

استرجاع الصور باستخدام الخوارزمية TITrDMCM وتقنيات التعلم الآلي

***م. دارين محلا

**أ.د. جبر حنا

* أ.د. مريم ساعي

الملخص

بسبب التزايد المتسارع في أحجام قواعد البيانات، برز نظام استرجاع الصور المستند إلى المحتوى (CBIR) كوسيلة واعدة لوصف واسترجاع الصور، من خلال استخلاص السمات المرئية للصورة (اللون، الشكل، النسجة). يهدف البحث إلى أمرين أولاً: اقتراح ثلاثة إصدارات موسعة للخوارزمية FDMCM (Four Diagonal Pixels Motif co-occurrence Matrix) وهي على التوالي: TIBrDMCM-TITrDMCM-TrBIDMCM. ثانياً: تحسين دقة استرجاع الصور للخوارزمية المقترحة TITrDMCM. حيث تم في الإصدارات الموسعة الثلاث تخفيض تعقيد الخوارزمية FDMCM من خلال تخفيض عدد النقاط المستخدمة كنقاط أولية للمسح، ففي الإصدار الموسع الأول TIBrDMCM استخدمت بكسلات القطر الرئيس كنقاط أولية للمسح، وفي الإصدار الموسع الثاني TITrDMCM استخدمت البكسلات القطرية الأفقية العلوية فقط كنقاط أولية للمسح، وفي الإصدار الثالث TrBIDMCM تم استخدام بكسلات القطر الثانوي فقط كنقاط أولية للمسح. حسن البحث دقة استرجاع الصور من خلال دمج الإصدار الموسع TITrDMCM مع خوارزميات التعلم الآلي. وأظهرت النتائج أن الإصدارين الموسعين الأول والثاني أعطت معايير تقييم جيدة وقريبة من الخوارزمية الأصلية FDMCM، مع انخفاض حجم شعاع السمات من 1152 سمة إلى 576 سمة. وأن دمج الخوارزمية TITrDMCM مع تقنيات التعلم الآلي حسن متوسط الدقة من 36.74% إلى 84% من أجل القاعدة Corel1k، ومن 71.49% إلى 94.33% من أجل Brodatz DB، ومن 75.83% إلى 99.21% من أجل Vistex DB، وذلك عند الدمج مع تقنية ensemble subspace discriminant.

كلمات مفتاحية: التعلم الآلي، استرجاع الصور بالاعتماد على المحتوى، متوسط الاستدعاء، متوسط الدقة.

* أستاذ-كلية الهندسة الميكانيكية والكهربائية-قسم هندسة الحاسبات والتحكم الآلي-جامعة تشرين-اللاذقية-سوريا.

** أستاذ-كلية الهندسة الميكانيكية والكهربائية-قسم هندسة الحاسبات والتحكم الآلي-جامعة تشرين-اللاذقية-سوريا.

*** طالبة دكتوراه-كلية الهندسة الميكانيكية والكهربائية-قسم هندسة الحاسبات والتحكم الآلي-جامعة تشرين-

اللاذقية-سوريا.

Image Retrieval Using Of TITrDMCM Algorithm and Machine Learning Techniques

Prof dr. Mariam M. Saai* Prof dr. Jaber Hanna** Eng. Darin Mhalla***

ABSTRACT:

Due to the rapidly increasing size of databases, the Content-Based Image Retrieval system has emerged as a promising method for describing and retrieving images by extracting the visual features of the image (color, shape, tissue). The research aims to do two things first: Suggest three extended versions of the algorithm (FDMCM- Four Diagonal Pixels Motif co-occurrence Matrix). Second: improving the image retrieval accuracy of the TITrDMCM algorithm. In the three extended versions, the complexity of the FDMCM algorithm was reduced by reducing the number of points used as peano scan motif. In the first extended version, TIBrDMCM, main diameter pixels were used as peano scan motif. In the second version, TITrDMCM, the top horizontal diagonal pixels were used. Third Version TrBIDMCM secondary diameter pixels were used. The accuracy of image retrieval was improved by integrating TITrDMCM with machine learning algorithms. The results showed that TITrDMCM and TIBrDMCM gave good evaluation criteria, which are close to the original FDMCM algorithm with reduced feature vector size from 1152 characters to 576 features. Integration the proposed algorithm TITrDMCM with machine learning techniques improved the average accuracy from 36.74% to 84% for Corel1k, from 71.49% to 94.33% for Brodatz DB and from 75.83% to 99.21% for Vistex DB when combined with ensemble subspace discriminant.

Keywords: Machine Learning, Content-Based Image Retrieval, Average Recall, Average Accuracy.

* Professor, Faculty Of Mechanical And Electrical Engineering , Department of Computer and Automatic Control Engineering ,Tishreen University, Lattakia, Syria.

** Professor, Faculty Of Mechanical And Electrical Engineering , Department of Computer and Automatic Control Engineering ,Tishreen University, Lattakia, Syria.

*** PHD Student, Faculty of Mechanical and Electrical Engineering, Department of Computer and Automatic control Engineering, Tishreen University, Lattakia, Syria.

1. المقدمة:

إن استرجاع الصور هو عملية البحث عن الصور ذات الصلة ضمن قواعد البيانات، واسترجاع الصور الأكثر مطابقة لصورة الاستعلام. يتم تصنيف تقنيات استرجاع الصور إلى استرجاع الصور بالاعتماد على النص (Text-Based Image Retrieval (TBIR)، واسترجاع الصور بالاعتماد على المحتوى (Content-Based Image Retrieval (CBIR)). تعتبر أنظمة TBIR الشكل الأولي لاسترجاع الصور، إذ تتم فهرسة أو وصف كل صورة يدوياً، فهي أنظمة سهلة بسيطة وسريعة، ولكن لها العديد من السلبيات، فهي لا تأخذ بالحسبان محتوى الصورة مثل خصائص اللون البصري وخصائص البنية وخصائص الشكل، بالإضافة إلى الجهد المطلوب لشرح كل صورة على حدة، والتباين في الإدراك البشري عند وصف الصورة، والذي يؤثر سلباً في دقة نظام الاسترجاع [1,2]. بينما تقوم أنظمة CBIR باسترجاع الصور المتشابهة [3,4,5,6,7] بالاعتماد على المحتوى المرئي للصورة، من خلال استخراج السمات المرئية منخفضة المستوى (اللون-الشكل-النسجة) من صور قاعدة البيانات، وتخزينها كأشعة سمات [8] لتتم مقارنتها مع شعاع السمات المستخرج من صورة الاستعلام، باستخدام إحدى مقاييس المسافات المعيارية [9]، وترتيب قيم المسافة تصاعدياً ليتم استرجاع صور قاعدة البيانات ذات المسافة الأقل بالنسبة لصورة الاستعلام. استخدمت خوارزميات CBIR في العديد من المجالات، مثل صور الأقمار الصناعية [10] للعثور على معادن الأرض والمسح الجوي ومراقبة الزراعة وإنشاء تقارير الطقس وتتبع الأجسام السطحية، و في مجال التصوير الطبي [11] فهو أحد المجالات البارزة لتطبيقات CBIR والتي يمكن استخدامها لمراقبة تقارير صحة المريض والمساعدة في التشخيص من خلال تحديد الحالات السابقة المماثلة وما إلى ذلك، وفي مجال مسح بصمات الأصابع [12] لاستخراج صور بصمات الأصابع المماثلة لصورة الاستعلام، والتي تؤدي إلى التحقق من الفرد حيث تستخدم بصمات الأصابع في القطاع المصرفي والكلديات والشركات ومختبرات الطب الشرعي. اقترح الباحثون العديد من الطرائق لاسترجاع الصور المتشابهة من قواعد البيانات، من خلال استخلاص سمات اللون أو الشكل أو النسجة أو باستخلاص سمات هجينة من أكثر من نوع، إذ اقترح الباحث D.Latha [13] طريقة لاستخلاص مجموعة من السمات الهجينة (سمات اللون والنسجة)، والتي تم توليدها باستخدام السمات الاتجاهية للرسم

البياني والسمات الإحصائية مثل المتوسط والانحراف المعياري، وميزة هذه الطريقة أنها مناسبة لاسترجاع الصور الكبيرة الحجم عبر الإنترنت. فيما قدم الباحث [14] Zenggang, X. طريقة لاسترجاع الصور باستخلاص سمات اللون والشكل، إذ استخلص سمات اللون باستخدام الرسم البياني التراكمي، وسمات الشكل باستخدام سبع لحظات ثابتة، ثم قام الباحث بدمج سمات اللون والشكل وفق أوزان معينة وقياس التشابه باستخدام قانون المسافة الإقليدية. بينما قدم الباحث [15] Alsmadi, M. K. طريقة لاسترجاع الصور من خلال دمج مجموعة من سمات اللون والشكل والنسجة، إذ قام باستخلاص سمات اللون في فضاء اللون ycbcr باستخدام التحويل المويجي المتقطع والرسم البياني للحواف (canny edge histogram)، واستخدم تحويل GLCM لاستخلاص سمات النسجة، وطريقة حواف canny لاستخلاص سمات الشكل. بينما اقترح الباحث [16] Kayhan, N. نهج لاسترجاع الصور بناءً على مزيج موزون من ميزات اللون والنسجة، إذ استخرج ميزات النسجة باستخدام أنماط ثنائية محلية معدلة (MLBP)، وأنماط اختلافات الجوار المحلية (LNDP) ومصفوفة التكرار ذات المستوى الرمادي (GLCM)، واستخلص سمات اللون باستخدام الرسم البياني اللوني. اعتمد بعض الباحثين على استخلاص سمات محلية من الصورة تتعلق بقيمة البكسل بشكل مباشر، وإيجاد العلاقة بين البكسل المركزي وجواره، مثل خوارزمية LBP [17]، LTrP [18]، LNP [1]، COaLTP [19]، LOtP [20]، LHdP [20]، FDMCM [21] . أو استخلاص سمات محلية من خلال تقسيم الصورة إلى مربعات متساوية الحجم واستنتاج شكل من كل مربع ثم استبداله بفهرس معين مثل خوارزمية MCM [22]، وخوارزمية MMCM [23]، وخوارزمية LMP [24]. في السنوات الأخيرة، استخدم الباحثون واصفات محلية مختلفة لاسترجاع الصور وتصنيفها. وتصنيف الصور هو إحدى مجالات التعلم الآلي بإشراف، ففي الوقت الحالي، تميل أنظمة الاسترجاع إلى استخراج الميزات من الصور باستخدام إحدى خوارزميات الاسترجاع، ثم تدريب مصنّقات التعلم الآلي على تصنيف الصور إلى أصناف محددة مسبقاً، وأخيراً اختبار النموذج من خلال تصنيف صور جديدة [1]. إذ اقترح الباحث [1] Alrahhah, M. طريقة لتصنيف صور النسجة بالاعتماد على الخوارزمية LNP ليكون شعاع السمات المستخلص دخل للمصنف knn والمصنف SVM الذي يقوم بتصنيف الصور .

2. أهمية البحث وأهدافه

إن الزيادة الكبيرة والسريعة في حجم قواعد بيانات الصور، والحاجة اليومية للتعامل مع كميات ضخمة من البيانات في ظل الانتشار الكثيف والموسع لاستخدام شبكات الانترنت، أدت إلى توجيه اهتمام الباحثين إلى أنظمة استرجاع الصور بالاعتماد على المحتوى، وظهرت العديد من الأبحاث التي تقترح خوارزميات فعالة لاسترجاع الصور من قواعد البيانات بدقة عالية. يهدف البحث إلى تخفيض تعقيد الخوارزمية FDMCM مع الحفاظ على دقة استرجاع جيدة، من خلال اقتراح إصدارات موسعة لخوارزمية FDMCM (TIBrDMCM-TITrDMCM) بدقة عالية مع تعقيد منخفض وحجم تخزين منخفض. وتحسين دقة أنظمة CBIR بدمج الإصدارات المقترحة مع تقنيات التعلم الآلي.

3. مواد البحث وطرائقه

3.1. تقنيات التعلم الآلي

في التعلم الآلي الخاضع لإشراف، يتم تقسيم مجموعة بيانات الصور إلى قسمين، القسم الأول لتدريب النظام وباقي الصور لاختبار النظام. بعد انتهاء مرحلة التدريب، يجب أن يتمتع النظام بالقدرة على إعطاء نتائج دقيقة من أجل بيانات جديدة. استخدم البحث ثلاثة أنواع من تقنيات التعلم الآلي بإشراف لتصنيف الصور وهي:

- **مصنفات (SVM-Support Vector Machine)** : تقوم بتصنيف البيانات من خلال إيجاد أفضل خط فاصل [25] (الذي يمتلك أكبر هامش) بين صنف وبقية الأصناف. والمقصود بالهامش الحد الأقصى للفجوات بين الأصناف، والتي لا تحتوي أي نقاط بيانات، والمقصود بناقلات الدعم نقاط البيانات الأقرب للخط الفاصل. استخدام البحث العديد من مصنفات SVM بناءً على تابع kernel وهي:

Cubic kernel, Quadratic kernel, Linear Kernel, Medium Gaussian.

- **مصنفات الجار الأقرب للتصنيف (KNN - K Nearest Neighbors)** :

خوارزمية الجار الأقرب (KNN) هي إحدى أنواع خوارزميات التعلم الآلي الخاضعة للإشراف، والتي يمكن استخدامها لحل مشكلات التصنيف [26].

تستخدم خوارزمية KNN خاصية "تشابه السمات" للتعليق بصنف البيانات الجديدة، مما يعني أنه سيتم تصنيف نقطة البيانات الجديدة (شعاع السمات)، بناء على مدى تشابهها مع النقاط الأقرب لها في مجموعة التدريب. يوجد أنماط متعددة من مصنفات KNN (التي تختلف عن بعضها البعض في المسافة بين الأصناف وفي عدد الجيران) وهي: Fine KNN, Medium KNN, Cubic KNN, Cosine KNN and Weighted KNN.

- مصنفات Ensemble:

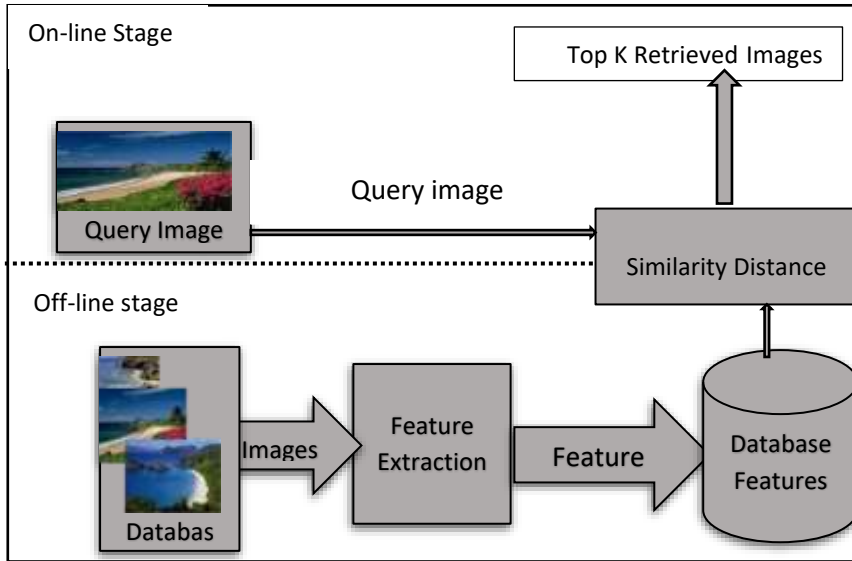
يستخدم العديد من المتعلمين الضعفاء لإنشاء نموذج عالي الجودة، إذ تعتمد الجودة على اختيار الخوارزمية [1]، استخدام البحث ثلاثة أنواع من مصنفات ensemble وهي:

- 1- مجوعات الأشجار المعبأة (Ensemble bagged trees)
- 2- مجوعات subspace discriminant
- 3- مجوعات subspace KNN

3.2. نظام استرجاع الصور المعتمد على المحتوى (Content-Based Image Retrieval)

يبين الشكل (1) مراحل نظام استرجاع الصور المستند إلى المحتوى، والذي يسمى اختصاراً CBIR. إذ يتألف نظام CBIR من مرحلتين: مرحلة التدريب لاستخراج السمات ويطلق عليها أيضاً مرحلة Off-Line، وفيها يقوم النظام باستخراج أشعة السمات لكل الصور الموجودة في قاعدة الصور وتخزينها في قاعدة السمات، ومرحلة الاختبار لاسترجاع الصور ويطلق عليها أيضاً مرحلة On-line، وفيها يقوم المستخدم بإدخال صورة إلى هذا النظام كصورة استعمال (دخل)، ثم يقوم النظام باستخراج شعاع السمات من هذه الصورة، وقياس نسبة التشابه (باستخدام إحدى المسافات المعيارية) بين شعاع سمات صورة الدخل وجميع أشعة السمات المخزنة في قاعدة السمات، والتي تم الحصول عليها في مرحلة التدريب [1]. بعد ذلك يتم ترتيب هذه المسافات بشكل

تصاعدي (حيث أن المسافة الأصغر تعني أن التشابه أكبر) واسترجاع أول k صورة كخرج لمرحلة الاختبار.



الشكل (1) مراحل نظام CBIR

3.3. مصفوفة التواجد المشترك للسويات الرمادية (Gray Level Co-Occurrence Matrix)

وتسمى اختصاراً GLCM، وهي مصفوفة تعبر عن التكرارات المشتركة للسويات الرمادية المتزامنة عند مسافة محددة وعند اتجاه محدد، ويتم حساب GLCM على صورة ما باستخدام المعادلة (8):

$$G_{(\Delta x, \Delta y)} = \sum_{p=1}^M \sum_{q=1}^N 1\{I(p, q) = i\} \text{ and } 1\{I(p + \Delta x, q + \Delta y) = j\} \quad (8)$$

حيث أن: $I(p, q)$ هي السوية الرمادية للبكسل في السطر p والعمود q ، وإن i, j هي قيم رمادية يتم حساب التواجد المشترك لهما و $\{1\}$ هي دالة مؤشر التابع الذي تم تعريفه مسبقاً، $\Delta x, \Delta y$ هما تعويضان موضعيان يعتمدان على المسافة والاتجاه اللذين يتم حساب العلاقات المشتركة بينهما، M و N عدد الصفوف والأعمدة للصورة المحددة.

يوضح الشكل (2) مثلاً لحساب GLCM، حيث أن المصفوفة الأولى عبارة عن مصفوفة الصورة والمصفوفة الثانية هي مصفوفة التواجد المشترك للسويات الرمادية [19].

1	4	←2	→3	4	
4	←2	→3	4	1	2
1	4	3	2	←2	→3
3	2	1	3	2	1

Pixel Value	1	2	3	4
1	0	1	1	2
2	2	1	3	0
3	0	3	1	2
4	1	2	1	0

الشكل (2) حساب مصفوفة GLCM لصورة باعتبار المسافة واحد ($d=1$) والاتجاه صفر $\theta=0^0$

3.4 خوارزمية مصفوفة التواجد المشترك للأشكال الناتجة عن البكسلات القطرية الأربعة (Four Diagonal Pixels Motif Co-Occurrence Matrix)

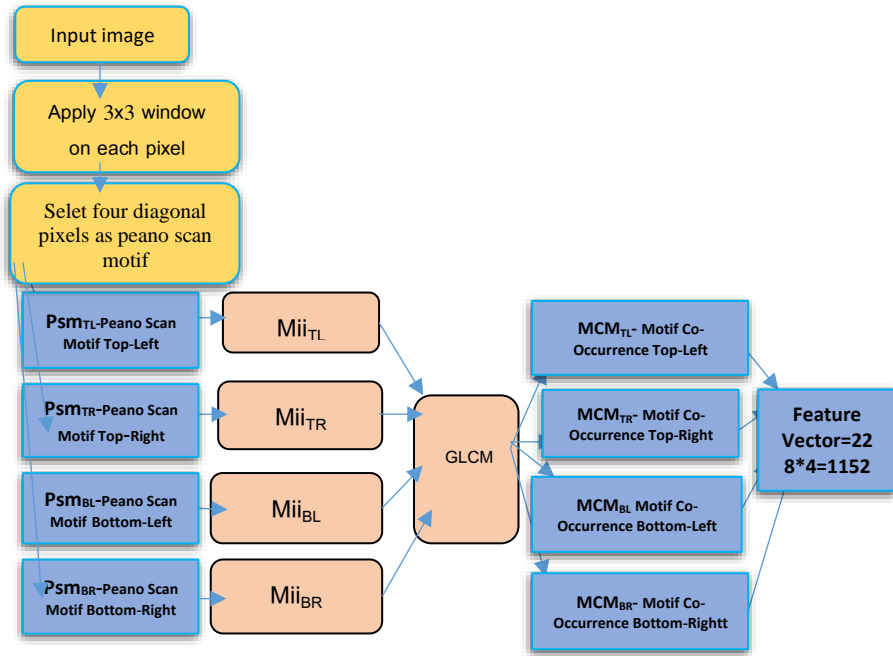
يبين الشكل (3) المخطط الصندوقي لخوارزمية FDMCM، التي تعتمد على تمرير نافذة 3×3 على كل بكسل من بكسلات الصورة، واختيار البكسلات القطرية الأربعة الموجودة في جوار البكسل المركزي لتكون نقاط أولية للمسح الضوئي (PSM-Peano Scan Motif)، من خلال إيجاد الفرق المطلق بين قيم البكسلات القطرية ونقطة PSM الأولية المختارة (إحدى البكسلات القطرية)، واستنتاج الشكل المعبر عن الفرق المتزايد للسويات الرمادية، وترميز الشكل الناتج بفهرس تتراوح قيمته من 1 إلى 6 وفق الشكل (4). ثم استبدال قيمة البكسل المركزي للجوار 3×3 بالفهرس الناتج للحصول على المصفوفات الأربعة [21]:

Miitl–Motif Indexed Image Top Left


Miitr– Motif Indexed Image Top Right

Miibl– Motif Indexed Image Bottom Left

Miibr- Motif Indexed Image Bottom Right



الشكل (3) المخطط الصندوقي لخوارزمية FDMCM



الشكل (4) فهرس الأشكال باعتبار PSM أعلى يسار المربع 2×2 [22,23]

وكل مصفوفة من المصفوفات السابقة بحجم مصفوفة الصورة الأساسية ولكن قيمها تتراوح من 1 إلى 6.

- ثم يتم استخدام تحويل GLCM لكل من المصفوفات السابقة من أجل $d=1,2$ و $\theta=0^\circ$ و 45° و 90° و 135° للحصول على المصفوفات الأربعة التالية وكل منها بحجم $36 \times 4 \times 2 = 288$ سمة:



MCMtl–Motif Co–occurrence Matrix Top Left

MCMtr– Motif Co–occurrence Matrix Top Right, MCMbl– Motif Co–occurrence Matrix Bottom Left, MCMbr– Motif Co–occurrence Matrix Bottom Right

- تحويل المصفوفات الناتجة إلى أشعة ودمج الأشعة الناتجة للحصول على شعاع سمات نهائي بطول 1152 (288x4) سمة.

3.5 قواعد البيانات المستخدمة:

قيم البحث الخوارزميات المقترحة باستخدام نوعين من قواعد بيانات الصور، وهي قواعد بيانات الصور الملونة (Color databases)، إذ استُخدمت القاعدة [27] Corel 1k التي تحتوي 1000 صورة ملونة بحجم 384×256 أو 256×384 مصنفة ضمن عشرة فئات، وتحتوي كل فئة على مئة صورة ملونة. وقواعد بيانات صور النسجة (Texture databases) حيث تم استخدام القاعدتين [28] MIT–VisTex و [29] Brodatz، وتتألف قاعدة بيانات صور النسجة Brodatz من 116 صنف، وكل صنف مؤلف من 16 صورة وبالتالي فإن العدد الإجمالي للصور هو $16 \times 116 = 1856$ صورة وكل منها بحجم 128×128 . أما قاعدة بيانات صور النسجة MIT–VisTex تحتوي على 40 صنف، وكل صنف مؤلف من 16 صورة بحجم 128×128 ، وبالتالي تتكون هذه القاعدة من $16 \times 40 = 640$ صورة. يبين الشكل (5) بعض العينات من قواعد بيانات الصور المستخدمة.



a

b

c

الشكل (5) بعض الصور من قواعد البيانات المستخدمة: (a) عينات من القاعدة الملونة Corel1k، (b) عينات من قاعدة النسجة Brodatz، (c) عينات من قاعدة النسجة Vistex

3.6. معايير تقييم الأداء

تنقسم معايير تقييم الأداء في هذا البحث إلى قسمين: معايير تقييم أداء أنظمة استرجاع الصور ومعايير تقييم أداء المصنفات.

3.6.1. معايير تقييم أداء أنظمة استرجاع الصور: استخدمت الأبحاث العديد من المعايير لتقييم أداء أنظمة استرجاع الصور، وهي الدقة (Precision) والاستدعاء (Recall) ومتوسط الدقة (mAP–mean Average Precision). يمكن حساب الدقة والاستدعاء ومتوسط الدقة كما في المعادلات (5-7) [19,30,31]:

$$\text{Precision} = \frac{\text{No. of retrieved relevant images}}{\text{No. of retrieved images}} \quad (5)$$

$$\text{Recall} = \frac{\text{No. of retrieved relevant images}}{\text{No. of relevant images}} \quad (6)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N \text{Average precision}_i \quad (7)$$

الدقة (Precision) بالتعريف هي عدد الصور المسترجعة ذات الصلة إلى عدد الصور المسترجعة ويتم حساب الدقة عندما يكون الخرج عشر صور فقط من أجل جميع قواعد البيانات المعيارية المستخدمة، والاستدعاء (Recall) بالتعريف هو عدد الصور المسترجعة ذات الصلة إلى العدد الكلي للصور ذات الصلة ضمن قاعدة البيانات [32] ويتم حساب الاستدعاء عندما يكون الخرج 100 صورة (العدد الكلي للصور ذات الصلة) من أجل القاعدة Corel1k و16 صورة من أجل قاعدتي الصور (Brodatz–Vistex DB) ويتم حساب متوسط الدقة mAP على النحو التالي :

- من أجل القاعدة Corel1k: يتم حساب الدقة عندما يكون الخرج فقط 10 صور، 20 صورة، 30 صورة، وحتى الـ 100 صورة من أجل كل صورة في قاعدة الصور، ثم نأخذ المتوسط ونكرر هذا الإجراء لجميع الصور في قاعدة الصور.

- من أجل قاعدتي الصور VisTex و Brodatz: يتم حساب الدقة عندما يكون الخرج فقط 4 صور، 6 صورة، 8 صورة، وحتى الـ 16 صورة من أجل كل صورة في قاعدة الصور، ثم نأخذ المتوسط ونكرر هذا الإجراء لجميع الصور في قاعدة الصور [32].

3.6.2. معايير تقييم أداء المصنفات:

استخدم هذا البحث الدقة كمقياس لأداء المصنف المدرب ويتم حسابها على النحو التالي [33]:

$$\text{Accuracy} = \frac{\text{No. of all images classified correctly}}{\text{The Total No. of images in the class}} \quad (8)$$

ولحساب الدقة، يقوم المستخدم بإدخال صورة استعلام إلى نظام CBIR واستخراج شعاع السمات باستخدام الخوارزمية المقترحة ثم يتم تصنيف صورة الاستعلام إلى الصنف الذي تنتمي إليه باستخدام المصنف المدرب. أخيراً، نسترجع جميع صور قاعدة البيانات التي تنتمي إلى نفس صنف صورة الاستعلام. أفضل دقة هي 1.0 أو (100% كنسبة مئوية)، في حين أن الأسوأ هو 0.0. وبالنظر إلى تعريف كل من متوسط الدقة ومتوسط الاستدعاء، نلاحظ أن كلاهما نفس المعنى [1].

4. منهجية البحث:

يتكون البحث من الآتي:


1. استخلاص السمات باستخدام الإصدارات الموسعة لخوارزمية FDMCM.
2. دمج الإصدارات المقترحة مع تقنيات التعلم الآلي لتحسين دقة استرجاع الصور من قواعد بيانات الصور.

4.1. استخلاص السمات باستخدام الإصدارات الموسعة لخوارزمية FDMCM

خضّص البحث تعقيد خوارزمية FDMCM من خلال تخفيض حجم شعاع السمات الناتج، وذلك بتقليل عدد النقاط المستخدمة كنقاط أولية للمسح، حيث تم تقليل عدد النقاط بثلاثة طرائق مختلفة للحصول على ثلاثة إصدارات موسعة لخوارزمية FDMCM، وهي على التوالي (TIBrDMCM-TITrDMCM-TrBIDMCM)، وذلك وفقاً لما يلي:

(أ) الإصدار الأول: مصفوفة التواجد المشترك للأشكال الناتجة عن البكسلين الواقعين أعلى يسار وأسفل يمين الجوار (Top Left Bottom Right Diagonal Motif Co-Occurrence Matrix)


يبين الشكل (6) الإصدار الموسع الأول لخوارزمية FDMCM، ويسمى اختصاراً TIBrDMCM والذي استخدم بكسلات القطر الرئيس (البكسل القطري في أعلى اليسار والبكسل القطري في أسفل اليمين) كنقاط أولية للمسح، بدلاً من استخدام البكسلات القطرية الأربعة كما هو الحال في خوارزمية FDMCM.



الشكل (6): المخطط الصندوقي للخوارزمية TIBrDMCM.

- من أجل البكسل القطري في أعلى اليسار نقوم بالخطوات التالية:
 1. إيجاد الفرق بالقيمة المطلقة بين قيم البكسلات القطرية الأربعة ونقطة PSM الأولية (البكسل القطري في أعلى اليسار).
 2. استنتاج الشكل المعبر عن الفرق المتزايد للسويات الرمادية، وترميز الشكل الناتج بفهرس تتراوح قيمته من 1 إلى 6، ليتم استبدال قيمة البكسل المركزي للجوار 3x3 بالفهرس الناتج كما موضح في الشكل (7).


3. تكرار الخطوات السابقة من أجل كل بكسل من بكسلات الصورة للحصول على المصفوفة $Miilt$ (Motif Indexed Image Top Left) بحجم مصفوفة الصورة الأساسية وتتراوح قيمها بين 1 و 6.
4. استخدام تحويل GLCM للمسافة "1" والاتجاهات 0° و 45° و 90° و 135° للحصول على 4 مصفوفات كل مصفوفة بحجم 6×6 . والمسافة "2" والاتجاهات 0° و 45° و 90° و 135° للحصول على 4 مصفوفات كل مصفوفة بحجم 6×6 .
5. تحويل المصفوفات الثمانية الناتجة إلى متجهات كل متجه بطول 36.
6. دمج المتجهات الناتجة بمتجه سمات واحد بطول $288 = 36 \times 8$ سمة.
- من أجل البكسل القطري في أسفل اليمين نكرر الخطوات السابقة نفسها، ولكن باعتبار نقطة المسح الأولية هي البكسل القطري الموجود في أسفل اليمين للحصول على شعاع سمات بطول 288.
 - نقوم بدمج شعاعي السمات الناتجين عن بكسلات القطر الرئيس لنحصل على شعاع سمات نهائي بطول $576 = 288 \times 2$ سمة.



الشكل (7): (a) النافذة 3×3 (b) الفرق المطلق باعتبار نقطة المسح الأولية هي البكسل القطري في أعلى يسار الجوار، (c) الشكل الناتج عن الفرق والفهرس الموافق له، (d) الفرق المطلق باعتبار PSM البكسل القطري في أسفل اليمين، (e) الشكل الناتج عن الفرق والفهرس الموافق له.

(ب) الإصدار الثاني: مصفوفة التواجد المشترك للأشكال الناتجة عن البكسلين الواقعين
أعلى يسار وأعلى يمين الجوار (Top Left Top Right Diagonal Motif
Co-Occurrence

في الإصدار TITrDMCM، استخدمت البكسلات الأفقية فقط (البكسل القطري الموجود في أعلى اليسار والبكسل القطري الموجود في أعلى اليمين) كنقاط أولية للمسح كما هو موضح في الشكل (8)، للحصول على ثماني مصفوفات كل منها بحجم 6x6 عند اختيار البكسل القطري في أعلى اليسار كنقطة أولية للمسح، وثمانى مصفوفات عند اختيار البكسل الأفقي في أعلى اليمين كنقطة أولية للمسح، ثم دمج المصفوفات جميعها للحصول على شعاع السمات النهائي بطول $36 \times 8 \times 2 = 576$ سمة.




الشكل (8): (a) النافذة 3x3 (b) الفرق المطلق باعتبار نقطة المسح الأولية هي البكسل القطري في أعلى يسار الجوار، (c) الشكل الناتج عن الفرق والفهرس الموافق له، (d) الفرق المطلق باعتبار PSM البكسل القطري في أعلى اليمين، (e) الشكل الناتج عن الفرق والفهرس الموافق له.

(ت) الإصدار الثالث: مصفوفة التواجد المشترك للأشكال الناتجة عن البكسلين الواقعين
أسفل يسار وأعلى يمين الجوار (Bottom Left Top Right Diagonal
Motif Co-Occurrence co-occurrence Matrix

استخدم هذا الإصدار بكسلات القطر الثانوي فقط (البكسل القطري في أعلى اليمين وأسفل اليسار) كنقاط أولية للمسح كما هو موضح في الشكل (9)، للحصول على ثماني مصفوفات كل منها بحجم 6x6 عند اختيار البكسل القطري في أعلى اليمين كنقطة أولية للمسح، وثمانى

مصفوفات عند اختيار البكسل القطري في أسفل اليسار كنقطة أولية للمسح، ويتم دمج المصفوفات جميعها للحصول على شعاع السمات النهائي بطول $36 \times 8 \times 2 = 576$ سمة.



الشكل (9): (a) النافذة 3×3 (b) الفرق المطلق باعتبار نقطة المسح الأولية هي البكسل القطري في أسفل يسار الجوار، (c) الشكل الناتج عن الفرق والفهرس الموافق له، (d) الفرق المطلق باعتبار PSM البكسل القطري في أعلى اليمين، (e) الشكل الناتج عن الفرق والفهرس الموافق له.

4.2. دمج الإصدار الموسع TITrDMCM مع تقنيات التعلم الآلي لتحسين دقة

استرجاع الصور

في مهمة التصنيف، تُقسم قاعدة الصور إلى قاعدتين: إحداها للتدريب والأخرى للاختبار، نسبة التقسيم في هذا البحث 80% من قاعدة الصور للتدريب و20% للاختبار. في مرحلة التدريب، تُستخرج أشعة السمات لجميع صور قاعدة التدريب باستخدام الخوارزمية المقترحة لنستفيد منها مع تسميات الصور لتدريب المصنف، وفي نهاية هذه المرحلة، يتم الحصول على مصنف مدرب وجاهز لتصنيف أي صورة من قاعدة الاختبار. أما مرحلة الاختبار فتبدأ بإدخال الصورة المراد معرفه الصنف الذي تنتمي إليه، لاستخراج شعاع السمات لها باستخدام نفس الطريقة المقترحة، والذي بدوره سيكون دخل المصنف (المدرّب في مرحلة التدريب)، الذي سيصنفها إلى الصنف المناسب. استخدمنا في عملنا المقترح كل من خوارزمية (SVM) (Support Vector Machine) وخوارزمية الجوار الأقرب (K-Nearest Neighbors) وخوارزمية Ensemble.

5. النتائج والمناقشات:

اختبر البحث أداء الإصدارات الموسعة الثلاثة من خوارزمية FDMCM وهي على التوالي (TIBrDMCM- TITrDMCM-BITrDMCM)، ومقارنتها مع أداء خوارزمية FDMCM

الأساسية وخوارزميات الأنماط المحلية الآتية: MCM, MMCM, LMP, LOtP, LHdP. وفق السيناريوهات الآتية:
 السيناريو الأول: اختبار أداء الإصدارات الموسعة الثلاثة من خوارزمية FDMCM باستخدام قاعدة بيانات الصور الملونة (Corel1k).
 السيناريو الثاني: اختبار أداء الإصدارات الموسعة الثلاثة من خوارزمية FDMCM باستخدام قاعدة بيانات النسجة Brodatz DB.
 السيناريو الثالث: اختبار أداء الإصدارات الموسعة الثلاثة من خوارزمية FDMCM باستخدام قاعدة بيانات النسجة Vistex DB.
 السيناريو الرابع: دمج الإصدار الموسع TITrDMCM مع تقنيات التعلم الآلي.

• السيناريو الأول:


يبين الجدول (1) والشكل (10)، أن الإصدارين الموسعين الأول والثاني (TIBrDMCM- FDMCM) أعطيا دقة جيدة قريبة من دقة FDMCM، وأعلى من دقة جميع الخوارزميات التي تمت المقارنة معها LMP، MMCM، MCM، LOtP، LHdP وذلك عند استخدام قاعدة بيانات الصور الملونة Corel1k. مع العلم أن طول شعاع السمات انخفض من 1152 (FDMCM) إلى 576 (الإصدارات الموسعة لخوارزمية FDMCM) كما هو موضح في الجدول (2). على عكس الإصدار الثالث BITrDMCM المعتمد على نقاط القطر الثانوي كنقاط أولية للمسح والذي أعطى دقة أقل بكثير من دقة FDMCM، وأقل من دقة جميع الخوارزميات التي تمت المقارنة معها LMP، MMCM، MCM، LOtP، LHdP .

Methods	corel1k		
	Precision	Recall	mAP
MCM	56.86	33.71	41.86

استرجاع الصور باستخدام الخوارزمية TITrDMCM وتقنيات التعلم الآلي

(1) بين	MMCM	55.88	33.84	41.9	الجدول مقارنة
	LMP	58.65	36.06	44.6	
	LOtP	58.8	35.3	44.8	
	LHdP	59.1	36.42	45.1	
	FDMCM	59.98	36.9	45.43	
	TITrDMCM	59.73	36.65	45.17	
	TIBrDMCM	60.37	36.39	45.17	
	TrBIDMCM	51.56	32.06	38.98	

الإصدارات الثلاثة الموسعة لخوارزمية FDMCM مع خوارزمية FDMCM وخوارزميات أخرى باستخدام قانون المسافة L1 من أجل القاعدة Corel1k.



الشكل (10) مقارنة بين الإصدارات الثلاثة الموسعة لخوارزمية FDMCM مع خوارزمية FDMCM وخوارزميات أخرى باستخدام قانون المسافة L1 من أجل القاعدة Core1k.

الجدول (2) طول شعاع السمات للإصدارات الموسعة المقترحة لخوارزمية FDMCM والخوارزميات التي تمت المقارنة معها

Method	Feature Vector Length
MCM	288
MMCM	576
LMP	1296
LOtP	3,363
LHdP	14,219
FDMCM	1152
TIBrDMCM	576
TITrDMCM	576
BITrDMCM	576


• السيناريو الثاني:

كما هو مبين في الجدول (3) والشكل (11)، أنه باستخدام قاعدة بيانات النسجة Brodatz DB فإن الإصدارين الموسعين الأول والثاني لخوارزمية FDMCM، التي انخفض فيها طول شعاع السمات من 1152 إلى 576 سمة، أعطت دقة جيدة قريبة من دقة FDMCM حيث

أن الخوارزمية TITrDMCM أعطت على التوالي $Precision=79.53\%$ ، $mAP=80.94\%$ ، $Recall=71.40\%$ وهي قريبة من نتائج الخوارزمية FDMCM $mAP=81\%$ ، $Recall=71.49\%$ ، $Precision=79.59\%$ وأعلى من دقة جميع الخوارزميات التي تمت المقارنة معها LMP، MMCM، MCM، LotP، LHdP . على عكس الإصدار الثالث BITrDMCM المعتمد على نقاط القطر الثانوي كنقاط أولية للمسح والذي أعطى دقة أقل بكثير من دقة FDMCM، وأقل من دقة جميع الخوارزميات التي تمت المقارنة معها.

الجدول (3) مقارنة بين الإصدارات الثلاثة الموسعة لخوارزمية FDMCM مع خوارزمية FDMCM وخوارزميات أخرى من أجل القاعدة Brodatz DB.

Brodatz DB			
Methods	Precision	Recall	mAP
MCM	74.4	65.09	76.2
MMCM	77.93	68.5	79.3
LMP	77	67.4	78.2
LotP	78.5	70.1	80.4
LHdP	78	70.4	80.7
FDMCM	79.59	71.49	81
TIBrDMCM	78.58	69.23	79.76
TITrDMCM	79.53	71.4	80.94
TrBIDMCM	64.26	54.2	66.69



الشكل (11) مقارنة بين الإصدارات الثلاثة الموسعة لخوارزمية FDMCM مع خوارزمية FDMCM وخوارزميات أخرى من أجل القاعدة Brodatz.

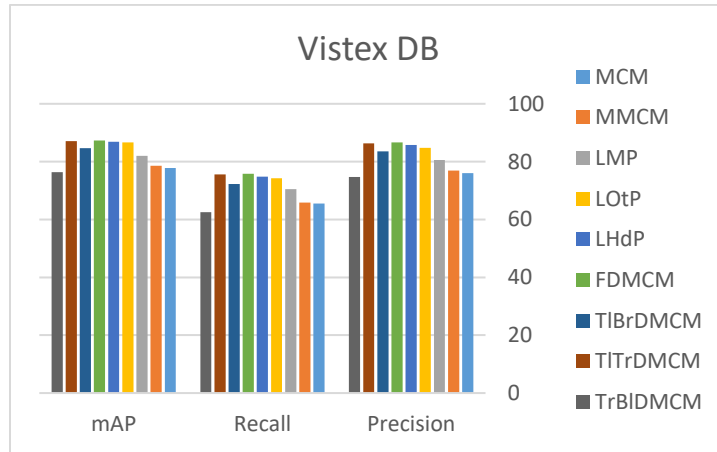
• السيناريو الثالث:

يبين الجدول (4) والشكل (12) أنه باستخدام قاعدة بيانات النسجة Vistex DB، فإن الإصدارين الموسعين الأول والثاني لخوارزمية FDMCM أعطت دقة قريبة من دقة FDMCM، إذ أن الخوارزمية TITrDMCM أعطت نتائج $Precision=86.36\%$ ، $mAP=87.09\%$ ، $Recall=75.59\%$ قريبة من نتائج FDMCM $mAP=87.26\%$ ، $Recall=75.84\%$ ، $Precision=86.64\%$ وأعلى من دقة جميع الخوارزميات التي تمت المقارنة معها MMCM، MCM، LOtP، LHdP، بينما الإصدار الثالث BITrDMCM (يعتمد على نقاط القطر الثانوي كنقاط أولية للمسح)، أعطى دقة أقل بكثير من دقة FDMCM، وأقل من دقة جميع الخوارزميات التي تمت المقارنة معها.

الجدول (4) مقارنة بين الإصدارات الثلاثة الموسعة لخوارزمية FDMCM مع خوارزمية FDMCM وخوارزميات أخرى من أجل القاعدة Vistex DB.

Vistex DB			
Methods	Precision	Recall	mAP
MCM	76.05	65.49	77.76
MMCM	76.95	65.87	78.52
LMP	80.56	70.55	82.05

LOtP	84.8	74.3	86.7
LHdP	85.8	74.8	86.9
FDMCM	86.64	75.84	87.26
TIBrDMCM	83.53	72.29	84.62
TITrDMCM	86.36	75.59	87.09
TrBIDMCM	74.7	62.49	76.38



الشكل (12) مقارنة بين الإصدارات الثلاثة الموسعة لخوارزمية FDMCM مع خوارزمية FDMCM وخوارزميات أخرى من أجل قاعدة البيانات.vistex DB.

ونلاحظ من الأشكال أن الخوارزمية TITrDMCM (التي اعتمدت البكسل الأفقي في أعلى اليسار والبكسل الأفقي في أعلى اليمين كنقاط أولية للمسح)، أعطت نتائج أفضل من الإصدارين الآخرين (TIBrDMCM, TrBIDMCM) من أجل قاعدة الصور الملونة وقاعدتي صور النسجة، ولذلك تم اختيارها لدمجها مع تقنيات التعلم الآلي.

السيناريو الرابع:

يهدف السيناريو الرابع إلى إجراء مقارنة بين أداء نظام CBIR باستخدام الخوارزمية المقترحة TITrDMCM لوحدها، مع أداء نظام CBIR باستخدام TITrDMCM بعد دمجها مع أنواع مختلفة من مصنفات التعلم الآلي التالية: مصنفات SVM بأنواعها المختلفة (Cubic, quadratic, Linear, Medium Gaussian Bagged)، مصنفات KNN بأنواعها المختلفة (Cubic, Cosine, Weighted) ومصفقات ensemble بأنواعها المختلفة (Bagged)

(Trees, Subspace Discriminant, Subspace KNN). أظهرت النتائج كما هو مبين في الجدول (5)، أن دمج تقنيات التعلم الآلي مع خوارزمية TITrDMCM حسن متوسط الدقة من 36.74% إلى 84% من أجل القاعدة Corel1k ومن 71.49% إلى 94.33% من أجل القاعدة Brodatz DB ومن 75.83% إلى 99.21% من أجل القاعدة Vistex DB عندما تم الدمج مع تقنية ensemble subspace discriminant.

الجدول (5) مقارنة بين نظام CBIR باستخدام الخوارزمية المقترحة TITrDMCM لوحدها مع نظام CBIR باستخدام الخوارزمية المقترحة TITrDMCM مع تقنيات التعلم الآلي.

Databases		Corel1k	Brodatz	Vistex
CBIR with TITrDMCM only		36.74	71.49	75.83
TITrDMCM+ KNN	Cosine	68.50%	83.28%	90.62%
	Weighted	73.50%	89.75%	93.75%
	Cubic	67.50%	85.17%	87.50%
TITrDMCM +SVM	Cubic	80%	87.87%	94.53%
	Quadratic	81.50%	87.33%	97.65%
	Linear	78.50%	85.71%	92.18%
	Medium Gaussian	78.50%	87.33%	96.09%
TITrDMCM+ Ensemble	Bagged Trees	73.50%	88.67%	96.09%
	Subspace Discriminant	84%	94.33%	99.21%
	Subspace KNN	59%	84.63%	90.62%

6. الاستنتاجات والخاتمة

اقترح البحث ثلاثة إصدارات موسعة لخوارزمية FDMCM، المستخدمة في مجال استرجاع الصور بالاعتماد على المحتوى، وذلك بهدف تخفيض أبعاد شعاع السمات مع المحافظة على معايير تقييم جيدة وأظهرت النتائج أنه:

- تم الحصول على أفضل دقة للاسترجاع باستخدام الإصدار الأول، والذي اعتمد على البكسلات القطرية الأفقية الموجودة في الجوار العلوي للبكسل المركزي، رغم انخفاض حجم شعاع السمات بمقدار النصف (من 1152 في الخوارزمية FDMCM إلى 576 في TITrDMCM)، يليه الإصدار الثاني المعتمد على بكسلات القطر الرئيس.
- أعطى الإصدار الثالث المعتمد على بكسلات القطر الثانوي معايير تقييم منخفضة بالمقارنة مع الخوارزمية الأصلية FDMCM والإصدارين السابقين، وبذلك لا ينصح بالاعتماد على بكسلات القطر الثانوي في عملية استخلاص السمات.
- دمج البحث الخوارزمية TITrDMCM مع مصنفات التعلم الآلي بأنواعها المختلفة، وذلك بهدف المقارنة بين أداء نظام CBIR باستخدام الخوارزمية TITrDMCM لوحدها، وأداء نظام CBIR باستخدام الخوارزمية TITrDMCM بعد دمجها مع مصنفات مختلفة للتعلم الآلي، وأظهرت النتائج أن دمج الخوارزمية مع مصنفات التعلم الآلي حسّن متوسط الدقة بنسبة 24.21% (من 71.49 إلى 94.33) من أجل القاعدة Brodatz و بنسبة 23.56% (75.83 إلى 99.21) من أجل القاعدة Vistex، وذلك عند الدمج مع المصنف ensemble Subspace Discriminant.
- وأن التحسن الكبير في متوسط الدقة كان باستخدام المصنف ensemble Subspace Discriminant من أجل القاعدة الملونة Core1k، إذ تحسّن متوسط الدقة بنسبة 56.26% (36.74 إلى 84)، وهذا يدل على أن السمات المستخلصة من صور القاعدة الملونة باستخدام الخوارزمية المقترحة TITrDMCM هي سمات فعالة ومميزة وقادرة على تدريب المصنف بشكل جيد.

وفي المستقبل، يمكن استخدام تقنيات التعلم العميق مع CBIR للحصول على المزيد من الدقة وتقليل زمن التدريب للآلة. أيضا، يمكن الجمع بين CBIR وتقنيات Hadoop لمعالجة قاعدة بيانات الصور الضخمة والعمل في بيئة موزعة.

References

1. Alrahal, M., & Supreethi, K. P 2019, *Content-Based Image Retrieval using Local Patterns and Supervised Machine Learning Techniques*. In 2019 Amity International Conference on Artificial Intelligence (AICAI),(pp. 118–124), IEEE.
2. He, T., Wei, Y., Liu, Z., Qing, G., & Zhang, D.2018, *Content based image retrieval method based on SIFT feature*. In 2018 International Conference on Intelligent Transportation, Big Data & Smart City (ICITBS) (pp. 649–652), IEEE.
3. Khan, U. A., Javed, A., & Ashraf, R. (2021). An effective hybrid framework for content based image retrieval (CBIR). *Multimedia Tools and Applications*, 80(17), 26911–26937.
4. Vimina, E. 1., & Divya, M. O. (2020). Maximal multi-channel local binary pattern with colour information for CBIR. *Multimedia Tools and Applications*, 79(35), 25357–25377.
5. Ammatmanee, C., & Gan, L. (2021). A ten-year literature review of content-based image retrieval (CBIR) studies in the tourism industry. *The Electronic Library*.
6. Rui, Y., Huang, T. S., & Chang, S. F. 1999, *Image retrieval: Current techniques, promising directions, and open issues*. *Journal of visual communication and image representation*, 10(1), 39–62.

7. Smeulders, A. W., Worring, M., Santini, S., Gupta, A., & Jain, R.2000, *Content-based image retrieval at the end of the early years*. IEEE Transactions on pattern analysis and machine intelligence, 22(12), 1349–1380
8. Nazir, A., Ashraf, R., Hamdani, T., & Ali, N.2018, *Content based image retrieval system by using HSV color histogram, discrete wavelet transform and edge histogram* descriptor. In 2018 international conference on computing, mathematics and engineering technologies (iCoMET), (pp. 1–6). IEEE.
9. Alkhawlani, M., Elmogy, M., & El Bakry, H. 2015, *Text-based, content-based, and semantic-based image retrievals*. a survey. Int. J. Comput. Inf. Technol, 4(01),58–66.
10. Alkhawlani, M., Elmogy, M., & El Bakry, H. 2015, *Text-based, content-based, and semantic-based image retrievals*. a survey. Int. J. Comput. Inf. Technol, 4(01),58–66.
11. Ramos, J., Kockelkorn, T. T., Ramos, I., Ramos, R., Grutters, J., Viergever, M. A., & Campilho, A.2016, Content-based image retrieval by metric learning from radiology reports: application to interstitial lung diseases. IEEE journal of biomedical and health informatics, 20(1), 281–292.
12. Gavrielides, M. A., Sikudova, E., & Pitas, I.2006, *Color-based descriptors for image fingerprinting*. IEEE transactions on multimedia, 8(4), 740–748.

13. Latha, D., & Sheela, C. (2022). Enhanced hybrid CBIR based on multichannel LBP oriented color descriptor and HSV color statistical feature. *Multimedia Tools and Applications*, 1–18.
14. Zenggang, X., Zhiwen, T., Xiaowen, C., Xue-min, Z., Kaibin, Z., & Conghuan, Y. (2021). Research on image retrieval algorithm based on combination of color and shape features. *Journal of signal processing systems*, 93(2), 139–146.
15. Alsmadi, M. K. (2020). Content-based image retrieval using color, shape and texture descriptors and features. *Arabian Journal for Science and Engineering*, 45(4), 3317–3330
16. Kayhan, N., & Fekri-Ershad, S. (2021). Content based image retrieval based on weighted fusion of texture and color features derived from modified local binary patterns and local neighborhood difference patterns. *Multimedia Tools and Applications*, 80(21), 32763–32790.
17. Pawar, M. P., & Belagali, P. P. 2010, *Image Retrieval Technique Using Local Binary Pattern (LBP)*. *IEEE Trans. Image Process*, 19(6), 1657–1663.
18. Murala, S., Maheshwari, R. P., & Balasubramanian, R. 2012, *Local tetra patterns: a new feature descriptor for content-based image retrieval*. *IEEE transactions on image processing*, 21(5), 2874–2886.
19. Naghashi, V. 2018, *Co-occurrence of adjacent sparse local ternary patterns: A feature descriptor for texture and face image retrieval*. *Optik*, 157, 877–889.

20. Raju, U. S. N., Suresh Kumar, K., Haran, P., Boppana, R. S., & Kumar, N. (2020). Content-based image retrieval using local texture features in distributed environment. *International Journal of Wavelets, Multiresolution and Information Processing*, 18(01), 1941001.
21. أ.د. مريم ساعي، أ.د. جبر حنا، م. دارين محلا 2021 استرجاع الصور بالاعتماد على المحتوى باستخدام مصفوفة التواجد المشترك للأشكال الناتجة عن البكسلات القطرية الأربعة، مجلة جامعة طرطوس، المجلد الخامس العدد الحادي عشر.
22. Jhanwar, N., Chaudhuri, S., Seetharaman, G., & Zavidovique, B. 2004, *Content based image retrieval using motif cooccurrence matrix. Image and Vision Computing*, 22(14), 1211–1220.
23. Obulesu, A., Kumar, V. V., & Sumalatha, L. 2018, *Content based image retrieval using multi motif co-occurrence matrix. International Journal of Image, Graphics and Signal Processing*, 11(4), 59.
24. Obulesu, A., Kumar, V. V., & Sumalatha, L. 2018, *Image retrieval based local motif patterns code. International Journal of Image, Graphics and Signal Processing*, 11(6), 68.
25. Smola, A. J., & Schölkopf, B. (2004). *A tutorial on support vector regression. Statistics and computing*, 14(3), 199–222.
26. M. Kuhn and K. Johnson 2016, *Applied predictive modeling*. New York: Springer.
27. Corel 1000 image database [Online]. Available: <http://wang.ist.psu.edu/docs/related/>
28. Vistex database [Online]. Available: <http://vismod.media.mit.edu/pub/VisTex/>

- 29.P. Brodatz, Textures: A Photographic Album for Artists and Designers. New York: Dover, 1996. University of Southern California, Los Angeles, "Signal and image processing institute," [Online]. Available: <http://sipi.usc.edu/database/>
- 30.Vipparthi, S. K., & Nagar, S. K.2015, *Integration of color and local derivative pattern features for content-based image indexing and retrieval*. Journal of the Institution of Engineers (India): Series B, 96(3),251-263.
- 31.N. Fathi, B. Vaseghi and m. Shemshadi 2016, "*An overview of content-based image retrieval techniques (CBIR)*", IOSR Journal of Computer Engineering, vol. 18, no. 04, pp. 108-116.
32. Alrahhah, M., & Supreethi, K. P. 2021 Full Direction Local Neighbors Pattern (FDLNP). IJACSA International Journal of Advanced Computer Science and Applications, Vol. 12, No. 1.
- 33.S. Sharma, "*Use of Artificial Intelligence Algorithm for Content-Based Image Retrieval System*"2018, International Journal of Advance Research, Ideas and Innovations in Technology, vol. 4, no., pp. 680-684, 2018

