

Early Diagnosis of Autism in Children Using Convolutional Neural Networks (CNNs)

Abdallah A. Oshah^{1*}, Montaha M. Mazkour¹, Marwa A. Omar¹

¹ Computer Department, Faculty of Engineering Sabratha, Sabratha University, Sabratha, Libya.

*Corresponding author email: Abdallah.oshah@sabu.edu.ly.

Received: 17-10-2024 | Accepted: 30-11-2024 | Available online: 15-12-2024 | DOI:10.26629/jtr.2025.11

ABSTRACT

The use of artificial intelligence (AI) alongside medical skills has witnessed significant growth in recent years, leading to impressive results in classification and processing, while facilitating the work of medical staff. Moreover, there has been an urgent need for software tools to assist in the early classification of diseases. In response to this need, this paper aims to develop a bidirectional neural network model with a web application interface for diagnosing Autism Spectrum Disorder (ASD) in children. The methodology employed relies on machine learning techniques for the early detection of this disorder, which includes collecting a comprehensive dataset containing 6,000 images, adjusting the image dimensions to focus on the facial area, and extracting morphological features associated with the disorder's symptoms. Edge detection techniques were applied, and images were segmented into recognizable parts. Subsequently, the model was trained using these features, and its performance was evaluated using metrics such as accuracy and F1 score. The proposed model achieved an accuracy ranging from 70% to 76% and an F1 score ranging from 75% to 79%, indicating its ability to classify cases of Autism Spectrum Disorder with high precision. The web application provides a user-friendly and accessible interface to utilize the diagnostic model, facilitating the screening and evaluation process. However, it is important to emphasize that the Convolutional Neural Network (CNN) model is a supportive tool for diagnosis and not a definitive solution. While it can assist in identifying potential cases of Autism Spectrum Disorder, the findings highlight the importance of expert involvement in diagnosis. Recommendations include expanding the dataset, applying data augmentation techniques, and training specialists to use the model and interpret its results correctly.

Keywords: Artificial Intelligence (AI) - Autism Spectrum Disorder (ASD) - Early Detection - Machine Learning (ML) - Convolutional Neural Networks (CNN)

التشخيص المبكر للتوحد عند الأطفال باستخدام الشبكات العصبية التلافيفية (CNN)

عبد الله عبد المجيد اوشاح¹ منتهي ميلود مذكور¹، مروه امحمد عمر¹

¹ قسم الحاسب الآلي، كلية الهندسة صبراتة، صبراتة، ليبيا.

ملخص البحث

يشهد استخدام الذكاء الاصطناعي إلى جانب المهارات الطبية نموًا ملحوظًا في السنوات الأخيرة، مما أدى إلى نتائج مبهرة في مجالي التصنيف والمعالجة، وسهّل عمل الكوادر الطبية. وازديادًا على ذلك، برزت الحاجة الملحة لأدوات برمجية تُساعد في تصنيف الأمراض بشكل مبكر. انطلاقًا من هذه الحاجة، تهدف هذه الورقة الي

تطوير نموذج شبكة عصبية ثنائية التوجه مع واجهة تطبيق ويب لتشخيص اضطراب طيف التوحد لدى الأطفال. تم الاعتماد على تقنيات التعلم الآلي للكشف المبكر عن هذا الاضطراب تتضمن المنهجية المستخدمة جمع مجموعة بيانات شاملة تحتوي على 6000 صورة، تعديل أبعاد الصور للتركيز على منطقة الوجه، واستخراج الميزات الشكلية المرتبطة بأعراض الاضطراب. تم تطبيق تقنيات كشف الحواف وتقسيم الصور إلى أجزاء يمكن التعرف عليها. بعد ذلك، تم تدريب النموذج باستخدام هذه الميزات، وتم تقييم الأداء باستخدام مقاييس مثل الدقة ومعدل F1. حقق النموذج المقترح دقة تتراوح بين 70% و76% ومعدل F1 يتراوح بين 75% و79%، مما يدل على قدرته على تصنيف حالات اضطراب طيف التوحد بدقة عالية. ويوفر تطبيق الويب واجهة سهلة الاستخدام وسهلة الوصول للاستفادة من نموذج التشخيص، مما يسهل عملية الفحص والتقييم. ومع ذلك، من المهم التأكيد على أن نموذج الشبكة العصبية التلافيفية (Convolutional Neural Network (CNN) يعد أداة داعمة للتشخيص وليس أداة نهائية. ففي حين أنه يُمكن أن يساعد في تحديد حالات اضطراب طيف التوحد المحتملة الاستنتاجات تشير إلى أهمية دور الخبراء في التشخيص، وتوصي بتوسيع مجموعة البيانات، تطبيق تقنيات تكبير البيانات، وتدريب المتخصصين على استخدام النموذج وتفسير نتائجه بشكل صحيح.

الكلمات الدالة: الذكاء الاصطناعي، اضطراب طيف التوحد، الكشف المبكر، التعلم الآلي، الشبكات العصبية التلافيفية.

1. المقدمة

يمكن علاجه، إلا أن التشخيص المبكر ضروري لتقديم التدخلات في الوقت المناسب اللازمة لتقليل أعراض المرض وتمكين الطفل من اكتساب المهارات الضرورية للوظيفة فيما بعد في الحياة. قد تم إجراء العديد من الدراسات لتقييم دور عدة ميزات مختلفة، بما في ذلك تتبع العين ومظهر الوجه والكلام وأنماط السلوك، والتي يمكن استخدامها لتشخيص طيف التوحد [5]. ومع ذلك، فإن هذه الميزات غالباً ما تكون ضعيفة جداً وصعبة التعرف عليها من قبل المهنيين، خاصةً عندما يتعلق الأمر بالأطفال الصغار جداً. قد يفتقر المهنيون في مجال الرعاية الصحية إلى الأدوات أو المهارات الكافية لتشخيص وعلاج الأطفال ذوي التوحد بطريقة فعالة. فغالباً ما لا يتلقون تدريباً رسمياً لتشخيص المرض، وأحياناً يواجهون مشكلات في التواصل مع الأطفال ذوي التوحد. باستخدام خوارزميات الذكاء

اضطراب طيف التوحد هو اضطراب تنموي عصبي معقد يؤثر مباشرة على قدرة الدماغ على معالجة المعلومات، عادةً ما يتم تشخيص هذا المرض في الأطفال بعد سن الثالثة ويتميز بنقص في التواصل البصري وعدم النظر في العينين وسوء التفاعل الاجتماعي والسلوكيات المتكررة [1]. يتأثر واحد من كل 70 طفلاً ولد حول العالم بالتوحد [2]. في الولايات المتحدة، يتم تشخيص حوالي 3.63% من الأولاد و1.25% من البنات الذين تتراوح أعمارهم بين 3 و17 سنة بالتوحد [3]. لا يوجد سبب واحد معروف لتطور التوحد. ومع ذلك، قد تكون العوامل البيئية والظفرات الجينية لها دور مهم في تطور هذا المرض [4]. يؤثر التوحد على أجزاء مختلفة من الدماغ وتم ربطه بعدة ظفرات. على الرغم من أن طيف التوحد لا يزال لا

- الحدود الزمنية: من سنة 2023 الى 2024

2.1 الدراسات السابقة

في هذا الجزء تناولنا الدراسات السابقة التي استخدمت تقنيات الذكاء الاصطناعي، وخاصة الشبكات العصبية التلافيفية (CNN)، في تشخيص اضطراب طيف التوحد (ASD) من خلال تحليل صور الأطفال .

في دراسة كل من: (Fazle Rabbi, Mahedy) بعنوان " A Convolutional Neural Network Model for Early-Stage Detection of Autism [8] (Rabbi, Hasan, "Spectrum Disorder

أجرى الباحثون في هذه الدراسة تجربة باستخدام خمس خوارزميات مختلفة للذكاء الاصطناعي لتحليل صور لأطفال مُصابين بالتوحد وأطفال آخرين غير مُصابين. وقد حققت خوارزمية الشبكات العصبية التلافيفية أعلى دقة في التصنيف، حيث وصلت إلى نسبة 92.31%.

تُسَير نتائج هذه الدراسة إلى إمكانية استخدام تقنيات الذكاء الاصطناعي لتطوير أنظمة مُساعدة للأطباء في تشخيص التوحد بشكل أسرع وأكثر دقة.

في دراسة أخرى أجراها (Narinder Kaur, Vijay) بعنوان " Early detection of ASD Traits in Children "

using CNN" [9]. قام الباحثون في هذه الدراسة تجربة باستخدام خوارزمية الشبكات العصبية التلافيفية لتحليل صور لأطفال مُصابين بالتوحد وأطفال آخرين غير مُصابين. حيث تم تدريب خوارزمية الشبكة العصبية التلافيفية على مجموعة بيانات تضم حوالي 400 صورة.

تقدم دراسة (Mujeep Rahman, Monica) بعنوان " Identification of Autism in Children Using Static Facial Features (Subashini in Children Using Static Facial Features and Deep Neural Networks) [10] ". نتائج

مُشجعة حول إمكانية استخدام تحليل ملامح الوجه والتعلم العميق في تشخيص التوحد المبكر. فمن خلال تحليل الصور الفوتوغرافية لوجه الطفل، يمكن للذكاء

الاصطناعي أو التعلم العميق المبنية على التعلم العميق للمرض، تظهر نتائج واعدة حيث تتفوق على أداء الإنسان في تقييم مجموعات كبيرة من البيانات. توفر هذه الخوارزميات توقعات دقيقة أيضًا [6].

الكشف المبكر عن اضطراب طيف التوحد (ASD) له أهمية بالغة في التأثير على المسار التطوري للأطفال المصابين به. فقد أظهرت الدراسات أن حوالي 70/1 طفل حول العالم يتم تشخيصهم باضطراب طيف التوحد، مع ملاحظة ارتفاع معدلات الانتشار على مر الوقت وتفاوتها بشكل كبير بين المجموعات الاجتماعية والديموغرافية [7]، تكمن المشكلة الرئيسية في أن عملية التشخيص التقليدية لاضطراب طيف التوحد تكون شاقة وطويلة للغاية. وبحلول الوقت الذي يتم فيه التشخيص الصحيح ووصف العلاج المناسب، قد يكون قد فات الأوان للتدخل المبكر لتقليل حدة الأعراض. هدفت هذه الورقة الي تطوير نموذج شبكة عصبية ثنائية التوجه مع واجهة تطبيق ويب للتشخيص المبكر لاضطراب طيف التوحد لدى الأطفال

1.1. مصادر وحدود البحث

عملية تدريب النموذج تمت على 6000 عينة لصور أطفال مصابين تتراوح أعمارهم ما بين 4 سنوات إلى 10 سنوات. تم أخذ العينات من منصة Kaggle وهي عبارة عن منصة مفتوحة توفر مجموعة كبيرة من البيانات لتدريب نماذج الآلة. وتم اختبار النظام على 18 حالة من مركز ابرار لذوي الاحتياجات الخاصة المطرد.

- الحدود المكانية: منصة Kaggle ، مركز ابرار لذوي الاحتياجات الخاصة المطرد.

- إنشاء واجهة تطبيق ويب سهلة الاستخدام تتيح للمتخصصين في الطب الوصول بسهولة إلى نموذج التشخيص واستخدامه في التقييمات العملية.

- التخطيط لتوسيع مجموعة البيانات وتنقيح النموذج

1.2 تصميم وتنفيذ النظام

تم استخدام لغة البايثون والتي تحتوي على مجموعة واسعة من الأدوات والمكتبات الهامة في مختلف مراحل تنفيذ النظام. من بين هذه الأدوات، تم استخدام واجهة برمجة التطبيقات عالية المستوى (High-Level API) مثل Keras من TensorFlow، والتي لعبت دورًا حاسمًا في نواة النظام. بالإضافة إلى ذلك، تم استخدام مكتبات أخرى مثل Matplotlib لعرض الصور وتصور البيانات

• مجموعة البيانات (Dataset)

لتعيين اضطراب طيف التوحد (ASD)، كان الحصول على مجموعات بيانات كبيرة ومتنوعة صعبًا بسبب الطبيعة المحددة وقلّة توفر صور مرتبطة باضطراب طيف التوحد. ومع ذلك، تمكنا من جمع مجموعة بيانات من موقع Kaggle تتكون من حوالي 6000 صورة تم تجميعها خصيصًا لاكتشاف اضطراب طيف التوحد. لقد تم تغيير حجم الصور في مجموعة البيانات بشكل موحد. أيضًا تم اختيار عدد 18 عينة عشوائية مصابة من مركز ابرار لذوي الاحتياجات الخاصة المطرد وذلك لتقييم اداء النموذج طبيا.

تتضمن مجموعة البيانات فئتين: "توحد" و"غير توحد" أو "إيجابي" و"سلبي"، تمثلان وجود أو عدم وجود اضطراب طيف التوحد. توزيع الفئات داخل مجموعة البيانات متوازن، حيث يوجد 3000 صورة لكل فئة. يضمن هذا التوازن عدم تحيز النموذج لأي فئة معينة ويمكنه التعلم من مجموعة متنوعة من الأمثلة. يُظهر الجدول (1) توزيع البيانات للتصنيفات الأربعة المختلفة.

الاصطناعي التعرف على أنماط ملامح الوجه التي قد تُشير إلى وجود اضطراب طيف التوحد.

2. الجانب العملي والمنهجية:

تركز المنهجية المقترحة على تطوير نموذج ذكاء اصطناعي للتشخيص المبكر لاضطراب طيف التوحد (ASD) للأطفال التي تتراوح اعمارهم ما بين أربع سنوات الى عشرة سنوات باستخدام شبكة عصبية تلافيفية (CNN). تتكون العملية من الخطوات التالية:

- جمع مجموعة شاملة من البيانات تتكون من 6000 صورة تلتقط أعراض وعلامات متنوعة لاضطراب طيف التوحد، مع ضمان تنوعها من حيث العمر والعرق والخلفيات الاجتماعية.
- تعديل ابعاد الصور من خلال التقليل في حجم الصور والتركيز على منطقة الوجه.
- استخراج الميزات المورفولوجيا التي تركز على الصفات الشكلية المرتبطة بأعراض اضطراب طيف التوحد، مما يمكن النموذج من التركيز على الخصائص الحرجة.
- تطبيق تقنيات كشف الحواف لتحديد حدود الميزات الرئيسية داخل الصور.
- تقسيم الصور إلى أجزاء أو كائنات يمكن التعرف عليها بشكل فردي.
- الحصول على مكونات منفصلة من الصور المعالجة، وتحويل البيانات المرئية إلى صيغة مناسبة لتدريب النموذج.
- استخدام الميزات المستخرجة لتدريب نموذج الشبكة العصبية التلافيفية باستخدام تقنيات التعلم المراقب، مع تحسينه لتحقيق تصنيف دقيق لحالات اضطراب طيف التوحد.
- تنفيذ النموذج المدرب لتصنيف الصور، وتحديد حالات اضطراب طيف التوحد المحتملة وتجميعها في فئات ذات صلة لتسهيل التعرف الفعال.
- تقييم أداء النموذج

• تصميم معمارية الشبكة العصبية التلافيفية للنموذج

يتألف النموذج من عدة طبقات تلافيفية وطبقات تجميع، تليها طبقات متصلة بالكامل لعملية التصنيف. تبدأ الهيكلية بطبقة تلافيفية تطبق 32 نواة بحجم (3, 3). ثم يليها طبقة تجميع بحجم نواة (2, 2). بعدها، تأتي طبقة تلافيفية أخرى تطبق 64 نواة بحجم (3, 3). وترافقها طبقة تجميع أخرى بحجم نواة (2, 2). أخيراً، تُطبق طبقة تلافيفية ثالثة تطبق 128 نواة بحجم (3, 3). وتليها طبقة تجميع بحجم نواة (2, 2).

لربط جزء استخراج السمات بجزء التصنيف من خلال طبقات متصلة بالكامل، يتم استخدام طبقة تسطيح لإعادة تشكيل الإخراج متعدد الأبعاد إلى مصفوفة أحادية البعد (D1). وتم استخدام طبقتين لعملية الاتصال الكامل، حيث تم إضافة طبقة اتصال كامل تحتوي على 128 نواة وايضا تستخدم وظيفة التنشيط ReLU. تم اختيار هذا الاختيار بناءً على كفاءته الحسابية وقدرته على تسريع التدريب دون التأثير بشكل كبير على الدقة. وتم اضافة طبقة اتصال كامل تحتوي على عقدة واحدة فقط وتستخدم وظيفة التنشيط من النوع (Sigmoid)، وهي مناسبة لمهام التصنيف. الشكل (2) يوضح هندسة النموذج. يتم تحديد إجمالي عدد المعاملات للنموذج بواسطة الأوزان والانحيازات في الطبقات التلافيفية والتجميع والاتصال بالكامل. يتم تدريب النموذج على مدى عشرين دورة باستخدام الانحدار التدريجي العشوائي كخوارزمية تعلم.



شكل 4: الواجهة الرئيس

جدول 1: توزيع البيانات للتصنيفات

الفئة	غير مصاب	مصاب	المجموع
المجمعة	1507	1507	3014
الاختبار	140	140	280
التدريب	1327	1327	2654
التحقق	40	40	80

1- الفئة المجمعة (Consolidated Category): يشير

إلى وجود نسخة موحدة من مجموعة البيانات في الدليل الموحد. يتم دمج الصور من مصادر أو أدلة مختلفة معاً لتحقيق التنظيم..

2- فئة التدريب (Train Category): يتم استخدام

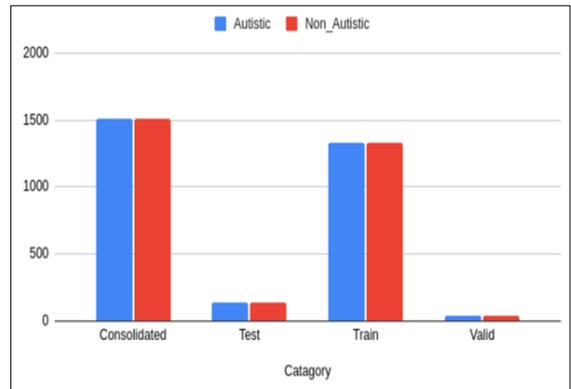
هذا القسم بشكل خاص لتدريب نموذج CNN. إنه الجزء الأكبر من مجموعة البيانات وعادة ما يحتوي على غالبية الصور.

3- فئة الاختبار (Test Category): يخصص هذا

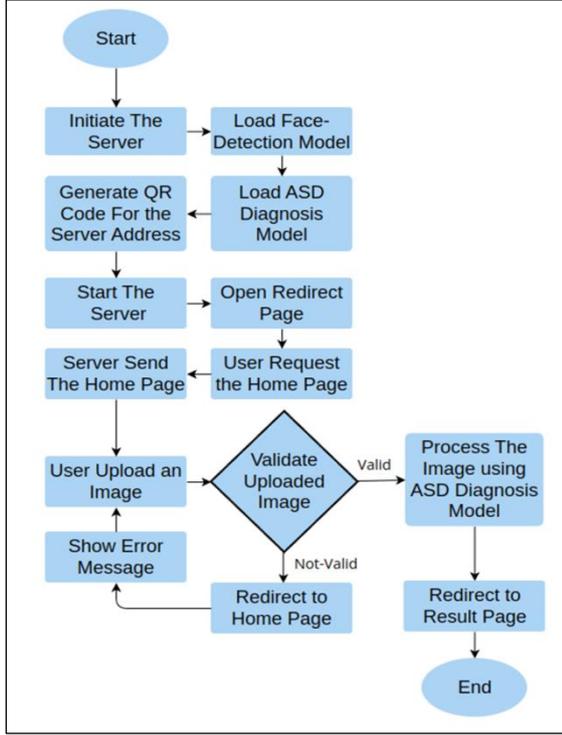
الدليل لتقييم أداء نموذج CNN المدرب على بيانات لم يرها من قبل.

4- فئة التحقق (Validation Category): يتم

استخدام هذا القسم لضبط نموذج CNN الأمثل وتحسين أدائه الفائق. الشكل (1) يوضح توزيع مجموعة البيانات (العينات).



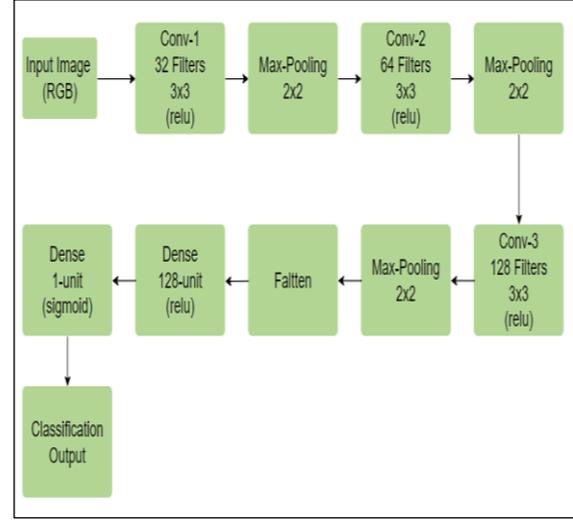
شكل 1: توزيع مجموعة البيانات.



شكل 3: خريطة تدفق لخوارزمية عمل النظام الرئيسية.

• تصميم واجهة النظام

تم توظيف تقنيات HTML و CSS و JavaScript لتطوير واجهة مستخدم فعالة وسهلة الاستخدام. تُستخدم HTML لبناء الهيكل الأساسي للصفحة، حيث تتضمن مكونات رئيسية مثل منطقة تحميل الصور و زر بدء عملية التشخيص. بدورها، تسهم CSS في تنسيق هذه العناصر بأسلوب جذاب ومنظم وسهل الاستخدام، أما JavaScript، فيضيف مستوى من التفاعلية للواجهة، مما يتيح للمستخدمين تحميل الصور عن طريق السحب والإفلات، بالإضافة إلى تفعيل زر التشخيص بشكل ديناميكي. تساهم هذه التقنيات مجتمعة في توفير تجربة مستخدم سلسة، مما يسهل على الأهل ومقدمي الرعاية بدء عملية التشخيص بشكل فعال وسريع كما موضح بالشكل (4). واجهة نتائج التشخيص في الشكل (5) و (6) تقدم للمستخدم نتائج التشخيص. تتضمن الواجهة نسبة الاحتمالية المئوية للإصابة بالمرض، حيث يوضح هذا الرقم النسبة المئوية لاحتمالية الإصابة بالمرض وفقاً لتحليل الصورة.



شكل 2: معمارية CNN للنموذج.

الجدول (2) يوضح عدد المرشحات، وأحجام التجميع، ووظائف التنشيط، وعدد العقد في كل طبقة.

جدول 2: معلومات الطبقات التلافيفية.

عدد المعاملات	النوع	الطبقة
896	Convolution	Conv2D-1
0	Max Pooling	MaxPooling2D-1
18496	Convolution	Conv2D-2
0	Max Pooling	MaxPooling2D-2
73856	Convolution	Conv2D-3
0	Max Pooling	MaxPooling2D-3
0	Flatten	Flatten-1
803840	Dense	Dense-1
129	Dense	Dense-2
897217		المجموع

بعد إنشاء نموذج CNN، الخطوة التالية هي تجميع وتدريب النموذج على مجموعة البيانات كما موضح في شكل (3) كتلة النظام الرئيسية .

الإحصائي. تمثل الصفوف الحالات المتوقعة، وتمثل الأعمدة الحالات الفعلية أو الحقائق الأساسية. وتعرض ملخص التوقعات في شكل مصفوفة. تُظهر كم من التوقعات صحيحة وغير صحيحة لكل فئة. تساعد في فهم الفئات التي يتم الخلط بينها من قبل النموذج باعتبارها فئة أخرى. يعرض الشكل (7) مصفوفة الارتباك الثنائية

		Actual Values	
		Positive (1)	Negative (0)
Predicted Values	Positive (1)	TP	FP
	Negative (0)	FN	TN

شكل 7: مصفوفة الارتباك الثنائية.

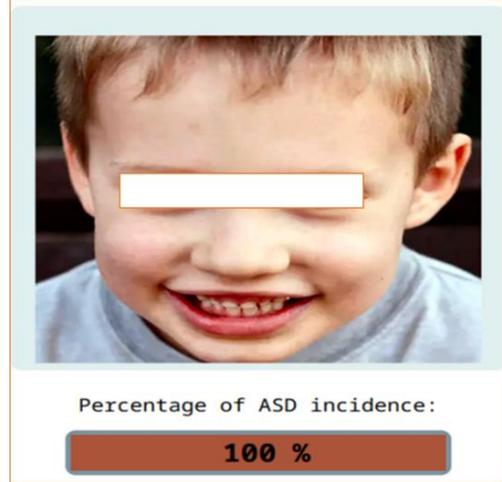
تتكون مصفوفة الارتباك من أربعة خصائص أساسية (أرقام) تُستخدم لتحديد مقاييس القياس للتصنيف. وهذه الأرقام الأربعة هي:

1- TP (إيجابي حقيقي): يُمثل TP عدد المرضى الذين تم تصنيفهم بشكل صحيح على أنهم مصابون بالتوحد، مما يعني أنهم مصابون بالمرض.

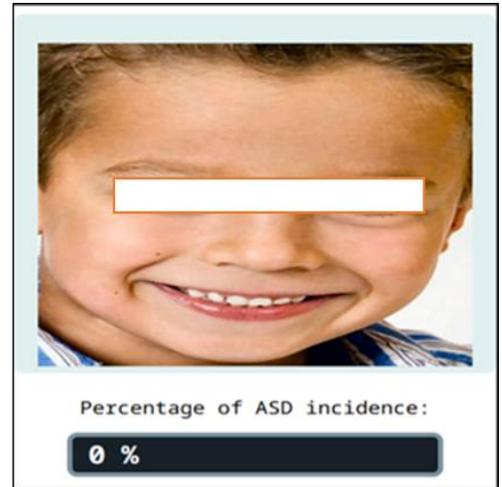
2- TN (سلبي حقيقي): يُمثل TN عدد المرضى الذين تم تصنيفهم بشكل صحيح على أنهم أصحاء.

3- FP (إيجابي خاطئ): يُمثل FP عدد المرضى الذين تم تصنيفهم بشكل خاطئ على أنهم مصابون بالمرض بينما هم في الواقع أصحاء. يُعرف FP أيضًا باسم خطأ من النوع الأول.

4- FN (سلبي خاطئ): يُمثل FN عدد المرضى الذين تم تصنيفهم بشكل خاطئ على أنهم أصحاء بينما هم في الواقع مصابون بالمرض. يُعرف FN أيضًا باسم خطأ من النوع الثاني.



شكل 5: واجهة نتائج التشخيص "طفل مريض"



شكل 6: واجهة نتائج التشخيص طفل سليم

3. النتائج والمناقشة

بعد انتهاء مرحلة تصميم النظام، تم استخدام 6000 صورة لتدريب الشبكة عبر 20 دورة تدريبية استغرق كل منها 42 ثانية تقريبًا، تم اختبار دقة التدريب كما موضح بالجدول (3).

جدول 3: دقة التدريب والاختبار

Training Accuracy	91.95%
Testing Accuracy	78.57%

3.1 تقييم أداء النموذج رياضيًا

لتقييم النموذج تم استخدام مصفوفة الارتباك، وهي تمثيل بصري لفعالية خوارزمية التعلم الآلي أو التصنيف

يُظهر الجدول (4) جميع مقاييس الأداء لنموذج الشبكة العصبية التلافيفية المدرب في هذه الدراسة

جدول 4: مقاييس الأداء للنموذج المستخدم

75.75%	دقة التصنيف
85.70%	دقة التنبؤ
73.17%	الحساسية
78.94%	مقياس F1

2.3 اختبار النموذج

لتحسين عملية اختبار النموذج، يجب وضعه في مواقف واقعية باستخدام عينات حقيقية ذات قيم معروفة لم تُعرض على النموذج مسبقًا. بعد ذلك، نقوم بتقييم النتائج التي حصلنا عليها من النموذج مقارنةً بالنتائج الفعلية، ومن ثم حساب دقة النظام. في هذا السياق، تم جمع 18 عينة من مركز ابرار لذوي الاحتياجات الخاصة بالمطرد وتم تمريرها للنموذج، حيث تم تقييم هذه العينات من قبل أخصائيين في المجال الطبي، مما يضيف دقة وموثوقية على القيم المرجعية المستخدمة في عملية اختبار النموذج الجدول (5) يعرض النتائج المتحصل عليها للنموذج باستخدام عينات تم تقييمها بواسطة أخصائيين. يوضح الشكل (9) عينة من الأطفال المصابون من مركز ابرار لذوي الاحتياجات الخاصة مع النتيجة التي أظهرها النظام

جدول 5: نتائج النموذج باستخدام عينات من مركز ابرار لذوي الاحتياجات الخاصة - المطرد

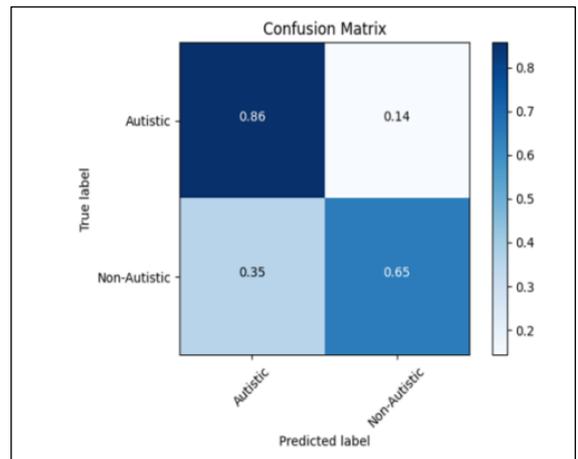
16	العينات التي أكد النموذج إصابتها وتبينت صحتها
2	العينات التي صنفها النموذج سليمة وهي مصابة
0	العينات التي صنفها النموذج مصابة وهي سليمة
0	العينات التي أكد النموذج عدم إصابتها وتبينت صحتها

الجدول (6) يعرض مقاييس الأداء للنموذج باستخدام عينات حقيقية.

فيما يلي معايير تقييم نموذج تشخيص اضطراب طيف التوحد:

- دقة التصنيف (Accuracy): تمثل نسبة المرضى المصنفين بشكل صحيح (TP+TN) إلى العدد الإجمالي للمرضى (TP+TN+FP+FN).
- دقة التنبؤ (Precision): تمثل نسبة المرضى المصنفين بشكل صحيح على أنهم مصابون بالمرض (TP) إلى إجمالي المرضى الذين توقع النموذج إصابتهم بالمرض (TP+FP).
- الاستدعاء (Recall): يُعرف الاستدعاء بأنه نسبة المرضى المصابين بالتوحد الذين تم تصنيفهم بشكل صحيح (TP) مقسومة على العدد الإجمالي للمرضى المصابين بالتوحد فعليًا. يقيس الاستدعاء عدد المرضى الذين تم تحديدهم على أنهم مصابون بالمرض. يُعرف الاستدعاء أيضًا بالحساسية.
- معدل (F1 Score) (F1): يُعرف أيضًا باسم مقياس F. يمثل معدل F1 التوازن بين دقة التنبؤ والاستدعاء.

يعرض الشكل (8) مصفوفة الارتباك لنموذج الشبكة العصبية التلافيفية الخاصة بهذه الدراسة للصفين "مصاب بالتوحد (Autistic)" وغير مصاب بالتوحد (Non-Autistic)".



شكل 8: مصفوفة الارتباك للنموذج المستخدم

يشير إلى قدرته على تصنيف حالات اضطراب طيف التوحد بدقة. تم تدريب النموذج على مجموعة بيانات تحتوي على 6000 صورة، مما استدعى جهودًا كبيرة لتغطية مجموعة متنوعة من أعراض وعلامات اضطراب طيف التوحد. كما تم اختبار النموذج باستخدام عينات حقيقية، وقد أظهر نتائج جيدة تدعم النتائج الرياضية التي تم الحصول عليها.

توفر واجهة تطبيق الويب منصة سهلة الاستخدام وسهولة الوصول للاستفادة من نموذج تشخيص اضطراب طيف التوحد. حيث تسهل هذه الواجهة عملية الفحص والتقييم، مما يجعلها أكثر ملاءمة وكفاءة للمختصين ومقدمي الرعاية والآباء.

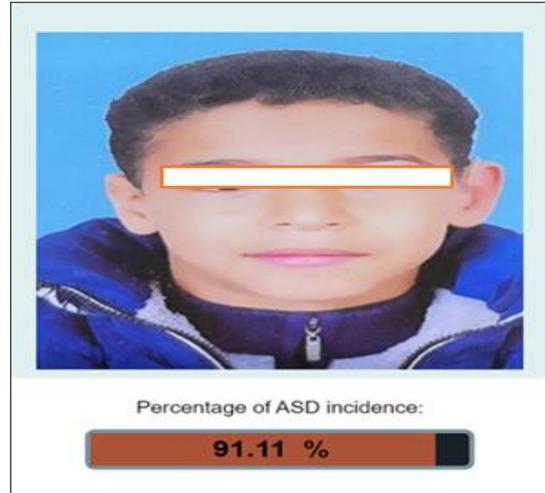
ومع ذلك، يجب أن ندرك أن تشخيص اضطراب طيف التوحد يتطلب تقييمًا شاملاً يتجاوز التحليل الصوري. على الرغم من أن نموذج CNN يظهر وعدًا في مساعدة تحديد حالات اضطراب طيف التوحد المحتملة، يجب استخدامه كأداة داعمة وليس كأداة تشخيصية قاطعة. لا يزال الخبراء والمتخصصون يلعبون دورًا أساسيًا في إجراء تشخيصات دقيقة لاضطراب طيف التوحد. ينبغي أن تتركز جهود البحث والتطوير المستقبلية على توسيع حجم مجموعة البيانات لتشمل مجموعة أوسع من حالات اضطراب طيف التوحد، بما في ذلك فئات عمرية مختلفة وخلفيات عرقية واجتماعية. بالإضافة إلى ذلك، يمكن أن يساعد تحسين النموذج المستمر والتعلم المستمر من البيانات الواقعية في تحسين دقة وموثوقية النظام مع مرور الوقت.

5. التوصيات

- 1- توسيع مجموعة البيانات من خلال التعاون مع مؤسسات البحث أو المستشفيات أو مراكز التوحد.
- 2- تطبيق تقنيات تكبير البيانات (Data Augmentation):

Error! No text of specified style in document. جدول 6 : مقاييس تقييم أداء النموذج.

88.00%	دقة التصنيف
88.00%	دقة التنبؤ
100.00%	الحساسية
91.00%	مقياس F1



شكل 9 : عينة من مركز ابرار بالمطرد

4. الاستنتاجات

تم في هذه الورقة تطوير نموذج شبكة عصبية ثنائية التوجه (CNN) مع واجهة تطبيق ويب لتشخيص اضطراب طيف التوحد (ASD) لدى الأطفال، وذلك باستخدام تقنيات التعلم الآلي للكشف المبكر عن اضطراب طيف التوحد. حقق النموذج دقة تتراوح بين 70% و76% ومعدل F1 يتراوح بين 75% و79%، مما

- [5] Papagiannopoulou EA, Chitty KM, Hermens DF, Hickie IB, Lagopoulos J. A systematic review and meta-analysis of eye-tracking studies in children with autism spectrum disorders. *Soc Neurosci*. 2014.
- [6] Ghazal TM, Abbas S, Munir S, Khan MA, Ahmad M. Alzheimer disease detection empowered with transfer learning. *Comput Mater Continua*. 2022.
- [7] Zeidan J, Fombonne E, Scorah J, Ibrahim A, Durkin MS, Saxena S, Yusuf A, Shih A, Elsabbagh M. Global prevalence of autism: A systematic review update. *Wiley Online Library*. 2021 Oct 7.
- [8] Géron A. *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow*. 2nd ed. O'Reilly Media; 2019.
- [9] Kaur N, KumarSinha V, Kang S. Early detection of ASD traits in children using CNN. 2nd Global Conference for Advancement in Technology (GCAT); 2021 Oct 1-3.
- [10] Rahman M, Subashini M. Identification of autism in children using static facial features and deep neural networks. 2022 Jan 8.

3- تدريب المتخصصين لتنظيم دورات تدريبية للمتخصصين في كيفية استخدام النموذج وتفسير نتائجه بشكل صحيح، لضمان اتخاذ قرارات مدروسة بناءً على نتائج النموذج.

6. المراجع

REFERENCES

- [1] Goh KL, Morris S, Rosalie S, Foster C, Falmer T. Typically developed adults and adults with autism spectrum disorder classification using centre of pressure measurements. *IEEE International Conference*; 2016.
- [2] Zaroff MC, Uhm SY. Prevalence of autism spectrum disorders and influence of country of measurement and ethnicity. *Soc Psychiatry Psychiatr Epidemiol*. 2012.
- [3] Kayalibay B, Jensen G, van der Smagt P. CNN-based segmentation of medical imaging data. *arXiv preprint*. 2017; Available from: <http://arxiv.org/abs/1701.03056>
- [4] Stevens E, Dixon DR, Novack MN, Granpeesheh D, Smith T. Identification and analysis of behavioral phenotypes in autism spectrum disorder via unsupervised machine learning. *Int J Med Inform*. 2019.