

## تحسين جودة إشارات الأهداف الحرارية الخافتة لتحسين أداء التعرف والتتبع

د. صادق برو \*

(تاريخ الإيداع ٢٠٢٥/١١/١١ . قُبل للنشر في ٢٠٢٦/١/٧)

### □ ملخص □

تُستخدم كاميرات التصوير الحراري لالتقاط الأشعة تحت الحمراء المنبعثة أو المنعكسة من الأهداف، وغالباً ما تكون النتائج على شكل صور رمادية. وعلى الرغم من قدرة الصور الحرارية على دعم الرؤية الليلية وتمييز الكائنات الحية والمصدرة للحرارة، فإن تطبيقها في الكشف والملاحقة والتعريف يواجه تحديات كبيرة مقارنة بالكاميرات المرئية الملونة. تكمن المهمة الأساسية في تتبع الأهداف في استخراجها من الفيديو والحصول على خصائصها المميزة مثل الموقع والحجم والسرعة والاتجاه بشكل مستمر.

تواجه خوارزميات الملاحقة التقليدية، المصممة للصور المرئية، صعوبات عند تطبيقها على الصور الحرارية بسبب فقدان التفاصيل المميزة، ما يقلل من دقتها وفعاليتها.

في هذه الدراسة، نقترح تعزيز السمات الضعيفة للأهداف الحرارية عبر إدخال سمة جديدة أطلق عليها "مركز الهدف الحراري الفعال"، ومن ثم استخدمنا هذه السمة لاستخراج "اتجاه المركز الفعال بالنسبة لمركز الهدف". تتيح هذه الميزتين تحسين تمييز الأهداف الضعيفة، مما يمكن من تطبيق خوارزميات معالجة الصور المرئية على الصور الحرارية بفاعلية تكبيراً واختبار الطريقة على محاكاة لأهداف حرارية ضعيفة السمات، حيث تم تحديد المركز الفعال واتجاه الهدف باستخدام خوارزمية بسيطة. كما تم مقارنة النتائج مع طريقة تحليل المكونات الرئيسية (PCA) لتحديد اتجاه الهدف، حيث أظهرت الطريقة المقترحة قدرة أعلى على كشف الاتجاه، وعند دمجها مع خوارزمية تتبع الأهداف المتعددة (MOT) مدعومة بمرشح كالمان، تم تحقيق أداء أفضل في تتبع الأهداف الحرارية.

**الكلمات المفتاحية:** الأشعة تحت الحمراء، الصورة الحرارية، ملاحقة الأهداف، ميزات الهدف، تحديد الاتجاه

\* مدرس في قسم هندسة تكنولوجيا الاتصالات - كلية هندسة تكنولوجيا المعلومات والاتصالات - جامعة طرطوس-سوريا

## Enhancing the Signal Quality of Low-Visibility Thermal Targets to Improve Recognition and Tracking Performance

Dr. sadek Pro\*

(Received 11/11/2025 . Accepted 7/1/2026)

□ ABSTRACT □

Thermal imaging cameras capture the infrared radiation emitted or reflected by targets, typically producing grayscale images. While thermal imagery supports night vision and facilitates the detection of living and heat-emitting objects, its application in target detection, tracking, and classification faces significant challenges compared to visible-color cameras. The primary task in target tracking is to extract the target from video frames and continuously obtain its distinctive features, such as location, size, velocity, and orientation.

Conventional tracking algorithms designed for visible images often struggle when applied to thermal images due to the loss of distinctive details, resulting in reduced accuracy and effectiveness. In this study, we propose enhancing weak target features in thermal images by introducing a new attribute called the Effective Thermal Target Center, which is then used to derive the relative orientation of the effective center with respect to the target center. These two features improve the distinguishability of low-feature targets, enabling visible-image-based algorithms to operate effectively on thermal images.

The proposed approach was tested on simulated low-feature thermal targets, where the effective center and target orientation were determined using a simple algorithm. The results were compared with Principal Component Analysis (PCA) for orientation estimation, showing higher orientation detection performance with the proposed method. When integrated with a Multi-Object Tracking (MOT) algorithm supported by a Kalman Filter, the approach demonstrated superior performance in tracking thermal targets.

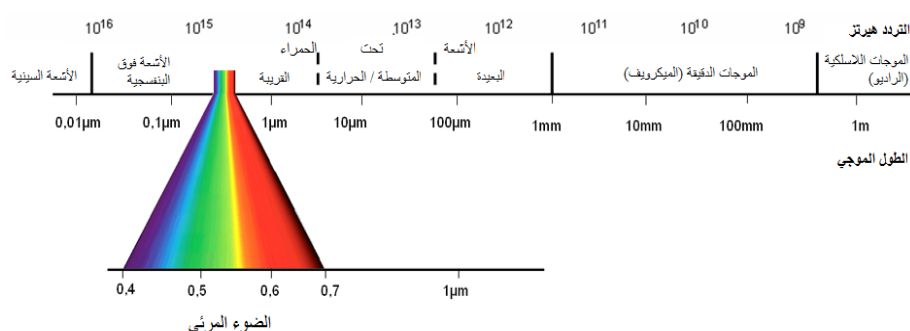
**Keywords:** infrared, thermal imaging, target tracking, target features, orientation detection

---

\*Lecturer, Communication Technology Engineering Department, Information and communication Technology Engineering, Tartous University, Syria.


## ١ - المقدمة

شهد مجال الرؤية الحاسوبية، طفرة نوعية في التطبيقات المتعددة، مدعوماً بتطورات واسعة في تقنيات الاستشعار، حيث أسهمت التطورات الحديثة في تكنولوجيا المعلومات والحوسبة في تعزيز القدرة على الابتكار والتطوير في مجالات الذكاء الاصطناعي وتكنولوجيا تحليل الصور. يُعد اكتشاف الأهداف المتحركة ضمن مقاطع الفيديو أحد التحديات المركزية في هذا المجال، إذ يتطلب التقاط المعلومات الحركية بدقة عالية وفعالية زمنية مناسبة، مما يجعل دراسة خوارزميات الكشف عن الأهداف المتحركة في الزمن الحقيقي أمراً بالغ الأهمية [1]. يمثل محور تتبع الأهداف محوراً أساسياً في أنظمة رؤية الحاسوب، إذ يتيح لأجهزة الحاسوب فهم البيئة المحيطة والتفاعل الفعال مع المستخدمين. وتتمثل المهمة الجوهرية في تتبع الأهداف باستخراجها من الفيديو والحصول على خصائصها المميزة، بما في ذلك الموقع والحجم وسرعة الحركة والاتجاه والدوران بشكل مستمر [2]. ورغم وجود عدد محدود من الخوارزميات القادرة على تتبع الأهداف بدقة في البيئات العملية باستخدام الكاميرات المرئية، فإن تحديات إضافية تنشأ عند استخدام الصور الحرارية، يظهر الشكل (١) الأطوال الموجية.



الشكل (١) موقع طيف الأشعة تحت الحمراء والأطوال الموجية

تنبعث من الأجسام ذات درجات الحرارة الأعلى من الصفر المطلق إشعاعات مستمرة تتركز في نطاق الأشعة تحت الحمراء (IR)، ويمكن التقاط هذه الإشعاعات بواسطة الكاميرات الحرارية (Thermal Cameras)، والتي عادةً ما تُنتج صوراً بتدرجات رمادية، بالمقارنة مع الكاميرات المرئية، توفر الأنظمة الحرارية ميزة العمل الليلي وتمييز الأهداف الحقيقية عن الأهداف المزيفة اعتماداً على الفروقات الحرارية والمنبعثة من الهدف والخلفية المرافقة له، كما تتميز بالقدرة على الرصد دون الحاجة لإرسال إشارات، ما يزيد من مستوى الإخفاء ويضمن جمع المعلومات على مدار الساعة في بيئات معقدة، بما في ذلك التطبيقات الصناعية، والروبوتية والرقمية والمؤلفات التلخايز للفلو [3] الحرارية، إلا أن معالجتها تواجه تحديات كبيرة بالمقارنة مع الصور المرئية، وتشمل هذه التحديات تغيير شكل الهدف، وطمس معالمه، وانخفاض دقة الصورة، وتعقيدات الخلفية، وهي عقبات تعيق تطوير أنظمة التعلم الذكي وتدريبها على عينات الأهداف الحرارية كما في (الشكل ٢) [4].



الشكل (٢) عينات التدريب لوجوه مختلفة بالكاميرا الحرارية عند درجات حرارة مختلفة [4]

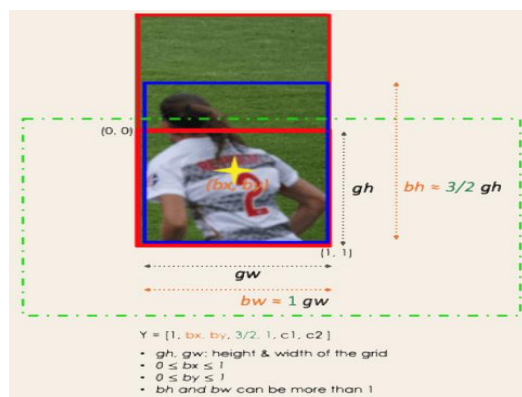
تتقسم خوارزميات التتبع إلى: تتبع هدف واحد (Single Object Tracking, SOT) وتتبع أهداف متعددة (Multi-Object Tracking, MOT). خلال دراسة مشاكل ضعف السمات في الأهداف الحرارية، تبرز صعوبة إضافية عند تتبع أهداف متعددة متشابهة في الشكل، خاصة عند تداخلها، حيث يصبح من الصعب تمييز كائن عن آخر بعد حدوث التداخل، كما يظهر في (الشكل ٣)، حيث توضح الإطارات المأخوذة من فيديو اقتراب وتداخل كائنان متشابهان، مما يؤثر الحاجة إلى تطوير خصائص مميزة إضافية للأهداف الضعيفة السمات.

استناداً إلى مراجعة الدراسات السابقة -كما سنرى لاحقاً- نقترح في هذا البحث استنتاج سمة جديدة للأهداف الحرارية ضعيفة الملامح، أطلقنا عليها المركز الفعال للكائن، ويتم تحديدها عبر إزاحة مركز الهدف الأصلي باتجاه منطقة السطوع الأعلى في الهدف (الشكلين ٤ و ٥). يمكن استخدام هذا المركز الجديد لتحديد اتجاه الهدف النسبي كزاوية بين شعاعي المركز الفعال والمركز الأصلي، ما يعزز قدرة النظام على اكتشاف الهدف وتتبع اتجاهه، ويدعم خوارزميات التعرف والتتبع، خاصة في تطبيقات الذكاء الاصطناعي [٥].


في القسم الأخير من الدراسة، نناقش نتائج التجارب التي تثبت فعالية هذه الطريقة في تحسين التعرف والتتبع للأهداف الحرارية الخافتة السمات.



الشكل (٣) جسمان متشابهان يتداخلان في الصورة الحرارية



الشكل (٤) معاملات المنجبة Y



الشكل (5) إزاحة مركز الهدف باتجاه منطقة الفعالية الأعلى

إن اللجوء إلى تقنية تحديد مركز جديد للكائن الحراري ينبع من الحاجة إلى معالجة نقاط الضعف الجوهرية في استخدام الصور الحرارية مقارنة بالصور المرئية، والتي تؤثر على أداء خوارزميات الملاحظة والتمييز. تشير الدراسات السابقة إلى أن الصور الحرارية، على الرغم من قدرتها على العمل في ظروف الإضاءة المنخفضة وتمييز الأجسام الحية المتحركة، لا تزال تعاني من قيود تتعلق بدقة الصورة وتشويش السمات في ظل الظروف المظلمة. كانت توصف الأشعة تحت الحمراء وكيفية توليد الصور الحرارية باستخدام الكاميرات الحرارية، حيث بينت النتائج أن الصور الحرارية أقل تأثراً بتغيرات الإضاءة وتمكن من تمييز الكائنات الحية بسهولة، خصوصاً عند الحركة، إلا أن الصور الحرارية تواجه صعوبات في تمثيل شكل الهدف بدقة، إذ تكون الأجزاء الأكثر حرارة أكثر وضوحاً، بينما تظل التفاصيل الدقيقة محدودة، مما يقلل من التباين والتمييز مقارنة بالصور المرئية. كما أشار [8] إلى أن الضجيج وخلفية الهدف يمثلان عقبات رئيسية في معالجة الصور الحرارية، خصوصاً عندما يكون الهدف صغيراً أو يتأثر بتداخل أو انعكاسات الخلفية.

لمواجهة هذه القيود، سعى العديد من الباحثين إلى تحسين استخراج السمات في الصور الحرارية. فقد أظهرت الدراسات [9] و [14] استخدام الشبكات العصبية التلافيفية (CNN) لتحليل الصور الحرارية في مجال الأمن، مع التركيز على اكتشاف الأشخاص في الصور والفيديوهات الحرارية. وأكدت الدراسات أن نماذج التعلم العميق المدربة على صور RGB مثل YOLO الأصلي (bYOLO) تحقق أداء منخفضاً عند تطبيقها مباشرة على الصور الحرارية، حيث بلغ متوسط دقة الاكتشاف (AP) حوالي ٧٪ فقط مقارنة بما يقرب من ٩٠٪ على صور RGB. وقد أظهرت إعادة تدريب النموذج على مجموعات بيانات حرارية خاصة تحسناً ملحوظاً في الأداء، ليصل متوسط الدقة إلى نحو ٣٠٪، مما يبرز الحاجة لتكييف الخوارزميات مع خصائص الصور الحرارية بشكل أفضل.

وأيضاً، أشارت الدراسة [4] إلى تدريب الشبكات العصبية على وجوه بشرية في الصور الحرارية باستخدام عدد هائل من العينات، مما أدى إلى تحسن جزئي في كشف الوجوه، لكنه لم يعالج الأهداف الأخرى، ما يؤكد محدودية تطبيق خوارزميات الرؤية المرئية مباشرة على الصور الحرارية بسبب ضعف السمات المميزة للكائنات. علاوة على ذلك، درس [2] استخدام شبكة عالية الدقة (HRNet) لاستخراج خريطة ميزات دقيقة للكشف عن زاوية الهدف، إلا أن فعالية هذه التقنية تتراجع بشكل كبير عند التعامل مع الصور الحرارية ضعيفة السمات، بسبب تشوه شكل الكائن وضعف الميزات الحرارية.

من جهة أخرى، أجريت دراسة مقارنة على كواشف السمات التقليدية للأهداف [10]، وهي كواشف لا تزال مستخدمة في الطرق الحديثة، لتقييم أدائها وفقاً لمعايير التكرارية، والتدرج، والدوران، والسرعة. أظهرت النتائج أن كاشف السمات Fast يتفوق من حيث السرعة، ما يجعله مناسباً لتطبيقات الزمن الحقيقي، لكنه يعاني من تراجع الدقة أثناء الدوران، في حين يظهر كاشف SIFT أداء أفضل من حيث التكرارية والدقة من التغيرات في الحجم، ولكنه أبطأ نسبياً.

الجدول (1) نتائج اختبار كواشف السمات بالترتيب

الترتيب	عدد النقاط المتوافقة	التكرارية	الدوران	السرعة	تغير الإضاءة	الدقة	الدوران
1	Fast	Sift	Surf	Fast	Surf	Sift	Orb
2	Surf	Surf	Star	Orb	Sift	Surf	Sift
3	Sift	Star	Sift	Brisk	Orb	Orb	Surf
4	Gfft	Mser	Orb	Star	Sift	Sift	Orb
5	Harris	Orb	Mser	Gfft	Orb	Surf	Sift
6	Orb		Brisk	Surf		Orb	Surf
7	Brisk			Sift			Sift

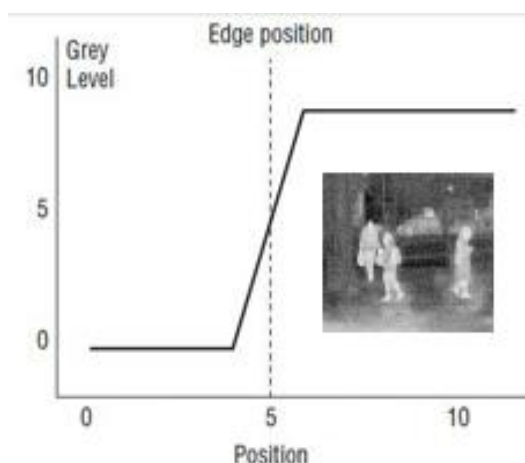
هذه التقييمات توفر أساساً لاختيار الكواشف الأكثر ملاءمة لتطوير خوارزميات تعزيز السمات للأهداف الحرارية ضعيفة الملامح.

## ٢- الطريقة المقترحة

تواجه خوارزميات الرؤية الحاسوبية التقليدية، المصممة لمعالجة الصور المرئية، صعوبات كبيرة عند تطبيقها على الصور الحرارية، خصوصاً في سياق تمييز الأهداف، نظراً لضعف السمات المميزة للكائنات في هذه الصور. لذلك، اقترحنا تعزيز السمات الأساسية للأهداف الحرارية عبر استحداث سمات جديدة تضاف إلى السمات التقليدية المستخدمة في الكشف والملاحقة، بهدف دعم قدرة النظام على تمييز وتعريف الأهداف بدقة أعلى.

## ٢-١ سمات الهدف التقليدي

تعد الحواف من أبرز السمات التي تعتمد عليها خوارزميات الكشف والتتبع، حيث تمثل الحافة انتقالاً حاداً في التدرج اللوني أفقياً أو عمودياً أو كلاهما. يمكن استنتاج الحواف بسهولة عبر حساب الاشتقاق بالنسبة للمحورين الأفقي والرأسي كما في الشكل (٦)، مع تطبيق عتبة لتحديد الحواف الفعلية [١١].



الشكل (6) المشتق كبير عندما تكون الحافة كبيرة

حيث تشير قيمة عالية للمشتق إلى وجود حافة ذات قيمة كبيرة سواء في X أو Y. ومن الضروري إجراء الاشتقاق على كلا المحورين لاستنتاج الحواف المائلة.


$$\nabla A(x, y) = \left( \frac{\partial A}{\partial x}, \frac{\partial A}{\partial y} \right) \quad (1)$$

كما يمكن استخدام مرشحات مختلفة للحصول على الحواف.

$$Gx = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} * \text{Image matrix} \quad (2)$$


$$Gy = \begin{bmatrix} 1 & 0 & -1 \\ 2 & 0 & -2 \\ 1 & 0 & -1 \end{bmatrix} * Image\ matrix$$

إضافة إلى الحواف، تعد الزوايا من السمات الهامة للكشف والتمييز، الشكل (٧) حيث تعرف بأنها نقاط التقاء الحواف. وتوجد خوارزميات عديدة لاكتشاف الزوايا، من أبرزها: خوارزمية Shi و Tomasi لاستخراج السمات، خوارزمية Harris لكشف الزوايا، وخوارزمية Fast Corner Detector.



الشكل (٧) انتماء النقطة إلى منطقة "مسطحة Flat"، حافة Edge، زاوية Corner"

أجرينا دراسة تجريبية باستخدام برنامج Matlab على كائن محاكٍ ضعيف الميزات: لاعب كرة قدم له عدة مناطق مشعة حرارياً غير متراففة مع مركزه، وتمتاز بتدرج حراري تدريجي، بحيث لا تظهر أي حواف واضحة سوى المحيط. طبقنا الخوارزميات السابقة لمحاولة تقييم تأثير نقص السمات على القدرة على اكتشاف الهدف وتتبع حركته، خصوصاً أثناء الدوران كما في (الشكل ٨).



الشكل (8) تطبيق خوارزميات مختلفة لكشف السمات على كائن يلتف


أظهرت النتائج أن السمات المكتشفة لا تتطابق بين الإطارات المختلفة بعد دوران اللاعب، مما يجعله غير مناسبة للتتبع المستمر، حتى عند تحديد عدد السمات الأقصى بـ ١٢، ولا تظهر أي حواف واضحة.

## ٢-٢ مركز الكائن الفعال

نظراً لنقص السمات في الصور الحرارية، اقترحنا سمة جديدة تُعرف باسم مركز الهدف الفعال، والتي تمكّن من حساب زاوية نسبية للكائن كميزة إضافية. هذه السمة تساهم في تحسين دقة تحديد اتجاه الكائن، ودعم خوارزميات الملاحقة والتعريف، خاصة عند وجود أهداف متعددة ضعيفة السمات.


مفهوم مركز الكتلة أو مركز الثقل في الميكانيك يوفر أساساً مناسباً لتعريف هذا المركز في الصور الحرارية. يمثل مركز الكتلة نقطة تمثل توزيع الكتلة أو الكثافة بشكل مركزي كما في الشكل (٩)، ويمكن استخدامه لتحديد موقع الجسم بدقة عالية [12].

$$m_1 \cdot d_1 = m_2 \cdot d_2 \quad (3)$$



الشكل (٩) بعد مركز ثقل جملة كتلتين  $m_1, m_2$  [12]

$$m_1 \cdot (x_c - x_1) = m_2 \cdot (x_2 - x_c) \quad (4)$$



الشكل (10) إحداثي مركز ثقل جملة كتلتين  $m_1, m_2$

ويكون إحداثي مركز الثقل كما في الشكل (١٠) بالنسبة لـ  $x$  هو:

$$x_c = \frac{m_1 x_1 + m_2 x_2}{m_1 + m_2} \quad (5)$$

وبالتعميم لجميع نقاط الجسم:

$$x_c = \frac{\sum_{i=1}^n m_i x_i}{\sum_{i=1}^n m_i} \quad (6)$$

وبالنسبة لـ  $y$ :

$$y_c = \frac{\sum_{j=1}^n m_j y_j}{\sum_{j=1}^n m_j} \quad (7)$$

في معالجة الصور، يُطبق هذا المفهوم عبر حساب عزم المنطقة، حيث تُعامل قيم البيكسل ككثافة احتمالية، ويتيح العزم من الدرجة الأولى تحديد إحداثيات المركز بالنسبة للمناطق الحرارية المميزة [١٣]. يعتمد عزم النظام من الدرجة  $(p + q)$  على القياس والتحويل والدوران وحتى على التكاملات ذات المستوى الثنائي ويعطى بواسطة:

$$m_{pq} = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} x^p y^q f(x, y) dx dy \quad (8)$$

وبالصورة الرقمية:

$$m_{pq} = \sum_{i=-\infty}^{+\infty} \sum_{j=-\infty}^{+\infty} i^p j^q f(i, j) \quad (9)$$

حيث  $(x, y), (i, j)$  هي إحداثيات النقطة بالمنطقة (إحداثيات البيكسل في الصور الرقمية).

ويكون العزم بالنسبة للمركز

$$\mu_{pq} = \sum_{i=-\infty}^{i=+\infty} \sum_{j=-\infty}^{j=+\infty} i - x_c^p j - y_c^q f(i, j) \quad (10)$$

حيث  $x_c, y_c$  هي إحداثيات ثقل الكائن (مركز الجاذبية) [١٣] والتي يمكن حسابها من:

$$y_c = \frac{m_{01}}{m_{00}} x_c = \frac{m_{10}}{m_{00}}$$

أي يمكن توظيف العزم من الدرجة الأولى لكل من  $m_{01}$  و  $m_{10}$  لإيجاد موضع الكائن

$$Object\ Center = (x_c, y_c) = \left( \frac{m_{10}}{m_{00}}, \frac{m_{01}}{m_{00}} \right) \quad (11)$$

يلاحظ أن الدرجة الصفرية ل العزم هي ببساطة البكسلات المحتواة في الكائن لأن:

$$i^0 = j^0 = 1$$

في الصور الحرارية، لا يكون توزيع السطوح متجانساً، مما يؤدي إلى اختلاف المركز الحراري عن المركز الهندسي التقليدي للهدف، ويؤثر سلباً على أداء الملاحقة، خاصة للأهداف الصغيرة أو منخفضة الإشعاع الحراري كما في (الشكل ١١).



الشكل (11) كائن في الصورة الحرارية، C1 مركز الهدف الفعلي، C2 مركز الفعالية الحرارية للهدف، C3 مركز الهدف الفعال.

لذلك، قمنا بتعريف مركز الهدف الفعال C3 كمتوسط موزون بين مركز الهدف الفعلي C1 ومركز فعالية الهدف C2، حيث يمثل C2 المنطقة الأعلى سطوحاً.

لإيجاد معادلة احداثيات المركز المنشود يجب الأخذ بعين الاعتبار ما يلي:

- المركز الأساسي للكائن
- تثقيل المناطق حساب الكثافة اللونية (السطوح)
- إزاحة مركز الثقل باتجاه الأوزان الكبيرة بشكل يتناسب مع أهمية كل نقطة حرارياً.
- من أهم العلاقات التي يمكن استخدامها علاقة التوازن في الكتل (مركز الثقل) أو معادلات العزم كما في

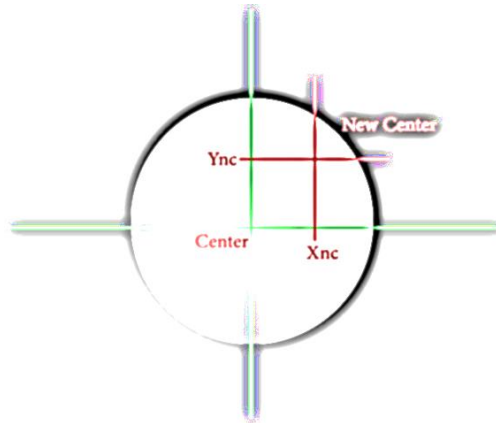
المعادلات (٦)(٧)، ففي حالة جسم:

$$x_c = \frac{\sum_{i=1}^n m_i x_i}{\sum_{i=1}^n m_i}$$

$$y_c = \frac{\sum_{j=1}^n m_j y_j}{\sum_{j=1}^n m_j}$$

ندخل هنا معامل لتثقيل الانزياح للمنطقة الفعالة بدلاً عن الكتلة، وباعتبار أن ما يميز المنطقة الفعالة هو شدة السطوع الشكل (١٢)، بالتالي يجب أن يتم حساب سطوع الجسم  $I$  بدلاً من الكتلة  $m$ ، ومن أجل هدف بأبعاد  $(n \times m)$  تصبح العلاقات:

$$x_{nc} = \frac{\sum_{i=1}^n I_i x_i}{\sum_{i=1}^n I_i} \quad y_{nc} = \frac{\sum_{j=1}^m I_j y_j}{\sum_{j=1}^m I_j} \quad (12)$$




الشكل (12) تمثيل لكائن مثالي ضعيف الميزات ومركزه الجديد NewCenter

يلاحظ بأن اعتماد نظام ألوان ثنائي  $(I = \{0,1\})$  سيعيدنا إلى مركز الشكل الأساسي إن من يحدد أبعاد الهدف على المحور هو أدنى بيكسل بأدنى سطوع محدد وأعلى بيكسل بأدنى سطوع لكل من المحورين الإحداثيين، أي يسمى بعتبة تدرج الرمادي المستخدمة في التجزئة "تابع العتبة" [١١]. إن منطقة اهتمام المعالجة (ROI) ستكون بعرض أكبر من  $n$  وارتفاع أكبر من  $m$  للسماح بالتقاط الهدف أثناء حركته في الإطارات التالية بالتالي يمكن تعميم المعادلات على منطقة الاهتمام (ROI) بتطبيق تابع العتبة Threshhold المستخدم في المرجع [١١] وهي عتبة تدرج الرمادي والهدف منها تحديد مركز فاعلية هدف حراري.

$$Th(I) = \begin{cases} 0 & \text{if } I < \text{Threshold} \\ 1 & \text{if } I > \text{Threshold} \end{cases}$$

نعدل في استخدامه على الشكل، إعطاء السطوع  $I$  القيمة 0 للبيكسلات التي سطوعها أقل من العتبة، والقيم 1 للقيم فوق العتبة الشكل (١٣).

$$Th(I) = \begin{cases} 0 & \text{if } I < \text{Threshold} \\ 1 & \text{if } I > \text{Threshold} \end{cases}$$



الشكل (13) تابع العتبة


ولابد للتخفيف من أثر الضجيج من تطبيق مرشح مكاني خطي لتصفية الصورة وإضافة ضبابية ناعمة [١١]. حيث من الممكن أن يحرف مركز الهدف الفعال عن المكان الفعلي تحت تأثير الضجيج بسبب دخوله كنتقليل في السطوع

$$g(x,y) = \sum_{s=-a}^a \sum_{t=-b}^b w(s,t)f(x+s,y+t) \quad (13)$$

حيث  $w(s,t)$  من النوع الغاوسي  $4 \times 4$

إن تطبيق طريقتنا لاكتشاف مركز فعالية هدف حراري سيمكن من تحديد نقطة جديدة عبارة عن مركز فعالية الهدف وسيشكل هذا المركز بالإضافة لمركز الهدف، شعاعاً طوله يمثل انزياح المركز الجديد عن الأصلي، بينما تمثل زاويته زاوية الهدف النسبية، كما في الشكل (١٤).

### ٢-٣ حساب اتجاه الهدف




الشكل (14) زاوية الهدف الفعال

إن زاوية اتجاه الهدف هي:

$$angle = \text{atan} \left( \frac{y_n - y_0}{x_n - x_0} \right) \quad (14)$$

$y, x$  ، هي احداثيي مركز الهدف

$y_n, x_n$  ، هي احداثيي مركز الهدف الفعال



الشكل (15) علاقة بعد المركز الجديد بدقة الزاوية

ومن الشكل (15) يتبين أنه كلما ابتعدنا عن المركز الكلاسيكي كلما تم تمثيل الاتجاه بشكل أفضل.


### ٢-٤ تحسين استقرار المركز الفعال

لتقليل تأثير الضجيج والانحراف الناتج عن اختلاف السطوع، يُنصح بتطبيق مرشحات مكانية خطية و Gaussian smoothing قبل حساب المركز الفعال. كما يتم ضبط معايير العتبة لضمان تضمين جميع

البيكسلات الممثلة للهدف ضمن منطقة الاهتمام، مع السماح بالتحرك ضمن الإطارات المتعاقبة. بهذه الطريقة، توفر السمة الجديدة مركزاً موثقاً لتحديد اتجاه الكائن ودعمه في خوارزميات الكشف والملاحقة، من خلال إعداد Pipeline كامل يشمل الخطوات المتبعة من مرحلة ما قبل المعالجة وصولاً إلى حساب مركز الهدف الفعال.


### ٣- التطبيق والنتائج

لتقييم فعالية الخوارزمية المقترحة والتحقق من نتائجها، تم تنفيذ التجارب باستخدام بيئة التطوير PyCharm مع لغة Python الإصدار ٣,٨، بالإضافة إلى Matlab، وفق ثلاث مراحل رئيسية:




#### ١-٣ المرحلة الأولى: كشف المركز الفعال وملاحقته

تم تطبيق الخوارزمية على إطارات الفيديو لمحاكاة هدف مثالي ضعيف السمات يتميز بتدرجات حرارية منخفضة ويدور حول نفسه. أظهرت النتائج قدرة الخوارزمية على تحديد المركز الفعال للهدف بدقة، وكذلك ملاحقته أثناء الدوران (الشكل ١٦، ١٧). يمثل المركز الفعال موقع وزمن النقطة المرجعية للهدف في كل إطار.



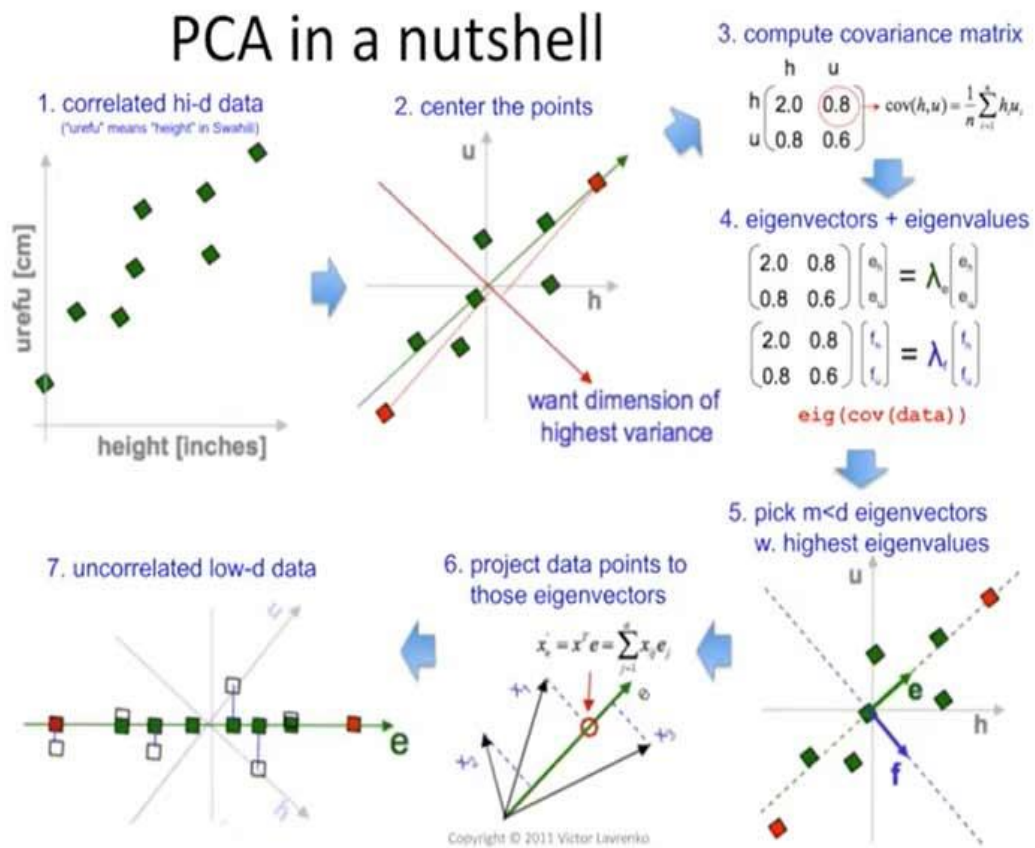
الشكل (١٦) كشف المركز الفعال للكائن الهدف (النموذجي)



الشكل (١٧) تطبيق الطريقة على هدف دائري،  $C_n$  تمثل المركز الفعال للهدف


#### ٢-٣ المرحلة الثانية: المقارنة مع خوارزمية PCA

لتوضيح فاعلية الطريقة في تحديد اتجاه الهدف، تمت مقارنة أدائها مع خوارزمية تحليل المكونات الرئيسية (Principal Component Analysis, PCA) المستخدمة تقليدياً لاستخراج منحى الأهداف. تعتمد PCA على إسقاط السمات على محور دوار لإيجاد محور يحقق أقصى مجموع للقيم، ممثلاً بذلك منحى الكائن (الشكل ١٨).

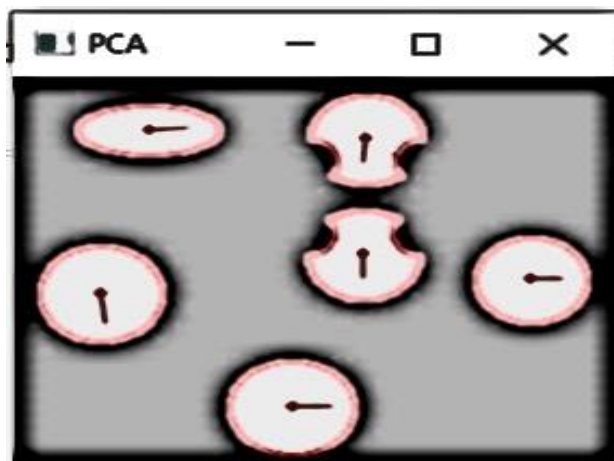


الشكل (18) طريقة PCA [14]

تم اختبار PCA على ١٠٠ صورة لأشكال متنوعة [14]، حيث نجحت في تحديد المنحى الصحيح لنحو ٦٥٪ من العينات، بينما فشلت في الأشكال المتناظرة أو الدائرية. كما لم تتمكن PCA من تحديد الاتجاه النسبي بين كائنين مختلفين عند مشاركة المنحى نفسه (الشكل 19, 20).




الشكل (19) مجموعة أشكال للاختبار



الشكل (20) نتائج تطبيق PCA على مجموعة الاشكال

بالمقابل، أظهرت الطريقة المقترحة قدرة أعلى على تحديد الاتجاه النسبي للأهداف التي فشلت PCA في كشفها (الشكل ٢١)، مع مدة زمنية أقل وإمكانية تحديد اتجاه الكائن وليس مجرد المنحى كما يظهر الجدول (2)



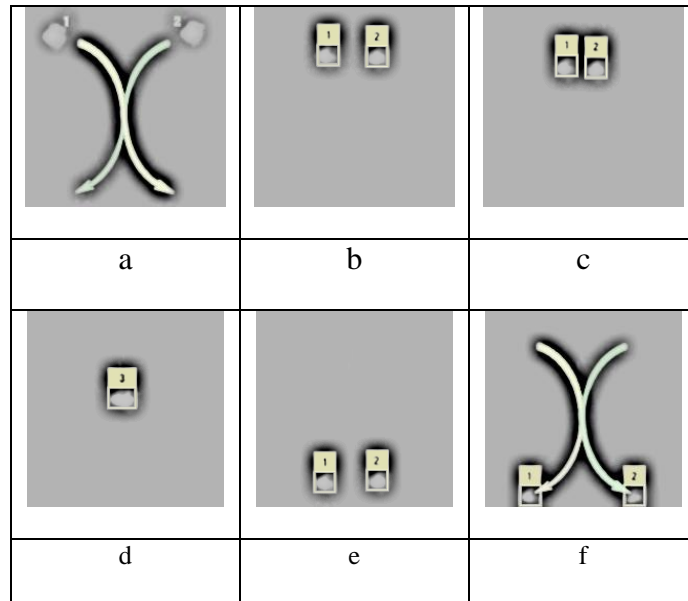
الشكل (21) نتائج تطبيق طريقتنا على مجموعة الاشكال

الجدول (2) القدرة على تحديد الاتجاه النسبي

الترتيب	رقم الشكل	الحجم	الدوران	الاتجاه
1	A	محقق	معروف	محدد
2	B	محقق	معروف	غير محدد
3	C	محقق	غير معروف	محدد
4	D	محقق	معروف	غير محدد
5	E	محقق	غير معروف	محدد
6	F	محقق	غير معروف	محدد


٣-٣ المرحلة الثالثة: ملاحقة هدفين متداخلين


تم إنشاء محاكاة لهدفين ضعيفي المعالم يتحركان بسرعة ثابتة وفق مسار محدد بحيث يتقاطعان في منتصف الإطار (الشكل ٢٢-ا). تم تطبيق خوارزمية تتبع الأهداف المتعددة (Multi-Object Tracking, MOT) المدعومة بمرشح كالمان (Kalman Filter). [15]



الشكل (22) نتائج تطبيق خوارزمية الملاحقة MOT

أظهرت النتائج أن الخوارزمية تتعقب الهدفين بشكل صحيح قبل التداخل، لكنها تفترض وجود هدف واحد أثناء التقاطع، مما يؤدي إلى تعريف خاطئ لمسارات الهدفين (الشكل ٢٢-د-ف).





الشكل (٢٣) نتائج دعم قرار التمييز في خوارزمية الملاحقة


عند دمج طريقة المركز الفعال لدعم القرار ضمن خوارزمية MOT، تم تحسين دقة التتبع من خلال ظهور الشكل الأول منفصل عن الشكل الثاني والتعريف بشكل ملحوظ، حيث استخدمت زاوية المركز الفعال لكل هدف كمعامل دخل لمرشح كالمان، مما مكن النظام من متابعة وتقدير الزوايا بعد التداخل وتصحيح مسارات الهدفين بعد التقاطع والانفصال (الشكل ٢٣).

### ٣-٤ تحليل الأخطاء


تم تحليل العلاقة بين دقة تقدير زاوية الهدف وبعد المركز الفعال عن المركز التقليدي للهدف، حيث أظهرت النتائج أن الخطأ يكون صغيراً عند زيادة البعد بين المركز الفعال والمركز التقليدي، ويمكن تحقيق دقة تصل إلى درجة واحدة عند بعد ٥٠ بيكسل (الشكل ٢٥ و ٢٦).

الخطأ في قياس الزاوية = عدد البكسلات (الزاوية للمركز الفعال الفعلية - الزاوية للمركز الفعال

المحسوبة) / ١٠٠



الشكل (٢٤) الخطأ المرتكب بقياس الزاوية



الشكل (25) العلاقة بين الخطأ المرتكب بقياس الزاوية وبعدي المركز الفعال

### ٣-٥ نقاط ضعف الطريقة

في الأهداف المتجانسة حرارياً، نقل جودة تحديد الاتجاه بسبب تقارب الشكل إلى التناظر. انخفاض جودة الأداء يحدث أيضاً عندما يكون مركز الفعالية الحرارية قريباً جداً من المركز التقليدي للهدف، مما يقلل من دقة قياس زاوية الهدف.

### ٤- الاستنتاجات

استطاعت الطريقة توفير أداة فعالة لتعزيز سمات الأهداف الحرارية ضعيفة الملامح، ودعم اتخاذ القرار في خوارزميات التعرف والتتبع وخاصة عند تقاطع الأهداف.

تمكّن الخوارزمية من تحديد زاوية الهدف النسبية، ما يسهل مراقبة دوران الكائنات أثناء الحركة.

تسهّل الطريقة عملية تشكيل مربعات الإحاطة المائلة عند استخدام الشبكات العصبية.

يتأثر الأداء بدرجة تجانس حرارة الهدف وقرب المركز الفعال من المركز التقليدي للهدف.

٥ - المراجع العلمية

- 1 - Bone, P., Young, R., & Chatwin, C. (2006). Position, rotation, scale and orientation invariant object tracking from cluttered scenes. *Optical Engineering*, 45(7)2 - Yuan, Z., Kou, S., Tang, Q., & Xu, F. (2021). A rotating object detection method based on anchor-free in remote sensing scene images. *Journal of Physics: Conference Series*, 2189
- 3 - Chen, C., & Li, D. (2021, September 6). Research on the detection and tracking algorithm of moving objects in images based on computer vision technology. *Hindawi Wireless Communications and Mobile Computing*, Article ID 1127017.
- 4 - Ashrafi, R., Azarbayjania, M., & Tabkhi, H. (2022). A fully annotated thermal infrared face dataset with various environmental conditions and distances. *arXiv:2205.02093*.
- ٥ - Zhang, L., Wang, H., Wang, L., Pan, C., Liu, Q., & Wang, X. (2021). Constraint loss for rotated object detection in remote sensing images. *Remote Sensing*. Isalkar, A. D., Gandhi, S. G., & Papat, M. K. (2020). IR and thermal image characteristics. *IJARIIIE*, 6(2), ISSN(O)-2395-4396
- 7 - Motorcu, H., Ates, H. F., Ugurdag, H. F., & Gunturk, B. K. (2021). HM-Net: A regression network for object center detection and tracking on wide area motion imagery. *IEEE*. <https://doi.org/10.1109>
- 8 - Rawat, S. S., Verma, S. K., & Kumar, Y. (2019). Review on recent development in infrared small target detection algorithms. *International Conference on Computational Intelligence and Data Science (ICCIDS)*.
- 9 - Ivašić-Kos, M., & Krišto, M. (2020, April). Human detection in thermal imaging using YOLO. *International Journal of Engineering and Advanced Technology (IJEAT)*, 9(4), ISSN: 2249–8958 (Online).
- 10 - Majdi Al-Khatib. (2015). Real-time position estimation based on images in large-scale environments. *High Institute of Applied Sciences and Technology*.
- 11 - Gonzalez, R. C., & Woods, R. E. (2018). *Digital image processing* (4th ed.). Pearson Education.
- 12- Gahramanova, A. (2019). Locating centers of mass with image processing. *UJMM*, 10.
- 13 - Wirth, M. A. (2004). *Shape analysis & measurement*. University of Guelph, Computing and Information Science.
- 14- Simplilearn. (2023). *Principal component analysis in machine learning*. Retrieved from <https://www.simplilearn.com/tutorials/machine-learning-tutorial/principal-component-analysis>.
- 15 - Van Assen, H. C., Egmont-Petersen, M., & Reiber, J. H. C. (2002). Accurate object localization in gray level images using the center of gravity measure: Accuracy versus precision. *IEEE Transactions on Image Processing*, 11(12).