



الجمهورية الجزائرية الديمقراطية الشعبية
وزارة التعليم العالي والبحث العلمي
جامعة الشهيد حمه لخضر- الوادي



كلية العلوم الدقيقة

تقرير نهاية السنة لاستكمال متطلبات نيل شهادة: ليسانس أكاديمي

قسم الإعلام الآلي

تخصص: نظم معلوماتية

الموضوع

التعرف على إشارات المرور باستخدام التعلم العميق

تحت إشراف الدكتورة :

❖ ستو طرابلس

من إعداد الطالبات :

❖ سلمى منى

❖ خزاني مريم

❖ غريبي أشواق

تمت مناقشة المذكرة بتاريخ: 2025/05/25 أمام اللجنة المكونة من الأساتذة:

جامعة الوادي.

رئيسا

كرثيو إسماعيل

جامعة الوادي.

مناقشا

خلادي نجوى هدى

السنة الجامعية: 2025/ 2024

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ
مَنْ كَفَرَ بَعْدَ إِيمَانِهِ
سَاءَ مَا يَحْكُمُهُ يَوْمَ الْقِيَامَةِ

الإهداء

(وَآخِرُ دَعْوَاهُمْ أَنِ الْحَمْدُ لِلَّهِ رَبِّ الْعَالَمِينَ) سورة يونس، الآية 10

الحمد لله الذي بفضلہ تتحقق الإنجازات، وبتوفيقه تُختتم الجهود وترتقي الطموحات

إلى من كان دعاؤهما سرّ التوفيق، وصبرهما زاد الطريق...

إلى والدي العزيزين، أنتما النور الذي أضاء دربي، والدعامة التي لم تهتز يوماً، لكما مني كل

الامتنان والحب، ما حييت...

إلى أمي، نبع الحنان، وصاحبة القلب الذي احتواني في لحظات ضعفي قبل قوتي،

وإلى أبي، السند والمُلهم، من علمتني عزيمته أن لا شيء مستحيل...

إلى إخوتي وأخواتي،

رفقاء الدرب، وأعمدة الأمان في حياتي...

وإلى خالي العزيز، الذي كانت كلماته دائماً مصدر تشجيع ودعم يدفعني للمضي قدماً، وكان

حسن تقديره واهتمامه يمدني بالقوة...

أهديكم هذه الثمرة التي نضجت بمحبتكم، ودعمكم الصادق.

إلى نفسي، التي اجتهدت وتخطت، وقاومت لتصل، رغم كل شيء.

إلى كل من ساندني بدعوة، أو حتى بكلمة أهداني فيها الطمأنينة...

أهدي لكم جميعاً هذا الجهد المتواضع.

شكر و عرفان

قد يقف المرء عاجزاً عن ردّ الجميل لذوي الفضل، وقد لا تطاوعه أساليب التعبير ليعبر عن معاني الشكر والتقدير، والشكر لله أولاً وأخيراً، على توفيقه لنا في إنجاز هذا العمل المتواضع.

ومن باب قول رسول الله صلى الله عليه وسلم: " مَنْ لَا يَشْكُرُ النَّاسَ لَا يَشْكُرُ اللَّهَ "

فبحمد الله عزّ وجلّ، الذي وفقنا لإتمام هذا العمل، نتقدم بجزيل الشكر والامتنان لأستاذتنا المشرفة ستو طرابلس، على توجيهاتها القيّمة، وصبرها وتفانيها، وما خصّتنا به من وقت وجهد كان له بالغ الأثر في مسارنا وتوجيهنا.

فقد كانت لنا نعم المرشدة والموجهة، ووقفت إلى جانبنا دعماً وإرشاداً في كل خطوة من خطوات هذا المشروع.

ولا يفوتنا أن نرفع أسمى آيات الشكر والتقدير لأساتذة الكلية الكرام، ولكل من قدّم لنا يد العون، ولو بكلمة طيبة أو دعم بسيط ساعدنا على المضي قدماً.

المخلص

تعد حوادث المرور من أبرز المخاطر التي تهدد حياة الإنسان، حيث تتسبب سنويا في عدد كبير من الوفيات على مستوى العالم. ومع الازدياد المستمر في أعداد المركبات وتعقيد حركة المرور، تتزايد احتمالية وقوع هذه الحوادث بشكل ملحوظ. وفي هذا السياق، تبرز الحاجة إلى تطوير حلول تقنية فعالة تساهم في الحد من هذه المخاطر، ويعد إنشاء أنظمة ذكية ومتقدمة قادرة على التعرف على إشارات المرور والتفاعل معها بدقة عالية أحد أبرز هذه الحلول.

مؤخرا، أظهرت الدراسات الحديثة دور تقنيات الذكاء الاصطناعي، خصوصا التعلم الآلي والتعلم العميق في العديد من المجالات، من بينها مجال السلامة المرورية. إذ تتيح هذه التقنيات بناء أنظمة قادرة على التعرف التلقائي على إشارات المرور والاستجابة لها بشكل فوري ودقيق.

في هذا الإطار، تم في هذه الدراسة تطوير نظام للتعرف على إشارات المرور باستخدام أحد نماذج التعلم العميق، وهو نموذج الشبكات العصبية الالتفافية - (Convolutional Neural Networks - CNN)، حيث تم تدريب النموذج المقترح وتقييم أدائه باستخدام قاعدة بيانات واسعة تحتوي على مجموعة متنوعة من صور إشارات المرور. وقد أظهرت النتائج تفوق النموذج المقترح مقارنة بأساليب التعلم الآلي التقليدية التي جربناها من حيث الدقة والكفاءة.

الكلمات المفتاحية: إشارات المرور، معالجة الصور، التعلم العميق، الشبكات العصبية الاصطناعية، التعلم الآلي، الذكاء الاصطناعي، التعرف على إشارات المرور.

Abstract

Traffic accidents are among the leading causes of fatalities worldwide, posing a significant threat to human life on a global scale. As vehicle density continues to rise and traffic systems grow increasingly complex, the risk of such accidents has escalated significantly. As a result, it has become essential to find effective solutions to reduce the risk of accidents. One of the most important solutions is the development of advanced and intelligent systems to accurately recognize and interact with traffic signs.

Recent studies have demonstrated the significant role of artificial intelligence technologies, particularly machine learning and deep learning, in enhancing various fields, with a notable impact on traffic safety. This is achieved through the development of systems based on these technologies to recognize and interact with traffic signs, thereby significantly enhancing road safety.

To this end, this study aims to develop a traffic sign recognition system based on a deep learning model, Convolutional Neural Networks (CNNs). The model was trained and evaluated using a large dataset of traffic sign images. The results demonstrated that the proposed model outperformed traditional machine learning methods.

Keywords: Traffic signs, image processing, deep learning, artificial neural networks, machine learning, artificial intelligence, traffic sign recognition.

Résumé

Les accidents de la route figurent parmi les principales causes de mortalité dans le monde, représentant une menace importante pour la vie humaine à l'échelle mondiale. Avec l'augmentation continue de la densité des véhicules et la complexité croissante des systèmes de circulation, le risque d'accidents s'est considérablement accru. Par conséquent, il est devenu essentiel de trouver des solutions efficaces pour réduire ce risque. L'une des solutions les plus importantes consiste à développer des systèmes intelligents et avancés capables de reconnaître et d'interpréter avec précision les panneaux de signalisation routière avec une grande précision.

Des études récentes ont démontré le rôle des technologies d'intelligence artificielle (IA), notamment l'apprentissage automatique et l'apprentissage profond, dans divers domaines, notamment la sécurité routière, en développant des systèmes s'appuyant sur ces technologies pour reconnaître et interagir avec les panneaux de signalisation, contribuant ainsi à améliorer de manière significative la sécurité sur les routes.

À cette fin, la présente étude vise à développer un système de reconnaissance des panneaux de signalisation basé sur un modèle d'apprentissage profond, les réseaux de neurones convolutifs (Convolutional Neural Networks – CNN). Le modèle a été entraîné et évalué à l'aide d'un vaste ensemble de données contenant des images de différents panneaux routiers. Les résultats ont démontré la supériorité du modèle proposé par rapport aux méthodes d'apprentissage automatique traditionnelles.

Mots-clés : panneaux de signalisation, traitement d'images, apprentissage profond, réseaux de neurones artificiels, apprentissage automatique, intelligence artificielle, reconnaissance des panneaux de signalisation.

فهرس المحتويات

فهرس المحتويات

..... الملخص	
..... Abstract	
.....Résumé	
I فهرس المحتويات.	
III..... قائمة الصور والأشكال.	
IV فهرس الجداول.	
V قائمة الاختصارات.	
1 المقدمة العامة.	
	الفصل الأول: معالجة الصور والتعرف على إشارات المرور
2 المقدمة	
3 1. مفاهيم عامة حول معالجة الصور	
3 1.1 تعريف الصورة.	
3 2.1 تعريف الصورة الرقمية.	
3 3.1 خصائص الصورة الرقمية.	
5 4.1 أنواع الصور الرقمية.	
6 2. مراحل معالجة الصور الرقمية.	
6 1.2 معالجة الصور "المستوى المنخفض Low-Level Process".	
7 2.2 تحليل الصور "المستوى المتوسط Mid-Level Process".	
7 3.2 الرؤية الحاسوبية "المستوى العالي High-Level Process".	
8 3. التعرف على إشارات المرور.	
8 1.3 التعرف بإشارات المرور.	
8 2.3 أهم أنواع إشارات المرور.	
11..... الخاتمة.	

الفصل الثاني: التعلم الآلي والتعلم العميق

12.....	المقدمة
13.....	1. تعريف الذكاء الاصطناعي "Artificial Intelligence"
13.....	2. التعلم الآلي "Machine Learning"
13.....	1.2 تعريف التعلم الآلي
13.....	2.2 أنواع طرق التعلم الآلي
17.....	3.2 آلية عمل التعلم الآلي
19.....	3. التعلم العميق "Deep Learning"
19.....	1.3 تعريف التعلم العميق
19.....	2.3 العلاقة بين الذكاء الاصطناعي والتعلم الآلي والتعلم العميق
20.....	3.3 أهم أنواع الشبكات العصبية الاصطناعية
25.....	4.3 آلية بناء نموذج الشبكة العصبية الاصطناعية "Building ANN Model"
26.....	4. الفرق بين التعلم الآلي والتعلم العميق
28.....	5. الدراسات السابقة في التعرف على إشارات المرور بتقنيات الذكاء الاصطناعي
28.....	1.5 الدراسات السابقة في التعرف على إشارات المرور بالتعلم الآلي
28.....	2.5 الدراسات السابقة في التعرف على إشارات المرور بالتعلم العميق
30.....	الخاتمة

الفصل الثالث: التصميم والتنفيذ

31.....	المقدمة
32.....	1. التصميم "Design"
32.....	1.1 الهيكل العام للنظام المقترح "General Architecture of the Proposed System"
33.....	2.1 وصف مجموعة البيانات "Dataset Description"
33.....	3.1 معالجة وتقسيم البيانات "Data Preprocessing and Splitting"
33.....	4.1 الشبكة العصبية الاصطناعية المستخدمة
35.....	5.1 التدريب والتعلم "Training and Learning"
35.....	6.1 الاختبار والتقييم "Testing and Evaluation"
35.....	2. التنفيذ "Implementation"
35.....	1.2 بيئة العمل "Development Environment"
37.....	2.2 خطوات التنفيذ "Implementation Steps"

43.....	3.2 التجارب ومناقشة النتائج "Experiments and Results Discussion"
45.....	3. واجهات النظام "System Interfaces"
46.....	1.3 واجهة التعريف بالمشروع
46.....	2.3 واجهة التعرف على إشارات المرور
47.....	2.3 واجهة دليل إشارات المرور
48.....	الخاتمة
49.....	الخاتمة العامة
50.....	قائمة المراجع

قائمة الصور والأشكال

الفصل الأول: معالجة الصور والتعرف على إشارات المرور

3	الشكل 1.1: صورة بخاصية البكسل
4	الشكل 2.1: تأثير الضوضاء على الصورة
4	الشكل 3.1: تأثير السطوع على الصورة
5	الشكل 4.1: تأثير التباين على الصورة
7	الشكل 5.1: مراحل نظام معالجة الصور
8	الشكل 6.1: صور الإشارات التحذيرية
9	الشكل 7.1: صور الإشارات التنظيمية
10.....	الشكل 8.1: بعض صور الإشارات الإرشادية
10.....	الشكل 9.1: صور إشارات العمل المؤقتة

الفصل الثاني: التعلم الآلي والتعلم العميق

16.....	الشكل 1.2: الخلية العصبية عند الانسان مقابل الخلية العصبية الاصطناعية
20.....	الشكل 2.2: العلاقة بين الذكاء الاصطناعي والتعلم الآلي والتعلم العميق
21.....	الشكل 3.2: هيكل عام للشبكة العصبية الالتفافية
23.....	الشكل 4.2: هيكل الشبكة العصبية العميقة DNN
23.....	الشكل 5.2: شبكة عصبية متكررة بسيطة
24.....	الشكل 6.2: الهيكل العام لشبكة خصومية توليدية
27.....	الشكل 7.2: الفرق بين التعلم الآلي والتعلم العميق

الفصل الثالث: التصميم والتنفيذ

32.....	الشكل 1.3: الهيكل العام للنظام المقترح
37.....	الشكل 2.3: استدعاء المكتبات

38.....	الشكل 3.3: تحميل مجموعة البيانات
38.....	الشكل 4.3: دالة المعالجة الأولية للبيانات
39.....	الشكل 5.3: تطبيق المعالجة الأولية على بيانات التدريب
39.....	الشكل 6.3: تحويل القوائم إلى مصفوفات
39.....	الشكل 7.3: تقسيم بيانات التدريب وتحويل التسميات إلى ترميز ONE_HOT ENCODING
40.....	الشكل 8.3: بناء نموذج CNN
40.....	الشكل 9.3: تجميع النموذج
41.....	الشكل 10.3: تدريب النموذج
41.....	الشكل 11.3: الرسم البياني للدقة والخسارة
42.....	الشكل 12.3: اختبار وتقييم النموذج
42.....	الشكل 13.3: طباعة الدقة
46.....	الشكل 14.3: واجهة التعريف بالمشروع
46.....	الشكل 15.3: واجهة للتعرف على إشارات المرور
47.....	الشكل 16.3: كيفية استخدام واجهة التعرف على الإشارات
47.....	الشكل 17.3: واجهة دليل إشارات المرور

فهرس الجداول

الفصل الثاني: التعلم الآلي والتعلم العميق

27.....	جدول 1.2 : الفرق بين التعلم الآلي والتعلم العميق
28.....	جدول 2.2 : الدراسات السابقة في التعرف على إشارات المرور بالتعلم الآلي
28.....	جدول 3.2 : الدراسات السابقة في التعرف على إشارات المرور بالتعلم العميق

الفصل الثالث: التصميم والتنفيذ

35.....	جدول 1.3: خصائص الجهاز
43.....	جدول 2.3: مراحل تطوير النموذج النهائي
45.....	جدول 3.3: مقارنة نتائج التعلم الآلي والتعلم العميق

قائمة الاختصارات

AI: Artificial Intelligence.

ML: Machine Learning.

SL: Supervised Learning.

DT: Decision Tree.

RF: Random Forest.

SVM: Support Vector Machine.

ANN: Artificial Neural Network.

USL: Unsupervised Learning.

RL: Reinforcement Learning.

SSL: Semi-Supervised Learning.

DL: Deep Learning.

CNN: Convolutional Neural Network.

DNN: Deep Neural Network.

RNN: Recurrent Neural Network.

GAN: Generative Adversarial Network.

المقدمة العامة

تعد السلامة المرورية من التحديات البارزة التي تواجه المجتمعات البشرية، لا سيما في ظل الارتفاع المستمر في أعداد المركبات على الطرق. وقد مثلت إشارات المرور أحد الحلول الفعالة التي ساهمت في تنظيم حركة السير وتوجيه السائقين، مما أدى إلى تقليل معدلات الحوادث بشكل ملحوظ.

تعتمد الطريقة التقليدية للتعرف على إشارات المرور على قدرة السائق في ملاحظة الإشارات وتفسيرها بشكل دقيق وفي الوقت المناسب. إلا أن هذه العملية قد تكون مرهقة ومعقدة، خاصة في ظروف الطقس السيئة أو عند انخفاض مستوى التركيز الناتج عن التعب أو الإرهاق.

في الآونة الأخيرة، ظهرت تقنيات تعتمد على الذكاء الاصطناعي، أبرزها التعلم الآلي والتعلم العميق، والتي أثبتت قدرتها العالية في مختلف المجالات مثل الطب، التعليم، الأمن وغيرها. وقد حققت هذه التقنيات أيضا نتائج واعدة في مجال السلامة المرورية، من خلال قدرتها على معالجة الصور والتعرف التلقائي على إشارات المرور بدقة وكفاءة عالية.

في هذا العمل، قمنا بتطوير نظام للتعرف على إشارات المرور بالاعتماد على أحد نماذج التعلم العميق، حيث تم تدريب النموذج وتقييمه باستخدام مجموعة بيانات ضخمة. بالإضافة إلى ذلك، تم تطبيق بعض خوارزميات التعلم الآلي وتدريبها على نفس مجموعة البيانات، بهدف إجراء مقارنة موضوعية.

تنقسم مذكرتنا إلى ثلاثة فصول وهي:

الفصل الأول "معالجة الصور والتعرف على إشارات المرور": في هذا الفصل، سيتم تعريف

المفاهيم الأساسية المتعلقة بمعالجة الصور، بالإضافة إلى مراحل معالجتها المختلفة. أيضا سيتم تعريف بإشارات المرور وأنواعها الرئيسية.

الفصل الثاني "التعلم الآلي والتعلم العميق": في هذا الفصل، سيتم تعريف الذكاء الاصطناعي وأهم تقنياته المتمثلة في التعلم الآلي والتعلم العميق مع التفصيل فيهما.

الفصل الثالث "التصميم والتنفيذ": وهو الفصل الأخير الذي سيتم فيه شرح كل ما يخص النظام الذي أنشأناه باستخدام نموذج من نماذج التعلم العميق. كما سنتم فيه مناقشة التجارب والنتائج التي حصلنا عليها.

الفصل الأول: معالجة الصور والتعرف على إشارات المرور

المقدمة

تعتبر معالجة الصور فرعا مهما من فروع علوم الحاسوب والهندسة، حيث تهدف إلى تحسين وتحليل الصور الرقمية باستخدام تقنيات متقدمة لاستخراج المعلومات المفيدة منها. تتنوع تطبيقات معالجة الصور بشكل كبير، بدءا من تحسين جودة الصور في التصوير الفوتوغرافي، وصولا إلى استخدامها في مجالات متعددة، نذكر بصفة خاصة مجال الأمن، الذي تتفرع منه عدة جوانب، أهمها أمن الطرقات باستخدام إشارات المرور.

يعتقد بعض الناس أن وجود إشارات المرور في الطرق أمر مزعج ومستقز، فهي تجعلهم في بعض الأحيان يتأخرون عن أعمالهم. لكن في الحقيقة، تعتبر هذه الإشارات ضرورية لضمان سلامة الجميع، إذ تلعب دورا هاما في تنظيم حركة المرور وتوجيه السائقين والمشاة، مما يساهم بشكل كبير في تقليل مخاطر وحوادث المرور.

في هذا الفصل، سنتطرق إلى المفاهيم الأساسية والعامية لمعالجة الصور التي تتمثل في تعريف الصورة بشكل عام، والصورة الرقمية بصفة خاصة، كما سنذكر أنواعها وجميع خصائصها، بالإضافة إلى ذلك سنقوم بشرح مراحل نظام معالجة الصور، وأخيرا سنتعرف على إشارات المرور وأهم أنواعها.

1. مفاهيم عامة حول معالجة الصور

1.1 تعريف الصورة


الصورة هي تمثيل بصري لوصف كائن، شخص أو شيء [2]، تستخدم لنقل المعلومات أو التعبير عن الأفكار والمشاعر. تتكون الصورة من مجموعة من العناصر البصرية مثل الألوان، والأشكال، والأنماط التي تتفاعل مع بعضها البعض لتكوين مشهد أو موضوع معين.

2.1 تعريف الصورة الرقمية

الصورة الرقمية هي الصورة التي يتم تخزينها ومعالجتها وتحميلها على الحاسوب أو على الانترنت، ويمكن تعديلها باستخدام البرامج المخصصة للتعديل. يكون سطحها مقسما إلى عناصر ذات حجم ثابت تسمى خلايا أو بكسلات [1].

3.1 خصائص الصورة الرقمية

1.3.1 البكسل "Pixel": هو الوحدة الأساسية في الصورة الرقمية، حيث تتكون كل صورة من مجموعة من البكسلات. كل بكسل يمثل نقطة واحدة فيها وله لون معين [2] (انظر الشكل 1.1).




الشكل 1.1: صورة بخاصية البكسل [6]

2.3.1 الدقة "Resolution": تشير إلى عدد البكسلات في الصورة [2]، بحيث كلما زادت الدقة، زادت التفاصيل والوضوح.

3.3.1 البعد "Dimension": يشير إلى أبعاد الصورة، سواء كانت ثنائية (طول × عرض) أو ثلاثية الأبعاد (طول × عرض × ارتفاع). الأبعاد تؤثر على كيفية عرض الصورة وكيفية استخدامها في التطبيقات المختلفة، مثل الطباعة أو العرض على الشاشات [2].

4.3.1 الضوضاء "Noise": هي التشويش غير المرغوب فيه في الصورة، والذي يمكن أن يظهر كحبيبات أو نقاط عشوائية [2] (انظر الشكل 2.1).



الشكل 2.1: تأثير الضوضاء على الصورة

5.3.1 السطوع "Luminance": يشير إلى مستوى الإضاءة في الصورة بشكل عام، و يمكن تعديله لتحسين مظهر الصورة [2] (انظر الشكل 3.1).




الشكل 3.1: تأثير السطوع على الصورة

6.3.1 الملمس "Texture": هو منطقة في الصورة الرقمية تتميز بخصائص متسقة تعكس

تفاصيل معينة، مما يعزز من عمق الصورة، ويجعلها تبدو أكثر واقعية وجاذبية [2].

7.3.1 التباين "Contrast": هو الفرق بين أفتح وأعمق الألوان في الصورة. فالتباين الجيد

يساعد في إبراز التفاصيل، بحيث عندما تكون نسبته عالية قد يجعل الصورة أكثر حيوية وجاذبية، أما إذا كان منخفضاً، فقد تبدو الصورة مسطحة أو غير مثيرة [2] (انظر الشكل 4.1).



الشكل 4.1: تأثير التباين على الصورة [6]

4.1 أنواع الصور الرقمية

تتقسم أنواع ملفات الصور الرقمية إلى فئتين رئيسيتين وهما ملفات الصور النقطية وملفات الصور المتجهة.

1.4.1 الصور النقطية "Raster": تندرج جميع تنسيقات الصور الأكثر شيوعاً على الإنترنت

ضمن فئة الصور النقطية مثل (JPEG – GIF – PNG). تتميز هذه الصور بأنها ثابتة، مما

يجعل تغيير حجمها بكفاءة أمراً صعباً، حيث يتطلب الأمر توسيع التصميم الأصلي ووحدات

البكسل لملء المساحة الإضافية. ونتيجة لذلك، قد تظهر الصورة بشكل ضبابي أو مشوشة، مما

يؤدي إلى انخفاض جودتها [1].

2.4.1 الصور المتجهة "Vector": تكون هذه التتسيقات أكثر مرونة مثل (SVG-PDF)، حيث تعتمد على نظام من الخطوط والمنحنيات في مستوى ديكارتي يتم قياسه بالنسبة للمساحة الإجمالية. وهذا يعني أنه يمكن تكبير الصورة الأصلية إلى أي حجم، دون فقدان الجودة أو حدوث أي تشويه، لأن ملفات الصور المتجهة تحسب المواضع بناء على نسبة مئوية من المساحة الإجمالية بدلا من وحدات البكسل [1].

2. مراحل معالجة الصور الرقمية

تمر عملية معالجة الصور الرقمية بالمراحل التالية (انظر الشكل 5.1) :

1.2 معالجة الصور "المستوى المنخفض Low-Level Process": هي مجموعة من التقنيات التي تستخدم لتحسين الصور أو استخراج المعلومات منها بناء على الخصائص الأساسية لها، مثل الألوان، التباين، والسطوع، دون الحاجة إلى تحليل المحتوى أو السياق. أهم العمليات التي تنتج:

❖ **إزالة الضوضاء (Reduce Noise):** وهي عملية إزالة التشويش من الصورة لتحسين جودتها.

❖ **تحسين التباين (Contrast Enhancement):** بحيث يتم تحسين الفروق بين الألوان أو الأضواء في الصورة لجعل التفاصيل أكثر وضوحا.

❖ **حدة الصورة (Image Sharpening):** تتم في هذه العملية تحسين وضوح الصورة ودقتها.

2.2 تحليل الصور "المستوى المتوسط Mid-Level Process": تعمل هاته المرحلة على

استخراج المعلومات أو تقسيمها باستخدام العديد من الطرق أهمها:

❖ **التجزئة (Segmentation):** هي عملية تقسيم الصورة إلى مناطق أو أجزاء متجانسة،

بناء على خصائص معينة مثل الكثافة، الألوان، أو الملمس. وتستخدم لاستخراج

المعلومات المهمة من الصورة للتعرف على الأشكال أو الكائنات داخلها.

❖ **التصنيف (Classification):** يتم في هذه العملية تحديد هوية الأجسام أو المناطق

في الصورة من خلال تصنيفها إلى فئات محددة، مثل "سيارة"، "شجرة"، أو "شخص"،

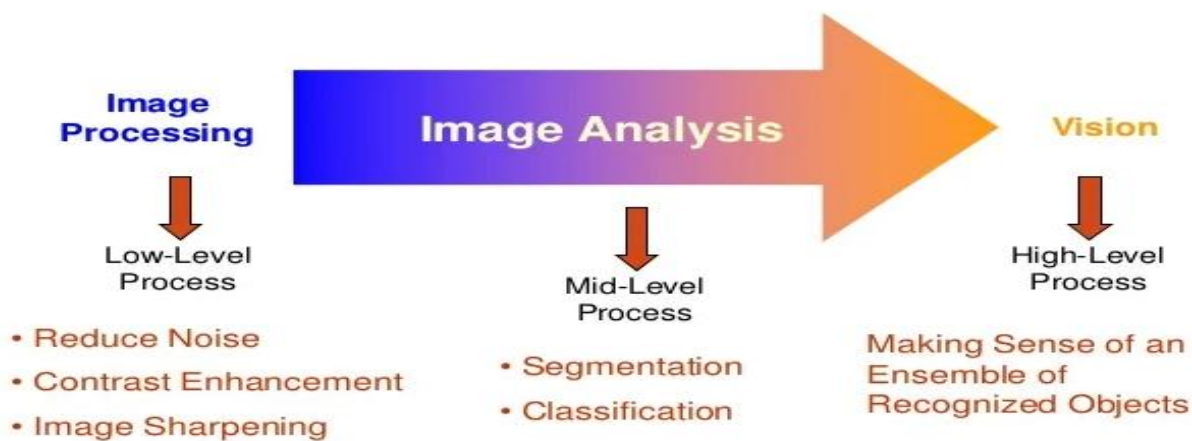
استنادا على الميزات المستخرجة، ويعتمد على خوارزميات التعلم الآلي أو التعلم العميق

لتطوير نماذج قادرة على التمييز بين الفئات المختلفة.

3.2 الرؤية الحاسوبية "المستوى العالي High-Level Process": وهذه هي آخر مرحلة

في النظام، حيث تتضمن فهم الصورة بشكل شامل، أو تفسيرها والتعرف عليها بطريقة مشابهة

لإدراك البشر.



الشكل 5.1 : مراحل نظام معالجة الصور [5]

3. التعرف على إشارات المرور

1.3 التعرف بإشارات المرور

إشارات المرور هي أدوات مرئية تقدم معلومات هامة للسائقين والمشاة بشأن قواعد المرور وظروف الطريق والمخاطر المحتملة. تأتي هذه الإشارات بأشكال وألوان ورموز متنوعة لنقل دلالات محددة. تساهم هذه العلامات في تعزيز سلامة وانسيابية حركة المرور على الطرق [3].

2.3 أهم أنواع إشارات المرور

1.2.3 الإشارات التحذيرية

تستخدم الإشارات التحذيرية لتنبيه وتحذير السائق وكافة مستخدمي الطريق من أوضاع خطيرة قائمة أو محتملة على الطريق. عموماً تكون جميع الإشارات التحذيرية ذات شكل مثلث، وتكون خلفية الإشارة باللون الأبيض، تحتوي على رموز أو رسوم باللون الأسود، وإطار باللون الأحمر [4] (انظر الشكل 6.1).

 منحطف للييسار	 منحطف للييمين	 منحطف حاد للييسار	 منحطف حاد للييمين
 منحطقات خطيرة من اليسار إلى اليمين	 منحطقات خطيرة من اليمين إلى اليسار	 طريق متعرج للييسار	 طريق متعرج للييمين
 صعود	 الطريق يضيق من الجانبين	 الطريق يضيق من اليسار	 الطريق يضيق من اليمين

الشكل 6.1 : صور الإشارات التحذيرية [4]

2.2.3 الإشارات التنظيمية

تستخدم هذه الإشارات لتعريف السائق وكافة مستخدمي الطريق بالأنظمة المرورية، والقيود، والمحظورات المختلفة الواجب التقيد بها أثناء القيادة أو استخدام الطريق. عموماً يكون شكلها دائري مخطط باللون الأحمر من الخارج، وتكون أرضيتها من الداخل باللون الأبيض أو الأزرق، عليها رسوم باللون الأسود أو الأبيض أو الأحمر [4] (انظر الشكل 7.1).



الشكل 7.1 : صور الإشارات التنظيمية [4]

3.2.3 الإشارات الإرشادية

تستخدم من أجل توجيه السائقين وكافة مستخدمي الطرق، لتسهيل حركتهم بين الطرقات والوصول إلى وجهاتهم المحددة، كما أنها توضع للتبنيه بوجود مرافق الخدمات على الطرق. وتأتي على شكل مستطيل طولي مغطى بالكامل باللون الأزرق، ويأتي الرسم الإرشادي بداخله باللون الأبيض [4] (انظر الشكل 8.1).



الشكل 8.1: بعض صور الإشارات الإرشادية

4.2.3 إشارات مناطق العمل المؤقتة

تستخدم هذه الإشارات لنفس الغرض التي تستخدم فيه الإشارات السابق ذكرها، مع اختلاف بسيط بأن إشارات مناطق العمل تحذر وتنظم لوضع طارئ ومؤقت على الطريق. عموماً يكون شكلها نفس أشكال الفئات المذكورة سابقاً مع اختلاف في اللون، بحيث تتكون ألوان إشارات مناطق العمل من أرضية صفراء، وإطار أحمر، وكتابة أو رسم باللون الأسود [4] (انظر الشكل 9.1).



الشكل 9.1 : صور إشارات العمل المؤقتة [4]

الخاتمة

قدمنا في هذا الفصل تعريفا حول الصور بصفة عامة والصور الرقمية بشكل خاص، ثم ذكرنا جميع خصائصها وأنواعها، بالإضافة إلى ذلك وضحنا مراحل نظام معالجة الصور في المجال التكنولوجي، وأخيرا تطرقنا إلى التعريف بإشارات المرور وأهم أنواعها، والتي تعتبر محور دراستنا.

في الفصل الثاني، سنتطرق إلى مفهوم الذكاء الاصطناعي ونتعمق في تقنياته المختلفة، بما في ذلك التعلم الآلي والتعلم العميق. سنقدم تعريف كل منهما مع ذكر كيفية استخدامهما، ثم سنحدد العلاقة بينهما مع توضيح أوجه الاختلاف. وأخيرا سنتناول دراسات سابقة أجريت باستخدام هاته التقنيات السابق ذكرها على إشارات المرور بصفة خاصة.

الفصل الثاني : التعلم الآلي والتعلم العميق

المقدمة

إن التطور السريع في التكنولوجيا وتعدد استخداماتها لدى البشر في الآونة الأخيرة، أدى إلى اكتشاف تقنيات متطورة باستخدام الذكاء الاصطناعي، والتي تسهل على الإنسان حياته اليومية وتختصر عليه جهده ووقته.

في السنوات الأخيرة، لعبت هذه التقنيات دورا بارزا في مجالات متنوعة، مثل الطب والرعاية الصحية، التعليم، التعرف على الصور وغيرها. حيث تعتمد هذه الأنظمة على تحليل البيانات البصرية واستخراج المعلومات منها بدقة.

ومن أبرز تقنيات الذكاء الاصطناعي التعلم الآلي والتعلم العميق، حيث يعتمد التعلم الآلي على خوارزميات تستخلص الأنماط من البيانات دون الحاجة إلى برمجة صريحة، في حين يعد التعلم العميق فرعا متقدما منه، يعتمد على الشبكات العصبية الاصطناعية لمعالجة البيانات بشكل أكثر تعقيدا ودقة.

في هذا الفصل، سنتعرف بشكل أعمق عن ماهية الذكاء الاصطناعي والتقنيات التي يعتمد عليها، والتي تشمل بشكل أساسي التعلم الآلي والتعلم العميق، مع إظهار الفروقات والعلاقة التي تجمع بينهما. وأخيرا، نعرض بشكل خاص الدراسات التي أجريت سابقا في التعرف على إشارات المرور باستخدام هذه التقنيات.

1. تعريف الذكاء الاصطناعي "Artificial Intelligence"

يعد الذكاء الاصطناعي (AI) من أهم مجالات علم الحاسوب، فهو يهدف إلى تطوير أنظمة قادرة على محاكاة التفكير البشري، مثل التعلم، التحليل، واتخاذ القرارات [7]. يعتمد الذكاء الاصطناعي على خوارزميات وتقنيات مختلفة، أهمها التعلم الآلي والتعلم العميق، التي تمكنه من معالجة البيانات واستخلاص الأنماط لاتخاذ قرارات ذكية دون تدخل بشري مباشر.

2. التعلم الآلي "Machine Learning"

1.2 تعريف التعلم الآلي

التعلم الآلي هو أحد فروع الذكاء الاصطناعي، الذي يتيح للحواسيب والأنظمة الذكية التعلم من البيانات، وتحسين أدائها بمرور الوقت دون الحاجة إلى برمجة صريحة. يعتمد هذا المجال على خوارزميات قادرة على تحليل البيانات، واكتشاف الأنماط، واتخاذ قرارات أو تقديم تنبؤات بناء على الخبرات السابقة.

2.2 أنواع طرق التعلم الآلي

يمكن تصنيف التعلم الآلي إلى أربعة أنواع رئيسية: التعلم الخاضع للإشراف، التعلم غير الخاضع للإشراف، التعلم المعزز، والتعلم شبه الخاضع للإشراف. يوفر كل نوع حلولاً فعالة لمجموعة واسعة من التطبيقات، مثل تصنيف الصور والنصوص، تحليل البيانات الضخمة، وتطوير أنظمة ذكاء اصطناعي قادرة على اتخاذ قرارات معقدة بشكل ذاتي.

1.2.2 التعلم الخاضع للإشراف "Supervised Learning"

في هذا النوع من التعلم، يتم تدريب الحواسيب باستخدام مجموعة من البيانات المصنفة، حيث يتم تزويد النموذج ببيانات معروفة النتائج مسبقاً. تقوم الخوارزميات بتحليل هذه البيانات وتطوير نموذج قادر على التنبؤ بالإجابات الصحيحة عند إدخال بيانات جديدة [10]. ينقسم إلى فئتين رئيسيتين:

❖ **التصنيف (Classification):** يهدف إلى تصنيف البيانات إلى مجموعات أو فئات

محددة، مثل تصنيف الرسائل الإلكترونية إلى "عادية" أو "غير مرغوب فيها".

❖ **التوقع (Regression):** يستخدم للتنبؤ بالقيم العددية مثل توقع أسعار العقارات بناء

على البيانات السابقة.

في التعلم الخاضع للإشراف، تستخدم العديد من الخوارزميات لحل مشكلات مختلفة بناء

على طبيعة البيانات ونوع المهمة المطلوبة، ومن أبرزها:

❖ **شجرة القرار (DT):** تستخدم في تصنيف البيانات من خلال إنشاء هيكل شجري يعتمد

على تقسيم البيانات إلى فروع بناء على ميزاتها. يمكن استخدامها لتحديد تصنيف

عنصر معين بناء على خصائصه [10].

❖ **الغابات العشوائية (RF):** تستخدم عادة في تصنيف البيانات من خلال إنشاء مجموعة

من أشجار القرار DT ودمجها معاً للحصول على تنبؤ أكثر دقة [11].

❖ **آلة المتجهات الداعمة (SVM):** تستخدم لتصنيف البيانات عن طريق إيجاد خط

فاصل أمثل (Hyperplane) بين فئات مختلفة من البيانات، مما يساعد في التصنيف

الدقيق.


❖ الشبكات العصبية الاصطناعية "Artificial Neural Network": وهي من أهم خوارزميات التعلم الآلي، وسميت بهذا الاسم لأنها تحاكي طريقة عمل الدماغ البشري والجهاز العصبي في معالجة المعلومات (انظر الشكل 1.2). تعتمد هذه الشبكات على مجموعة من الطبقات المتصلة، التي تعمل معا لتحليل البيانات واستخلاص الميزات المهمة، مما يجعلها فعالة في التعامل مع المهام المعقدة مثل التعرف على الصور، معالجة اللغة الطبيعية، التنبؤات المالية، والتحكم الذاتي في الروبوتات. بالإضافة إلى ذلك تعد الشبكات العصبية الاصطناعية اللبنة الأساسية في بناء نماذج التعلم العميق [12].

❖ تنقسم الشبكات العصبية إلى ثلاث طبقات رئيسية [12]:

✓ **طبقة الإدخال (Input Layer):** تستخدم لإدخال البيانات الأولية إلى الشبكة العصبية الاصطناعية وكل عقدة في هذه الطبقة تمثل ميزة (Feature) من البيانات.

✓ **الطبقة المخفية (Hidden Layer):** تتكون من واحدة أو أكثر من الطبقات التي تعالج البيانات بعد إدخالها. تحتوي هذه الطبقة على عقد (Neurons) تقوم بإجراء عمليات حسابية وتحويل البيانات باستخدام وظائف التنشيط مثل ReLU أو Softmax. كما تستخدم هذه الطبقات لاستخلاص الميزات المعقدة من البيانات، فكل طبقة تخزن معلومات أكثر تعقيدا من السابقة.

✓ **طبقة الإخراج (Output Layer):** تنتج النتيجة النهائية (التي تكون عبارة عن قيمة مستمرة أو تصنيف صورة إلى فئة معينة أو غيرها)، بناء على البيانات التي مرت عبر الطبقات المخفية.



الشكل 1.2 : الخلية العصبية عند الانسان مقابل الخلية العصبية الاصطناعية [12]

2.2.2 التعلم غير الخاضع للإشراف "Unsupervised Learning"

يتم استخدام التعلم غير الخاضع للإشراف عندما لا تتوفر بيانات مصنفة مسبقاً، حيث يعتمد النموذج على تحليل البيانات لاكتشاف الأنماط والعلاقات المخفية دون الحاجة إلى إشراف بشري [10]. ومن أهم أنواع التعلم من دون إشراف:

❖ **تقليل الأبعاد (Dimensionality Reduction):** هو عملية تبسيط البيانات عن

طريق تقليل عدد الميزات (features) مع الاحتفاظ بأكبر قدر ممكن من المعلومات المهمة لتحسين الأداء وتقليل التعقيد.

❖ **التجميع (Clustering):** يهدف إلى تجميع البيانات المتشابهة في مجموعات، مثل

تصنيف العملاء وفقاً لأنماط الشراء الخاصة بهم.

3.2.2 التعلم المعزز " Reinforcement Learning "

يعد التعلم المعزز أحد أنواع التعلم الآلي، حيث يتعلم النموذج من خلال التفاعل مع بيئته عبر تنفيذ الأفعال وتلقي ردود الفعل. يعتمد على نظام المكافآت والعقوبات، حيث يتم تعزيز الإجراءات التي تؤدي إلى نتائج إيجابية وتقليل تلك غير الفعالة. تكون المكافآت والعقوبات عبارة عن قيم رقمية تستخدم لإرشاد النموذج نحو اتخاذ قرارات أفضل [11].

على سبيل المثال، في لعبة الشطرنج إذا قام النظام بحركة صحيحة تقربه من الفوز، يحصل على مكافأة رقمية، بينما إذا قام بحركة أدت إلى خسارة قطعة مهمة، يحصل على عقوبة رقمية، هذا يساعده على تحسين أدائه واستراتيجيته في المستقبل.

4.2.2 التعلم شبه الخاضع للإشراف "Semi-supervised Learning"

يجمع هذا الأسلوب بين البيانات المصنفة وغير المصنفة، حيث يتم تدريب النموذج باستخدام كمية محدودة من البيانات المصنفة، مع الاستفادة من البيانات غير المصنفة لتحسين دقته. يستخدم هذا النوع في العديد من التطبيقات، مثل تصنيف المستندات، والتعرف على الأمراض من الصور الطبية، وغيرها [11].

3.2 آلية عمل التعلم الآلي

يتم تدريب نماذج التعلم الآلي عبر سلسلة من المراحل التي تتيح لها التعلم من البيانات وتحسين دقتها بمرور الوقت ، وتشمل هذه المراحل ما يلي [10]:

✓ **جمع البيانات "Data Collection"**: تعتبر هذه المرحلة الأولى في أي مشروع تعلم آلي، حيث يتم جمع البيانات اللازمة لتدريب النموذج. يمكن أن تأتي البيانات من مصادر متعددة مثل قواعد البيانات، الإنترنت، وغيرها.

✓ **معالجة البيانات "Data Processing"**: بعد جمع البيانات، يجب معالجتها وتنظيفها. على سبيل المثال، في سياق معالجة الصور يتم إزالة الصور التالفة، تعديل حجم الصور، التحكم في التدرجات اللونية وغيرها. هذه الخطوة ضرورية لضمان جودة البيانات المستخدمة في التدريب.

✓ **استخراج الميزات "Feature Extraction"**: في هذه المرحلة، يتم تحويل البيانات الخام (مثل الصور أو النصوص) إلى مجموعة من الميزات (features) المهمة التي تساعد النموذج في التعلم واتخاذ قرارات دقيقة.

✓ **تقسيم البيانات "Data Splitting"**: يتم تقسيم البيانات إلى مجموعتين رئيسيتين: مجموعة التدريب (Training Set) ومجموعة الاختبار (Test Set). تستخدم مجموعة التدريب لتدريب النموذج، بينما تستخدم مجموعة الاختبار لتقييم أداء النموذج.

✓ **اختيار النموذج "Model Selection"**: تتضمن هذه المرحلة اختيار الخوارزمية المناسبة للتعلم الآلي بناء على طبيعة المشكلة والبيانات المتاحة. يمكن أن تشمل الخيارات خوارزميات الغابات العشوائية، أشجار القرار، الشبكات العصبية الاصطناعية، وغيرها.

✓ **تدريب النموذج "Model Training"**: بعد اختيار النموذج، يتم تدريبه باستخدام مجموعة التدريب. يتضمن ذلك ضبط المعلمات وتحسين الأداء لتحقيق أفضل النتائج.

✓ **تقييم النموذج "Model Evaluation"**: بعد التدريب، يتم تقييم النموذج باستخدام مجموعة الاختبار. يتم استخدام مقاييس مثل الدقة "Accuracy" لتحديد مدى فعالية النموذج.

3. التعلم العميق "Deep Learning"

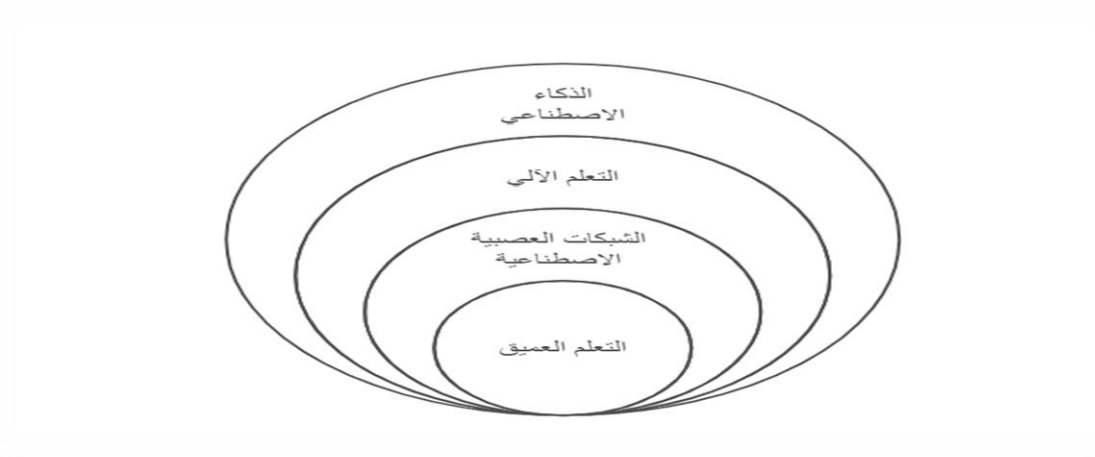
1.3 تعريف التعلم العميق

التعلم العميق هو أحد فروع تعلم الآلة، يتميز بدقته العالية وتعقيده مقارنة بأساليب تعلم الآلة الأخرى، حيث تعتمد خوارزمياته على تحليل البيانات لاستخراج الأنماط والميزات تلقائياً. بعد ذلك، تستخدم هذه الخوارزميات المدربة لاتخاذ قرارات ذكية بناء على البيانات الجديدة [12].

على سبيل المثال، إذا أردنا استخدام نموذج التعلم العميق لتحديد صورة سيارة، فإن النموذج لا يحتاج إلى تدخل بشري مباشر لاستخراج الميزات مثل الشكل والحجم والعجلات. بدلا من ذلك، يقوم التعلم العميق باكتشاف واستخراج الميزات تلقائياً داخل النموذج، مما يمكنه من تصنيف الصور واتخاذ التنبؤات بدقة عالية دون الحاجة إلى برمجة صريحة لكل ميزة.

2.3 العلاقة بين الذكاء الاصطناعي والتعلم الآلي والتعلم العميق

يوضح الشكل 2.2 أدناه العلاقة بين الذكاء الاصطناعي، التعلم الآلي والتعلم العميق، حيث تعد العلاقة علاقة ترابطية. يمثل الذكاء الاصطناعي المجال الأشمل الذي يهدف إلى تمكين الآلة من محاكاة القدرات العقلية البشرية. في حين أن التعلم الآلي هو أحد الفروع الرئيسية للذكاء الاصطناعي، إذ يركز على تطوير خوارزميات تمكّن الأنظمة من التعلم تلقائياً من البيانات، وبناء نماذج قادرة على اتخاذ قرارات و التنبؤ بنتائج جديدة. أما التعلم العميق، فهو بدوره فرع من فروع التعلم الآلي يعتمد على بنية الشبكات العصبية الاصطناعية، حيث تستخلص الخصائص التمثيلية والمميزة للبيانات بشكل هرمي، مما يمنح الأنظمة قدرة عالية على التعامل مع المهام المعقدة مثل التعرف على الصور والنصوص.



الشكل 2.2 : العلاقة بين الذكاء الاصطناعي والتعلم الآلي والتعلم العميق

3.3 أهم أنواع الشبكات العصبية الاصطناعية


يوجد العديد من الشبكات العصبية المستخدمة في التعلم العميق، من أهمها:

- الشبكة العصبية الالتفافية (Convolutional Neural Network).
- الشبكة العصبية العميقة (Deep Neural Network).
- الشبكة العصبية التكرارية (Recurrent Neural Network).
- الشبكة الخصومية التوليدية (Generative adversarial network).

1.3.3 الشبكة العصبية الالتفافية "CNN"

الشبكات العصبية الالتفافية هي نوع خاص من الشبكات العصبية الاصطناعية المصممة لمعالجة البيانات والتعرف على الأنماط بفعالية. تعتمد هذه الشبكات على مبدأ أن الصور تحتوي على ميزات محلية مترابطة، لذا بدلا من تحليل الصورة بالكامل دفعة واحدة ، يتم تحليل أجزاء صغيرة منها باستخدام فلاتر، تمر عبر الصورة، لاستخراج الميزات المهمة والمفيدة فقط .

ويمكن تلخيص هيكل الشبكة العصبية الالتفافية في الشكل 3.2 التالي:



الشكل 3.2: هيكل عام للشبكة العصبية الالتفافية [11].

تتكون الشبكة العصبية الالتفافية من عدة طبقات، ولكل طبقة وظيفة محددة في تحليل الصورة هذه الطبقات هي:

✓ **طبقة الإدخال (Input Layer):** هي أول طبقة تستقبل الصورة الأصلية، وتحولها إلى بيانات يمكن معالجتها في الطبقات اللاحقة [8].

مثال بسيط: نفرض أن لدينا صورة وجه بحجم 32×32 بكسل، وملونة (RGB)، مما يعني أنها تحتوي على ثلاث قنوات (Red, Green, Blue).

تمثيل الصورة في طبقة الإدخال: $(32 \times 32 \times 3)$. بحيث كل بكسل يحتوي على 3 قيم، واحدة لكل لون: (الأحمر، الأخضر، الأزرق).

✓ **طبقة الالتفاف (Convolutional Layer):** استخراج الميزات: هذه الطبقة هي الأهم، حيث يتم فيها تمرير "فلتر" صغيرة على الصورة لاستخراج الميزات المهمة، مثل الحواف والأشكال. فكل فلتر هو عبارة عن مصفوفة صغيرة من الأرقام، ومع كل تمريرة للفلتر، يتم ضرب قيم البكسلات بقيم الفلتر وجمعها لإنتاج "خريطة الميزات" (Feature Map) التي تظهر المناطق المهمة في الصور [8].

مثال بسيط: تخيل أن لديك صورة وجه، ستتمكن الفلاتر من اكتشاف الحواف أولاً (مثل حدود العينين والفم)، ثم تكتشف أشكالاً أكثر تعقيداً مثل ملامح الوجه.

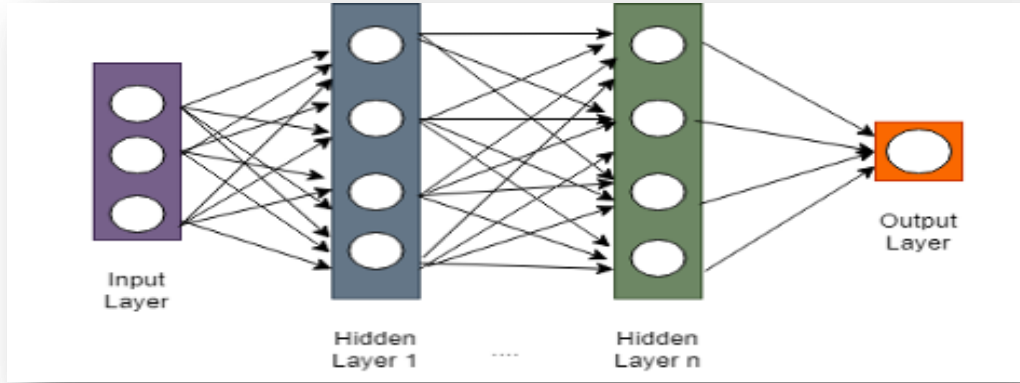
✓ **طبقة الدمج (Pooling Layer) تقليل حجم البيانات:** الهدف من هذه الطبقة هو تقليل حجم المعلومات مع الاحتفاظ بالأجزاء المهمة، مما يجعل الشبكة أسرع وأقل تعقيداً. تقوم بأخذ جزء صغير من الصورة، وتستبدله بقيمة واحدة، تمثل أهم ميزة في ذلك الجزء [8].

✓ **الطبقة المتصلة بالكامل (Fully Connected Layer) اتخاذ القرار النهائي:** بعد استخراج الميزات وتقليل حجم البيانات، تأتي هذه الطبقة التي تحول المعلومات المستخرجة إلى قرارات و في هذه الطبقة، يتم ربط جميع الميزات المستخرجة ببعضها وتوصيلها بنظام تصنيف يحدد النتيجة النهائية، مثل تصنيف الصورة إلى "قطة" أو "كلب" [8].

مثال بسيط: تخيل أنك ترى صورة حيوان، وعيونك التقطت بعض التفاصيل (أذان طويلة، جسم صغير، ذيل قصير). عقلك الآن يربط هذه التفاصيل ويقرر أن الصورة لحيوان "أرنب".

2.3.3 الشبكة العصبية العميقة "DNN"

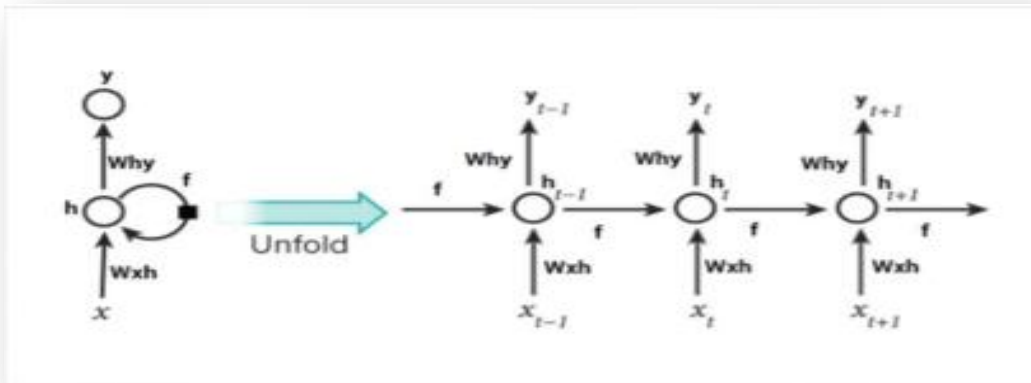
الشبكة العصبية العميقة (DNN) هي شبكة اصطناعية متعددة الطبقات تمرر البيانات من طبقة الإدخال إلى طبقة الإخراج عبر عملية التعلم العكسي (انظر الشكل 4.2). حيث تبدأ بتعيين قيم عشوائية للأوزان المرتبطة بوصلات الخلايا العصبية الافتراضية، ثم تعدل هذه الأوزان تدريجياً باستخدام خوارزميات تحسين مثل الانحدار التدريجي، لضبط المخرجات وتحقيق دقة أعلى في التنبؤات [11].



الشكل 4.2: هيكل الشبكة العصبية العميقة DNN [11]

3.3.3 الشبكة العصبية التكرارية "RNN"

تعد الشبكات العصبية المتكررة RNN نموذجاً متقدماً في التعلم العميق، حيث تستخدم في معالجة البيانات المتسلسلة، مثل التعرف على الكلام وتحليل النصوص [11]. تمتاز هذه الشبكات بقدرتها على حفظ المعلومات السابقة والتعامل مع السياق، مما يجعلها فعالة في فهم البيانات ذات الطبيعة الزمنية. تعمل RNN من خلال تمرير المعلومات عبر عدة طبقات متكررة، مما يمكنها من استيعاب الروابط الزمنية بين البيانات (انظر الشكل 5.2).

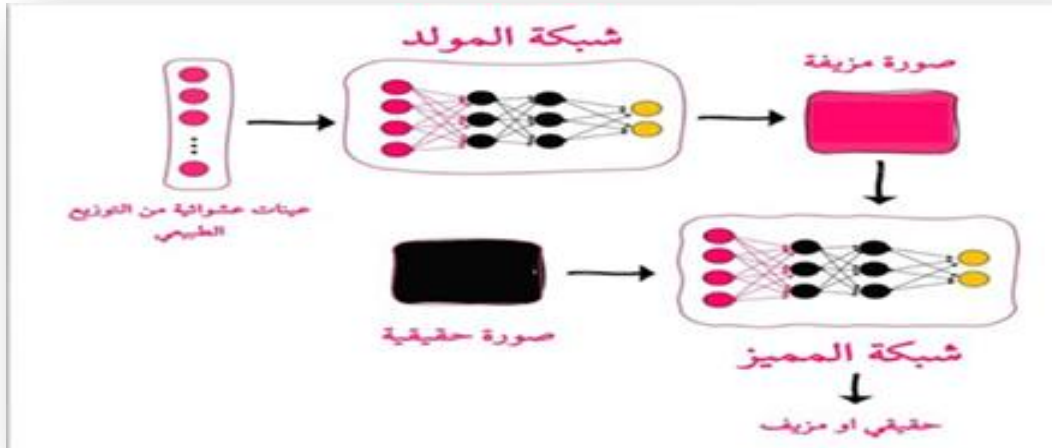


الشكل 5.2 : شبكة عصبية متكررة بسيطة [11]

4.3.3 الشبكة الخصومية التوليدية "GAN"

تعد شبكات GAN واحدة من أبرز تقنيات التعلم العميق، حيث تستخدم لتوليد بيانات جديدة تحاكي البيانات الأصلية. تعتمد هذه الشبكات على نموذج تدريب مزدوج يضم عنصرين رئيسيين : الأول يعرف بالمولد، وهو المسؤول عن إنشاء بيانات جديدة، والثاني هو المميز، الذي يعمل على التفريق بين البيانات الحقيقية والمزيفة (انظر الشكل 6.2). يتم تحسين أداء المولد عبر تدريبه لمواجهة المميز، مما يؤدي إلى إنشاء بيانات صناعية ذات جودة عالية وقريبة من الواقع.

تستخدم شبكات GAN في مجالات متعددة، مثل توليد الصور، والفيديوهات، وحتى النصوص، وتحسين جودة البيانات المستخدمة في التدريب على نماذج التعلم الآلي، مما يجعلها أداة قوية في إنشاء المحتوى الاصطناعي [11].



الشكل 6.2 : الهيكل العام لشبكة خصومية توليدية [11]

4.3 آلية بناء نموذج الشبكة العصبية الاصطناعية "Building ANN Model"

تمر عملية بناء نموذج الشبكة العصبية الاصطناعية على عدة مراحل وهي [12]:

✓ **تحديد نوع الشبكة:** مثل الشبكات العصبية الالتقافية CNN للصور، أو الشبكات العصبية التكرارية RNN لمعالجة النصوص والسلاسل الزمنية.

✓ **تحديد عدد الطبقات العصبية (Layers) ونوعها:** مثل الطبقات المخفية (Hidden Layers)، وطبقات الإسقاط (Dropout) لمنع فرط التعميم (Overfitting).

✓ **تحديد عدد العقد العصبية (Neurons) في كل طبقة.**

✓ **اختيار وظيفة التفعيل (Activation Function):** مثل ReLU، Softmax، أو Sigmoid، حسب طبيعة المشكلة.

بعد بناء النموذج، يتم تمرير البيانات إليه وتحديث الأوزان عبر عملية التدريب [12]:

✓ **تمرير البيانات للأمام (Forward Propagation):** تمرير البيانات عبر الطبقات لحساب المخرجات.

✓ **حساب الخطأ (Loss Computation):** قياس الفرق بين المخرجات الفعلية والمتوقعة باستخدام دالة الخسارة.

✓ **الانتشار العكسي (Backpropagation):** تعديل الأوزان باستخدام خوارزمية تحسين مثل Adam أو SGD.

✓ **تحديد عدد الدورات التدريبية (Epochs) وحجم الدفعة (Batch-Size):** وهما يؤثران على سرعة ودقة التعلم.

✓ إدخال البيانات على دفعات (Mini-batch Training) : لتقليل استهلاك الذاكرة وتحسين الأداء.

✓ مراقبة دقة النموذج أثناء التدريب.

بعد التدريب، يتم اختبار النموذج على مجموعة الاختبار، ولقياس أدائه يتم تطبيق معايير تقييم خاصة أهمها:

✓ الدقة (Accuracy): وهي نسبة التنبؤات الصحيحة التي قام بها النموذج على إجمالي عدد التنبؤات.

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

حيث :

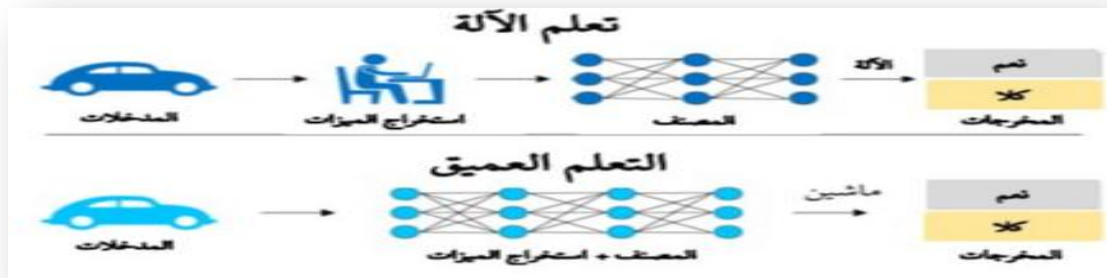
- TP (True Positives) : وهي التنبؤات الإيجابية الصحيحة.
- TN (True Negatives) : وهي التنبؤات السلبية الصحيحة.
- FP (False Positives) : وهي التنبؤات الإيجابية الخاطئة.
- FN (False Negatives) : وهي التنبؤات السلبية الخاطئة.

4. الفرق بين التعلم الآلي والتعلم العميق

أثبتت الدراسات الحديثة أن التعلم العميق أكثر دقة من التعلم الآلي، نظرا لنسب الدقة العالية التي حققها في مختلف المجالات. والآن، سنعرض جدولاً يوضح الفرق بينهما من حيث البنية، الأجهزة والبيانات المستخدمة، وقت التدريب وأهم اختلاف الذي يتمثل في كيفية استخراج الميزات (انظر الشكل 7.2).

جدول 1.2 : الفرق بين التعلم الآلي والتعلم العميق [8].

المعيار	التعلم الآلي	التعلم العميق
البنية	يعتمد على خوارزميات بسيطة مثل SVM.	يستخدم شبكات عصبية عميقة متعددة الطبقات مثل CNN.
الأجهزة المستخدمة	يعمل على الأجهزة العادية.	يحتاج إلى أجهزة قوية.
البيانات المستخدمة	لا يحتاج إلى كم هائل من البيانات فهو يعمل بشكل جيد مع بيانات أقل.	يتطلب كميات ضخمة من البيانات للفهم والتعلم بشكل أعمق.
وقت التدريب	يكون التدريب فيه سريع خاصة عند استخدام بيانات أقل.	يستغرق وقتاً أطول في التدريب نظراً لحجم البيانات الكبير.
استخراج الميزات	يتم استخراج الميزات يدوياً، وذلك بتحديد الطريقة المستخدمة في استخراج الخصائص المهمة ثم يتم ادخالها إلى النموذج.	استخراج الميزات يكون تلقائياً داخل الشبكة العصبية الاصطناعية دون تدخل خبير.



الشكل 7.2 : الفرق بين التعلم الآلي والتعلم العميق [8]

5. الدراسات السابقة في التعرف على إشارات المرور بتقنيات الذكاء الاصطناعي

نحتاج قبل البدء في تنفيذ مشروعنا، بتلخيص أحدث ما توصلت إليه الدراسات والأبحاث في التعرف على إشارات المرور في التعلم الآلي (انظر الجدول 2.2)، وفي التعلم العميق (انظر الجدول 3.2).

1.5 الدراسات السابقة في التعرف على إشارات المرور بالتعلم الآلي.

جدول 2.2 : الدراسات السابقة في التعرف على إشارات المرور بالتعلم الآلي

مؤلفو الدراسة	الخوارزميات	قاعدة البيانات	نسبة الدقة %
Nethravathi et al.2022 [13].	SVM	قاعدة بيانات أنشئت يدويا	98.33
Sugiharto et al. 2022 [9].	HOG + SVM	GTSDDB (German Traffic Sign Detection Benchmarks)	79.05
	HOG + Random Forest		79.64
	HOG + KNN		81.65

2.5 الدراسات السابقة في التعرف على إشارات المرور بالتعلم العميق

جدول 3.2 : الدراسات السابقة في التعرف على إشارات المرور بالتعلم العميق.

مؤلفو الدراسة	الطرق	قاعدة البيانات	نسبة الدقة %
Nethravathi et al.2022 [13].	CNN	قاعدة بيانات أنشئت يدويا.	96.40 "دقة التحقق"
Ghouse et al. 2025. [16].	VGG19	GTSRB	99.64
	EfficientNetB7		99
	ASNet		99.72

Ilyass et al. 2025. [15].	CNN	TT100K+Augmentation	99.06
		TT100K	99.62
		GTSRB	98.90
Song et al. 2025. [14].	E-MobileViT	GTSRB	99.61
		BTSD	99.26
		TSDR	97.34

أظهرت بعض الدراسات السابقة (الجدول 2.2 والجدول 3.2) أن خوارزميات التعلم الآلي التقليدي أعطت نتائج متفاوتة، حيث أن بعضها لم يكن فعالا بشكل كبير، باستثناء دراسة واحدة حققت نسبة دقة جيدة. أما في مجال التعلم العميق، فقد حققت أغلب الدراسات دقة عالية، لأن أغلبها اعتمدت على نماذج جاهزة ومدربة مسبقا مثل VGG19 و E-MobileViT. ورغم قوة هذه النماذج، إلا أن لها عدة عيوب، من بينها تعقيد البنية وكثرة الطبقات، مما يجعلها ثقيلة على الأجهزة ذات الموارد المحدودة. كما أن تعديلها حسب متطلبات معينة قد يكون صعبا.

في المقابل، اعتمدت دراستنا على بناء شبكة عصبية التلافية (CNN) بسيطة، وتم تدريبها على كامل قاعدة بيانات GTSRB التي تحتوي على 43 فئة. ورغم أن النظام المقترح حقق دقة أقل مقارنة ببعض الدراسات التي استخدمت نماذج جاهزة، إلا أن دراستنا تميزت بعدة جوانب، منها البساطة وسهولة التطبيق، والقدرة على التكيف مع البيئات محدودة الموارد، إضافة إلى ذلك واقعية مجموعة البيانات المستخدمة وتنوعها. كما أن بنية النموذج قابلة للفهم والتعديل، ويمكن تتبع طريقة عمله خطوة بخطوة، مما يجعله مناسباً للأغراض التعليمية والتطوير المستقبلية، على عكس بعض النماذج الجاهزة التي تُعتبر معقدة قد يصعب فهم طريقة عملها.

الخاتمة

في هذا الفصل، قدمنا مفهوم الذكاء الاصطناعي وتقنياته الرئيسية، التي تتمثل في التعلم الآلي والتعلم العميق. بدأنا بتعريف التعلم الآلي، مراحل، والأساليب التي يعتمد عليها، ثم انتقلنا إلى التعلم العميق، حيث قدمنا تعريفه، وأشرنا إلى أشهر أنواع الشبكات العصبية المستخدمة فيه مع توضيح آلية عمله. كما ناقشنا العلاقة بين الذكاء الاصطناعي وتقنياته، مع التركيز على الاختلافات الأساسية بين التعلم الآلي والتعلم العميق. وفي ختام الفصل، استعرضنا بعض الدراسات السابقة حول التعرف على إشارات المرور باستخدام تقنيات التعلم الآلي والتعلم العميق.

في الفصل الأخير، سننتقل إلى تصميم وتنفيذ النظام الخاص بنا، الذي يعتمد على التعلم العميق في التعرف على إشارات المرور. سنقدم شرحاً تفصيلياً لهيكلة النظام الذي سيعتمد على الشبكة العصبية الالتفافية "CNN"، ثم سنقوم بتجربة بعض الطرق التقليدية للتعلم الآلي، لنبين الفرق بينها وبين النموذج المقترح.

الفصل الثالث: التصميم والتنفيذ

المقدمة

في الفصل الأول، قدمنا المفاهيم الأساسية لمعالجة الصور ومراحل النظام المتعلق بها، إلى جانب التعريف بإشارات المرور وأهم أنواعها. بعد ذلك، قمنا بتعريف الذكاء الاصطناعي وأهم تقنياته المتمثلة في التعلم الآلي والتعلم العميق، مع التفصيل فيهما في الفصل الثاني.

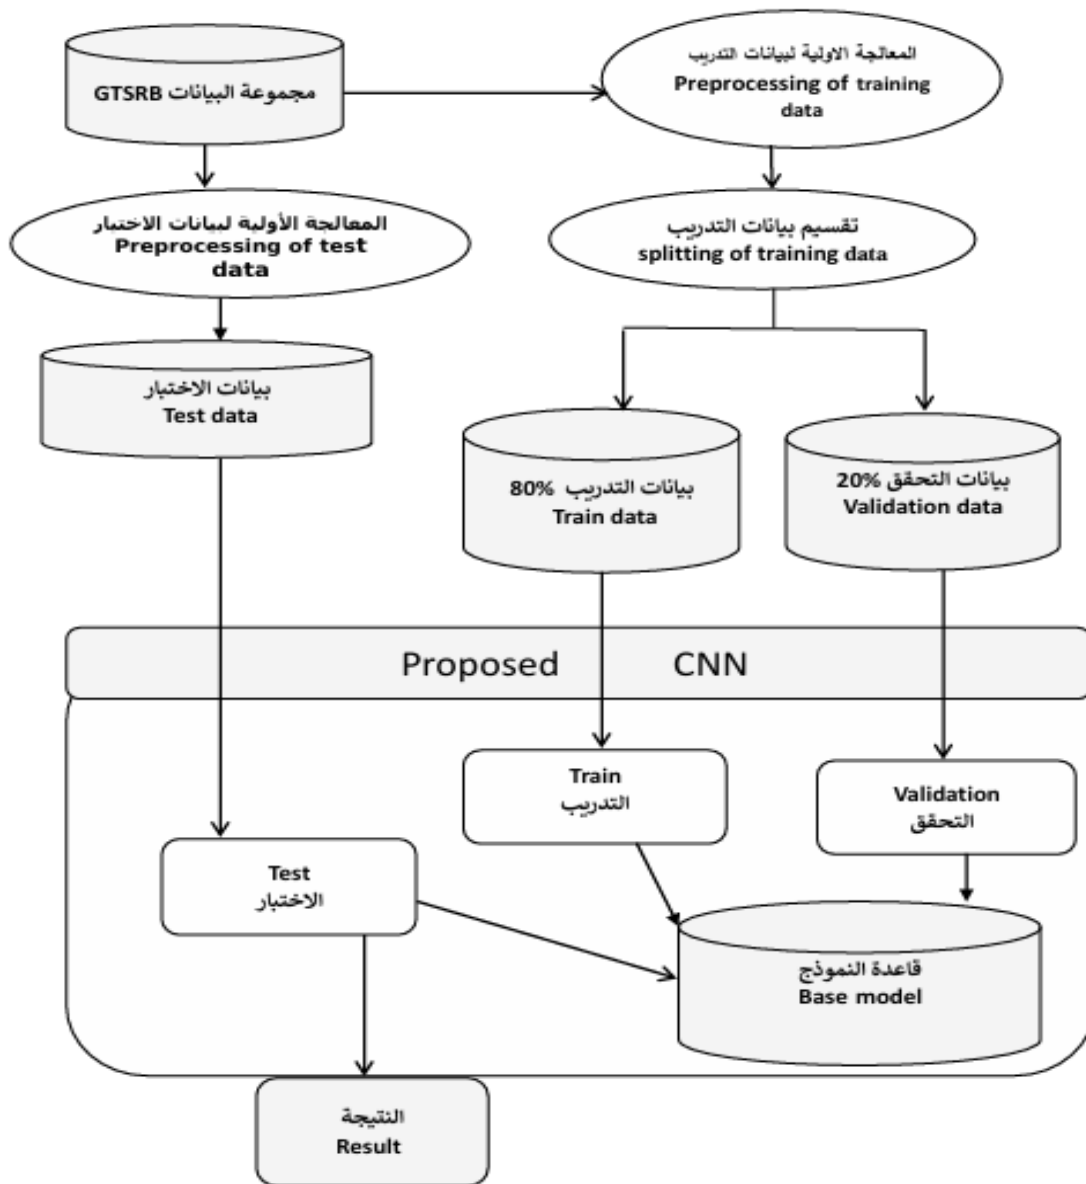
في هذا الفصل، سنعرض الهيكل العام للنظام المقترح، وسنقوم بوصف مجموعة البيانات المستخدمة. بعد ذلك، سنعرف بيئة العمل التي أعددناها، والمتمثلة في تعريف خصائص الجهاز وأدوات التطوير، ثم سنشرح كيفية بناء النموذج، بدءاً من المعالجة الأولية للبيانات وصولاً إلى تدريب النموذج واختباره. كما سنقوم بوضع التجارب التي مر بها نموذجنا. بعدها سنذكر بعض الخوارزميات التقليدية للتعلم الآلي التي جربناها، لنقارنها مع نموذجنا ونبين أفضليته وتفوقه في التعرف على إشارات المرور. وأخيراً، سنعرض واجهات النظام التي صممناها.

1. التصميم "Design"

في هذا الجزء، سنعرض الهيكل العام للنظام المقترح، وسنعرف مجموعة البيانات التي استخدمناها، بالإضافة إلى ذلك، سنشرح مراحل التنفيذ التي مررنا بها أثناء إنجاز النظام.

1.1 الهيكل العام للنظام المقترح "General Architecture of the Proposed System"

يوضح الشكل 1.3 الهيكل العام للنظام المقترح للتعرف على إشارات المرور بالتعلم العميق:



الشكل 1.3: الهيكل العام للنظام المقترح

2.1 وصف مجموعة البيانات "Dataset Description"

GTSRB (German Traffic Sign Recognition Benchmark) هي مجموعة البيانات التي اعتمدنا عليها، نظرا لأنها من أكثر ال DataSet استخداما وشهرة. فهي تحتوي على أكثر من 50000 صورة، مقسمة بين مجموعة التدريب TrainingSet، ومجموعة الاختبار TestingSet.

تحتوي مجموعة التدريب على 39209 صورة مصنفة داخل 43 مجلدا، حيث يمثل كل مجلد فئة واحدة من إشارات المرور (مثل: منع، تحذير، إرشاد...). بينما تحتوي مجموعة الاختبار على 12630 صورة عشوائية دون تصنيف، والهدف منها هو التحقق من قدرة النموذج على تصنيف إشارات جديدة بشكل صحيح.

3.1 معالجة وتقسيم البيانات "Data Preprocessing and Splitting"

تعتبر هاته المرحلة الخطوة الأولى والضرورية لتهيئة البيانات وتجهيزها، من أجل استخدامها في تدريب وتعليم النموذج. حيث قمنا بتوحيد حجم الصور، وتحويلها إلى مصفوفات رقمية، ثم تجميعها في قوائم وتحويل هاته القوائم إلى مصفوفات Numpy. أيضا تم تقسيم البيانات، في حالتنا قسمنا بيانات التدريب إلى تدريب وتحقق، وبعدها تم تحويل التسميات الفئوية البالغ عددها 43 فئة إلى متجهات ثنائية (Binary Vectors) تحتوي على 43 خانة، حيث يمثل كل تصنيف بمصفوفة تحتوي على قيمة 1 في موضع الفئة الصحيحة، و 0 في باقي الخانات.

4.1 الشبكة العصبية الاصطناعية المستخدمة

وهذه هي أهم مرحلة في بناء النظام، حيث استخدمنا نموذج الشبكة العصبية الالتفافية CNN، لإنشاء مشروعنا للتعرف على إشارات المرور.

يتكون النموذج المقترح من طبقة إدخال، متبوعة بأربع طبقات مخفية، وأخيرا طبقة الإخراج.

- ✓ **طبقة الإدخال:** وهي طبقة "Conv2D"، تحتوي على 32 فلتر، ودالة تنشيط ReLU. حيث يتم تطبيق عملية الالتفاف، لاستخراج الميزات الأولية، مثل الأشكال، والحواف.
- ✓ **الطبقات المخفية:** والتي تتكون من أربع طبقات كما ذكرنا سابقا، وهي:
- **الطبقة الأولى:** وهي طبقة "Conv2D"، تحتوي على 32 فلتر، ودالة تنشيط ReLU. حيث تتعمق في استخراج الميزات المهمة.
 - **الطبقة الثانية:** وهي طبقة "Conv2D"، تحتوي على 64 فلتر، ودالة تنشيط ReLU. حيث يتم اكتشاف تفاصيل أكثر تعقيدا في الإشارات.
 - **الطبقة الثالثة:** وهي طبقة "Conv2D"، تحتوي على 64 فلتر، ودالة تنشيط ReLU. حيث تزيد من فهم النموذج لصور الإشارات.
 - **الطبقة الرابعة:** وهي طبقة "Dense"، تحتوي على 256 عقدة، ودالة تنشيط ReLU. حيث يتم تجميع الميزات المستخرجة وربطها لاتخاذ القرار النهائي.
- ✓ **طبقة الإخراج:** وهي طبقة "Dense"، تحتوي على 43 عقدة الذي يمثل عدد الفئات، ويتم هنا تطبيق عملية التصنيف، واتخاذ القرار النهائي، باستخدام دالة التنشيط Softmax.
- ✓ يحتوي النموذج أيضا على MaxPooling، التي تستخدم لتقليل حجم البيانات مع الحفاظ على المعلومات المهمة، وBatchNormalization، التي تهدف إلى موازنة القيم الناتجة من الطبقات. أيضا Dropout، التي تستخدم لتفادي الoverfitting. وأخيرا GlobalAveragePooling، التي تقوم بتلخيص وتنظيم أهم الميزات في الصورة، لتسهيل معالجتها في الطبقة الأخيرة.

5.1 التدريب والتعلم "Training and Learning"

بعد بناء الشبكة العصبية الاصطناعية، يتم تدريب النموذج باستخدام البيانات التي تم تحضيرها. سنستخدم دالة الخسارة (Categorical_Crossentropy) في تقييم أداء النموذج، فهي تستخدم بكثرة في التصنيف متعدد الفئات. كما سنستعمل محسن آدم (Adam) لتحديث الأوزان في النموذج وتقليل الخسارة.

6.1 الاختبار والتقييم "Testing and Evaluation"

بعد تدريب النموذج، تأتي المرحلة الأخيرة وهي اختباره لمعرفة مدى فعاليته. سنستخدم مقياس الدقة "Accuracy" لتقييم النموذج (لقد شرحنا مقياس الدقة في الفصل الثاني في الصفحة 26).

2. التنفيذ "Implementation"

1.2 بيئة العمل "Development Environment"

1.1.2 خصائص الجهاز

جدول 1.3: خصائص الجهاز

الوصف	الخاصية
Intel(R) Core(TM) i3-6100U CPU @ 2.30GHz	المعالج CPU
8.00 غيغابايت	الذاكرة الحية RAM
Lenovo	الشركة المصنعة
نظام تشغيل بإصدار 64 بت ومعالج يستند إلى x64	نوع نظام التشغيل

2.1.2 أدوات التطوير

❖ **كولاب "Colab"**: هو بيئة برمجية مجانية عبر الإنترنت، تتيح للمستخدم الاستفادة من وحدات المعالجة المركزية (CPU) ووحدات المعالجة الرسومية (GPU) القوية، دون الحاجة إلى استثمار في أي معدات. حيث يمكن استخدامه لكتابة وتنفيذ الكود، وتطوير النماذج، والتعاون مع مطورين آخرين في المشاريع [18].

❖ **لغة بايثون "Python"**: ظهرت لغة بايثون (Python) في أوائل التسعينات، كأحدى لغات البرمجة عالية المستوى. فهي تتميز ببساطتها وسهولة تعلمها، الأمر الذي جعلها من أكثر اللغات استخداماً في مجالات متعددة، أبرزها تحليل البيانات، الذكاء الاصطناعي، وتعلم الآلة. كما أن وجود عدد كبير من المكتبات الجاهزة والتمكاملة ساهم في انتشارها بشكل واسع بين الباحثين والمطورين، نظراً لما توفره من أدوات تسهل بناء النماذج البرمجية بكفاءة وسرعة [11].

❖ **أهم المكتبات المستخدمة "Main libraries used":**

✓ **مكتبة "Numpy"**: تعتبر هاته المكتبة من أهم المكتبات المجانية مفتوحة المصدر في بايثون، وتستخدم بشكل رئيسي في إجراء العمليات الحسابية والمعالجات الرقمية. وتتميز بسرعتها في معالجة البيانات العددية بفضل دعمها للمصفوفات متعددة الأبعاد [11].

✓ **مكتبة "Pandas"**: هي مكتبة خاصة بتحليل البيانات، حيث يمكن من خلالها قراءة الملفات ذات الصيغة (CSV) [7].

✓ **مكتبة "Keras"**: وهي مكتبة مفتوحة المصدر، تستخدم في بناء الشبكات العصبية الاصطناعية بطريقة سلسة. تعمل كواجهة برمجة عالية المستوى فوق أطر عمل قوية مثل TensorFlow، وتستخدم بشكل واسع في تطوير نماذج التعلم العميق [11].

✓ مكتبة "Scikit Learn": وهي مكتبة مفتوحة المصدر، من أهم استخداماتها تقسيم البيانات إلى مجموعات تدريب واختبار، وحساب دقة النموذج [7].

✓ مكتبة "Matplotlib": تستخدم مكتبة Matplotlib في بايثون لإنشاء الرسوم البيانية والمخططات التوضيحية، وتعد من الأدوات المهمة لعرض نتائج النماذج البرمجية وتحليل البيانات. كما أنها تستخدم بكثرة في التطبيقات العلمية والهندسية لتسهيل فهم البيانات من خلال تمثيلها بصريا [11].

2.2 خطوات التنفيذ "Implementation Steps"

❖ استدعاء المكتبات اللازمة "Importing the Required Libraries"

✓ بدأنا كأول مرحلة باستدعاء المكتبات اللازمة لاستخدامها في بناء النموذج، كما هو موضح في الكود التالي:

```
import numpy as np
import os
import pandas as pd
from PIL import Image
from sklearn.model_selection import train_test_split
from keras.utils import to_categorical
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Conv2D, MaxPool2D, Dropout, Dense, BatchNormalization, GlobalAveragePooling2D
import matplotlib.pyplot as plt
from sklearn.metrics import accuracy_score
```

الشكل 2.3: استدعاء المكتبات

❖ تحميل مجموعة البيانات "Loading the Dataset"

✓ قمنا بتحميل مجموعة البيانات من موقع Kaggle، الذي يوفر قواعد بيانات كبيرة في مختلف المجالات. الكود التالي يوضح كيفية تحميلها من Kaggle:

```
import kagglehub
path = kagglehub.dataset_download('meowmeowmeowmeowmeow/gtsrb-german-traffic-sign')

print('Data source import complete.')
print('Path is:',path)

Data source import complete.
Path is: /kaggle/input/gtsrb-german-traffic-sign
```

الشكل 3.3: تحميل مجموعة البيانات

❖ معالجة وتقسيم البيانات "Data Preprocessing and Splitting"

✓ في هذه المرحلة، أنشأنا دالة تقوم بتغيير وتوحيد حجم الصور، وتحويلها إلى مصفوفات رقمية. بعد ذلك، يتم جمع البيانات والتسميات في قائمتي data و labels على التوالي، كما هو موضح في الكود التالي:

```
# Function to load and preprocess images
def load_images_from_directory(path, image_size=(30, 30)):
    images = os.listdir(path)
    data = []
    labels = []
    class_id = int(path.split('/')[-1])

    for image_filename in images:
        try:
            image = Image.open(os.path.join(path, image_filename))
            image = image.resize((image_size))
            image = np.array(image)
            data.append(image)
            labels.append(class_id)

        except:
            print(f"Error loading image: {os.path.join(path, image_filename)}")

    return data, labels
```

الشكل 4.3: دالة المعالجة الأولية للبيانات

✓ طبقنا دالة المعالجة الأولية (الشكل 4.3) على بيانات التدريب، كما هو موضح في الكود التالي:

```
# Retrieving the images and their labels
data = []
labels = []
num_classes = 43
current_path = os.getcwd()

for class_id in range(num_classes):
    path = os.path.join(current_path, '/kaggle/input/gtsrb-german-traffic-sign/Train', str(class_id))
    class_data, class_labels = load_images_from_directory(path)
    data.extend(class_data)
    labels.extend(class_labels)
```

الشكل 5.3: تطبيق المعالجة الأولية على بيانات التدريب

✓ بعد وضع البيانات في قائمة data، والفئات في قائمة labels، سنقوم بتحويلهما إلى مصفوفات Numpy، كما هو موضح في الكود التالي:

```
# Converting lists into numpy arrays
data = np.array(data)
labels = np.array(labels)
print(data.shape, labels.shape)

(39209, 30, 30, 3) (39209,)
```

الشكل 6.3: تحويل القوائم إلى مصفوفات

✓ قمنا بتقسيم مجموعة التدريب إلى مجموعتين، وهما مجموعة التدريب Training Set بنسبة 80%، ومجموعة التحقق Validation Set بنسبة 20%. ثم حولنا قائمة التسميات "labels" إلى ترميز One_Hot Encoding، كما هو موضح في الكود التالي:

```
# Splitting training and testing dataset
X_train, X_test, y_train, y_test = train_test_split(data, labels, test_size=0.2, random_state=42)
print(X_train.shape, X_test.shape, y_train.shape, y_test.shape)

# Converting the labels into one hot encoding
y_train_one_hot = to_categorical(y_train, num_classes)
y_test_one_hot = to_categorical(y_test, num_classes)

(31367, 30, 30, 3) (7842, 30, 30, 3) (31367,) (7842,)
```

الشكل 7.3: تقسيم بيانات التدريب وتحويل التسميات إلى ترميز One_Hot Encoding

❖ بناء النموذج "Model Building"

✓ في هذه المرحلة، قمنا ببناء نموذج الشبكة العصبية الاصطناعية الالتفافية (لقد تم شرح هيكله النموذج في جزء التصميم صفحة 34_33)، كما هو موضح في الكود التالي:

```
# Building the CNN model
model = Sequential()
model.add(Conv2D(filters=32, kernel_size=(5, 5), activation='relu', input_shape=X_train.shape[1:]))
model.add(Conv2D(filters=32, kernel_size=(5, 5), activation='relu'))
model.add(MaxPool2D(pool_size=(2, 2)))
model.add(BatchNormalization())
model.add(Dropout(rate=0.25))

model.add(Conv2D(filters=64, kernel_size=(3, 3), activation='relu'))
model.add(Conv2D(filters=64, kernel_size=(3, 3), activation='relu'))
model.add(MaxPool2D(pool_size=(2, 2)))
model.add(BatchNormalization())
model.add(Dropout(rate=0.25))

model.add(GlobalAveragePooling2D())
model.add(Dense(256, activation='relu'))
model.add(BatchNormalization())
model.add(Dropout(rate=0.5))
model.add(Dense(num_classes, activation='softmax'))
```

الشكل 8.3: بناء نموذج CNN

❖ تجميع النموذج "Model Compilation"

✓ من أجل تحسين النموذج، استخدمنا محسن "Adam" الذي يقوم بضبط الأوزان في النموذج، مع وظيفة الخسارة "Categorical_Crossentropy" التي تتعامل بشكل جيد مع التصنيف متعدد الفئات.

```
# Compilation of the model
model.compile(loss='categorical_crossentropy', optimizer='adam', metrics=['accuracy'])
```

الشكل 9.3: تجميع النموذج

❖ تدريب النموذج "Model Training"

✓ لتدريب النموذج، حددنا عدد حلقات التكرار 15 حلقة "epochs"، مع إدخال البيانات على 32 دفعة "batch_size"، كما هو موضح في الكود التالي:


```
epochs = 15
history = model.fit(X_train, y_train_one_hot, batch_size=32, epochs=epochs, validation_data=(X_test, y_test_one_hot))
```

```
Epoch 10/15
981/981 — 129s 131ms/step - accuracy: 0.9802 - loss: 0.0654 - val_accuracy: 0.9958 - val_loss: 0.0152
Epoch 11/15
981/981 — 131s 133ms/step - accuracy: 0.9815 - loss: 0.0609 - val_accuracy: 0.9938 - val_loss: 0.0218
Epoch 12/15
981/981 — 142s 133ms/step - accuracy: 0.9866 - loss: 0.0429 - val_accuracy: 0.9932 - val_loss: 0.0265
Epoch 13/15
981/981 — 139s 131ms/step - accuracy: 0.9875 - loss: 0.0421 - val_accuracy: 0.9973 - val_loss: 0.0086
Epoch 14/15
981/981 — 139s 128ms/step - accuracy: 0.9867 - loss: 0.0412 - val_accuracy: 0.9978 - val_loss: 0.0074
Epoch 15/15
981/981 — 129s 132ms/step - accuracy: 0.9855 - loss: 0.0503 - val_accuracy: 0.9967 - val_loss: 0.0105
```

الشكل 10.3: تدريب النموذج

✓ من خلال الشكل 10.3، نرى أن نسبة دقة التدريب بلغت 98.55%، بينما نسبة دقة التحقق بلغت 99.67%.

✓ بعد ذلك، وضعنا الرسم البياني للدقة والخسارة "Plotting graphs for accuracy and loss" كما في الشكل التالي:



الشكل 11.3: الرسم البياني للدقة والخسارة

❖ اختبار وتقييم النموذج "Model Testing and Evaluation"

✓ وهذه هي آخر مرحلة، حيث قمنا بتحميل ملف الاختبار Test.csv من مجموعة البيانات، ثم طبقنا عليه المعالجة الأولية كالسابق، بعدها اختبرنا نموذجنا على هذه البيانات، كما هو موضح في الكود التالي:

```
y_test = pd.read_csv('/kaggle/input/gtsrb-german-traffic-sign/Test.csv')

labels = y_test["ClassId"].values
imgs = y_test["Path"].values
data=[]

for img in imgs:
    image = Image.open("/kaggle/input/gtsrb-german-traffic-sign/"+img)
    image = image.resize((30,30))
    data.append(np.array(image))

X_test=np.array(data)

# Make predictions on the test data
pred_probs = model.predict(X_test)
pred = np.argmax(pred_probs, axis=1)
```

الشكل 12.3: اختبار وتقييم النموذج

✓ بعد اختبار النموذج، قمنا بطباعة نسبة دقته "Accuracy"، والتي كانت حوالي 96.34% كما هو موضح في الكود التالي:

```
#Accuracy with the test data
print(accuracy_score(labels, pred))

395/395 ————— 15s 38ms/step
WARNING:absl:You are saving your model as an HDF5
0.9634996041171813
```

الشكل 13.3: طباعة الدقة

3.2 التجارب ومناقشة النتائج "Experiments and Results Discussion"

1.3.2 التجارب "Experiments"

مر تطوير هذا النموذج بالعديد من التجارب، نذكر أهمها:

جدول 2.3: مراحل تطوير النموذج النهائي

النموذج	قاعدة البيانات	تقسيم البيانات %	عدد الفلاتر والعقد	دوال التنشيط	نسبة الدقة %
النموذج الأول 1	GTSRB	40 تحقق 60 تدريب	32-64- 128-128_ 43	LeakyReLU, SELU, ReLU, Softmax	92.27
النموذج الثاني 2	GTSRB	20 تحقق 80 تدريب	32-64- 128-128_ 43	LeakyReLU, SELU, ReLU, Softmax	93.12
النموذج الثالث 3	GTSRB	25 تحقق 75 تدريب	32-64- 128-128_ 43	LeakyReLU, SELU, ReLU, Softmax	95.02
النموذج الرابع 4	GTSRB	30 تحقق 70 تدريب	32-64- 128-128_ 43	LeakyReLU, SELU, ReLU, Softmax	95.86
النموذج	GTSRB	20 تحقق	32_32_64_	ReLU,	94.42

الخامس 5	+تقليل البيانات	80 تدريب	64_256_43	Softmax	
النموذج النهائي	GTSRB	20 تحقق	32_32_64_	ReLU,	96.34
[17]		80 تدريب	64_256_43	Softmax	

2.3.2 مناقشة النتائج "Results Discussion"

❖ مناقشة نتائج التعلم العميق "Discussion of Deep Learning Results"

من خلال الجدول 2.3 أعلاه، نلاحظ أن النماذج من 1 إلى 4 اعتمدت على نفس النموذج، مع اختلاف في نسبة تقسيم بيانات التدريب. وقد أظهر النموذج الرابع أعلى نسبة دقة مقارنة ببقية النماذج السابقة. بعد ذلك، قمنا بالبحث على "GitHub"، ووجدنا نموذجاً أفضل من حيث الهيكلية، وتم تجربته ليحقق أعلى نسبة دقة بين جميع التجارب التي أجريناها. كما قمنا بتعديل هذا النموذج عن طريق تقليل حجم البيانات، ولكن للأسف كانت نسبة الدقة أقل عند تطبيق هذا التعديل.

❖ مناقشة نتائج التعلم الآلي "Discussion of Machine Learning Results"

في هذه المرحلة، قمنا بمقارنة نتائج النموذج الذي اعتمدنا عليه باستخدام التعلم العميق مع نتائج خوارزميات للتعلم الآلي التي قمنا بتجربتها، والمتمثلة في: SVM+HOG، RandomForest +HOG. حيث اعتمدنا تقسيم البيانات بنسبة 80% للتدريب و20% للتحقق.

وكانت الدقة التي تم تحقيقها في هذه الدراسة من خلال تطبيق خوارزميات التعلم الآلي غير كافية، حيث كانت أعلى دقة 93.79% والتي حصلنا عليها باستخدام SVM+ HOG. وبالتالي، فضلنا استخدام نموذج التعلم العميق كأداة استراتيجية للتعرف على إشارات المرور. والجدول التالي يوضح الدقة المتحصل عليها لكل نموذج:

جدول 3.3: مقارنة نتائج التعلم الآلي والتعلم العميق

النموذج	نسبة الدقة%
SVM + HOG	93.79
Random Forest + HOG	92.60
Proposed CNN	96.34

3. واجهات النظام "System Interfaces"

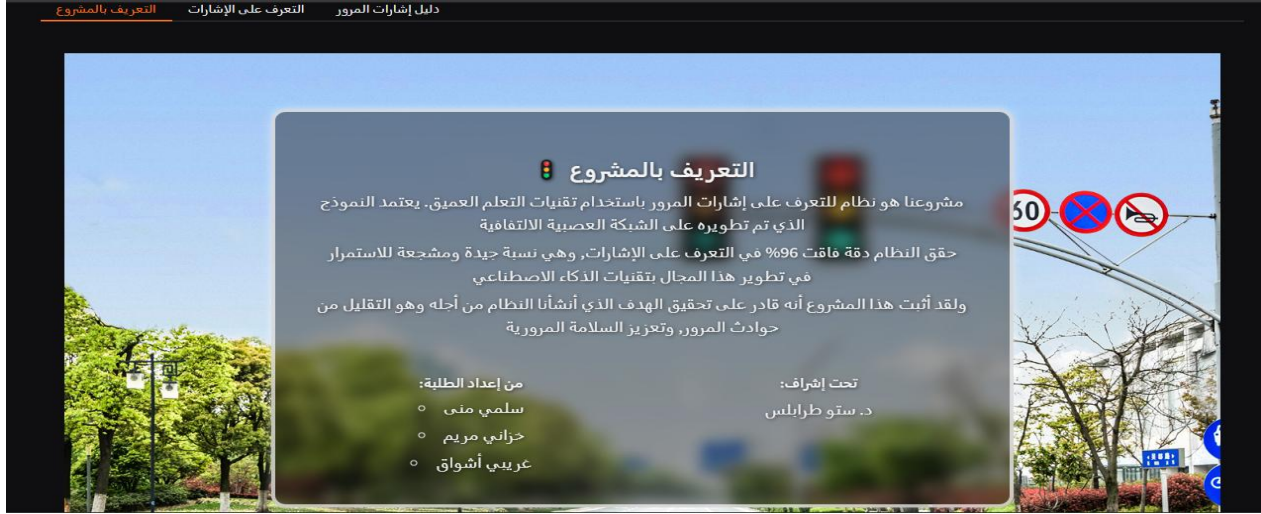
سنقدم الآن واجهات النظام التي تم إنشاؤها باستخدام Gradio، وهي أداة مفتوحة المصدر، تستخدم لبناء واجهات بسيطة وسريعة لتطبيقات الذكاء الاصطناعي.

تتمثل الواجهات التي أنجزناها في:

- ✓ واجهة التعريف بالمشروع.
- ✓ واجهة التعرف على إشارات المرور.
- ✓ واجهة دليل إشارات المرور.

1.3 واجهة التعريف بالمشروع

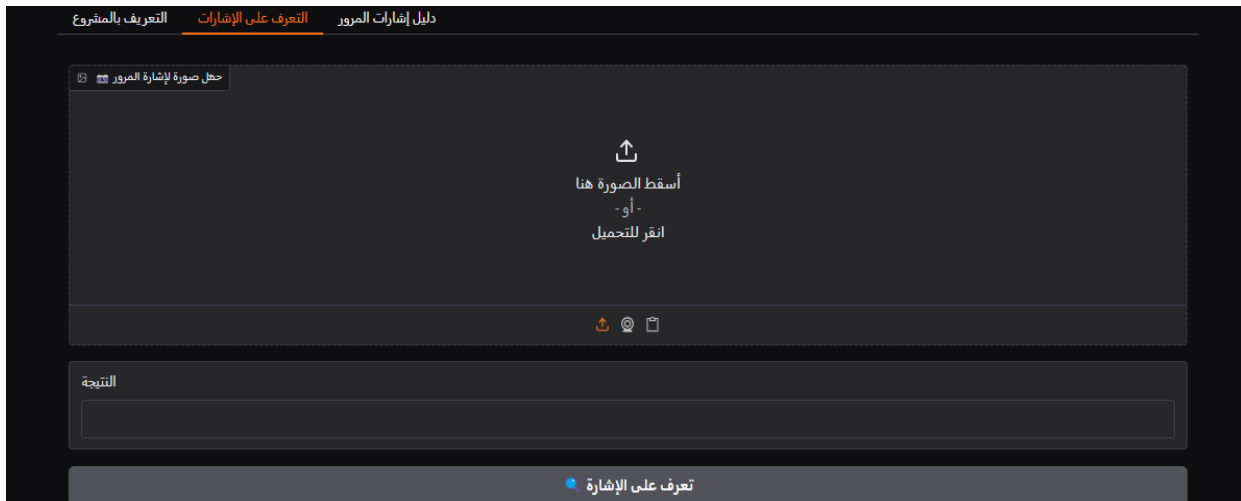
✓ في هذه الواجهة، قمنا بتعريف المشروع بشكل مختصر.



الشكل 14.3: واجهة التعريف بالمشروع

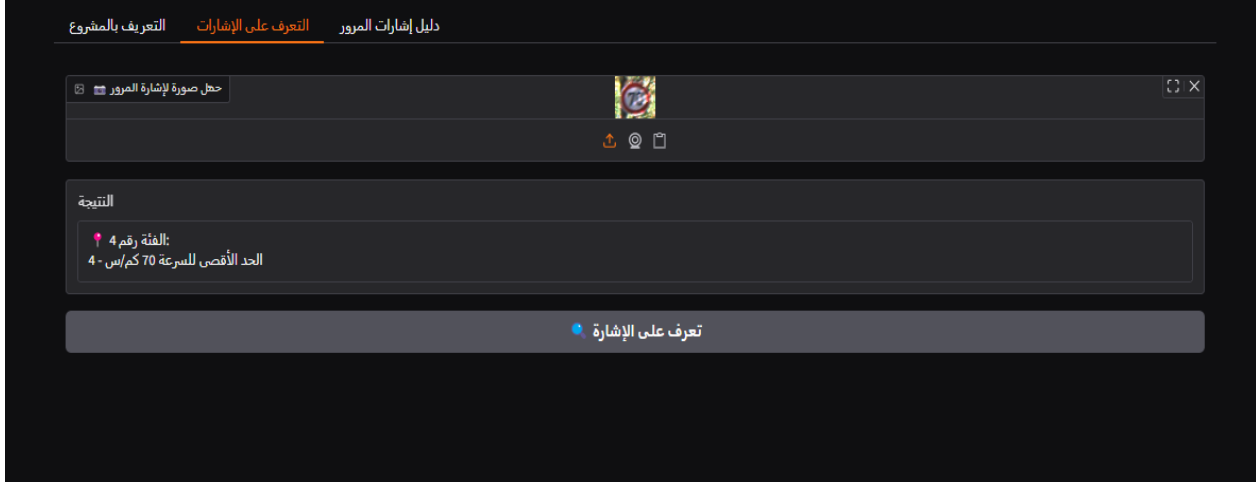
2.3 واجهة التعرف على إشارات المرور

✓ وهي الواجهة الرئيسية في النظام، حيث يتم تحميل صورة من ملف معين أو سحبها من الويب، ووضعها في خانة تحميل الصورة ثم الضغط على زر التعرف على الإشارة، كما هو موضح في الشكل:



الشكل 15.3: واجهة للتعرف على إشارات المرور

✓ في الشكل التالي، تم تطبيق مثال لتوضيح النتيجة التي كانت التعرف على اسم الإشارة، ورقم الفئة التي تنتمي إليها في مجموعة البيانات المستخدمة.



الشكل 16.3: كيفية استخدام واجهة التعرف على الإشارات

2.3 واجهة دليل إشارات المرور

✓ وهي واجهة تحتوي على معلومات كل فئة (إشارة) من مجموعة البيانات التي استخدمناها.



الشكل 17.3: واجهة دليل إشارات المرور

الخاتمة

في هذا الفصل قدمنا الجزء التطبيقي لمشروعنا، حيث بدأنا بجزء التصميم، قمنا بعرض الهيكل العام للنظام، إلى جانب وصف مجموعة البيانات المستخدمة. بعد ذلك، شرحنا المراحل التي مررنا بها أثناء عملية الإنجاز. ثم انتقلنا إلى جزء التنفيذ، بداية من إعداد بيئة العمل، وصولاً إلى بناء النموذج وتدريبه واختباره. كما استعرضنا التجارب التي خضع لها نموذجنا، والتي مكنته من تحقيق دقة تجاوزت 96%. وقد قمنا بمقارنة أداء النموذج مع بعض خوارزميات التعلم الآلي التقليدية الأخرى، ليتبين تفوقه في مهمة التعرف على إشارات المرور. وأخيراً، عرضنا واجهات للنظام الذي قمنا بتطويرها.

الخاتمة العامة

وفي الختام، تُظهر نتائج هذا البحث أهمية تطوير أنظمة ذكية للتعرف على إشارات المرور، بهدف تحقيق السلامة المرورية وتقليل الحوادث. من خلال تطبيق تقنيات الذكاء الاصطناعي، تم تحقيق نتائج مشجعة، حيث وصل النموذج المطور بالشبكة العصبية الالتفافية "CNN" إلى نسبة دقة تفوق 96%. وهذا يعكس الإمكانيات الكبيرة التي يمكن أن توفرها هذه التقنيات في تعزيز فعالية أنظمة المرور.

بناء على ذلك، يمكن القول بأن هذا العمل قد ساهم في تعزيز أهمية الذكاء الاصطناعي في مجال المرور، تماما كما ساهم في مجالات أخرى. كما يشير إلى مستقبل واعد لتطبيق هذه التقنيات في تطوير أنظمة مساعدة للسائقين. ويبقى مجال البحث مفتوحا لمواصلة التطوير، سواء من خلال تحسين دقة التصنيف لجميع أنواع الإشارات أو من خلال دمج النظام في بيئات واقعية.

قائمة المراجع

قائمة المراجع

- [1] الموقع: "قطوف"، "ما هي أنواع الصور الرقمية"، على الرابط <https://qtoof.academy/images-types/> ، آخر وصول في 25 جانفي 2025.
- [2] Berrezoug, L., & Benyagoub, A. (2021). Utilisation des algorithmes de l'intelligence artificielle appliquée à l'aide à la conduit. "Mémoire de Master". École Supérieure des Sciences Appliquées. De la page 22 à la page 28.
- [3] الموقع : "إجابة"، "ما هي إشارات المرور؟"، على الرابط : <https://www.ejaba.com/tag-إشارات-المرور/> ، آخر وصول في 21 جانفي 2025.
- [4] الموقع: " وزارة الداخلية السعودية"، " دليل إشارات المرور"، على الرابط: [دليل إشارات المرور - وزارة الداخلية السعودية](#) ، آخر وصول في 21 جانفي 2025.
- [5] Blake, M. (n.d.). What is digital image processing? [PowerPoint slides]. SlidePlayer. Disponible sur : [What is Digital Image Processing? - ppt download](#) .Consulté le 20 février 2025.
- [6] Young, I. T., Gerbrands, J. J., & van Vliet, L. J. (2007). Fundamentals of image processing. Delft University of Technology. Pages 3_11_46.
- [7] منار, د. ،العفراء, ع.(2020). " التعرف على اشارات المرور باستخدام الشبكات العصبية"، « مذكرة ليسانس»، جامعة الشهيد حمه لخضر -الوادي- ص58_17_14، متاح على الرابط <https://dSPACE.univ-eloued.dz/handle/123456789/25247> ، آخر وصول في 27 فيفري 2025.
- [8] وزان، م. . التعلم العميق: المبادئ والمفاهيم والأساليب (ترجمة علاء, ط.). (2022). ص117_30 ملف PDF ،متاح على الرابط [تحميل كتاب التعلم العميق المبادئ والمفاهيم والاساليب pdf - مكتبة نور](#) ،آخر وصول في 25 فيفري 2025.
- [9] Sugiharto, A., Wirawan, P. W., Nugroho, F. A., Yudiantomo, S. A., Pratama, R., & Mahe, M. H. (2022). "Comparison of SVM, Random Forest and KNN Classification By Using HOG on Traffic Sign Detection". . Disponible sur : [Comparison of SVM, Random Forest and KNN Classification By Using HOG on Traffic Sign Detection | IEEE Conference Publication | IEEE Xplore](#) . Consulté le 05 avril 2025.
- [10] الموقع: "LinkedIn" ،"ما هو تعلم الالة (machine learning)؟"، على الرابط : [ما هو تعلم الالة \(machine learning\)؟](#) ، آخر وصول في 03 مارس 2025.

- [11] نسرين, م. ، مروة, ف. ، أماني, ف. (2024). " التنبؤ بمرض السكري باستخدام طرق التعلم العميق" ، « مذكرة ليسانس» ، جامعة الشهيد حمه لخضر –الوادي- ص 10_13_14_15_16_21_22.
- [12] الموقع: "مجتمع أكايا العربي لنهج الذكاء الاصطناعي"، " التعلم العميق والشبكات العصبية الاصطناعية"، على الرابط : <https://acaiaworld.com/blog/deep-learning-and-artificial-neural-networks/>، آخر وصول في 02 مارس 2025.
- [13] Nethravathi, T. L., Akshay, K. A., Awati, S., Gautam, J., & Praveen, A. Y. (2022). "Traffic Sign Recognition System Using Machine Learning". Department of Computer Science & Engineering, Sir M Visvesvaraya Institute of Technology, Bengaluru, Karnataka, India.
- [14] Song, S., Ye, X., & Manoharan, S. (2025). " E-MobileViT: A lightweight model for traffic sign recognition". Industrial Artificial Intelligence. Disponible sur : <https://doi.org/10.1007/s44244-025-00024-2> . Consulté le 20 mars 2025.
- [15] I., Bouhoute, A., & Zinedine, A. (2025). Advancing Traffic Sign Recognition: Explainable Deep CNN for Enhanced Robustness in Adverse Environments. Disponible sur : [Advancing Traffic Sign Recognition: Explainable Deep CNN for Enhanced Robustness in Adverse Environments](#). Consulté le 05 avril 2025.
- [16] Ghose, M., Farag, S., & Butt, U. (2025). " Traffic sign recognition based on CNN vs different transfer learning techniques". In Proceedings of SPIE 13540, Fifth Symposium on Pattern Recognition and Applications (SPRA 2024) (Vol. 1354004). SPIE. Disponible sur : <https://doi.org/10.1117/12.3057582> . Consulté le 21 mars 2025.
- [17] Le site:"github". Disponible sur : [noumannahmad/Traffic Sign Recongnition](#). Consulté le 10 avril 2025.
- [18] Le site:"ByteXD"."What is Google Colab". Disponible sur : [What is Google Colab: A Beginner's Guide - ByteXD](#). Consulté le 20 avril 2025.