الدعم SVM، وذلك باستخدام نفس مجموعة المعطيات وبنفس الشروط ودون تحضير مسبق لها. تبين الدراسة التجريبية أن الطريقة المقترحة تعطي أفضل نتيجة حيث تصل الدقة إلى 99.98% وتلها طريقة آلة ناقلات الدعم الضبابية بدقة 98.60%. أجريت مقارنة للطريقة المقترحة مع طرق أخرى وباستخدام نفس مجموعة المعطيات، إلا أن الطرق الأخرى تناولت مسألة تحضير ومعالجة المعطيات واختيار الميزات، أثبتت دراسة المقارنة أن الطريقة المقترحة W-KNSVM تتفوق على الطرق الأخرى. أي أن الطريقة المقترحة تناسب المعطيات الموجودة في العالم الحقيقي والتي يمكن أن تكون مشوبة، ناقصة أو فيها ضجيج.

بناءً على النتائج التي تم التوصل إليها توصي الدراسة باستخدام الطريقة المقترحة كأداة قياسية لتلائم المعطيات الخام ضمن العالم الحقيقي، وتساعد على أخذ القرار من قبل الخبراء المختصين بتشخيص اضطراب طيف التوحد لدى الأطفال.

## 7- قائمة المراجع.

- Akbulut, Y., Şengür, A., Guo, Y., & Polat, K. (2017). KNCM: Kernel neutrosophic c-means clustering. Applied Soft Computing, 52, 714-724.

- Broumi S., Jun Y., & Mani P. (2021). Theory, Algorithms, and Application within Neutrosophic Modeling and Optimization. Journal of mathematics, Special Issue.
- Elhassouny, A., Idbrahim, S., & Smarandache, F. (2019). Machine learning in Neutrosophic Environment: A Survey. Neutrosophic Sets and Systems.
- Jannat, S. K., & Canavan, S. (2021, January). Classification of autism spectrum disorder across age using questionnaire and demographic information. In 25th International Conference on Pattern Recognition. Springer, Cham.
- Han, J., Kamber, M., & Pei, J. (2011). Data Mining: Concepts and Techniques (Third Edition). The Morgan Kaufmann Series in Data Management Systems.
- Guo, Y., & Sengur, A. (2015). NCM: Neutrosophic c-means clustering algorithm. Pattern Recognition, 48(8), 2710-2724.
- Levy, S., Duda, M., Haber, N., & Wall, D. P. (2017). Sparsifying machine learning models identify stable subsets of predictive features for behavioral detection of autism. Molecular autism, 8(1), 1-17.
- Lin, C. F., & Wang, S. D. (2002). Fuzzy support vector machines. IEEE transactions on neural networks, 13(2), 464-471.
- Pratap, A., & Kanimozhiselvi, C. S. (2014). Predictive assessment of autism using unsupervised machine learning models. International Journal of Advanced Intelligence Paradigms, 6(2), 113-121.
- Raj, S., & Masood, S. (2020). Analysis and detection of autism spectrum disorder using machine learning techniques. Procedia Computer Science, 167, 994-1004.
- Salama, A. A., & Alblowi, S. A. (2012). Neutrosophic set and neutrosophic topological spaces. IOSR Journal of Mathematics (IOSR-JM), 3(4).
- Salama A., & Samarandache F. (2015) Neutrosophic Crisp Set theory. Education Publishing Colombia.
- Salgado, L. N. R., Argilagos, M. E. R., Garrido, A. S., Herrera, A. R. V., & Al-Subhi, S. H. S. (2021). Model for the Diagnosis of Autism Based on Neutrosophic Cognitive Maps. Neutrosophic Sets and Systems, 44, 125.
- Souza, P. V., Guimaraes, A. J., Araujo, V. S., & Lughofer, E. (2021). An intelligent Bayesian hybrid approach to help autism diagnosis. Soft Computing, 25(14), 9163.
- Sujatha, R., Aarthy, S. L., Chatterjee, J., Alaboudi, A., & Jhanjhi, N. Z. (2021). A Machine Learning Way to Classify Autism Spectrum Disorder. International Journal of Emerging Technologies in Learning (ijET), 16(6), 182-200.
- Thabtah F. (2017). Autistic Spectrum Disorder Screening Data for children, <http://archive/ics.edu/ml/machine-learning-databases/00419>.

- Tohka J., & Gils M V. (2021). Evaluation of Machine Learning algorithms for health and wellness application. A tutorial Computers in Biology and Medicine, 132. <https://doi.org/10.1016/j.combiomed.2021.104324>.
- Vakadkar, K., Purkayastha, D., & Krishnan, D. (2021). Detection of Autism Spectrum Disorder in Children Using Machine Learning Techniques. SN Computer Science, 2(5), 1-9.