

Design and Evaluation of a Model for Detecting and Identifying the Optimal Vein Using Artificial Intelligence Algorithms

Abdallah Oshah^{*1}, Kolthom Khalid¹, Ahlam Alhadi¹, Heba Omar¹

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

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

Received: 28-09-2025 | Accepted: 20-11-2025 | Available online: 25-12-2025 | DOI:10.26629/jtr.2025.50

ABSTRACT

This paper aims to design and develop an integrated system based on Artificial Intelligence and computer vision technologies for the highly accurate detection of superficial veins, with the goal of supporting medical practices and reducing errors during injection and blood withdrawal procedures. The study followed an experimental-applied approach, divided into several stages, starting with data collection from publicly available infrared vein image databases, followed by training and testing models using three different algorithms (YOLOv11, U-Net, and ORB) and then analyzing the results to select the most efficient model. The test results showed that the YOLOv11 algorithm outperformed the others, achieving high accuracy in vein detection and making it the optimal choice for implementation in the final system. An interactive interface was developed using Python and the Tkinter library to enable users to upload images, run algorithms, and display results conveniently and efficiently. A field evaluation was conducted at Sabratha Teaching Hospital using a questionnaire to measure the system's effectiveness and acceptance among healthcare practitioners, and the results demonstrated a high level of satisfaction. This study highlights the importance of integrating Artificial Intelligence technologies into medical applications to improve the quality of healthcare services and reduce challenges associated with vein identification procedures.

Keywords: Artificial Intelligence, Computer Vision, YOLOv11, U-Net, ORB.

تصميم وتقييم نموذج لكشف وتحديد أفضل وريد باستخدام خوارزميات الذكاء الاصطناعي

عبدالله أشاح¹، كلثوم خالد¹، أحلام الهادي¹ هبة عمر¹

¹قسم هندسة الحاسوب ، كلية الهندسة ، جامعة صبراته ، صبراته، ليبيا.

ملخص البحث

تهدف هذه الورقة إلى تصميم وتطوير نظام متكامل قائم على تقنيات الذكاء الاصطناعي والرؤية الحاسوبية للكشف عن الأوردة السطحية بدقة عالية، وذلك بهدف دعم الممارسات الطبية وتقليل نسبة الخطأ أثناء عمليات الحقن وسحب الدم. تم تنفيذ هذه الورقة وفق المنهج التطبيقي التجاري (Experimental-Applied Approach) ، حيث تم تقسيمه إلى مجموعة من المراحل تبدأ بجمع البيانات من قواعد بيانات مفتوحة متخصصة في صور الأوردة الملقطة بالأشعة تحت الحمراء، تليها مرحلة تدريب وختبار النماذج باستخدام ثلاث خوارزميات مختلفة هي: YOLOv11 ، U-Net، ORB، ثم تحليل النتائج لاختيار النموذج الأكثر كفاءة. أظهرت نتائج الاختبارات تفوق خوارزمية YOLOv11 على بقية الخوارزميات، محققة دقة عالية في الكشف عن الأوردة، مما جعلها الخيار الأمثل لتطبيقها في

النظام النهائي. تم تصميم واجهة تفاعلية باستخدام لغة Python ومكتبة Tkinter لتمكين المستخدم من تحميل الصور وتشغيل الخوارزميات وعرض النتائج بطريقة سهلة وسريعة. كما تم إجراء تقييم ميداني في مستشفى صبراتة التعليمي باستخدام استبيان لقياس فاعلية النظام ومدى قبوله لدى الممارسين الصحيين، وأظهرت النتائج مستوى عال من الرضا. تؤكد هذه الدراسة على أهمية دمج تقنيات الذكاء الاصطناعي في التطبيقات الطبية التي تسهم في تحسين جودة الخدمات الصحية وتقليل التحديات المرتبطة بإجراءات تحديد الأوردة.

الكلمات الدالة: الذكاء الاصطناعي، الرؤية الحاسوبية، ORB، U-Net، YOLOv11.

منطقة الأشعة تحت الحمراء القريبة (NIR) من الطيف الكهرومغناطيسي أكثر شيوعاً في تطوير نوع منخفض التكلفة ولكن فعال من أجهزة تحديد الأوردة [2]. تتعلق هذه الورقة البحثية من فكرة الجمع بين الذكاء الاصطناعي وتقنيات الرؤية الحاسوبية لاستحداث جهاز ذكي محمول يطبق خوارزميات مثل YOLOv11 و U-Net و ORB على صور الأشعة تحت الحمراء بهدف الكشف الدقيق عن موقع الأوردة بشكل آني، وتضمنت الدراسة تدريب هذه الخوارزميات علىمجموعات بيانات متخصصة ثم مقارنة أدائها العلمي لاختيار النموذج الأفضل، مع تصميم واجهة تفاعلية تتيح تطبيق التقنية عملياً عبر مكتبة Tkinter بلغة بايثون داخل البيئة الطبية. وامتداداً لذلك تم تنفيذ تجربة ميدانية في مستشفى صبراتة التعليمي لاستطلاع آراء الممارسين حول النظام المقترن وقياس مدى فاعليته وقبوله في الميدان، وترتکز أهمية الدراسة على معالجة إحدى أكثر المشاكل شيوعاً في الممارسة الطبية اليومية، إذ يسعى البحث إلى تقليل نسبة المحاولات الفاشلة أثناء الحقن أو سحب الدم وتقليل الوقت وتحسين راحة المرضى وتقديم مؤشرات بصرية سهلة وسريعة للأطباء والممرضين مع توفير حل عملي واقتصادي بديل للأجهزة الطبية الكبيرة المعقدة، ويهدف البحث إلى تصميم منظومة متكاملة توظف الذكاء الاصطناعي للتمييز الدقيق للوريد وتجرب خوارزميات متقدمة على بيانات حقيقة ومقارنة الأداء بين النماذج وبناء واجهة رسومية ديناميكية تعرض النتائج بشكل تطبيقي.

1. المقدمة

بعد الوصول الوريدي أحد المكونات الأساسية والأكثر أهمية لرعاية المرضى سواء في المستشفى أو في أماكن المرضى المتنقلة. بعد الوصول الوريدي الآمن والموثوق مسألة مهمة في الممارسة اليومية، ويزداد أهمية أن يكون الأطباء العائليون على دراية بالخيارات المتاحة وقادرين على توجيه المرضى بشأن الأجهزة المناسبة. هناك مجموعة متنوعة من الخيارات المتاحة للوصول الوريدي. يجب أن يتم اختيار جهاز الوصول الوريدي بما يتاسب مع احتياجات كل مريض، وكذلك مع نوع التسريب، ومدته، وتكراره. في هذه المراجعة المختصرة، سنستعرض القضايا المتعلقة باختيار أجهزة الوصول الوريدي وصيانتها. الأوردة هي أوعية دموية موجودة في جميع أنحاء جسمك، تقوم بجمع الدم الفقير بالأكسجين وإعادته إلى قلبك. تشكل الأوردة جزءاً من جهاز الدورى، فهي تعمل مع الأوعية الدموية الأخرى والقلب للحفاظ على حركة الدم. تحتوي الأوردة على معظم الدم في جسمك؛ في الواقع، حوالي 75٪ من دمك موجود في الأوردة. مع التقدم السريع في الذكاء الاصطناعي والرؤية الحاسوبية أصبح بالإمكان الاستفادة من الخوارزميات الحديثة في تحليل الصور الطبية الرقمية وتحديد الأنماط الحيوية بدقة، وهو ما فتح المجال أمام تطوير أنظمة ذكية قادرة على تمييز موقع الأوردة السطحية داخل الصور وتحسين دقة الممارسات الطبية [1]. في الآونة الأخيرة، أصبح استخدام

Li Ming et al., "Infrared Object Detection Method Based on DBD-YOLOv8," 2024. حيث قدمو تحسينا

لخوارزمية YOLOv8 عبر آلية Dual-Branch Detection (DBD)، لتعزيز دقة كشف الأجسام في الصور الحرارية (Infrared)، متتجاوزين دقة النماذج التقليدية في ظروف الإضاءة المنخفضة، مما يجعل هذه التقنية مرجعية مهمة لتطبيقات كشف الأوردة باستخدام كاميرات ما دون الحمراء [6].

M. Adamu et al., "Detection of Varicose Veins Using YOLO: A Comprehensive Review," 2023.

استعرضوا فيها استخدام خوارزميات YOLO الإصدارات (v3 ، v5 ، v7 ، v8) في كشف دوالي الأوردة، مشيرين إلى تحديات مثل الإضاءة غير المنتظمة وتبابين لون الجلد، وبينوا أن YOLO قادر على المعالجة في الزمن الحقيقي بدقة عالية، واقتربوا دمجها مع تقنيات معالجة مسبقة للصور وكاميرات متخصصة مثل NIR لتعزيز الأداء في أنظمة ذكية للكشف عن الأوردة [7].

Edwin Salcedo and Patricia Peñaloza, "Edge AI-Based Vein Detector for Efficient Venipuncture in the Antecubital Fossa," *MICAI 2023 / Lecture Notes in Computer Science (LNCS 14392)*, 2023.

الدراسة بناء قاعدة بيانات مكونة من 2,016 صورة مرمرة من 1,008 مشاركين، وتطوير نموذج U-Net معدل مخصص لمنطقة الطية المرفقة، ثم ضغط النموذج ليعمل على جهاز Raspberry Pi 4B باستخدام Dynamic Range Quantization، محققا معدل تتبع بلغ 5.14، ومقدار IoU بواقع

2. مشكلة البحث

تتمثل مشكلة البحث في صعوبة تحديد الأوردة بدقة خاصة لدى الأطفال وكبار السن باستخدام الطرق التقليدية، ما يؤدي أحيانا إلى زيادة محاولات الحقن والضغط على كل من المريض والطبيب. هذه التحديات تبرز الحاجة إلى وسيلة ذكية وفعالة تعتمد على تقنيات حديثة لاكتشاف الأوردة بشكل تلقائي ومرئي.



شكل 1. شفاف قتحي الأوردة

3. الدراسات السابقة

في هذا الجزء، نستعرض أبرز الدراسات التي تناولت موضوع كشف الأوردة باستخدام تقنيات الذكاء الاصطناعي، ورؤية الحاسوب، بالإضافة إلى خوارزميات اكتشاف الأجسام مثل (YOLO) ، وتقنيات تحليل الصور الطبية.

Zhikang Yang et al., "A Near-Infrared Imaging System for Robotic Venous Blood Collection," *Sensors*, 2024.

عصبية هجينية (BYOL-pretrained ResNet18) داخل U-Net لتحسين تجزئة صور الأوردة ثم ثبتوها خوارزمية مطورة لـ AD-Census لخريطة الأعماق، مما أدى إلى تحسين ملحوظ في مؤشرات الأداء مثل BCE و Dice و IoU، إضافة إلى خفض خطأ خوارزمية الأعماق بنسبة 25.7%， ما يعزز دقة تحديد موقع الحقن في الأنظمة الروبوتية لسحب الدم [5].

- تم تصميم واجهة برمجية مرئية تحاكي عمل النظارة الذكية، باستخدام صور مأخوذة بكاميرا تعمل بالأشعة تحت الحمراء (IR) ، حيث تسمح الواجهة بتحميل الصور وتشغيل الخوارزميات عليها وتحليل النتائج، مما يحدد نطاق التطبيق في بيئة البرمجيات التجريبية بدلاً من الأجهزة المادية.
- الحدود المكانية: مستشفى صبراته التعليمي - ليبية.
- الحدود الزمنية: سنة واحدة (2025).

5. منهجية الدراسة

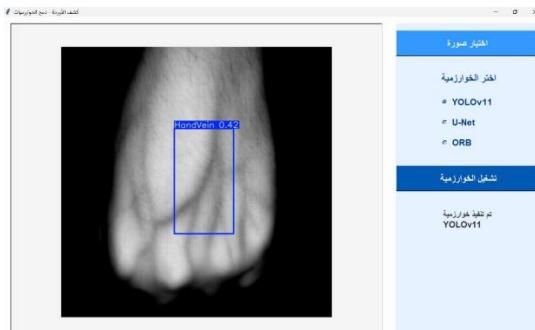
- تم اعتماد المنهج التطبيقي التجاري لتصميم وتطوير نظام متكامل يستخدم الذكاء الاصطناعي والرؤية الحاسوبية للكشف عن الأوردة.
- بدأت الدراسة بجمع بيانات صور الأوردة من قواعد بيانات مفتوحة متخصصة بالأشعة تحت الحمراء لتوفير عينات تدريب متعددة.
- تم تدريب ثلاث خوارزميات YOLOv11 ، U-Net ، ORB على البيانات وتحليل الأداء بناءً على معايير الدقة، ثم أجري اختبار مقارن لاختيار النموذج الأكفاء.
- تم بناء واجهة المستخدم البرمجية باستخدام لغة Python ومكتبة Tkinter لتمكين تحميل الصور وتشغيل الخوارزميات وعرض النتائج بشكل تفاعلي ومرئي.
- شملت المرحلة الأخيرة إجراء تقييم ميداني داخل مستشفى صبراته التعليمي بواسطة استبيان لقياس مدى فاعلية النظام وقبوله لدى الممارسين الصحيين. تم جمع بيانات الاستبيان من الممارسين الصحيين في مستشفى صبراته التعليمي بعد تجربة النظام المقترن . شمل

- 0.957 ، مما أتاح أداء فعالاً وموثوقاً ضمن جهاز محمول منخفض التكلفة [8] .
- Yun Yang et al., "Human Dorsal Hand Vein Segmentation Method Based on GR-UNet Model," 2023. وقدموا فيها نموذج GR-UNet المطور لنقسيم أوردة ظهر اليد باستخدام صور NIR ، وأظهرت النتائج دقة عالية مقارنة بنماذج U-Net التقليدية، مما يبرز جدوى استخدام هذه التقنية في الأنظمة الذكية المساعدة في الإجراءات الطبية مثل سحب الدم [8] .

- Tianyi Pan et al., "Competitive Real-Time Near Infrared (NIR) Vein Finder Imaging Device to Improve Peripheral Subcutaneous Vein Selection in Venipuncture for Clinical Laboratory Testing," 2021. تم فيها تصميم جهاز لحظي للكشف عن الأوردة تحت الجلد باستخدام تقنية الأشعة تحت الحمراء CMOS-IR (NIR) ، حيث استخدمو كاميرا LED بطول موجي 1080p بـ 960 نانومتر ، إلى جانب خوارزميات لمعالجة وتحسين الصورة في الزمن الحقيقي. أجريت التجربة على 242 شخصاً، وحقق الجهاز نسبة دقة في تحديد الأوردة في ظهر اليد تصل إلى 100% ، وأداء جيد في الذرع دون الحاجة لاستخدام الأربطة الضاغطة (tourniquet) ، مما يشير إلى إمكانية تحسين معدلات النجاح في سحب الدم، مع توصية بإدماج التقنية في أنظمة عرض مباشرة أو نظارات طبية ذكية [9] .

4. مصادر وحدود البحث

- شمل جمع البيانات إجراء استبيان ميداني في المستشفى لتقدير فعالية النظام ، كما تم الاعتماد على بيانات صور مفتوحة المصدر (HyperVein و VEINCV-RL) لتدريب واختبار الخوارزميات المستخدمة.

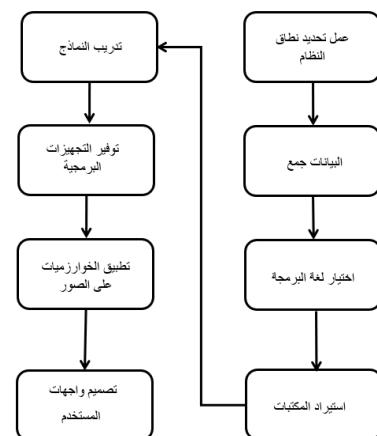


شكل 4 بـ حـيلـل الـلـلـهـور وـنـر يـالـهـيـلـلـهـا لـاـخـيلـلـهـا
الـخـوارـزـمـيـهـا لـهـيـلـهـا.

6. النتائج والمناقشة

في هذه المرحلة تم تدريب وتقدير خوارزميات كشف الأوردة باستخدام YOLOv11 و U-Net و ORB. تم إعداد بيئة التدريب باستخدام مكتبة Ultralytics لتدريب خوارزمية YOLOv11، وتم تجهيز ملفات البيانات بمسارات الصور، حيث شملت 1247 صورة مأخوذة من قاعدة بيانات HyperVein المتخصصة في صور الأوردة بالأشعة تحت الحمراء. تم تقسيم البيانات إلى 80% للتدريب و 20% لاختبار لضمان التوازن بين المجموعات، كما تم ضبط معامل العشوائية (random_state) لضمان ثبات النتائج في كل تجربة.نفذت عملية التدريب على 50 دورة تدريبية (epochs) مع تصغير حجم الصور إلى 216×216 بكسل لتسريع التدريب وتحقيق توازن بين الدقة وسرعة التنفيذ، حيث بلغت دقة النموذج حوالي 86%. أما نموذج U-Net فتم تدريسه على بيانات من قاعدة VEINCV-RL مع إعادة تحجيم الصور إلى 256×256 بكسل، واستخدام 50 دورة تدريبية مع دالة خسارة Binary Crossentropy لتحسين الدقة. وقد أظهرت النتائج تحديات في تمييز الأوردة عن التفاصيل غير المهمة مع زيادة عدد الدورات التدريبية. بينما خوارزمية ORB تعتمد على استخراج الميزات من الصور دون تدريب مسبق، وتستخدم مباشرة على الصور بكفاءة عالية وسرعة تنفيذ فائقة. تم تصميم واجهة المستخدم باستخدام مكتبة Tkinter في بيئة Python لعرض

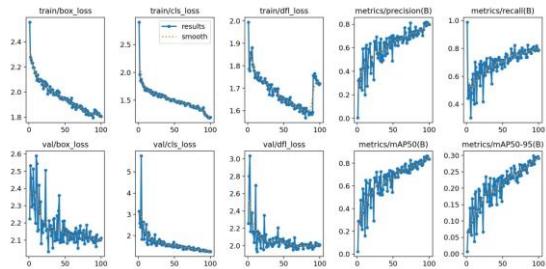
الاستبيان مجموعة من الأسئلة لقياس سهولة الاستخدام، دقة الكشف، سرعة الاستجابة، ورضا المستخدمين عن الواجهة البرمجية. بعد استلام الاستبيانات، تم فرز الإجابات وتحليلها يدويا من خلال عد وتسجيل تكرار كل إجابة لكل محور من محاور التقييم. بعد ذلك، تم حساب النسب المئوية لكل محور لتقدير مستوى الرضا العام وتحديد أكثر الجوانب التي نالت استحسان المشاركين. أظهرت النتائج أن معظم المشاركين قيموا النظام بدرجات عالية في محوري الدقة وسهولة الاستخدام، مما يدل على فعالية النظام وملاءمته للبيئة الطبية الواقعية.



شكل 2. مخطط مراحل تصميم النظام.

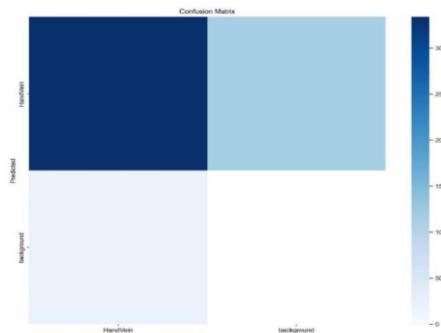


شكل 3. لواجهة لـ تج^{هيبي} قللنظام



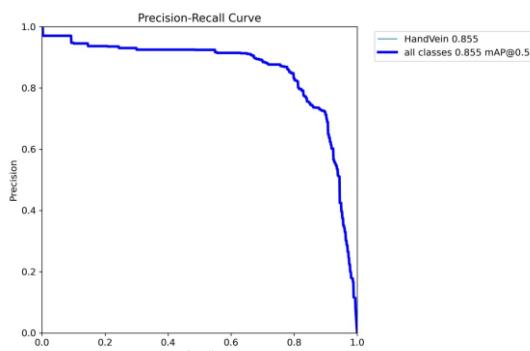
شكل 5. منحنيات الخسارة والدقة أثناء تدريب نموذج YOLOv11.

تم تقييم أداء النموذج على بيانات التحقق باستخدام عدة مقاييس. الشكل (6) يعرض مصفوفة الالتباس. هذا الشكل يوضح عدد التوقعات الصحيحة والخاطئة لكل فئة من الصور.



شكل 6. مصفوفة الالتباس لنتائج نموذج YOLOv11.

الشكل (7) يعرض منحنى Precision-Recall. هذا الشكل يوضح العلاقة بين الدقة والاستدعاء عند تغيير قيمة العتبة.



شكل 7. منحنى الدقة والاستدعاء (Precision-Recall) لنموذج YOLOv11.

النتائج وتسهيل التفاعل المباشر مع الصور والخوارزميات من قبل المستخدم.

جدول 1. مقارنة أداء خوارزميات كشف الأوردة.

الخوارزمية	نوع الخرج	الصور المستخدم	عدد الصور التدري	عدد الصور الاختبار	دقمة التسخون	سرعة التنفيذ	الملاحظات
YOLOv1	عند موقع الوريد (Bounding Box)	1247	7	108	86%	عالية	المناسبة للتنفيذ في الوقت الحقيقي، الفضل خوارزمية في الموقع
U-Net	قناة الوريد بالكامل (Segmentation Mask)	10	10	10	86%	متوسطة	تتطلب بيانات دقة، قوية في استخراج الشكل
ORB	نقاط مميزة (Keypoints)	1247	-	-	لا تقتصر تقليدية	سرعة جدا	مساعدة في التعرف البصري، لا تستخرج الشكل الكامل

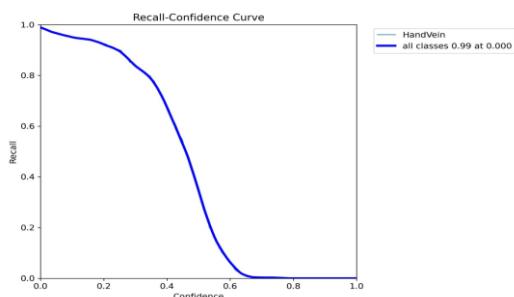
1.6 نتائج التدريب خوارزمية YOLOv11

تم تدريب نموذج YOLOv11 باستخدام بيانات صور أوردة اليد. أثناء التدريب، تم تسجيل قيم مؤشرات الأداء والخسائر والشكل 5 يعرض منحنيات تطور الخسارة والدقة أثناء عملية التدريب لجميع الدورات التدريبية. هذا الشكل يوضح سلوك كل من خسارة الصندوق وخسارة التصنيف وخسارة DFL بالإضافة إلى قيم mAP50 و mAP50-95 مع كل دورة تدريبية.

جدول 3. تحليل منحنى الثقة (Precision).

الملاحظة	القيمة	المقياس
أداء ضعيف في البداية	~0.15-0.40	Precision عند ثقة (0-0.2) منخفضة
استقرار عند مستوى مرتفع	~0.95-0.90	Precision عند ثقة 0.4- (0.6) متوسطة
تراجع واضح في الدقة	~0.65	انخفاض
الدقة = 1.00 وهي القيمة المئوية	0.788	أفضل نقطة (Threshold)

شكل 9: يعرض منحنى الاستدعاء (Recall). هذا الشكل يوضح كيف تتغير قيمة الاستدعاء مع تغيير العتبة.



شكل 9. منحنى العلاقة بين الثقة والاستدعاء لنموذج YOLOv11

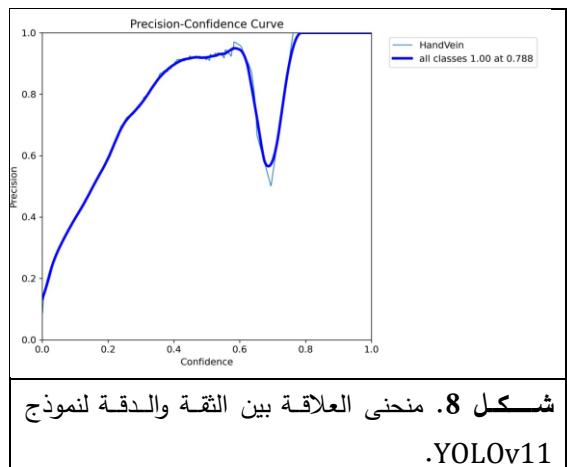
يبيّن منحنى Recall-Confidence أن الاستدعاء (Recall) يبدأ قريباً من القيمة العظمى (≈ 0.99) عند مستويات الثقة المنخفضة، ثم يبدأ في الانخفاض التدريجي مع زيادة الثقة. بعد نقطة ثقة حوالي 0.5، ينخفض الاستدعاء بشكل حاد حتى يصل إلى الصفر تدريجياً عند ثقة أكبر من 0.7. هذا يوضح أن تقليل عتبة الثقة يساعد النموذج على استرجاع أكبر عدد من الحالات، بينما رفعها يقلل الاستدعاء بشكل كبير.

يبين منحنى Precision-Recall أن النموذج حافظ على قيم عالية من الدقة (Precision) عبر نطاق واسع من الاستدعاء (Recall)، حيث ظل المنحنى قريباً من القيمة العليا حتى حدود 0.8 من الاستدعاء، ثم بدأ في الهبوط التدريجي. قيمة $mAP@0.5 = 0.855$ تدل على أداء قوي ومتوازن في الكشف والتصنيف.

جدول 2. تحليل منحنى Precision-Recall.

الملاحظة	القيمة	المقياس
دقة مرتفعة جداً في البداية	~0.99	Recall عند Precision (منخفض)
استدعاء جيد مع الحفاظ على دقة عالية	~0.80	Precision عند Recall (مرتفع)
بداية الانخفاض الواضح في الدقة	0.90-0.80	نقطة الانعطاف
مؤشر شامل على جودة النموذج	0.855	$mAP@0.5$

الشكل (8) يعرض منحنى الدقة (Precision) هذا الشكل يوضح كيف تتغير قيمة الدقة عند تغيير قيم العتبة.



شكل 8. منحنى العلاقة بين الثقة والدقة لنموذج YOLOv11.

يبيّن منحنى Precision-Confidence أن الدقة ترتفع تدريجياً مع زيادة الثقة، وتستقر في قيم عالية (0.9-1.0) عند مستويات متوسطة من الثقة. هناك انخفاض ملحوظ حول قيمة ثقة ~ 0.65 ثم تعود الدقة لارتفاع لتصل إلى 1.0 عند ثقة 0.788. هذا يعكس أن اختيار عتبة الثقة المناسبة يحقق أفضل أداء للنموذج.

جدول 5. تحليل فني F1 Score

الملاحظة	القيمة	المقياس
بداية ضعيفة للأداء	~0.20-0.40	عند ثقة منخفضة (0.0-0.1)
ارتفاع واضح و قريب من الذروة	~0.70-0.80	F1 عند ثقة متوسطة (0.2-0.3)
افضل توازن بين الدقة و الاستدعا	0.81	القيمة المثلث
انبهار في الأداء مع زيادة الثقة	~0.0	عند ثقة مرتفعة (0.6-)

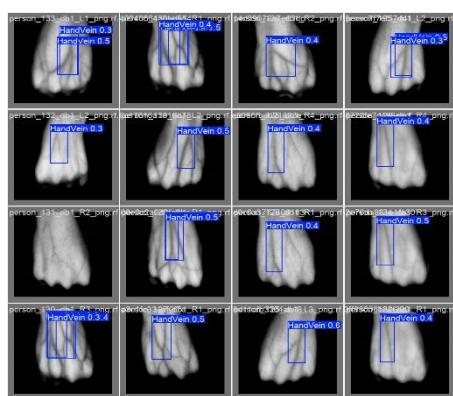
جدول 4. تحليل منحنى الاستدعا (Recall)

الملاحظة	القيمة	المقياس
اعلى قيمة استدعا	~0.99	عند ثقة Recall منخفضة (0.0)
بداية الانخفاض التدريجي	~0.80-0.60	عند ثقة Recall متوسطة (0.3-0.4)
هبوط واضح و سريع في الاستدعا	~0.5	نقطة الانحدار الحاد
الاستدعا شبه معنون	~0.0	عند ثقة Recall مرتفعة (0.7-)

يعرض شكل 10 منحنى F1 Score. هذا الشكل يوضح تغير قيمة F1 Score مع تغير العتبة.

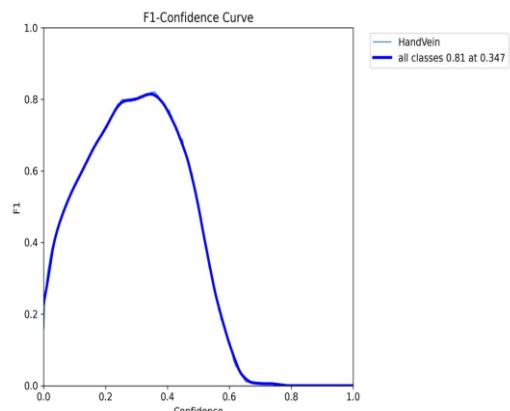
تم عرض نتائج التوقع لمجموعات بيانات التحقق. في هذه الصور، يتم عرض الصناديق التنبؤية بواسطة النموذج على الصور الأصلية.

شكل 11. يعرض الصور الأصلية مع الصناديق التنبؤية لمجموعة التحقق رقم 0.



شكل 11. صور التحقق مع الصناديق التنبؤية الناتجة من نموذج YOLOv11.

الشكل (12) يعرض القيم الصحيحة المقابلة لنفس مجموعة الصور.

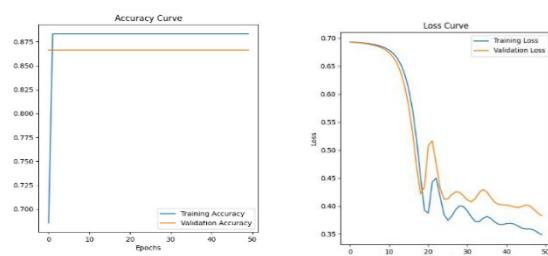


شكل 10. منحنى العلاقة بين الثقة ودرجة F1 لتحديد التوازن بين الدقة والاستدعا.

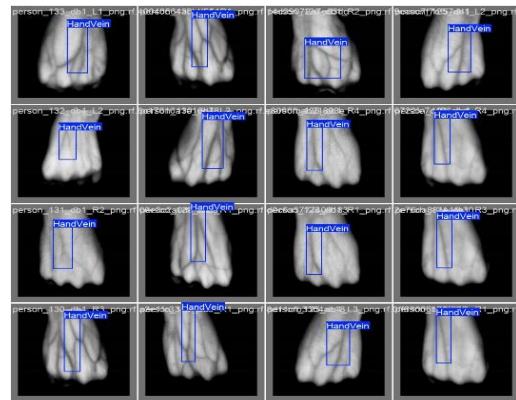
يبين منحنى F1-Confidence أن قيمة الـ F1 ترتفع تدريجياً مع زيادة الثقة حتى تصل إلى الذروة عند مستوى ثقة يقارب 0.347، حيث تسجل القيمة العظمى لـ F1 وهي 0.81 بعد ذلك يبدأ المنحنى في الانخفاض واضح كلما زادت الثقة، حتى يصل إلى مستويات منخفضة جداً عند قيم ثقة أعلى من 0.6. هذا يدل على أن أفضل أداء للنموذج (من حيث التوازن بين الدقة والاستدعا) يتحقق عند عتبة ثقة متوسطة وليس عالية.

(binary crossentropy) كمقاييس للخسارة، ودقة التصنيف كمؤشر رئيسي للأداء. تم تنفيذ التدريب لعدد 50 دورة (Epoch)، وقد أظهرت النتائج ما يلي: بلغت قيمة الخسارة النهائية 0.3827 على مجموعة التحقق، وهي قيمة منخفضة نسبياً تشير إلى قدرة النموذج على تعلم التوزيع الصحيح للبيانات دون وجود انحراف كبير. كما بلغت الدقة النهائية على مجموعة التحقق 0.8660 (أي ما يعادل 86.6٪)، وهي نسبة جيدة جداً في مجال معالجة الصور الطبية، وتؤكد فعالية النموذج في تحديد ملامح الأوردة بدقة.

خلال تدريب نموذج U-Net، أظهرت منحنيات الخسارة انخفاضاً مستمراً في كل من خسارة التدريب وخسارة التحقق، مما يدل على تعلم مستقر وتدريجي للنموذج دون ظهور علامات فرط التعلم، حيث بدأت الخسارة مرتفعة في البداية ثم انخفضت واستقرت مع وجود تذبذبات بسيطة في منحني التحقق، مع توازن جيد بين الدقيقتين عند نهاية التدريب بنسبة خسارة حوالي 0.35 للتدريب و 0.39 للتحقق. أما منحنيات الدقة فارتقت بسرعة خلال الدورات الأولى، حيث استقرت دقة التدريب عند حوالي 88.3٪ ودقة التتحقق عند 86.6٪، مع استقرار وثبات عاليين يعكسان قدرة النموذج على التعلم وعدم وجود فرط تعلم. وأظهرت التقييمات البصرية نجاح النموذج في تمييز حدود الأوردة بوضوح في صور الأشعة تحت الحمراء، حيث تمكن من تتبع البنية الوريدية بدقة باستخدام الأقنعة المولدة، مما يؤكد فعالية النموذج في تطبيقاته العملية على الصور الطبية.



شكل 15. منحنيات الخسارة والدقة أثناء تدريب نموذج U-Net

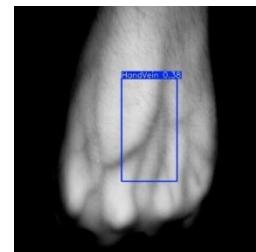


شكل 12. صور القيم الصحيحة المقابلة لصور التحقق

تم اختبار النموذج المدرب على صورة منفردة بهدف التتحقق من فعالية النموذج في كشف موقع الأوردة بعد انتهاء التدريب. أظهر النموذج قدرة على تحديد مناطق الأوردة داخل الصورة باعتماد الصناديق الت Tessellated Bounding Boxes (TBBs). يتم في هذه المرحلة مقارنة الصورة الأصلية بالصورة الناتجة بعد تطبيق النموذج عليها. يفضل عرض كل من الصورة الأصلية والصورة بعد الكشف لتوضيح الفرق بينهما بشكل مباشر وبياني.



شكل 13. الصورة الأصلية لليد قبل تطبيق نموذج الكشف YOLOv11

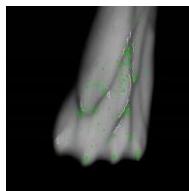


شكل 14. الصورة الناتجة بعد تطبيق نموذج

2-6 نتائج اختبار نموذج U-Net

تم تدريب نموذج U-Net باستخدام مجموعة بيانات متخصصة تحتوي على صور أوردة اليد وأقنعتها الثنائية (binary masks)، واستخدم في ذلك خوارزمية

الحوارف Canny لتحسين وضوح التفاصيل. خلال معالجة الصور، تم رسم النقاط المميزة وحفظ النتائج، وأظهرت الاختبارات البصرية زيادة عدد النقاط وتوافقها بشكل أفضل مع ملامح الأوردة بعد التحسين مقارنة بالإصدار الأصلي. توضح النتائج فعالية التحسينات في تعزيز دقة الكشف عن الأوردة وتوضيح بنية الوريد في الصور الطبية.



شكل 17. مقارنة نتائج خوارزمية ORB قبل التحسين وبعد

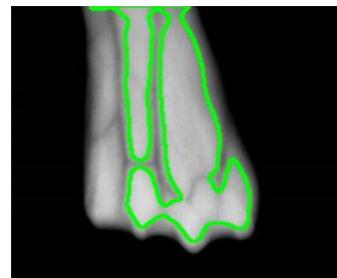
7. الخاتمة

في هذه الورقة تم تصميم واجهة ذكية تسمح للمستخدم بتحميل صورة يد ومعالجتها باستخدام ثلاث خوارزميات مختلفة هي ORB ، YOLOv11 ، و U-Net . تم تدريب كل خوارزمية بشكل مستقل على مجموعات بيانات مخصصة واختبار أدائها على مجموعات مختلفة من الصور. أظهرت النتائج أن خوارزمية YOLOv11 حققت أفضل أداء في كشف موقع الأوردة بدقة بلغت 86 % وسرعة تنفيذ عالية، مما يجعلها الأنسب للتطبيق في الوقت الحقيقي . أما خوارزمية U-Net فقدمت دقة مماثلة (86%) لكنها تعمل بسرعة متوسطة وتعتمد على بيانات تدريب دقيقة لاستخراج قناع الوريد الكامل، في حين أن خوارزمية ORB تعتمد على النقاط المميزة بسرعة عالية لكنها غير دقيقة لاستخراج الشكل الكامل للوريد.

8. التوصيات

استنادا إلى النتائج التي تم الحصول عليها، يوصى باعتماد خوارزمية YOLOv11 في التصميم النهائي للجهاز الذكي نظراً لتوارثها بين الدقة العالية وسرعة

يوضح الشكل (16) نتيجة نموذج U-Net بعد تمرير صورة أشعة تحت الحمراء لليد البشرية، حيث تمكّن النموذج من تمييز حدود الأوردة بدقة عالية من خلال تتبع البنية الوريدية باستخدام الأقنعة الناتجة، مظهراً فاعلية عالية في فصل الأوردة عن الخلفية وتوفير نتائج واضحة لتطبيقات الكشف الطبي .



شكل 16. نتيجة تطبيق نموذج U-Net على صورة يد بالأشعة تحت الحمراء

3.6 نتائج اختبار نموذج ORB

تم تطبيق خوارزمية ORB عبر استيراد مكتبات OpenCV و لإدارة الصور والملفات مع تحديد مجلدات للصور الأصلية والمعالجة. تم إنشاء كاشف لاستخراج 1000 نقطة مميزة عبر صورة CLAHE monochrome محسنة باستخدام تقنية CLAHE لزيادة وضوح التفاصيل، ثم تم رسم نقاط المميزات على الصور وحفظها. شملت التحسينات على الخوارزمية تحويل الصور إلى رمادية، تحسين التباين، تطبيق فلتر Gaussian Blur، واستخدام كشف الحوارف Canny، لتعزيز جودة الكشف. تظهر المقارنات البصرية أن النسخة المحسنة من ORB زادت عدد النقاط المكتشفة ووضوحاً مع توافق أعلى مع ملامح الأوردة مقارنة بالنسخة الأصلية، مما يؤكد كفاءتها في الكشف الدقيق عن الأوردة. تم تطبيق خوارزمية ORB باستخدام مكتبات OpenCV و لإدارة مجلدات الصور، حيث تم إنشاء كاشف لاستخراج 1000 نقطة مميزة من الصور المحوّلة لدرج الرمادي والمعالجة بتحسين التباين CLAHE ، كما شملت التحسينات تطبيق فلتر Gaussian Blur وكاشف

- https://my.clevelandclinic.org/health/body/233_60
- [4] Kenhub. Venules: Anatomy and Function. Kenhub Online Library. 2025. Available from: <https://www.kenhub.com/en/library/anatomy/venue>
- [5] Meissner MH. Lower extremity venous anatomy. Seminars in Interventional Radiology. 2005;22(3):147–156. Available from: <https://doi.org/10.1055/s-2005-921948>
- [6] Liu Y, Zhang W, Li X, et al. Leveraging thermal infrared imaging for pig-ear detection: The TIRPigEar dataset and deep learning performance. Animals. 2025;15(1):41. Available from: <https://doi.org/10.3390/ani15010041>
- [7] Chen Z, Zhang Y, Wang L, et al. Body temperature detection of group-housed pigs based on YOLOv11m-OBB and thermal imaging. Animals. 2025;15(5):642. Available from: <https://doi.org/10.3390/ani15050642>
- [8] Wu X, Hong D, Chanussot J. UIU-Net: U-Net in U-Net for infrared small object detection. IEEE Transactions on Image Processing. 2023;32:364–376. Available from: <https://doi.org/10.1109/TIP.2022.3228497>
- [9] Wang, X., Han, C., Li, J., Nie, T., Li, M., Wang, X., & Huang, L. (2024). *Multiscale Feature Extraction U-Net for Infrared Dim-and Small-Target Detection*. Remote Sensing, 16(4), 643. <https://doi.org/10.3390/rs16040643>

المعالجة، مما يجعلها الأنسب للتطبيق العملي في بيئات طبية حقيقة. كما ينصح بالعمل على تحسين أداء خوارزمية U-Net من خلال توسيع قاعدة بيانات التدريب وتطوير بنية النموذج لزيادة دقة عملية التجزئة وتحسين قدرتها على تحديد الأوردة بدقة أكبر. إضافة إلى ذلك، يوصى بدمج خوارزميات ما بعد المعالجة لتصفيه نتائج خوارزميتي U-Net و ORB بهدف رفع الدقة العامة للنظام وتقليل الأخطاء الناتجة عن الضوضاء في الصور.

وفي المستقبل، يقترح تطوير نظارة ذكية متكاملة تعتمد على تقنيات الواقع المعزز (Augmented Reality) لعرض موقع الأوردة في الزمن الحقيقي، بما يسهل على الأطباء والممرضين عملية تحديد الوريد بدقة وسرعة. كما يستحسن دمج النظام مع قواعد بيانات المستشفيات لتوثيق الإجراءات الطبية بشكل مؤشف ومنظم، مما يعزز من كفاءة إدارة السجلات الطبية. وأخيراً، يمكن الاستفادة من تقنيات الذكاء الاصطناعي التوليدية (Generative AI) في إنشاء بيانات تدريب اصطناعية إضافية لتحسين أداء النماذج وتعزيز قدرتها على التعلم والتعامل مع مختلف الحالات السريرية.

8. المراجع

- [1] Sabri A, Szallas J, Holmes KS, Labib L, Mussivand T. Failed attempts and improvement strategies in peripheral intravenous catheterization. Bio-Medical Materials and Engineering. 2013;23(1-2):93–108. Available from: <https://doi.org/10.3233/BME-120735>
- [2] Pan C-T, Francisco MD, Yen C-K, Wang S-Y, Shiue Y-L. Vein pattern locating technology for cannulation: A review of the low-cost vein finder prototypes utilizing near infrared (NIR) light to improve peripheral subcutaneous vein selection for phlebotomy. Sensors (Basel). 2019;19(16):3573. Available from: <https://doi.org/10.3390/s19163573>
- [3] Cleveland Clinic. Veins: Anatomy and Function. Cleveland Clinic Health Library. 2025. Available from: