

## تصميم وتنفيذ نظام رؤية ذكي للأشخاص ضعيفي البصر باستخدام الشبكات العصبية العميقة

أ. د. م. نائر أحمد ابراهيم\*

م. علي عدنان عبود\*\*

(تاريخ الإيداع ٢٠٢٥/٢/٢٦ . قُبِلَ للنشر في ٢٠٢٥/٧/١)

□ ملخص □

يواجه الأشخاص من ذوي الإعاقة البصرية تحديات كبيرة في حياتهم اليومية، لا سيما فيما يتعلق بالتنقل والتعرف على الأشياء المحيطة بهم. ويسعى هذا البحث إلى تطوير نظام ذكي مساعد يعتمد على تقنيات الذكاء الاصطناعي، وتحديدًا الشبكات العصبية العميقة، من أجل التعرف على الكائنات المختلفة وتقديم تغذية صوتية مباشرة للمستخدم، بما يساهم في تحسين إدراكه لمحيطه وفهمه للبيئة المحيطة بشكل أفضل.

يعتمد النموذج المقترح على تدريب خوارزمية تعلم عميق باستخدام مجموعة صور لأجسام تُعد ذات صلة مباشرة باحتياجات الأشخاص ضعاف البصر، مثل الأدوية والأوراق النقدية والمواقع. وبالإضافة إلى التعرف على الأشياء، يوفر النظام إمكانية تقدير المسافة بين المستخدم والعوائق أو الأشخاص في البيئة المحيطة من خلال مبدأ تشابه المثلثات، دون الاعتماد على حسابات المسافة التقليدية، مما يقلل من التكاليف ويزيد من كفاءة النظام.

يعتمد النظام على أجهزة منخفضة التكلفة وهي ESP32-CAM لبث الفيديو و Raspberry Pi 3 Model

B لمعالجة البيانات. إلى جانب الاستفادة من منصة Google Colab في تنفيذ المهام الحاسوبية المعقدة بكفاءة.

أظهرت نتائج التقييم أداءً متميزاً للنموذج في التعرف على الكائنات ضمن الفئات الثلاث، حيث سجلت قيم الدقة (Precision) لكلٍ من الأوراق النقدية، المواقع، والأدوية على التوالي: ٩٦,٢%، ٩٧%، و ٩٩,٣%، في حين سجلت قيم الاسترجاع (Recall) للفئات نفسها: ٩٧%، ٩٧,٥%، و ٩٩,٥%. أما متوسط الدقة (mAP)، فقد بلغ ٩٨,٢% للأوراق النقدية، ٩٨% للمواقع و ١٠٠% للأدوية.

تعكس هذه النتائج قدرة النموذج العالية على التصنيف الموثوق للكائنات في الفئات المستهدفة، مما يؤكد فعاليته وأهميته في التطبيقات العملية التي تتطلب موثوقية وتميزاً عاليين في التعرف والتصنيف.

**الكلمات المفتاحية:** اكتشاف الكائنات، قياس المسافة، الشبكات العصبية العميقة، الرؤية الحاسوبية، المربع المحيط.

\*أستاذ دكتور في قسم هندسة الامتعة الصناعية - كلية الهندسة التقنية - جامعة طرطوس سوريا.

\*\* طالب دراسات عليا، ماجستير هندسة التحكم والامتعة الصناعية - كلية الهندسة التقنية - جامعة طرطوس - سوريا.

## Design and Implementation of an Intelligent Vision System for Visually Impaired Individuals Using Deep Neural Networks

Dr. Their Ahmad Ibrahim\*

Eng. Ali Adnan Abboud\*\*

(Received 26/2/2025 . Accepted 1/7/2025)

### □ ABSTRACT □

Visually impaired individuals face significant challenges in their daily lives, particularly with regard to mobility and object recognition. This research aims to develop an intelligent assistive system based on artificial intelligence technologies, specifically deep neural networks, to recognize various objects and provide real-time auditory feedback to the user. This contributes to enhancing the user's awareness and understanding of their surrounding environment.

The proposed model is trained using a deep learning algorithm on a dataset of images containing objects directly relevant to the needs of visually impaired individuals, such as medications, banknotes, and locations. In addition to object recognition, the system estimates the distance between the user and surrounding obstacles or people by applying the principle of triangle similarity, eliminating the need for traditional distance sensors. This approach reduces costs and improves the system's efficiency.

The system relies on low-cost hardware components, namely the ESP32-CAM for video streaming and the Raspberry Pi 3 Model B for data processing, while leveraging the Google Colab platform to perform complex computational tasks efficiently.

Evaluation results demonstrate outstanding performance of the model in recognizing objects within the three target categories. The precision values for banknotes, locations, and medications are 96.2%, 97%, and 99.3% respectively, while the recall values are 97%, 97.5%, and 99.5% for the same categories. The mean average precision (mAP) reaches 98.2% for banknotes, 98% for locations, and 100% for medications.

These results reflect the model's high reliability and classification accuracy, confirming its effectiveness and significance in practical applications that require robust and accurate object recognition.

**Keywords:** Object Detection, Distance Measurement, Deep Neural Networks, Computer Vision, Surrounding Box.

---

\*Professor in Department of Industrial Automation, Faculty of Technical Engineering, Tartous University, Syria.

\*\*Postgraduate Student, Master's in Control and Industrial Automation Engineering – Faculty of Technical Engineering – Tartous University, Syria.

**1- مقدمة:**

وفقاً للإحصائيات الأخيرة الصادرة عن منظمة الصحة العالمية، (WHO) يبلغ عدد الأشخاص الذين يعانون من ضعف البصر في جميع أنحاء العالم حوالي 285 مليوناً، منهم 246 مليوناً يعانون من ضعف البصر و 39 مليوناً مصابون بالعمى التام [1]. ومع نمو السكان وتفاقم الشيخوخة، من المتوقع أن يزيد هذا العدد ثلاث مرات بحلول عام ٢٠٤٠ [2]. وبالتالي، فإن مشكلة التعامل مع التكلفة المرتفعة المتزايدة لنظام الرعاية الصحية تسبب عبئاً ثقيلاً في العديد من البلدان. عادةً ما يكون الأشخاص الذين يعانون من ضعف البصر غير قادرين على إدراك المعلومات الخارجية، مما يؤدي إلى صعوبات ومضايقات في الحياة اليومية [3]. على سبيل المثال يتعرضون إلى السقوط بسهولة بسبب الاصطدام بالعقبات والأشياء القريبة التي من الصعب التعرف عليها.

تم اقتراح العديد من الحلول لمساعدة الأشخاص ضعاف البصر على إدراك المعلومات الخارجية. على سبيل المثال العصا البيضاء وهي أداة تقليدية للأشخاص ضعاف البصر للتنقل في محيطهم وجعل أنفسهم مرئيين للآخرين، تم تحسينها مؤخراً لتكون قابلة للطّي وأخف وزناً وأكثر سهولة [4]. ومع ذلك، فإن استخدام العصا البيضاء له حدود من حيث اكتشاف العوائق المحتملة. فهي غير قادرة على تقديم تحذير مسبق للعوائق التي قد تقترب من مسافة بعيدة، وقد لا تتعرف أيضاً على تلك العوائق المرتفعة الموجودة فوق الركبة. يستخدم العديد من الأشخاص أيضاً الأجهزة التي تدعم نظام تحديد المواقع العالمي (GPS) كأدوات مساعدة، تعمل هذه الأجهزة كواجهة ملاحية وتوجيه لتحديد المناطق المرغوبة. على الرغم من فعاليتها في تحديد المناطق، إلا أنها ليست دقيقة في تجنب وتحديد العوائق. في كثير من الحالات، تُستخدم طرق أخرى لاكتشاف العوائق، والتي تستند إلى أكواد الاستجابة السريعة، للتعرف على أنواع مختلفة من العوائق في أماكن مختلفة مثل مراكز التسوق [5]، ومع ذلك، تحتاج هذه الأساليب إلى بنية تحتية متقدمة من الناحية التكنولوجية ودعم شخص ثالث لإنجاز المهام.

مع التطورات الأخيرة في العلوم والتكنولوجيا، يمكن تحسين حياة الأشخاص الذين يعانون من ضعف البصر ويمكن جعل التنقل أسهل وأكثر فعالية. يمكن أن يساعد التكامل الفعال للرؤية الحاسوبية ومعالجة الصور في تطوير نموذج قوي وفعال وقليل التكلفة لمساعدة الذين يعانون من ضعف البصر.

يتمحور هذا العمل على تطوير تقنية مساعدة تعتمد على الذكاء الاصطناعي، تهدف إلى مساعدة ضعاف البصر على إدراك بيئتهم المحيطة وتجنب العقبات من خلال توجيهات صوتية. يتم تدريب النظام باستخدام شبكات عصبية عميقة تعتمد على بيانات محسنة لتعزيز دقته وموثوقيته، كما توظف التقنية أساليب الرؤية الحاسوبية لتوفير حلول فعالة وأمنة، تتيح التعرف على الأشياء المحيطة، واكتشاف العقبات، وتجنب الاصطدامات.

**٢- أهمية البحث وأهدافه:**

تكمن أهمية هذا البحث في تصميم جهاز صغير الحجم يتميز بدقة عالية وقابل للارتداء لضعاف البصر قادر

على:

- اكتشاف الأجسام والتعرف عليها.
  - معرفة المسافة بين الشخص ضعيف البصر وبين العائق الذي أمامه بدون حساس مسافة.
- الهدف العام من هذا البحث هو:** تصميم نظام رؤية ذكي باستخدام الشبكات العصبية العميقة يساهم في حل المشاكل التي يتعرض لها الشخص الضعيف البصر أثناء التنقل، من خلال:
- إمكانية اكتشاف الكائنات المحيطة.

- تحديد المسافة بين الشخص ضعيف البصر وبين العوائق.
- تطوير آلية لمعالجة المعطيات الضخمة بسرعة وكفاءة.

### ٣- طرائق البحث ومواده:

في البداية، سيتم توصيف نظام التعرف على الكائنات، وتحديد التجهيزات الرئيسية المستخدمة، ثم شرح آلية عمل النظام.

تشمل التجهيزات المستخدمة: Raspberry Pi 3، وحدة ESP32-CAM المزودة بكاميرا OV2640، إلى جانب مصدر تغذية.

تم استخدام الأدوات البرمجية التالية: لغة Python، موقع Roboflow، ومنصة Google Colab للمعالجة السحابية.

تم اختيار نموذج YOLOv8n نظراً لخفته وسرعته، مما يجعله مناسباً للتنفيذ على الأجهزة محدودة الموارد. ويُعد YOLO (اختصاراً لـ You Only Look Once) من نماذج الشبكات العصبية الالتفافية المخصصة لاكتشاف الكائنات في الزمن الحقيقي، حيث يُجري عملية التنبؤ بمواقع الكائنات وفئاتها دفعةً واحدة، مما يمنحه تفوقاً في السرعة مقارنةً بالنماذج التقليدية.

ونظراً لاختلاف طبيعة الكائنات المستهدفة، تم تدريب ثلاث نسخ من النموذج، كلٌّ منها مخصص لنوع مختلف من الكائنات (الأوراق النقدية، الأدوية، والمواقع). يُوضّح الجدول (١) الخصائص البنوية لكل نسخة مخصصة بحسب نوع الكائنات.

الجدول (١): الخصائص البنوية لنماذج YOLOv8n المخصصة حسب نوع الكائنات

اسم النموذج	عدد الطبقات	عدد المعلمات	عدد العمليات الحسابية لكل صورة
نموذج الأوراق النقدية	129	3,011,628	8.2 مليار
نموذج الأدوية	72	3,006,428	8.1 مليار
نموذج المواقع	98	3,007,228	8.1 مليار

تُظهر النتائج أن جميع النماذج حافظت على خفة الحجم وانخفاض استهلاك الموارد، مع وجود اختلاف بسيط في عدد الطبقات والمعاملات نتيجة التخصيص تبعاً لنوع الكائنات. ونظراً لمتطلبات المشروع التي تستلزم أداءً فعالاً وسرعة معالجة عالية، تم اختيار YOLOv8n لما يوفره من توازن مثالي بين الكفاءة والسرعة مقارنةً بالإصدارات الأكبر من السلسلة نفسها، كما يوضّح الجدول (٢) الذي يعرض مقارنة بين نسخ YOLOv8 من حيث عدد المعلمات والعمليات الحسابية لكل صورة [٦].

الجدول (٢): مقارنة بين نسخ YOLOv8 من حيث عدد المعلمات والعمليات الحسابية

اسم النموذج	الحجم (size)	عدد المعلمات	عدد العمليات الحسابية لكل صورة
YOLOv8n	٦٤٠×٦٤٠	3.2 مليون	8.7 مليار
YOLOv8s	٦٤٠×٦٤٠	11.2 مليون	28.6 مليار
YOLOv8m	٦٤٠×٦٤٠	25.9 مليون	78.9 مليار
YOLOv8l	٦٤٠×٦٤٠	43.7 مليون	165.2 مليار

#### 4- دراسات مرجعية:

نظراً لأهمية استخدام تقنيات الذكاء الاصطناعي، ولا سيما نماذج الكشف عن الأجسام، في مساعدة ذوي الإعاقة البصرية على التنقل الآمن وفهم البيئة المحيطة، فقد أجريت العديد من الدراسات التي وظفت نماذج YOLO بمختلف إصداراتها ضمن أنظمة ذكية تهدف إلى تحقيق هذا الغرض. تستعرض الفقرات التالية أبرز هذه الدراسات، مع تسليط الضوء على الأساليب المعتمدة والنتائج المحققة، وذلك لتحديد التوجهات البحثية السابقة وتقييم مدى فاعليتها في هذا السياق.

اقترح الباحث **Wei Wang** وآخرون عام ٢٠٢٤ طريقة لاكتشاف العوائق تهدف إلى مساعدة المكفوفين وضعاف البصر على التنقل في البيئات الخارجية، وذلك من خلال الاستفادة من نموذج YOLO-OD المُصمم لتحسين التمييز بين العوائق باختلاف أحجامها. تم تقييم النموذج على قاعدة بيانات عامة، وبلغ متوسط الدقة فيه ٣٠,٠٢%، مما يُظهر إمكانية استخدامه في تطبيقات المساعدة البصرية والتنقل الآمن لذوي الإعاقة البصرية [٧].

في دراسة أخرى، قدّم الباحث **Jeloux P. Docto** وآخرون عام ٢٠٢٢ نظاماً ذكياً يُساعد ذوي الإعاقة البصرية في اكتشاف الأجسام داخل الأماكن المغلقة، وذلك باستخدام نموذج YOLOv4-tiny لاكتشاف الأجسام. يعتمد النظام على كاميرا موصولة بوحدة Raspberry Pi 4B لالتقاط الصور، والتي تُعالج لاحقاً لتحديد نوع الجسم. بعد التعرف، تُقدّر المسافة الفاصلة بين الجسم والكاميرا باستخدام خوارزمية قياس المسافة، وتُعرض النتائج على المستخدم من خلال مخرجات صوتية. أُجري النظام أربعين (٤٠) تجربة على كائنات من مجموعة بيانات COCO ضمن بيئات داخلية. بلغ المتوسط العام لمقاييس F1 والدقة والاسترجاع وصحة التنبؤ ٨٣,٠٠% [٨].

بينما طوّر الباحث **Akilesh Salunkhe** وآخرون عام ٢٠٢١ تطبيقاً بسيطاً يعمل على الهواتف الذكية بنظام أندرويد، يهدف إلى مساعدة ضعاف البصر على فهم محيطهم عبر التعرف على الأجسام في الزمن الحقيقي وتحويلها إلى أوصاف صوتية. يعتمد التطبيق على كاميرا الهاتف حصرياً لالتقاط المشهد، ويستخدم مكتبة TensorFlow Object Detection API لاكتشاف الأجسام، تليها عملية تحويل النتائج إلى صوت باستخدام مكتبة التحويل من النص إلى كلام. ويُسهّم اعتماد TensorFlow Lite في تنفيذ المعالجة محلياً على الهاتف دون الحاجة إلى اتصال بالإنترنت. وقد بلغت دقة النظام نحو ٩٠% [٩].

وقد قام الباحث **Helawe Behailu Erdaw** وآخرون عام ٢٠٢١ بتطبيق نموذج YOLOv2 على مجموعة بيانات معدّة مسبقاً تحتوي على ثلاث فئات مختلفة هي: الحفر، وسلال القمامة، والأعمدة، كما تم اقتراح تقنية تُعرف بـ "الذاكرة قصيرة الأمد" (Short-Term Memory) تأخذ في الاعتبار المعلومات بين الإطارات لتعزيز قدرة

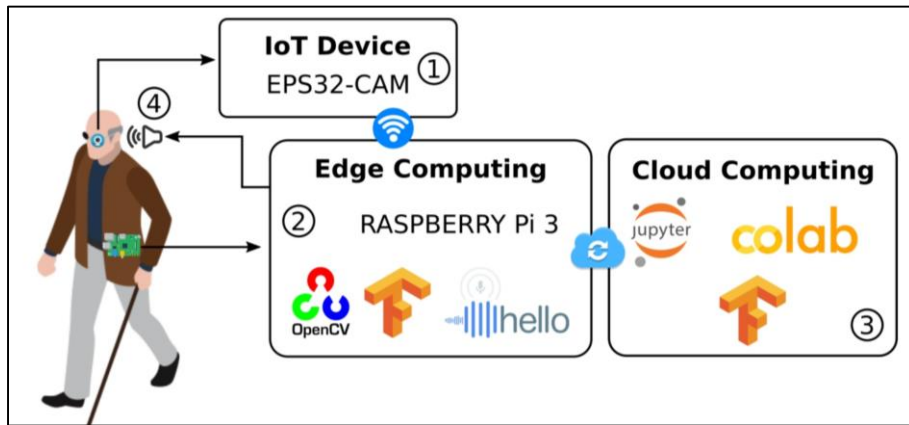
النموذج YOLO على الكشف ضمن بث الفيديو، من خلال تضمين مهام تقدير موقع الجسم وحجمه. وقد حقق النظام دقة متوسطة (mAP) بلغت ٦٠,١٧%، بسرعة كشف متوسطة قدرها ٣٤,٦ إطاراً في الثانية [١٠].

وقدمت الباحثة Mouna Afif عام ٢٠٢٠ دراسة تقترح فيها شبكة عصبية التلافية عميقة (DCNN) لاكتشاف الأجسام في البيئات الداخلية، بهدف دعم تنقل ذوي الإعاقة البصرية. يعتمد التصميم على نموذج YOLOv3، وتم استخدام مجموعة بيانات جديدة تحتوي على نحو ٨٠٠٠ صورة تغطي ١٦ فئة من الأجسام الداخلية، مع تنوع في الإضاءة والتصاميم المعمارية. أظهرت النتائج أن النموذج حقق متوسط دقة (mAP) بلغ ٧٣,١٩% [١١].

## ٥- تصميم النظام:

### ٥-١ مكونات النظام:

يوضح الشكل (١) نظام الرؤية المراد تصميمه :



الشكل (1): مخطط نظام الرؤية المصمم


ينقسم المخطط المقترح إلى أربعة أجزاء رئيسية، هي:

- ١- الكاميرا: تعمل على التقاط الصور المباشرة للبيئة المحيطة لتوفير بيانات مرئية لمعالجة المعلومات.
- ٢- المعالجة المحلية: تستقبل الصور من الكاميرا وتقوم بمعالجتها باستخدام خوارزميات متقدمة للتعرف على الكائنات وتصنيفها بدقة.
- ٣- المعالجة السحابية: تُوفّر بيئة معالجة متطورة تُسهم في تسريع تنفيذ عمليات الاستدلال وتحليل الصور، مما يُقلّل من التأخير الزمني ويُعزّز كفاءة الأداء، خاصة في التطبيقات التي تتطلب استجابة فورية في الوقت الحقيقي.
- ٤- وحدة الإخراج الصوتي: تقدّم لضعيف البصر تغذية صوتية تفاعلية توضح أسماء الكائنات المكتشفة والمسافات الفاصلة بينها وبينه، مما يُتيح له استيعاب البيئة المحيطة بسهولة.

## ٥-٢ المكونات المادية للنظام:

### ٥-٢-١ شريحة الراسبيري باي :

قمنا باختيار راسبيري باي ٣ موديل B المبيّن في الشكل (٢)، وهو أحدث نسخة متوفرة من الإصدار B، حيث تعمل بنظام تشغيل لينكس، ويمتلك المواصفات التي تلبي احتياجات النظام المراد تصميمه.



الشكل (2): Raspberry Pi 3 Model B.

### ٥-٢-٢ الشريحة ESP32-CAM:

هي عبارة عن وحدة تحكم دقيقة قوية مزودة بكاميرا مدمجة. تتميز بشريحة ESP32 الموثوقة، والتي تضمن الأداء العالي واستهلاك الطاقة المنخفض. تلتقط كاميرا OV2640 المضمنة صوراً ومقاطع فيديو واضحة بدقة تصل إلى ١٦٠٠ × ١٢٠٠ بكسل، مما يجعلها مثالية للمراقبة في الوقت الفعلي ومعالجة الصور. يظهر الشكل (٣) شريحة ESP32-CAM المستخدمة.



الشكل (٣): شريحة ESP32-CAM

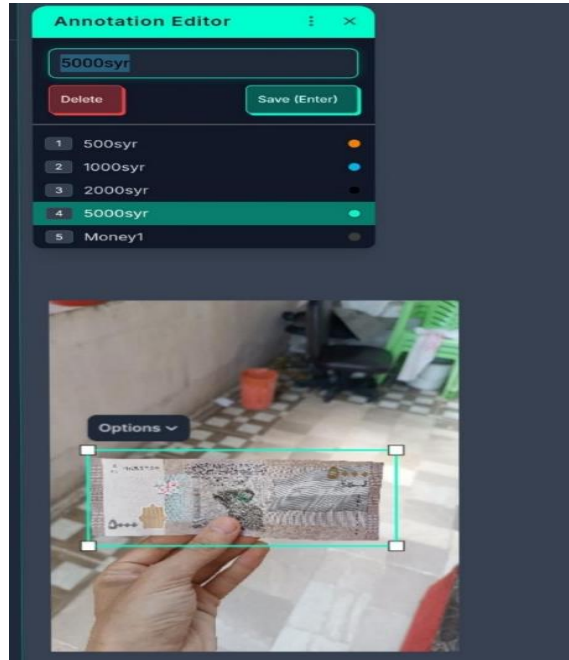
### ٥-٣ البدء في تدريب الشبكة العصبية:

تمهيداً لتدريب النموذج، تُستخدم منصة Roboflow، التي تُعد أداة متخصصة في تسهيل بناء نماذج الرؤية الحاسوبية، حيث تتيح إنشاء مشروع جديد ورفع الصور الخاصة بالنظام المقترح. تدعم المنصة تجهيز البيانات وتصديرها بصيغ تتوافق مع نماذج الكشف عن الكائنات، ولا سيما إصدارات YOLO المختلفة، مما يُسهّل لاحقاً تدريب النموذج المطلوب.

بعد تجهيز مجموعة البيانات، يتم تصديرها بصيغة مناسبة لاستخدامها في بيئة Google Colab، وهي منصة سحابية توفر موارد حوسبة قوية تساهم في تسريع عملية التدريب وتحسين دقة النموذج في اكتشاف العناصر وقياس المسافات.

### ٥-٣-١ تحديد الكائنات وتصنيفها:

في هذه المرحلة، يتم تحديد كل كائن داخل الصور عن طريق رسم إطار يحيط به، مع إسناد اسم مناسب له يعبر عن الفئة التي ينتمي إليها، كخطوة تمهيدية لتدريب النموذج على التعرف على هذه الكائنات. يُوضّح الشكل (٤) مثالاً على عملية تحديد الكائنات وتصنيفها بالشكل المناسب.



الشكل (٤): تحديد الكائن وتسميته

### ٥-٣-٢ تقسيم التدريب/الاختبار (Train/Test Split):

في هذه المرحلة يتم فصل البيانات إلى تقسيمات التدريب والتحقق والاختبار لمنع النموذج من الإفراط في التجهيز وتقييم النموذج بدقة.

#### مجموعة التدريب (Training Set):

تحتوي على البيانات التي يتعلم منها النموذج. أثناء التدريب، يقوم النموذج بضبط الأوزان والمعاملات الداخلية استناداً إلى هذه البيانات. الهدف هو تقليل دالة الخسارة (Loss Function)، مثل خطأ التصنيف أو خطأ التنبؤ.

#### مجموعة التحقق (Validation Set):

هي مجموعة فرعية من البيانات تُستخدم لتقييم أداء النموذج أثناء عملية التدريب. تهدف هذه المجموعة إلى قياس قدرة النموذج على التعميم على بيانات جديدة لم يتعلمها خلال التدريب. تُستخدم أيضاً لضبط معاملات النموذج، مثل عدد الطبقات في الشبكات العصبية، بالإضافة إلى اكتشاف مشكلات مثل الإفراط في التكيف (Overfitting). إذا كان أداء النموذج جيداً على مجموعة التحقق، فهذا يشير إلى أنه يتعلم الأنماط بشكل صحيح، مما يساعد في تحسين أدائه قبل مرحلة الاختبار النهائي.

**مجموعة الاختبار (Test Set):**


تُستخدم فقط بعد اكتمال التدريب وضبط جميع المعلمات. وتهدف إلى تقييم أداء النموذج على بيانات جديدة تماماً. ولا يمكن استخدامها أثناء التدريب لأنه إذا استخدمنا مجموعة الاختبار أثناء التدريب أو لضبط المعلمات، فسنخاطر بتحيز التقييم، ولن نتمكن من قياس الأداء الحقيقي للنموذج في العالم الواقعي.

**٣-٣-٥ خيارات التعزيز (Augmentation):**

هو أسلوب يُستخدم لتحسين تدريب النماذج عن طريق تعديل الصور الموجودة لزيادة تنوع البيانات. عند تدريب نموذج على مجموعة من الصور، قد تكون هذه الصور محدودة في عددها أو لا تعكس جميع الظروف التي قد تظهر في العالم الحقيقي. وهنا تأتي فائدة التعزيز (Augmentation)، حيث تُعدّل الصور بطرق بسيطة مثل التدوير أو تغيير الحجم أو تعديل الألوان أو القص، وذلك لخلق نسخ جديدة من الصور الأصلية. الهدف من هذه العملية هو تمكين النموذج من التعرف على الأشياء في ظروف مختلفة. فعلى سبيل المثال، إذا كان النموذج يتدرّب على صور لسيارات، فإنّ التعزيز قد يساعده على التعرف على السيارة سواء كانت مائلة، أو مظلمة، أو ضمن إضاءة مختلفة. وهذا بدوره يُعزّز من مرونة النموذج ويُمكنه من التعمق في الأنماط الأساسية للكائنات، بدلاً من التركيز فقط على تفاصيل الصورة الأصلية.

**٤-٥ قياس المسافة:**

يعد تقدير المسافة بين الشخص ضعيف البصر والعوائق أمامه أمراً ضرورياً لضمان تنقله بأمان. هناك عدة طرق لقياس المسافة، مثل استخدام الموجات فوق الصوتية والليزر والرؤية الحاسوبية. في هذا البحث، سيتم الاعتماد على طريقة قائمة على الرؤية فقط، دون الحاجة إلى حساسات إضافية، مما يقلل التكلفة والتعقيد. تعتمد هذه الطريقة على العلاقة بين الحجم الحقيقي للكائن وحجمه الظاهر في الصورة، بالاستفادة من البعد البؤري للكاميرا ومبدأ تشابه المثلثات لحساب المسافة بدقة. يوضح الشكل (٥) كيفية حساب المسافة بالاعتماد على حجم الكائن في الصورة.



الشكل: (٥): حساب المسافة بالاعتماد على حجم الكائن في الصورة

حيث أن  $f$ : تمثل البعد البؤري للكاميرا المستخدمة،  $w$ : البعد المرجعي للكائن في الصورة (بالبكسل) يمكن حسابه برمجياً.

$d$ : هي المسافة بين الكاميرا والجسم الذي أمامه، وهي المسافة التي نريد حسابها.

$W$ : البُعد المرجعي للكائن في الواقع، يجب ادخاله يدوياً في البرنامج، فمثلاً لو أردنا قياس المسافة بين الكاميرا ولوحة حائط، يجب قياس عرض اللوحة وليكن 50 cm وادخال  $W=50$ . من تشابه المثلثات ينتج ان:

$$\frac{f}{d} = \frac{w}{W} \quad (1)$$

$$F = w * \frac{d}{W} \quad (2)$$


$$d = W * \frac{f}{w} \quad (3)$$

بما أن كلاً من  $f$  (البعد البؤري للكاميرا) و  $w$  (البُعد المرجعي للكائن في الصورة) معلوم، فإن حساب المسافة  $d$  يتطلب معرفة البُعد المرجعي للكائن في الواقع  $W$ .

تكمن المشكلة في أن تقدير المسافة يعتمد على معرفة الأبعاد الفعلية للكائن، مما يستلزم استخدام كائنات ذات بعد ثابت، وهو أمر صعب للغاية. لذا، كان من الضروري إيجاد كائنات ذات أبعاد ثابتة يمكن استخدامها كمرجع موثوق. بعد البحث، تبين أن المسافة بين الحدقتين لدى البالغين تُعدّ قيمة ثابتة، حيث تبلغ قيمتها 64 mm لدى الذكور و62 mm لدى الإناث، بمتوسط عام 63 mm، كما هو موضح في الشكل (٦). ونظراً لثبات هذه القيمة لدى الأفراد البالغين [12]، يمكن اعتمادها كمرجع موثوق لقياس المسافة. أي أن  $W=63$  mm.

وبعد تحديد قيمة  $W$ ، أصبح من الممكن حساب المسافة بين الكاميرا وأي شخص بالغ يقف أمامها بدقة،

باستخدام المعادلة (٣).



الشكل (6): متوسط البعد بين الحدقتين

- في البداية، نحتاج إلى حساب العمق البؤري للكاميرا  $f$  ، لذلك يتم إجراء عملية المعايرة كما يلي:
- يُوضَع الكائن أو الجسم على مسافة معلومة تم قياسها مسبقاً، وهي ٦٠ سم في هذا المثال، أي  $d=60$ .
  - يُحدّد مركز كل حدقة (في العين اليمنى واليسرى)، ثم يُرسم خط بينهما، وتُحسب المسافة بين العينين برمجياً، ومن ذلك يتم الحصول على  $w$ ، وفي حالتنا  $w=80$ .
  - علماً بأن المسافة الحقيقية بين الحدقتين هي ٦٣ mm أي أن  $W=6.3$  cm.
  - يُحسب البعد البؤري  $f$  باستخدام المعادلة (٢)، وبعد إجراء الحساب نجد أن  $f=6.3$  cm.
  - وتُستخدم هذه القيمة مباشرة في الخطوة التالية.
  - بعد ذلك، يمكن حساب المسافة  $d$  باستخدام المعادلة (٣).

## ٦- اختبار النظام ومناقشة النتائج:

## ٦-١ تحليل دقة النموذج باستخدام مجموعات التحقق والاختبار:


لضمان دقة وفعالية النموذج المصمم لاكتشاف الأجسام وتصنيفها، يتم تقييم أدائه باستخدام مجموعتي التحقق والاختبار، حيث تلعب كل منهما دوراً أساسياً في عملية التقييم.

**نتائج مجموعة التحقق (Validation Set):** تُستخدم أثناء التدريب لضبط المعلمات وتحسين أداء النموذج. تعكس هذه المجموعة أداء النموذج أثناء التدريب، لكنها ليست كافية لتقييم أدائه الحقيقي بشكل كافي، لأن بياناتها تُستخدم بالفعل في تحسينه. الاعتماد على مجموعة التحقق فقط يؤدي إلى تقييم غير موضوعي، حيث يتم اختبار النموذج على بيانات سبق استخدامها في تحسينه، مما قد يؤدي إلى تقييم متحيز لا يعكس قدرة النموذج الحقيقية على التعميم.


**نتائج مجموعة الاختبار (Test Set):** تُستخدم بعد اكتمال التدريب لتقييم الأداء النهائي للنموذج على بيانات جديدة لم تُستخدم أثناء التعلم. تعطي هذه المجموعة مؤشراً حقيقياً لقدرة النموذج على التنبؤ في مواقف جديدة. ومع ذلك، الاعتماد على مجموعة الاختبار فقط دون استخدام مجموعة التحقق يعني عدم وجود فرصة لضبط وتحسين النموذج أثناء التدريب، مما قد يؤدي إلى نموذج غير محسّن بشكل كافٍ أو أداء دون المستوى المطلوب.

## ٦-٢-١ تحليل نتائج النموذج في تصنيف الأوراق النقدية:

يُظهر كل من الشكلين (٧) و(٨) نتائج تحليل أداء النموذج على مجموعتي التحقق والاختبار، حيث حقق دقة إجمالية بلغت ٩٨%. أظهرت معظم الفئات دقة ١٠٠%، باستثناء فئة "1000syr" في مجموعة التحقق، التي سجلت ٩٤%، وفئة "2000syr" في مجموعة الاختبار، التي سجلت ٩٣%. تعكس هذه النتائج أداءً مستقرًا للنموذج، مع إمكانية تحسين دقة بعض الفئات بشكل إضافي.



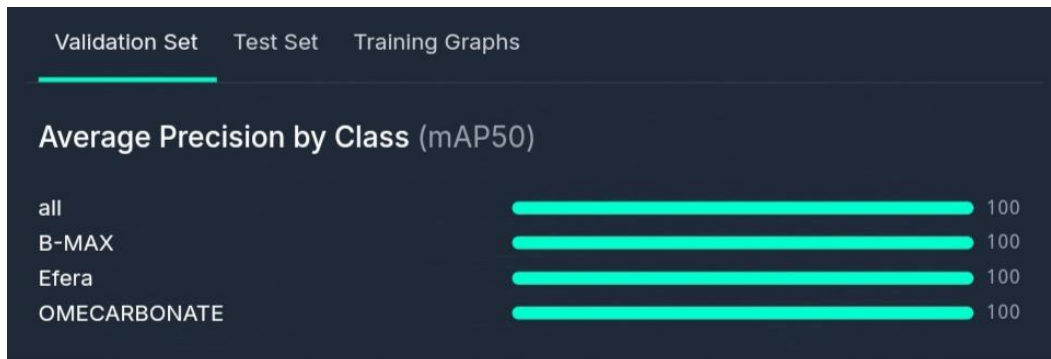
الشكل (7): نتائج مجموعة التحقق للأوراق النقدية



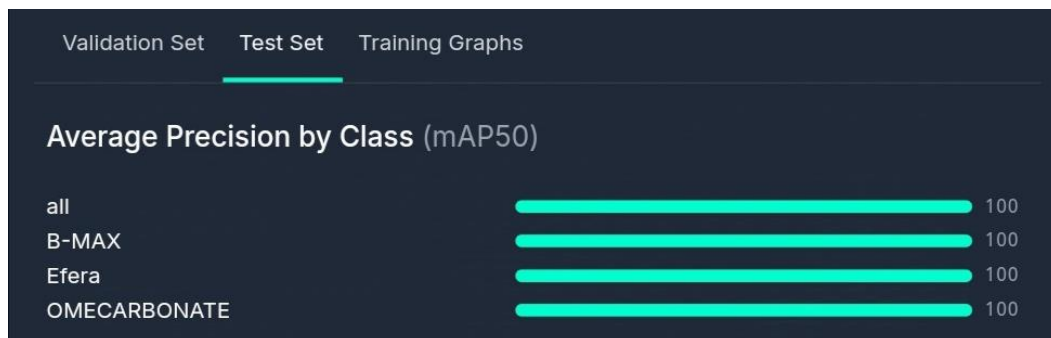
الشكل (8): نتائج مجموعة الاختبار للأوراق النقدية

### ٦-٢-٢ تحليل نتائج النموذج في تصنيف الأدوية:

يُظهر كلٌّ من الشكلين (٩) و (١٠) نتائج تحليل أداء النموذج على مجموعتي التحقق والاختبار، حيث حققت كلٌّ من المجموعتين دقة بنسبة ١٠٠% لجميع الفئات التي تم تدريب النموذج عليها، وعددها ثلاث فئات، وهي: B- Efera.max و Omecarbonate. تعكس هذه النتائج كفاءة عالية للنموذج في اكتشاف الكائنات وتصنيفها بدقة، مما يدل على قدرته على التعميم ضمن البيانات المستخدمة في التحقق والاختبار.



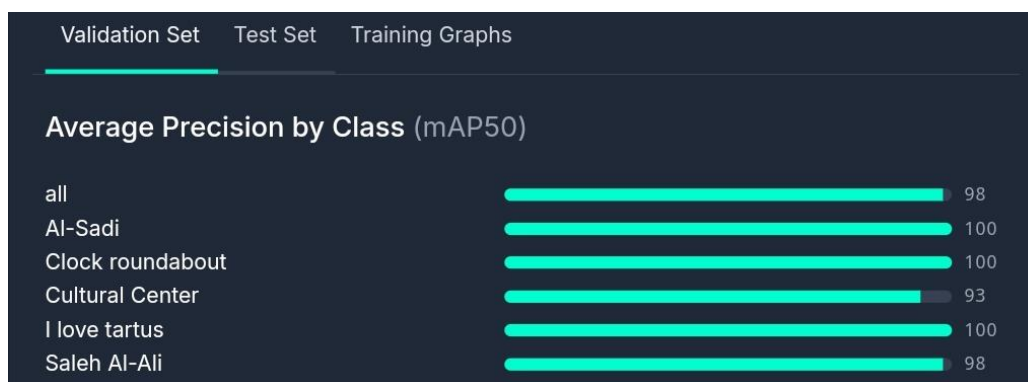
الشكل (9): نتائج مجموعة التحقق للأدوية




الشكل (10): نتائج مجموعة الاختبار للأدوية

### ٦-٢-٣ تحليل نتائج النموذج في تصنيف المواقع:

يظهر كل من الشكلين (١١) و (١٢) نتائج تحليل أداء النموذج على مجموعتي التحقق والاختبار، حيث تُبرز النتائج كفاءة النموذج في اكتشاف المواقع بدقة إجمالية بلغت ٩٨% على مجموعة التحقق (Validation Set) و ٩٩% على مجموعة الاختبار (Test Set). حققت الفئات دقة ممتازة بلغت ١٠٠% باستثناء انخفاض طفيف في دقة التحقق لموقع "المركز الثقافي" (٩٣%) و "صالح العلي" (٩٨%)، مما يعكس أداءً مستقرًا مع إمكانية تحسين دقة هذه المواقع.



الشكل (١١): نتائج مجموعة التحقق للمواقع



الشكل (١٢): نتائج مجموعة الاختبار للمواقع

### ٦-٢ تحليل نتائج الدقة والاسترجاع ومتوسط الدقة:

تُعدُّ نتائج الدقة (Precision) والاسترجاع (Recall) ومتوسط الدقة (mAP: mean Average Precision) مؤشرات حاسمة لتقييم أداء النموذج. تعبر هذه المقادير عن مدى كفاءة النموذج في تحديد الكائنات بدقة واكتشافها بشكل كامل، حيث يقيس Precision مدى دقة النموذج في تحديد الكائنات الصحيحة، بينما يقيس Recall قدرته على اكتشاف جميع الكائنات المستهدفة. أما mAP، فيجمع بين Precision و Recall ليعطي تقيماً شاملاً ودقيقاً لأداء النموذج في استرجاع الكائنات الصحيحة المكتشفة وتصنيفها بشكل صحيح. تُسهم هذه المؤشرات في تحسين النموذج للوصول إلى توازن أفضل بين دقته وشموليته في الكشف.

### ٦-٢-١ تحليل نتائج الدقة والاسترجاع ومتوسط الدقة على الأوراق النقدية:

يظهر الشكل (١٣): نتائج التدريب النموذجي الخاص بالعملات حيث أن: Precision = 96.2% تعني أن ٩٦,٢% من الكائنات التي اكتشفها النموذج كانت صحيحة، بينما كانت خاطئة ٣,٨%. Recall = 97% تعني أن النموذج تمكن من اكتشاف ٩٧% من الكائنات الحقيقية، بينما لم يكتشف ٣%. mAP = 98.2% تعني أن النموذج يقدم أداءً عالياً جداً في اكتشاف وتصنيف الكائنات بدقة.



الشكل (13): نتائج التدريب النموذجي الخاص بالأوراق النقدية

### ٦-٢-٢ تحليل نتائج الدقة والاسترجاع ومتوسط الدقة على الأدوية:

يظهر الشكل (١٤): نتائج التدريب النموذجي الخاص بالأدوية، حيث أن التوضيح كما في الفقرة السابقة (نتائج الدقة والاسترجاع ومتوسط الدقة على الأوراق النقدية).



الشكل (14): نتائج التدريب النموذجي الخاص بالأدوية

### ٦-٢-٣ تحليل نتائج الدقة والاسترجاع ومتوسط الدقة على المواقع:

يظهر الشكل (١٥): نتائج التدريب النموذجي الخاص بالمواقع، حيث أن التوضيح كما في الفقرة السابقة (نتائج الدقة والاسترجاع ومتوسط الدقة على الأوراق النقدية).



الشكل (15): نتائج التدريب النموذجي الخاصة بالمواقع

### ٦-٣ المنحنيات الرسومية التدريبية (Training Graphs):

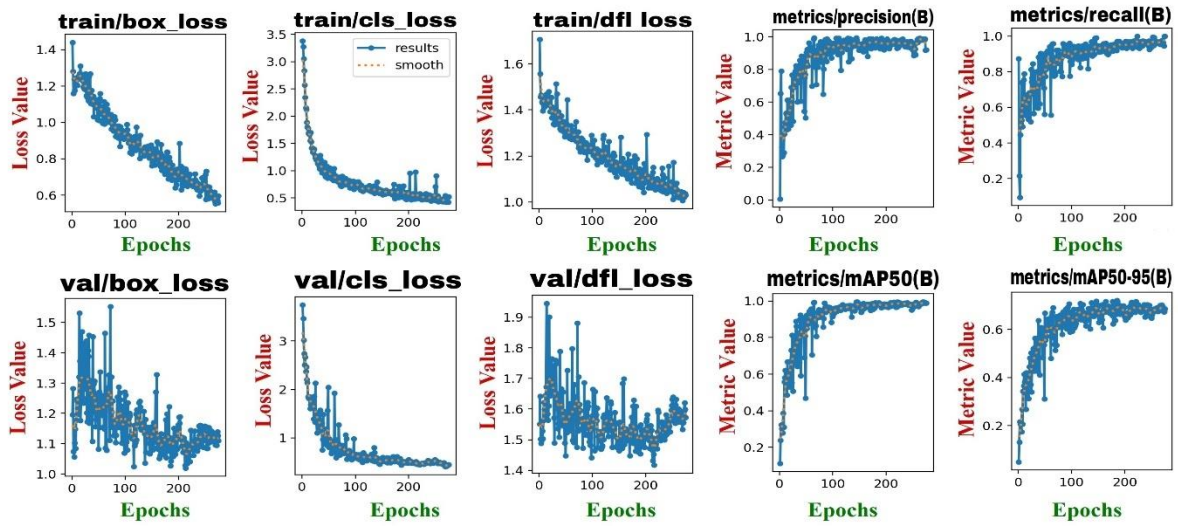
- الهدف منها هو تقديم تصور مرئي لأداء النموذج خلال عملية التدريب. تساعد هذه الرسوم البيانية في:
  - ١-مراقبة عملية التدريب: توضح كيفية استجابة النموذج لبيانات التدريب بمرور الوقت، ما يساعد في فهم تقدم التعلم ومدى استقرار الأداء.
  - ٢- تقييم الأداء: تسهل مقارنة أداء النموذج على بيانات التدريب والتحقق لاكتشاف المشاكل مثل الإفراط أو نقص التعلم.
  - ٣- تحليل النتائج: تعرض المنحنيات مؤشرات تقييم الأداء مثل الخسارة (Loss) والدقة (Accuracy) لتحديد جودة النموذج.

٤- **ضبط النموذج**: تساعد في اتخاذ قرارات بشأن تعديل معلمات التدريب أو إيقاف التدريب في الوقت المناسب. بشكل عام، تُستخدم هذه المنحنيات لضمان أن النموذج يتعلم بشكل صحيح ويحقق أداءً جيداً قبل نشره.

### 6-3-1 المنحنيات الرسومية التدريبية الأوراق النقدية:

يُبين الشكل (١٦) المنحنيات الرسومية التدريبية للعمليات، ومن هذه المنحنيات نستنتج ما يلي:

- منحنيات خسارة التصنيف (cls loss) في التدريب والتحقق متقاربة بشكل كبير، مما يعني أن النموذج يتعامل مع مهمة التصنيف بشكل مستقر، وهي المهمة الأساسية التي تعتمد عليها مهام الرؤية الحاسوبية. يشير ذلك إلى أن النموذج قد تعلم تمييز الكائنات وتصنيفها بدقة، مما يثبت فعاليته في التعميم على بيانات جديدة.
  - بالنسبة لمنحنيات box loss و dfl loss، يوجد تفاوت ملحوظ بين التدريب والاختبار، وهو أمر طبيعي، حيث أن تحديد المربعات وتوقع الفروقات أكثر تعقيداً من التصنيف. الأهم هو أن كلا المنحنيين يسيران في نفس الاتجاه وينخفضان معاً، مما يدل على أن النموذج يتعلم بشكل صحيح. نظراً لأن الهدف الأساسي من النظام هو تصنيف العملات وتحولها إلى صوت، وليس تحديد مواقعها بدقة عالية، فلا حاجة لتحسين هذه القيم بشكل كبير.
  - نلاحظ من منحنى metrics/precision أن القيمة ١ تظهر عند العتبات التي تعني أن النموذج حقق دقة مثالية في تصنيفه للعناصر الإيجابية.
  - نلاحظ من منحنى metrics/Recall أن القيمة ١ تظهر عند العتبات التي تؤدي إلى تصنيف جميع الحالات الإيجابية بدقة، مع عدم وجود حالات خاطئة.
  - استقرار metrics/mAP50 عند القيمة ١ يعني أن جميع التنبؤات التي ينتجها النموذج تتداخل مع الحقيقة بنسبة ٥٠% على الأقل، وبالتالي يتم تصنيفها على أنها صحيحة.
  - استقرار metrics/mAP50-95 عند القيمة ٠,٦ يُعتبر جيدة جداً لأنه يعكس أداءً قوياً عبر مجموعة من قيم IOU بما في ذلك القيم الصارمة مثل ٠,٧٥ و ٠,٩٠. هذه القيمة تُظهر أن النموذج لا يكتفي بالكشف عن الكائنات بشكل عام، بل يحدد مواضعها بدقة عالية في معظم الحالات، مما يشير إلى كفاءة النموذج وقدرته على العمل في ظروف مختلفة.
- المحور الأفقي** في جميع الرسوم البيانية يُمثل عدد الحقبات (Epochs)، أي عدد مرات تكرار التدريب على مجموعة البيانات. **أما المحور العمودي** فيختلف باختلاف نوع المنحنى:
- في رسوم الخسائر (box loss, cls loss, dfl loss): يُمثل مقدار الخسارة (Loss Value).
  - في مؤشرات Precision و Recall و mAP50 و mAP50-95: تعبّر القيم الظاهرة عن مستويات الأداء، وتتراوح بين ٠ و ١، حيث تشير القيم الأعلى إلى أداء أفضل للنموذج.

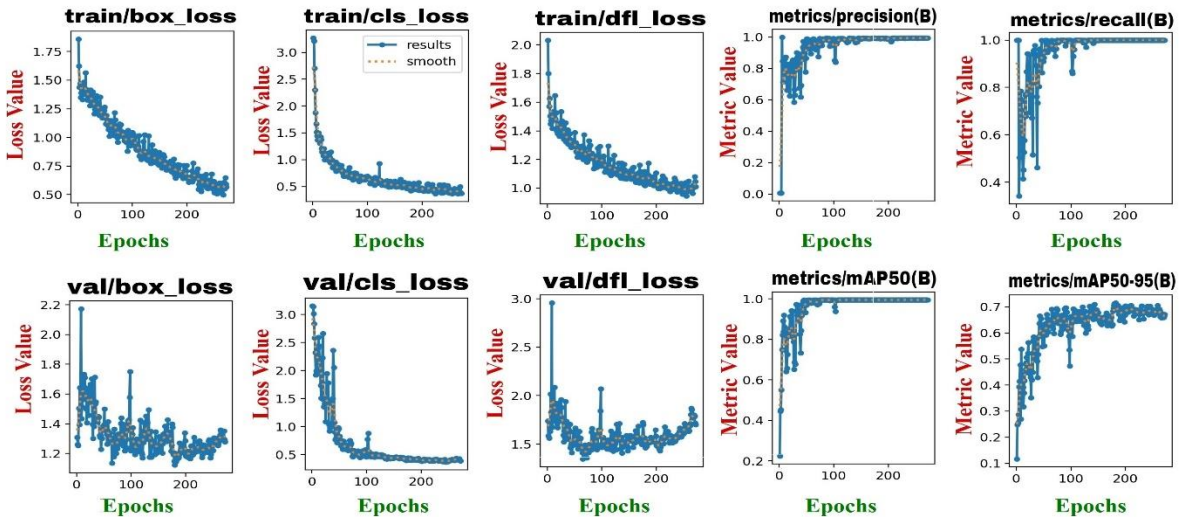


الشكل (16): المنحنيات الرسومية التدريبية للأوراق النقدية

### ٦-٣-٢ المنحنيات الرسومية التدريبية للأدوية:

يُبين الشكل (١٧) المنحنيات الرسومية التدريبية للأدوية، ومن هذه المنحنيات نستنتج ما يلي:

- منحنيات box loss و dfl loss تُظهر تقارباً أفضل بكثير بين منحنيات التدريب والاختبار مقارنةً بالعملات، ويُعزى ذلك إلى عدة أسباب، أبرزها زيادة حجم البيانات التي تم استخدامها في التدريب.
- بالنسبة لبقية المنحنيات، كما ورد في الفقرة السابقة (المنحنيات الرسومية التدريبية للأوراق النقدية).

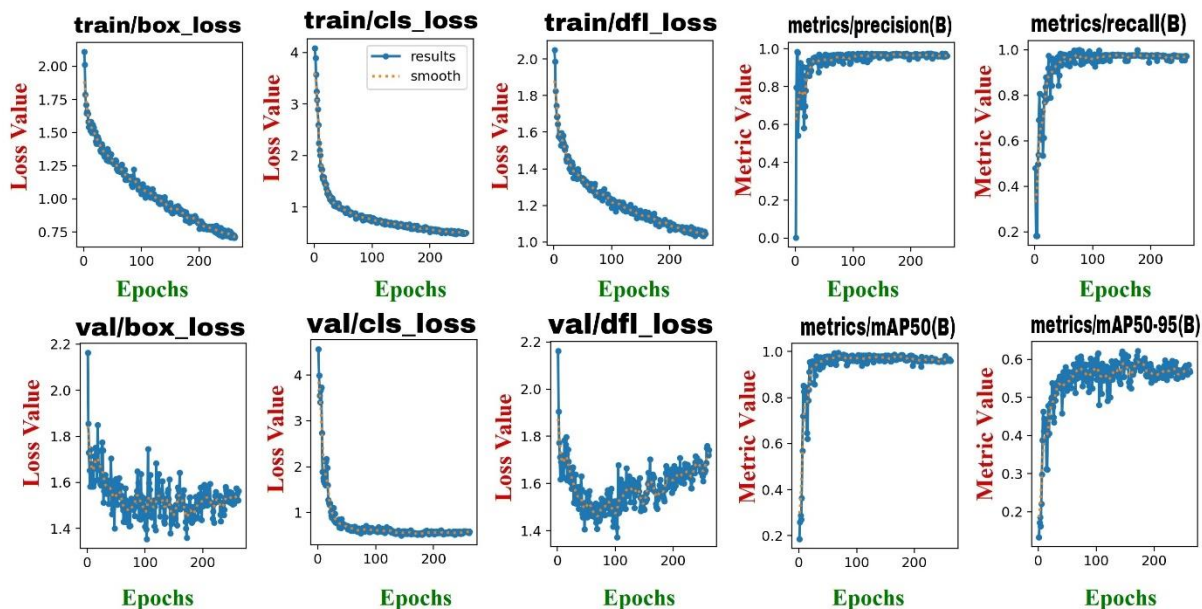


الشكل (١٧): المنحنيات الرسومية التدريبية للأدوية

### ٦-٣-٣ المنحنيات الرسومية التدريبية للمواقع:

يبين الشكل (١٨) المنحنيات الرسومية التدريبية للمواقع، ومن هذه المنحنيات نستنتج ما يلي:

- منحنى cls loss متقارب بشكل كبير جداً، وهذا يعود إلى أن الاختلافات بين المواقع كبيرة جداً وأكثر وضوحاً (مثل اختلاف الشكل أو اللون أو الحجم)، وبالتالي يسهل على النموذج التمييز بينها.
- بالنسبة لبقية المنحنيات، كما في الفقرتين السابقتين (المنحنيات الرسومية التدريبية للأوراق النقدية والأدوية).




الشكل (١٨): المنحنيات الرسومية التدريبية للمواقع

#### ٦-٤ نتائج الاختبارات العملية:

التجربة العملية لها أهمية بالغة في التحقق من صحة النماذج النظرية من خلال ربطها بالتطبيق العملي، حيث تساهم في قياس دقة النتائج وتوثيقها، واختبار كفاءة النظام تحت ظروف مختلفة، مما يعزز من موثوقيته وإمكانية تطويره. كما توفر إثباتاً عملياً لدعم الفرضيات، وتحفز الابتكار بحل التحديات التي قد تظهر أثناء التنفيذ، مما يجعلها خطوة أساسية في تحسين الأداء وتطوير التطبيقات المستقبلية.

#### ٦-٤-١ نتائج التجربة العملية لاكتشاف الأوراق النقدية:

نلاحظ من الشكل (١٩) أنه تم التعرف على جميع العملات النقدية بشكل صحيح، رغم وجود ضبابية كبيرة، خاصة في فئتي ٥٠٠ و ١٠٠٠ ليرة. يعود ذلك إلى استخدام زيادة البيانات الضبابية أثناء تدريب الشبكة العصبية، مما ساعد في تحسين قدرة النموذج على التعرف على العملات حتى في ظروف تصوير غير مثالية. وهذا يؤكد أهمية إضافة مثل هذه التحسينات خلال عملية التدريب.



الشكل (١٩): نتائج الاختبار على عملات ورقية مختلفة

## ٦-٤-٢ نتائج التجربة العملية لاكتشاف الادوية:

نلاحظ من الشكل (٢٠) أن دقة اكتشاف الأدوية عالية جداً، حيث تم التعرف على الأدوية بنجاح على الرغم من الضبابية الكبيرة جداً، خاصة في عبوتي Efera و Omecarbonate. يعود هذا الأداء القوي إلى إدراج بيانات ضبابية أثناء تدريب الشبكة العصبية، مما عزز قدرة النموذج على التعرف على الأدوية حتى في البيئات ذات جودة تصوير منخفضة. وهذا يبرز أهمية استخدام تقنيات زيادة البيانات لتحسين دقة النموذج في ظروف متنوعة.



الشكل (20): نتائج الاختبار على ادوية مختلفة

## ٦-٤-٣ نتائج التجربة العملية لاكتشاف المواقع:

يُظهر الشكل (٢١) لافتة (السعدي)، ونلاحظ أن النظام تمكن من التعرف عليها بدقة، رغم وجود عائق أمامها وهو الشجرة التي تغطي جزءاً كبيراً من اللافتة. ومع ذلك، استطاعت الشبكة العصبية التعرف عليها بفعالية، مما يدل على كفاءتها في التعامل مع العوائق البصرية أثناء عملية الاكتشاف.



الشكل (٢١): لافتة السعدي للسيارات في طرطوس

يُظهر الشكل (٢٢) دوار الساعة، ونلاحظ أنّ النظام تمكّن من التعرف عليه في ظروف طبيعية تماماً، على الرغم من وجود السيارات في المشهد. ويُشير ذلك إلى قدرة النموذج على اكتشاف المعالم البارزة حتى في ظل وجود عناصر متحركة ضمن البيئة المحيطة.



الشكل (٢٢): دوار الساعة في طرطوس

يُظهر الشكل (٢٣) التعرف على لافتة "I love Tartous" من مسافة تجاوزت ٣٠ متراً، مما يعكس قدرة النظام على التعرف على العناصر البصرية ضمن بيئة واقعية، حتى في ظروف غير مثالية من حيث البعد. تُعد هذه المسافة كبيرة نسبياً في تطبيقات الرؤية الحاسوبية، ما يُبرز ملاءمة النظام لمساعدة الأشخاص ضعاف البصر دون الحاجة إلى الوقوف أمام العنصر البصري أو الاقتراب منه كثيراً.




الشكل (٢٣): لافتة I love tartous

يوضح الشكل (٢٤) قدرة النموذج على التعرف على دوار "صالح العلي" من اتجاهات متعددة، سواء من الأمام أو الخلف. يشير ذلك إلى تدريب الشبكة العصبية بفعالية، مما يمكنها من التعرف على المعالم المختلفة بدقة عالية بغض النظر عن زاوية الرؤية.



الشكل (٢٥): دوار (صالح العلي في طرطوس)

يُظهر الشكل (٢٥) التعرف على تمثال اليد الموجود مقابل المركز الثقافي من زوايا مختلفة، سواء من الأمام أو الخلف. يعكس ذلك قدرة النموذج المدرب على التعرف على الكائنات في مختلف الاتجاهات بدقة عالية، مما يعزز كفاءته في بيئات متنوعة.



الشكل (٢٥): تمثال اليد مقابل المركز الثقافي

#### ٦-٥ نتائج الاختبار على قياس المسافة:

يوضح الشكل (٢٦) دقة قياس المسافة باستخدام الطريقة المعتمدة على تشابه المثلثات، حيث أظهرت النتائج تطابقاً كبيراً بين القيم المحسوبة برمجياً والقياسات الفعلية باستخدام شريط القياس. نلاحظ أن النظام قام بقياس المسافة برمجياً دون الحاجة إلى استخدام حساس مسافة، وكانت النتيجة دقيقة جداً. تم التحقق من صحة القياس باستخدام متر القياس، حيث أظهرت الشاشة قيمة مقدارها ٤٠,٦٣، وهي مطابقة تماماً للقياس المأخوذ بالمتر اليدوي. يؤكد هذا الاختبار فعالية النهج المستخدم في تقدير المسافات بدقة، مما يبرز أهمية استغلال المبادئ الرياضية، مثل تشابه المثلثات، في تطوير أنظمة عملية وموثوقة للاستدلال على المسافات بالاعتماد على الكاميرا فقط، دون الحاجة إلى مستشعرات إضافية.



الشكل (٢٦): نتائج اختبار قياس المسافة

## ٧- الاستنتاجات والتوصيات:

### الاستنتاجات:

يشكل النظام المصمم حلاً عملياً وفعالاً لدعم المكفوفين أو ضعاف البصر، إذ يعتمد على تقنيات متطورة منخفضة التكلفة تتيح إمكانية استخدامه في تطبيقات يومية متنوعة. كما يوفر النظام أساساً يمكن تطويره مستقبلياً لتوسيع نطاق وظائفه وتحسين أدائه. بناءً على نتائج البحث، توصلنا إلى الاستنتاجات التالية:

□ أظهر النظام المصمم دقة ملحوظة في تصنيف العملات، الأدوية، والمواقع، حيث تجاوزت معدلات الأداء مثل mAP و Precision و Recall نسبة ٩٦%، مما يجعله أداة موثوقة لدعم المكفوفين في التعرف على البيئة المحيطة.

□ الاعتماد على مبدأ تشابه المثلثات كبديل لحساسات المسافة التقليدية أثبت كفاءته، حيث تطابقت النتائج مع القياسات الفعلية باستخدام أداة قياس، مما يؤكد فعالية هذا النهج كبديل اقتصادي لحساسات المسافة.

- أظهر النظام تكاملاً فعالاً بين ESP32CAM و Raspberry Pi في تقديم بث فيديو ومعالجة البيانات. هذا التكامل يؤكد إمكانية بناء أنظمة ذكية باستخدام معدات منخفضة التكلفة وفعالة من حيث الأداء.
- وفرت بيئة Colab إمكانيات معالجة عالية الدقة ساهمت في تدريب النماذج بفعالية. استخدامها متاح للمشروع الاستفادة من تقنيات الحوسبة السحابية دون الحاجة إلى استثمار موارد محلية مكلفة.
- يمكن بسهولة توسيع النظام ليشمل فئات جديدة مثل الأدوات المنزلية، الأجهزة الإلكترونية، والأطعمة، مما يزيد من فائدته للمكفوفين ويجعله أكثر شمولية في مختلف البيئات.

### التوصيات:

- إضافة تقنيات مثل GPS لتوفير إرشادات دقيقة في البيئات الخارجية وتحديد الموقع الجغرافي، إلى جانب استخدام تقنيات التعرف على النصوص (OCR) لتحويل النصوص المطبوعة في البيئة المحيطة إلى صوت، مثل قراءة أسماء الشوارع أو الإرشادات المكتوبة.
- لضمان قابلية الاستخدام في البيئات الخارجية، يجب تصميم الجهاز بمواد مقاومة للماء والغبار، مع مراعاة أن يكون خفيف الوزن وسهل الحمل لفترات طويلة دون التسبب بإرهاق المستخدم.

## المراجع:

1. Jivrajani, K.; Patel, S.K.; Parmar, C.; Surve, J.; Ahmed, K.; Bui, F.M.; Al-Zahrani, F.A. AIoT-based smart stick for visually impaired person. *IEEE Trans. Instrum. Meas.* **2023**, *72*, 2501311.
2. Ackland, P.; Resnikoff, S.; Bourne, R. World blindness and visual impairment: Despite many successes, the problem is growing. *Community Eye Health* **2017**, *30*, 71–73.
3. Real, S.; Araujo, A. Navigation systems for the blind and visually impaired: Past work, challenges, and open problems. *Sensors* **2019**, *19*, 3404.
4. Husin, M.H.; Lim, Y.K. InWalker: Smart white cane for the blind. *Disabil. Rehabil. Assist. Technol.* **2020**, *15*, 701–707.
5. Idrees, A., Iqbal, Z., & Ishfaq, M. (2020). An efficient indoor navigation technique to find optimal route for blinds using QR codes. arXiv.
6. Vinod, D. N., Kapileswar, N., Simon, J., Polasi, P. K., Padmavathi, B., & Adhikari, P. (2024). Validation and performance contrast of deep neural network based mechanism for real-time automatic safety helmet detection. *SSRG International Journal of Electrical and Electronics Engineering*, *11*(5), 102–118.
7. Wang, W., Jing, B., Yu, X., Sun, Y., Yang, L., & Wang, C. (2024). YOLO-OD: Obstacle detection for visually impaired navigation assistance. *Sensors*, *24*(23), 7621.
8. Docto, J. P., Labininay, A. I., & Villaverde, J. F. (2022). Third eye hand glove object detection for visually impaired using You Only Look Once (YOLO)v4-Tiny algorithm. In *2022 IEEE International Conference on Artificial Intelligence in Engineering and Technology (IICAET)* (pp. 1–6). IEEE.
9. Salunkhe, A., Raut, M., Santra, S., & Bhagwat, S. (2021). Android-based object recognition application for visually impaired. *ITM Web of Conferences*, *40*, 03001.
10. Erdaw, H. B., Taye, Y. G., & Lemma, D. T. (2023). A real-time obstacle detection and classification system for assisting blind and visually impaired people based on YOLO model. In *2023 International Conference on Information and Communication Technology for Development for Africa (ICT4DA)* (pp. 79–84). IEEE.
11. Afif, M., Ayachi, R., Pissaloux, E., et al. (2020). Indoor objects detection and recognition for an ICT mobility assistance of visually impaired people. *Multimedia Tools and Applications*, *79*(31), 31645–31662.
12. Murray, N. P., Hunfalvay, M., & Bolte, T. (2017). The reliability, validity, and normative data of interpupillary distance and pupil diameter using eye-tracking technology. *Translational Vision Science & Technology*, *6*(4), Article 1.