

Enhancement Near Duplicate Retrieval for Multimedia communication

Abstract

In this work, we aim to improve the recovery of semi-duplicate NDIR images when the query image is a sub-image of an entire scene or part of it.

To achieve this, we suggest combining more than one image property. We applied image segmentation to the entire scene to optimize restored results.

We will present and evaluate simulation results using MATLAB for both the SIFT algorithm, the CBIR algorithm, and the results of the proposed image recovery method. the SIFT algorithm, the CBIR algorithm, and the results of our proposed image recovery method. The database approved in the search consists of 652 images.

Key Words:

Features image local, NDIR, SIFT, CBIR, Segmentation.

تحسين استعادة الصور في اتصالات الوسائط المتعددة

الملخص

في هذا العمل، نهدف إلى تحسين استعادة الصور شبه المكررة NDIR عندما تكون صورة الاستعلام صورة فرعية لمشهد كامل أو جزء منه. لتحقيق ذلك، نقترح دمج أكثر من خاصية واحدة للصورة. طبقنا تجزئة الصورة على المشهد بأكمله لتحسين النتائج المستعادة. سنقدم نتائج المحاكاة باستخدام MATLAB مع تقييم لها لكل من خوارزمية SIFT وخوارزمية CBIR، ونتائج طريقتنا المقترحة في استعادة الصور. قاعدة البيانات المعتمدة في البحث مكونة من 652 صورة.

الكلمات المفتاحية:

سمات الصورة المحلية، استعادة الصور شبه المكررة، تحويل السمات غير المتغير مع المقاييس، استعادة الصورة اعتماداً على المحتوى، تجزئة الصور.

1. مقدمة:

يعيش عالمنا اليوم في حقبة رائعة من الصور المرئية التي مكنتنا من الوصول إلى المعلومات ومعالجتها ومشاركتها بسهولة بالغة. تاريخياً كان لدينا ثقة في مصداقية هذه الصور. مع النمو السريع للتقدم التكنولوجي في التكنولوجيا الرقمية من حيث الخوارزميات والأدوات القوية، مثل Photoshop و CorelDraw لمعالجة الصور الرقمية التي تأتي مع تحديات أمنية كبيرة تثير سؤالاً في هذه الثقة [1]. بشكل عام تزييف الصور هو معالجة الصور الرقمية سواء من حيث إحداث خلل في البيانات أو إدخال بعض المعلومات في الصور. استعادة الصور شبه المكررة (NDIR) يمكن تعريفه بأن مهمته البحث عن إصدارات مختلفة لنفس الصورة التي تخضع لعمليات تحرير متعددة مثل تعين الألوان، وتغيير المقاس، وتغيير التنسيق، وما إلى ذلك [2,3,4]. يمكن لصورتين أن تعتبرا صوراً شبه مكررة إذا كانتا كلاهما تنتهي إلى نفس المشهد ولكن مع اختلاف بسيط في زاوية التقاط الصورة وظروف السطوع. في بعض الحالات الفريدة [3]، أو إذا كانت بعض ظروف الصور مختلفة مثل التباین والتمويه والضوضاء وضغط jpg ، إلخ. تهتم هذه المقالة بكشف التكرارات الجزئية، أي الصور ذات الحشو والاقتاصص، ولكنها لا تزال تحتوي على صور فرعية شبه مكررة. تحتوي خوارزميات NDIR على العديد من القيود [4]، على سبيل المثال، قد تعاني الخوارزميات التقليدية التي تعتمد على المظهر من التغيرات في مشكلة الإضاءة والتطابق، والنوع الآخر من الخوارزميات التي تستخدم الميزة المحلية للعثور على صور مشابهة في بعض الأحيان لا تحسن التشوّه المحلي والارتباط المكانى بين مجموعتين من نقطتين . أحد أهم القيود في أساليب استعادة الصور شبه المكررة هي حالة التركيز على جزء معين من الصورة إذ إن اقتاصص جزء من الصورة قد يتسبب في تغيير معالمها الأساسية المستخدمة في كشف التشابه.

سمات الصورة المحلية [9] تعرف بأنها البنى الجزئية من الصورة التي تختلف عن مجاوراتها المباشرة وهي ترتبط بتغير في خصائص الصورة (الكتافة، اللون، النسيج)، يمكن أن تكون السمات المحلية نقطة أو حافة أو بقعة من الصورة. الهدف الأساسي للسمات المحلية الحصول على تمثيل قوي للصورة تسمح بشكل فعال بمطابقة البنى الجزئية بين الصور. في العام 2018 [5] كان هدف الباحثون اقتراح خوارزمية لمطابقة نقاط السمات لصورة سفينة بالاستناد إلى تحليل المكون الرئيسي وميزات تحويل سمات تغيير الحجم (PCA-SIFT). خلصت المقال إلى إمكانية الخوارزمية المقترنة في مطابقة هدف السفينة مع عينة السفينة المراد التعرف عليها، بغرض التحقق الدقيق من هدف السفينة من خلال مطابقة الصورة.

وفي العام 2019 [6] هدف الباحثون إلى اقتراح تقنية محسنة لإيجاد التطابق بين الصور، بالاعتماد على الشبكات العصبية الالتفافية CNN وعلى التحويل الموجي المنفصل DWT بدلاً من اتباع خوارزمية CBIR الأساسية للاستعادة. بينت الدراسة كفاءة التقنية في استعادة الصور مقارنة مع CBIR وذلك من حيث الدقة والقيم المستعادة بالإضافة لتقليل الزمن وزيادة التفاعل ومع المستخدم.

في العام 2018 [7] قام الباحث بدراسة ثلاثة طرق للكشف عن ميزات الصورة وهي SIFT, SURF, PCA-SIFT. ومقارنة أداء أساليب الكشف عن الميزات القوية للتغيرات الحجم، الدوران، التمويه، تغيرات الإضاءة، وغيرها. وخلاصت إلى

أن SURF سريع وذو أداء جيد لكنه ليس مناسب للتغيرات الدوران والإضاءة. في حين أن SIFT بطيء وغير مجيء في تغييرات الإضاءة لكنه ثابت في حالة تغير الحجم والدوران أما PCA-SIFT هو الخيار الأفضل في جميع الحالات. في العام 2017 [8] قام Rajesh، مع مجموعة من الباحثين بدراسة أنواع مختلفة من تزييف الصورة وتقنيات الكشف الخاصة بها، وركزوا بشكل أساسي على تلك القائمة على البيكسل، وخلصوا إلى أن جميع المنهجيات المدروسة لديها قدرة التعرف على التزييف، إلا أن بعض الخوارزميات لديها مشكلة تعقيد الوقت وغيرها لديها مشكلة تتعلق بتحديد منطقة التزييف الفعلية. مثبتين الحاجة الملحة لتطوير خوارزمية فعالة لكشف التزييف في الصور.

١.١ الخوارزميات المستخدمة في البحث:

١.١.١ تحويل السمات غير المتغير مع المقاييس

: SIFT (Scale Invariant Feature Transform)

تعد خوارزمية [9] SIFT كاشف وواصف للنقاط المميزة، تعامل الـ SIFT بشكل أساسي مع الصور الرمادية. وتعتمد على تجاهل النقاط السيئة والإبقاء على النقاط الأكثر أهمية.

١.٢.١ استعادة الصور اعتماداً على المحتوى

: CBIR (Colour Based Image Retrieval)

خوارزمية اعتمدت بهدف استعادة الصور التلقائي من قاعدة البيانات من خلال ميزات اللون والشكل. يعتمد مبدأ CBIR على حساب رسم بياني ثلاثي الأبعاد لتحويل HSV للصورة بأكملها. تمتاز بالسهولة والفعالية في استخراج السمات، تتطلب وقت أقل للعثور على الصور ذات الصلة [10,11].

٢. أهمية البحث:

نتيجة التطور الكبير للصور على الانترنت خاصة بعد الاستخدام المتزايد للهواتف الذكية، كثرت الصور المشابهة وأصبح يوجد أكثر من نسخة لنفس الصورة. عملية البحث عن الصور في قواعد البيانات باتت مطلوبة على نطاق واسع كالبحث عن الصور، والصور المشابهة، والصور الأصلية وغيرها. الخوارزميات المعتمدة في استعادة الصور تستغرق وقت طويلاً وذلك بالاعتماد على أساس عديدة من ميزات الصور المتعددة. تقليل من الوقت المستغرق لعملية البحث عن الصور المشابهة والمزيفة في قواعد البيانات. تطبيقات استعادة الصور كثيرة ذكر منها:

- البحث عن صورة معينة ضمن قاعدة بيانات ضخمة من الصور اعتماداً على بعض محتوى الصورة المستهدفة.
- التعرف على الأشياء وتتبعها.
- الكشف عن انتهاكات حقوق النشر.
- كشف التزييف.

٣. أهداف البحث:

تلخص أهداف البحث فيما يلي:

1. تحسين استعادة الصور المكررة عن طريق الجمع بين أكثر من نوع واحد من خوارزميات استعادة الصورة.

2. تقليل الوقت المستغرق لعملية البحث عن الصور في قواعد البيانات الكبيرة.
3. اقتراح تحسين للكشف عن الصور واستعادتها.
4. إنجاز تطبيق عملي للتحسين المقترن بصورة مشابهة لصورة الدخل.

5. طرائق البحث ومواده:

تم تطبيق عمليات المحاكاة على برنامج Matlab2018b، باستخدام حاسب شخصي بنظام تشغيل Windows7، وقد تضمنت عمليات المحاكاة عدة مراحل وفقاً لخوارزمية المقترنة وهي:

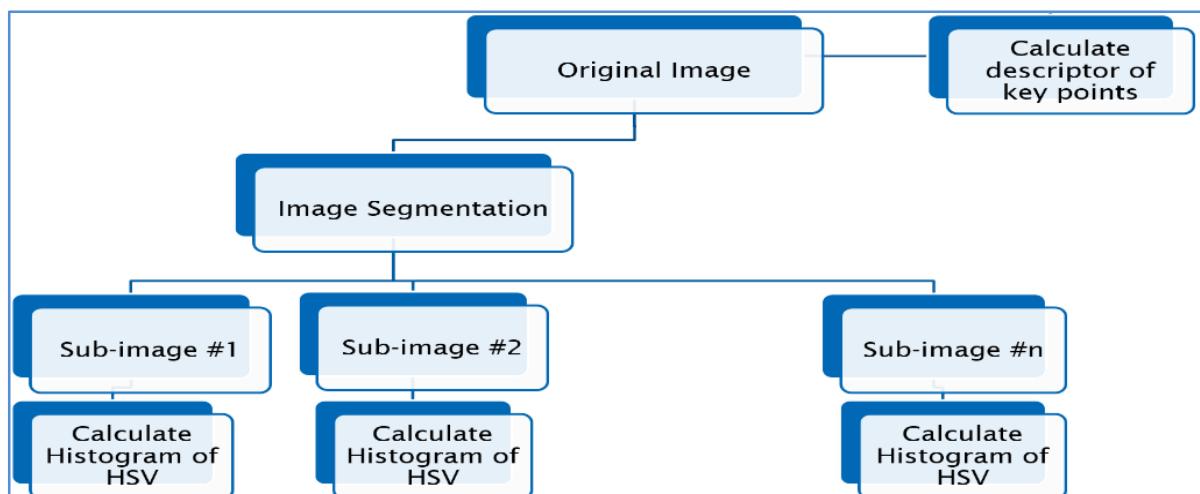
- اختيار قاعدة المعطيات.
- تشكيل قاعدة معطيات جديدة من القاعدة المختارة.
- البحث ضمن القاعدة التي تم بنائها.

1.5 اختيار قاعدة المعطيات:

تحتوي قاعدة المعطيات المختارة على مجموعة كبيرة من الصور لكتائن معروفة وأشياء متنوعة وذلك لجعل البحث ذو مجال واسع فالصور الملونة بمكونات الأحمر والأخضر والأزرق RGB يجعلها مناسبة لتطبيق خوارزمية CBIR، وأبعاد الصور متعددة لتتناسب إمكانية تطبيق خوارزمية SIFT العدد الكلي لقاعدة المعطيات المختارة هو 652 صورة.

2.5 مرحلة تشكيل قاعدة البيانات:

- تطبيق خوارزمية SIFT لكل صورة وإيجاد النقاط الهمة لها Key Point.
- حفظ جميع النقاط الهمة الناتجة وربطها باسم الصورة المطابقة لها.
- تقسيم الصورة إلى عدد من الصور الفرعية المتقطعة.
- حساب الرسم البياني اللوني HSV لكل صورة فرعية ناتجة عن التقسيم.
- حفظ الرسوم البيانية وربطها مع الصورة المطابقة للأصل.

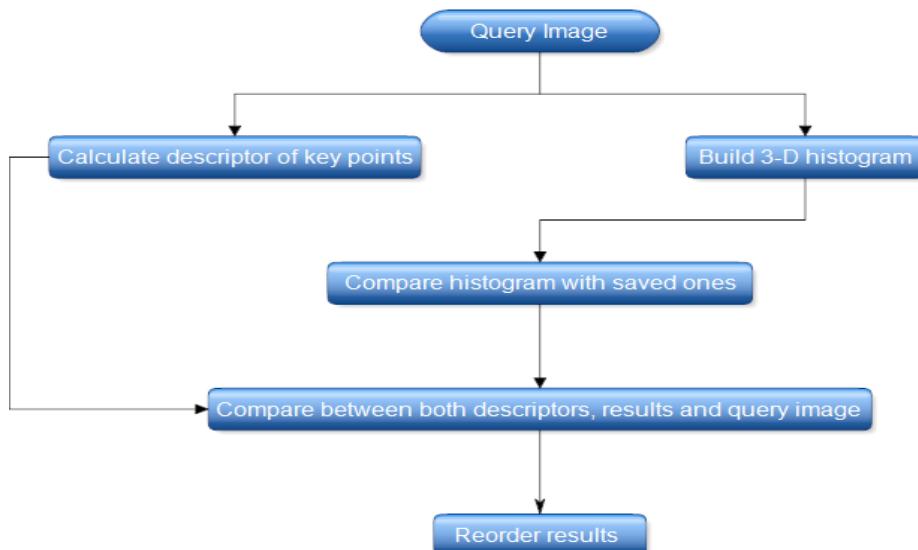


الشكل 1: توليد قاعدة البيانات.

المخطط الصندوقي في الشكل (1) يوضح المراحل السابقة.

5.3 مرحلة البحث ضمن قاعدة المعطيات:

- ١- حساب الرسم البياني ثلاثي الأبعاد للمخطط التكراري اللوني HSV وحساب النقاط الهامة وحفظها في قاعدة المعطيات.
 - ٢- مقارنة الرسم البياني اللوني لصورة الاستعلام مع تلك المحفوظة في قاعدة المعطيات.
 - ٣- استعادة الصور الأكثر تطابقاً مع صورة الاستعلام.
 - ٤- إعادة ترتيب الصور وفقاً لحساب المسافة بين وصفات صورة الاستعلام ووصفات الصور المستعادة.
- المخطط الصندوقي في الشكل(2) يوضح ما سبق.



الشكل2: مخطط مرحلة البحث.

6. النتائج التجريبية ومناقشتها

تعود مبررات التحسين المقترن إلى أن مطابقة الصور بالاعتماد على المخطط التكراري اللوني يسبب تشوهات بسهولة كبيرة، فأي صورتين متباينتين بالتوزع اللوني سيكون لهما المخطط التكراري اللوني نفسه وبالتالي فإن النتائج المستعادة ستكون خاطئة وغير دقيقة لذلك تم اختيار خوارزمية SIFT. في هذا المقال نقترح طريقة محسنة للكشف عن الصور المزيفة بالاعتماد على قياس المسافة بين الرسم البياني اللوني لصورة الاستعلام وتلك المحفوظة في قاعدة البيانات للعثور على أقرب صور قد تحتوي على صورة الاستعلام ومن ثم تطبيق خوارزمية SIFT لترتيب النتائج من الأقرب إلى الأبعد. الفكرة تتمثل في اعتبار الصورة مجموعة من الصور الفرعية ويجب معالجتها على أنها عدة صور وليس قطعة واحدة. لذا سنلجأ إلى تقسيم الصورة بطريقة مفيدة في كسر العلاقة بين ميزات الصور الفرعية التي ستحدث نتيجة المعالجة للصورة كقطعة واحدة، وذلك سيتم عن طريق تقسيم الصورة إلى عدة صور فرعية وتطبيق نوعين من أساليب استعادة الصور. حتى الآن لا توجد خوارزمية يمكن استخدامها لتجزئ الصور تلقائياً وتلبّي جميع المواصفات المطلوبة لتطبيق ما. أما طرق التجزئة المعروفة لا يمكن أن تعمل مع الخوارزمية المقترنة لأسباب عديدة منها:

- عدم إمكانية فصل الصور الفرعية بسهولة.
- مكلف حسابياً.
- عدم إمكانية معالجة حالة الأشياء والأغراض المتقطعة في خلفيات الصور.

طريقة التجزئة المقترحة تأخذ ثلاث معطيات كمعاملات دخل أساسية، لنجعل على مجموعة من الصور الفرعية كمعطيات في الخرج، معاملات الدخل للخوارزمية هي كالتالي:

- الخطوة الأفقية وهي نسبة مئوية من عرض الصورة نشير إليها بالرمز H_s .
 - الخطوة الرأسية وهي نسبة مئوية من ارتفاع الصورة نشير إليها بالرمز V_s .
 - النسبة المئوية المتداخلة نشير إليها بالرمز O_p ، يتم استخدامه لتحديد التقاءع بين الصور.
- فيما يلي العلاقات الرياضية لحساب حجم الصور الفرعية والنسب المئوية من الصورة الأصلية:

$$\text{sub image size (pixels)} = (H_s \times V_s) \times (\text{parent image size}) \dots \dots (1)$$

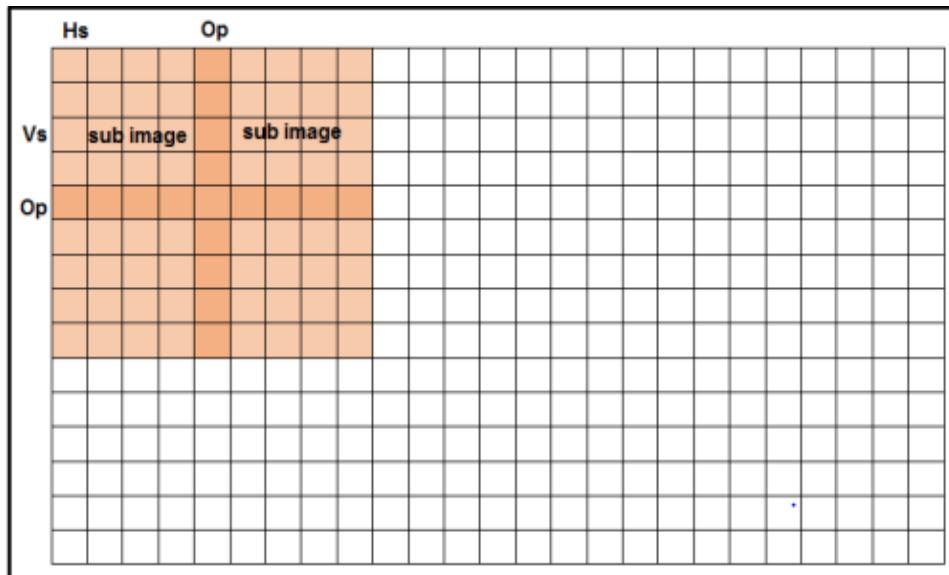
$$\text{sub image width (pixels)} = H_s \times (\text{parent image width}) \dots \dots (2)$$

$$\text{sub image height (pixels)} = V_s \times (\text{parent image height}) \dots \dots (3)$$

أما العلاقات الرياضية لحساب نسبة التقاءع بين الصور الفرعية بواسطة النسب المئوية المتراكبة:

$$H_o = O_p \times (\text{parent image width}) ; \text{in pixels unit} \dots \dots (4)$$

$$V_o = O_p \times (\text{parent image height}) ; \text{in pixels unit} \dots \dots (5)$$



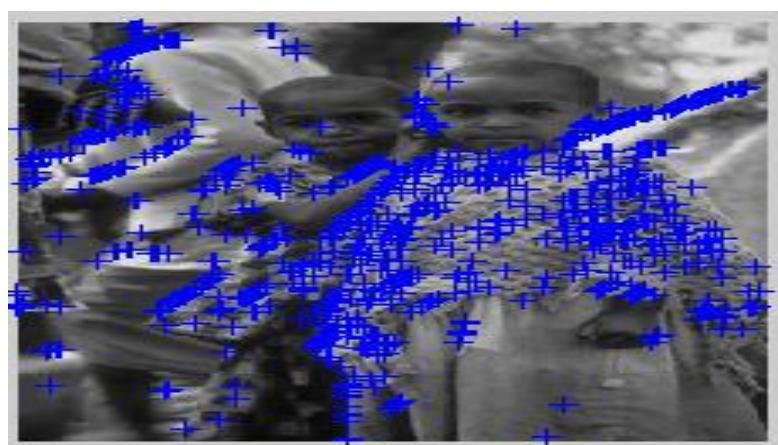
الشكل 3: تجزئة الصور باستخدام الشبكة.

الشكل (3)، يوضح لنا آلية تجزئة الصورة باستخدام الشبكة وفق الخطوات التالية:

- نحدد ثلاثة متغيرات تنتج عنها مجموعة صور فرعية.
- نأخذ نسبة مئوية من عرض الصورة Hs.
- نأخذ نسبة مئوية من ارتفاع الصورة Vs.
- نحسب النسبة المئوية للتدخل بين الصور Op .

١.٦ النبذة والمحاكاة:

تستخدم خوارزمية CBIR في العثور على النتائج الأولية لأن خوارزمية SIFT تعتمد على استخراج النقاط المميزة من الصورة ثم حساب واصف كل نقطة مميزة ولكن لا يتم توزيع النقاط المميزة على الصورة بأكملها، فقد تكون بعض الأجزاء تحتوي على نقاط مميزة لا تحتويها الأجزاء الأخرى، وهذه نقطة ضعف في خوارزمية SIFT لأنها في حالة التركيز على جزء من الصورة التي لا تحتوي على نقاط مميزة، سيتم الحصول على نتائج خاطئة.



الشكل 4: توزع النقاط المميزة في خوارزمية SIFT .

كما نلاحظ من الشكل (4)، أنه إذا كانت صورة الاستعلام هي رأس الطفل الذي لا يحتوي على أي نقطة مميزة عندها ستكون نتيجة الاستعادة غير صحيحة. ولهذا السبب تم اختيار خوارزمية CBIR للحصول على النتائج الأولية. وفيما يلي ندعم سبب اختيار خوارزمية CBIR أولاً.

كما هو ملاحظ في الشكل (7) الصورة a خاطئة في حين أن الصورة الصحيحة لصورة الاستعلام تكون في المرتبة الرابعة للصورة b.

نستنتج أن مساوى تطبيق خوارزمية SIFT على الصور المقسمة ومن ثم خوارزمية CBIR تتلخص بالتالي:

- حجم قاعدة البيانات الكبير.

- تتطلب وقت أطول لبناء قاعدة البيانات مقارنة بالحل المقترن.

- في بعض الحالات ، عند تطبيق خوارزمية SIFT على الصور المقسمة، تظهر صورة الاستعادة الصحيحة في النتائج الأولية، ولكن عند إعادة ترتيب النتائج الأولية باستخدام خوارزمية CBIR، فإن النتائج النهائية لا تتضمن الصورة الصحيحة.



الشكل 5: a: نتائج تطبيق SIFT أولاً ثم CBIR . b: النتائج وفق الحل المقترن .

الشكل 5: a: نتائج تطبيق SIFT أولاً ثم CBIR .

6.2 تقييم النتائج:

الفكرة تعتمد على تقييم أداء عمل كل من خوارزمية CBIR وخوارزمية SIFT ومن ثم المقارنة مع الخوارزمية المقترنة. وفق المعايير التالية:

✓ قاعدة البيانات المختارة تتكون من 652 صورة الموجودة في Math Works website. وتتمتع بالخصائص التالية:

- جميع الصور ذات بعد ثابت، بعرض 250 pixels وارتفاع 250 pixels.
- بعض الصور ذات دقة مختلفة.
- بعض الصور تتنمي لنفس المشهد مع اختلاف بسيط في الإضاءة في بعض الأحيان.
- بعض الصور تختلف في المشهد لكنها متشابهة إلى حد كبير من حيث الألوان.

صور الاستعلام عددها 100 تم اقتصاصها وربطها مع مجموعة البيانات الأصلية. وقد تم اختيارها بشكل عشوائي في معظم الحالات تبدأ الصور التي تم اقتصاصها في الموضع (0,0) من الصورة الأصلية. أما تجزئة الصور فقد تم اختيار النسبة المئوية للخطوة الأفقية والشنقوقية بمقدار 0.25 ونسبة التداخل بمقدار 0.05، النتائج المستعادة هي أقرب عشرة صور. لكل Query Image سيتم استعادة أول أقرب عشرة نتائج. يتم اختبار الخوارزميات مرتبين متتاليين:

- ✓ أولاً: اختيار حجم كل صورة مجزأة بشكل عشوائي، بحد أقصى قدره 35% من الصورة الأصلية.
- ✓ ثانياً: حجم كل صورة مجزأة 60% من الصورة الأصلية.

آلية تحديد عدد نقاط عملية التقييم:

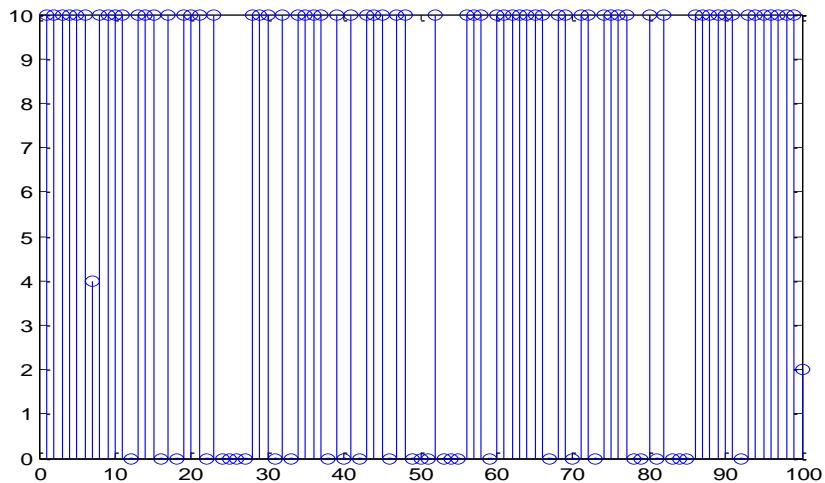
1. توليد ملف script على مجلد الصور ويعيد أسماء الصور ويقارنها ومن ثم يعرضها.
2. تقييم النتائج العشرة الأولى لكل صورة.
3. تمنح الصورة الصحيحة عدداً معيناً من النقاط.
4. يتم حساب عدد نقاط النتيجة الصحيحة وفق التالي:

$$\text{points} = \max(0, [10 + 1 - (\text{the position of correct result})])$$

نحدد لكل صورة استعلام عدداً من النقاط، لنتمكّن من الحصول على منحني لكل من (الحل المقترن، SIFT,CBIR). يمثل المحور (X) أرقام صور الاستعلام، ويمثل المحور (Y) عدد النقاط التي سيحصل عليها كل استعلام. حيث تحصل كل صورة استعلام على عشرة نقاط، مما يعني أن جميع النتائج جاءت في الموضع رقم واحد لكل صورة استعلام. سنوضح فيما يلي أداء كل من الخوارزميات (الحل المقترن، SIFT,CBIR).

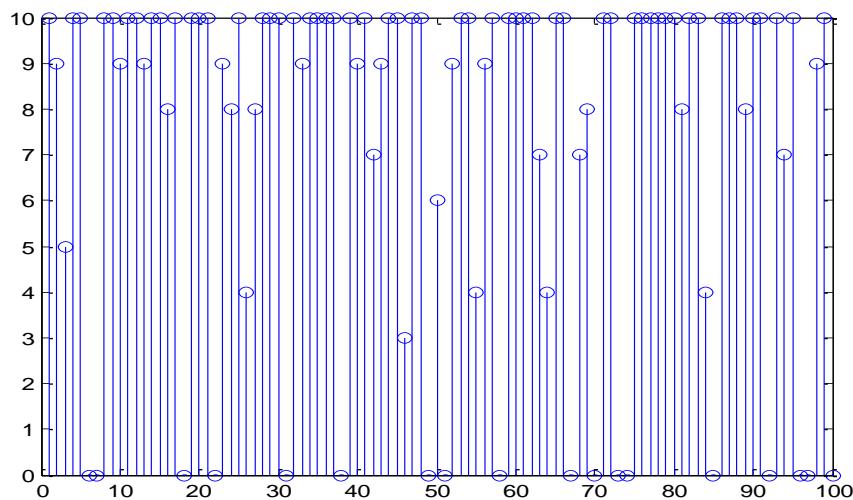
1.2.6 الصورة المجزأة عشوائياً:

نتائج اختبار الخوارزميات للصور حيث سيكون الحجم الأقصى لكل صورة مجزأة بمقدار أقل من 35% من الصورة الأصلية وذلك بشكل عشوائي.



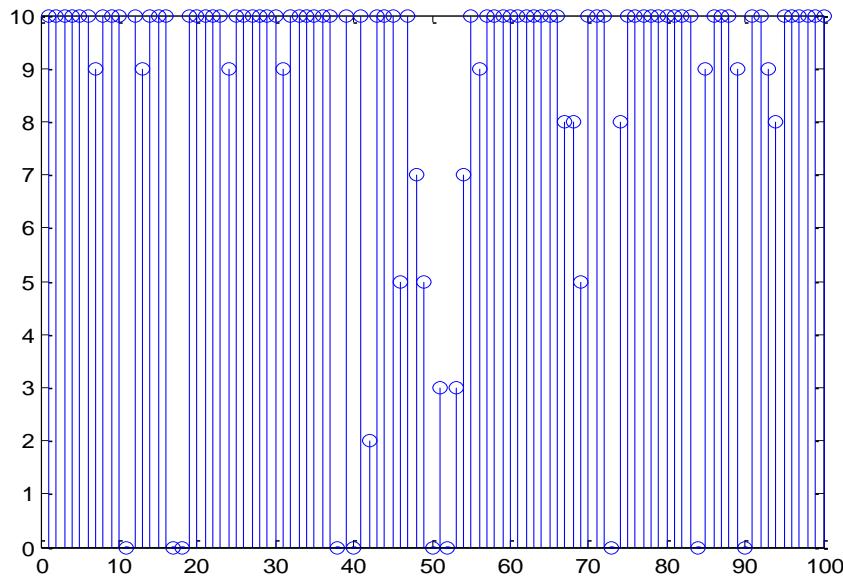
الشكل 6: أداء CBIR لصور مجزأة عشوائياً

يوضح الشكل (6) أداء خوارزمية CBIR إذ نلاحظ أن بعض النتائج غير صحيحة وتأخذ القيمة صفر (على المحور Y)، وأن عدد النتائج المقابلة لعشرة نقاط ليس كبيراً وهي التي تحدد النتيجة الصحيحة.



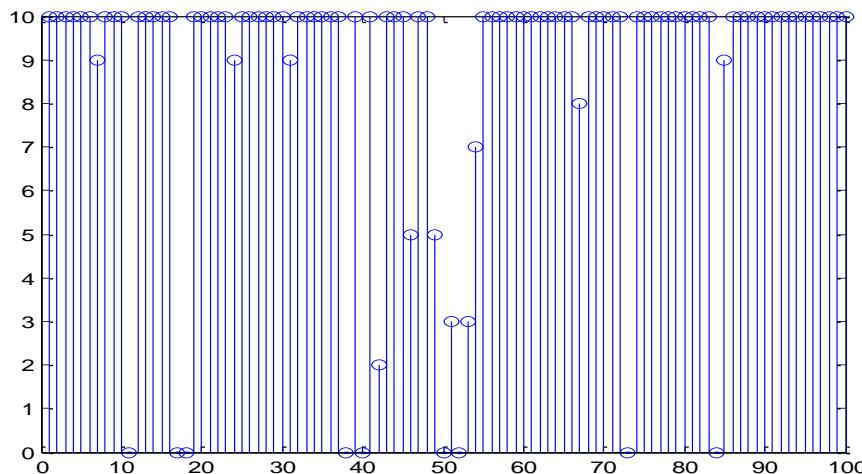
الشكل 7: أداء SIFT لصور مجزأة عشوائياً.

الشكل (7) يبيّن أداء خوارزمية SIFT، حيث نلاحظ أن النتائج إما لأول صورة تم استعادتها أو للنتيجة الخاطئة وهذا سوف يزداد الانحراف المعياري مقارنة مع أداء عمل CBIR.



الشكل 8: أداء الحل المقترن قبل تطبيق خوارزمية SIFT لصور مجڑأة عشوائياً.

الشكل (8) يبيّن أداء الحل المقترن قبل تطبيق خوارزمية SIFT وفيه نلاحظ أن النتائج أفضل من أداء الخوارزميات السابقة إذ نلاحظ تحسن الأداء مقارنة بهما.

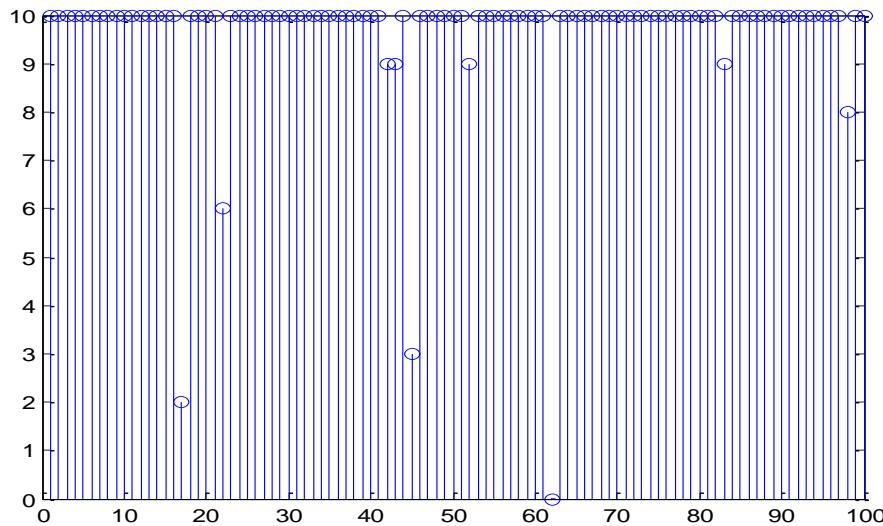


الشكل 9: أداء الحل المقترن بعد تطبيق خوارزمية SIFT لصور مجڑأة عشوائياً.

الشكل (9)، يبيّن أداء الحل المقترن بعد تطبيق خوارزمية SIFT، ومن خلاله نلاحظ تحسن الأداء بشكل أفضل مما كان عليه في حالة عدم تطبيق خوارزمية SIFT على الحل المقترن.

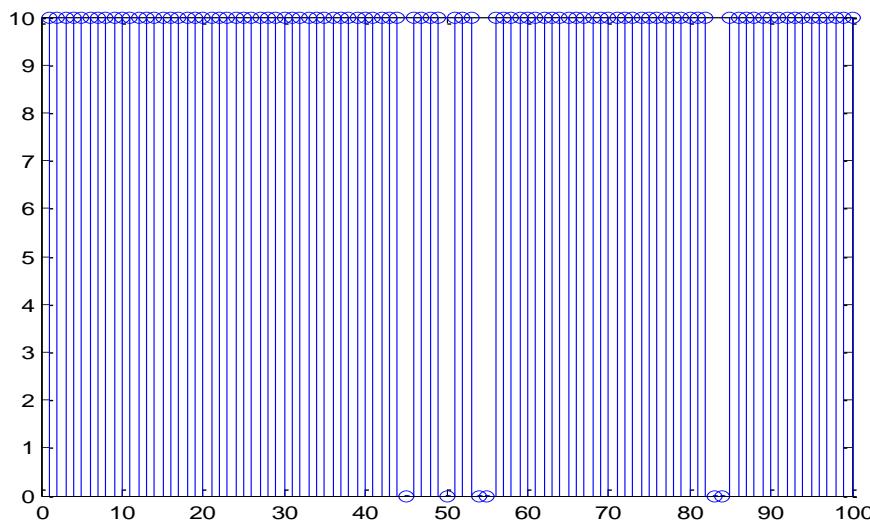
6.3.1 تجزئة الصور بنسبة 60%:

سندين نتائج اختبار الخوارزميات لحالة الصور المجزأة بنسبة 60% وذلك للحالات الثلاث (الحل المقترن، (SIFT,CBIR



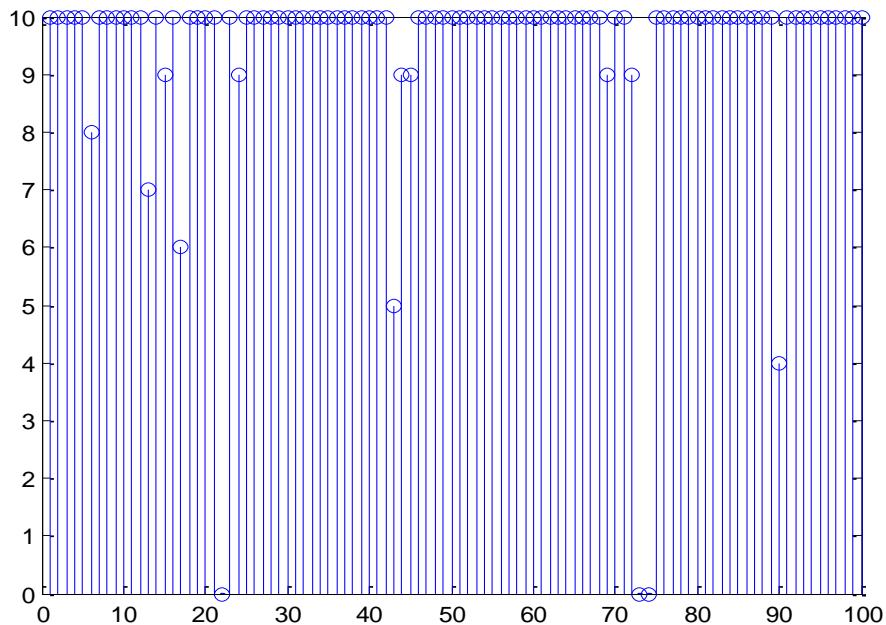
الشكل 10: أداء CBIR لصور مجزأة بنسبة 60%.

يوضح الشكل (10) أداء خوارزمية CBIR في حالة الصور المجزأة بنسبة 60%， ومن خلاله يتبيّن لنا أن أداء الخوارزمية قد تحسّن عما كان عليه في حالة الصور المجزأة بنسبة عشوائية أقل من 35%.



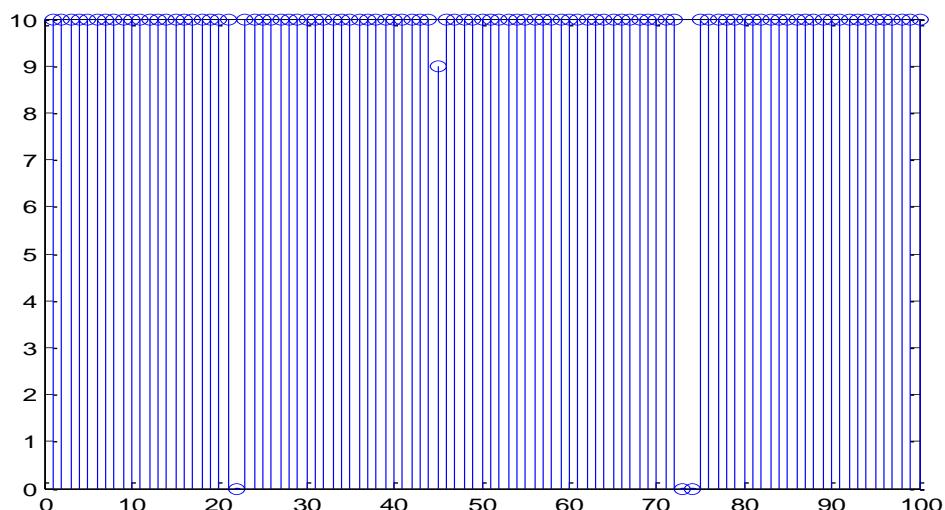
الشكل 11: أداء SIFT لصور مجزأة بنسبة 60%.

أما الشكل (11) يبيّن لنا أداء خوارزمية SIFT، لحالة صور مجزأة بنسبة 60% من الصورة الأصلية. وفيه نلاحظ أن أداء الخوارزمية أفضل بكثير مما كان عليه في حالة الصور المجزأة بنسبة عشوائية أقل من 35% من الصورة الأصلية. إذ إن النتائج تصبح بعيدة عن بعضها البعض (إما صفر أو عشرة).



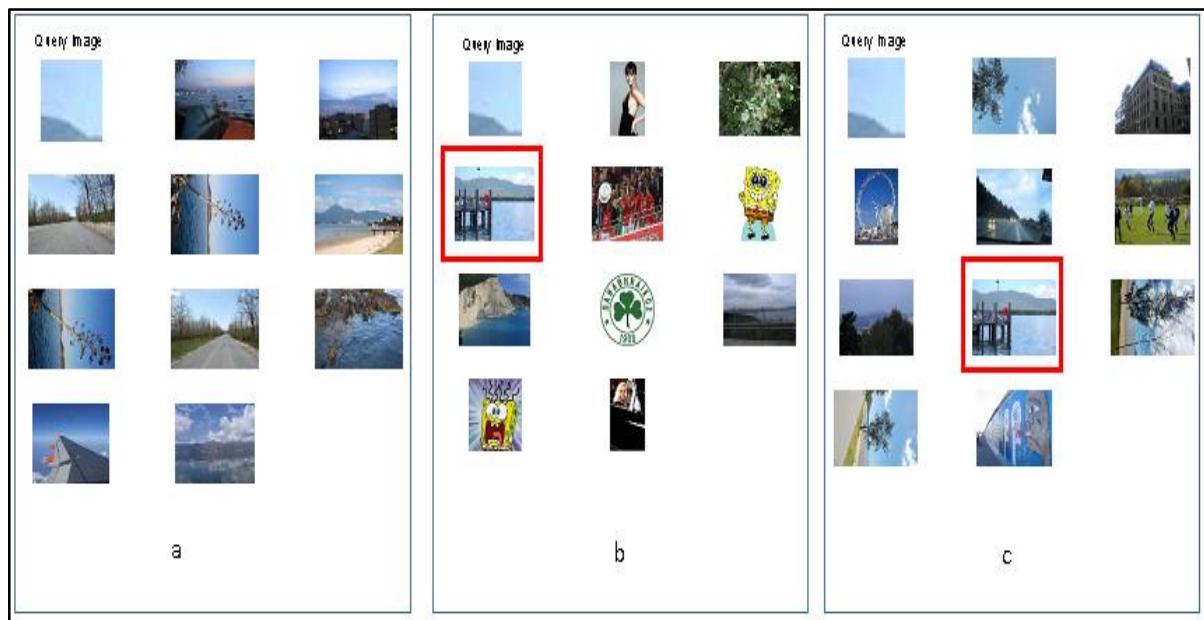
الشكل 12: أداء الحل المقترن قبل تطبيق خوارزمية SIFT لصور مجزأة

الشكل (12) يوضح نتائج الحل المقترن قبل تطبيق خوارزمية SIFT، لحالة الصور المجزأة بنسبة 60% من الصورة الأصلية. ومن خلاله نلاحظ أن أداء الحل المقترن في هذه الحالة أفضل من الخوارزميات المدروسة لحالة الصور المجزأة بنسبة عشوائية أقل من 35%.



الشكل 12: أداء الحل المقترن بعد تطبيق خوارزمية SIFT لصور مجزأة

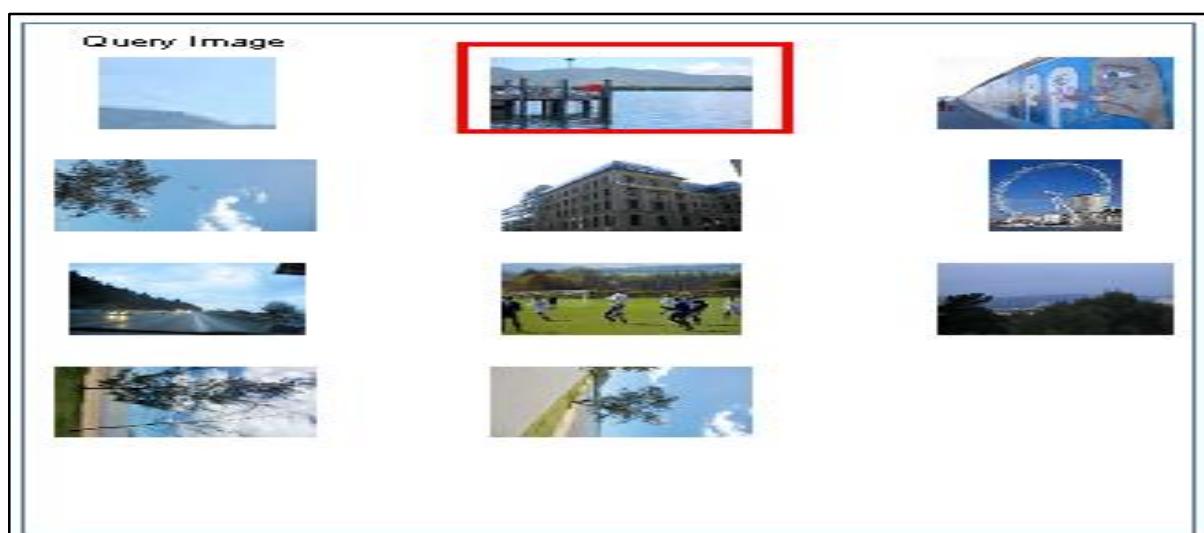
من الشكل (12) نلاحظ أن أداء الحل المقترن أصبح أفضل في الأداء بعد تطبيق خوارزمية SIFT.



الشكل13: نتائج محاكاة الخوارزميات على صورة مجزأة عشوائيا.

نستعرض من خلال الشكل (13)، نتائج محاكاة الخوارزميات السابقة وذلك على صورة مجزأة عشوائياً وفيه نلاحظ ما يلي:

- a : يظهر حالة فشل خوارزمية CBIR في العثور على النتيجة الصحيحة.
- b: يبين أن خوارزمية SIFT تمكنت من استعادة الصورة الصحيحة ولكن كنتيجة ثانية.
- c: يبين أن الحل المقترن قبل تطبيق خوارزمية SIFT يستعيد الصورة الصحيحة في المرتبة السابعة.



الشكل14: نتيجة الحل المقترن بعد تطبيق خوارزمية SIFT.

من خلال الشكل (14) نلاحظ أن الحل المقترن يعطي النتيجة الصحيحة في المرتبة الأولى بعد تطبيق خوارزمية SIFT. أخيراً من خلال تطبيق الخوارزميات السابقة على عدد من Query image تمكنا من الحصول على بعض المعلومات الهامة:

- الحل المقترن في كلتا الحالتين المدروستين أفضل من الخوارزميات المدروسة من حيث عدد النقاط الإجمالي والوسطي إذ إنه يكون أعلى مقارنة مع SIFT & CBIR.
- خوارزمية SIFT هي الأسوأ من حيث الأداء مقارنة بالحل المقترن.
- كلما زاد حجم Query image يصبح أداء كل من SIFT & CBIR متقارب إلى حد كبير.

Case of queries	Method name	Total points (%)	Mean	Standard Deviation
Randomly cropped images Max (35%)	CBIR	74,6	7.460 0	3.8387
	SIFT	67,6	6.760 0	4.6604
	Proposed	86,9	8.690 0	3.1098
cropped images 60%	CBIR	96,5	9.65	1.5067
	SIFT	94,0	9.4	2.3868
	Proposed	96,9	9.69	1.7156

الجدول 1: تقييم العمل.

يلخص الجدول التالي (1) تقييم الحل المقترن ومقارنته مع الخوارزميات المدروسة.

7. الاستنتاجات والتوصيات:

من خلال هذا المقال تم التوصل إلى عدد من النتائج الهامة:

- لا تعد خوارزمية SIFT مثالية في حالة التركيز على جزء معين من الصورة إذ سيحدث تشوه في نقاط الاهتمام مما يؤدي إلى تدهور في الأداء، لكن من خلال عمليات المحاكات لاحظنا أنه عند تطبيق خوارزمية SIFT ستكون احتمالية استرداد الصورة الأصلية كنتيجة أولى عالية.
- يجب تقسيم الصورة إلى عدد من الصور الفرعية لكي تتغلب على مشاكل CBIR ومن ثم تطبيق خوارزمية SIFT للاستفادة من ميزة استعادة الصورة الأصلية كنتيجة أولى.

تم من خلال هذا المقال اقتراح بعض الأساليب الجديدة من أجل استعادة الصورة شبه المكررة. يمكن تحسين العمل بعدة طرق:

- إمكانية استخدام البرمجة الموازية لتعزيز عملية البحث في قاعدة البيانات وتقليل الوقت المستهلك.

- تطوير طريقة تجزئة الصورة، عن طريق استخراج الأغراض المهمة فقط في الصورة من أجل الحصول على عمليات بحث أسرع وعدد أقل من الأجزاء وحجم قاعدة البيانات أصغر.

مزايا الحل المقترن:

- الدقة: من خلال الحصول على نتائج دقيقة كما أظهرت النتائج التجريبية.
- المرونة: من خلال إمكانية تعديل معاملات تجزئة الصورة.

سلبيات الحل المقترن:

- يستهلك وقت لبناء قاعدة المعطيات.
- بطيء لأنه يحتاج وقت أطول للبحث في قاعدة المعطيات بسبب وجود عدد كبير من العناصر في قاعدة المعطيات والمرتبطة بالعدد الهائل للأجزاء.

8. المراجع:

- [1] PNRL Chandra Sekhar, Dr. T N Sankar” Review of Image Splicing Forgery Detection Techniques” Journal of Emerging Technologies and Innovative Research (JETIR). December 2016, Volume 3, Issue 1 2 JETIR (ISSN-2349-5162).
- [2] K. K. Thyagharajan, V. R. Hasini, H. Joshna, A. Jenifer Sweetlin “Near-Duplicate Image Identification using Pulse Coupled Neural Networks” International Journal of Advance Research in Computer Science and Management Studies. Volume 5, Issue 3, March 2017 pg. 85-92.
- [3] D. Xu, T.-J. Cham, S. Yan and S.-F. Chang, "Near duplicate image identification with partially Aligned Pyramid Matching," in Conference on Computer Vision and Pattern Recognition, Anchorage, AK, USA, 2010.
- [4] J. Zhu, S. C.H. Hoi, M. R. Lyu and S. Yan, "Near-duplicate Keyframe Retrieval by Nonrigid Image Matching," in The 16th ACM International Conference on Multimedia, Vancouver, British Columbia, Canada, October 26–31, 2008.
- [5] Min Li, Zhidan Luo, Xianjie Yuan and Yuhang Xing Xi'an Research Institute of High Technology, Xi'an 710025 China. "Image of Ship Target Matching Algorithm Based on PCA-SIFT in the Complicated Environments with Noise " 2018.
- [6] Ana Terasa, Mayur Waghela, Anagha Jagtap, Shreeyesh Chauhan Research.” Content Based Image Retrieval Using Wavelet Transform “2019.
- [7] PNRL Chandra Sekhar¹, Dr. T N Sankar² 1 Research Scholar, 2 Professor Dept of CSE, KL University, Vijaywada pchsekhar@hotmail.com,

tnshankar2004@kluniversity."Review of Image Splicing Forgery Detection Techniques "2016.

[8] M. Hassaballah, Aly Amin Abdelmgeid and Hammam A. Alshazly." Image Features Detection, Description and Matching".2017

[9] Sachendra Singh, Shalini Batra," An efficient bi-layer content-based image retrieval System".2020

[10] Pawandeep Kaur, Sakshi Thakral, Mandeep Singh, "Color Based Image Retrieval System".2012

[11] D. Mustafa and M. A. Hassan, "A Comparison between Different Segmentation Techniques Used in Medical Imaging," American Journal of Biomedical Engineering, vol. 6, no. 2, pp. 59-69, 2016.