

## استرجاع التفاصيل المخفية تحت الظلال في الصور الساتلية باستخدام تقنية التعلم الآلي

م.زينة لطفي<sup>(1)</sup> أ. د. م. عادل خضور علي<sup>(2)</sup>

### الملخص

تعتبر تقانة كشف الظلال واسترجاع ما هو مخفي تحت الظل من التقانات المهمة واللازمة لزيادة وضوح الصور الساتلية فائقة التمييزية. تعاني التقانات المستخدمة حالياً لإزالة الظلال من أثر الحواف للظلال المكتشفة، ويؤدي استخدام التدريب المحدود بمجموعة من البيانات إلى عدم تناسق اللون في منطقة الظل. تم في هذا البحث اقتراح طريقة جديدة تعتمد على شبكة تجميع الهرم الغوصي التي يتم فيها إجراء سلسلة من عمليات العنقدة Clustering، وتجميع سمات الصورة بشكل هرمي للمراقبة والتنبؤ على التوالي، حيث تم استخدام هذه الطريقة على مجموعة بيانات SRD Standard Reference Data التي تحتوي على مليون ونصف المليون صورة (خالية من الظل / صور تحتوي الظل). تم تقييم النتائج باستخدام معاملات تحسين الصورة، مثل مؤشر التشابه الهيكلي في منطقة الظل Structural Similarity Index (SSIM-S) Measure In Shadow Area ومعامل ذروة نسبة الإشارة إلى الضجيج في منطقة الظل The Peak-Signal-To-Noise (PSNR-S) In Shadow Area، وعند استخدام شبكة تجميع الهرم الغوصي والشبكات العصبونية التلافيفية حققت الطريقة المقترحة أفضل نتائج وخاصةً لقيم المعاملات PSNR-S و SSIM-S.

الكلمات المفتاحية: الكشف عن الظلال، إزالة الظلال، معاملات تحسين الصورة، معامل التشابه الهيكلي SSIM-S، معامل نسبة الإشارة إلى الضجيج PSNR-S.

(1) طالبة دكتوراه كلية الهندسة الميكانيكية والكهربائية.

(2) أستاذ في كلية الهندسة الميكانيكية والكهربائية قسم هندسة الإلكترونيات، جامعة دمشق.

## Retrieving The Hidden Details Under The Shadows On Satellite Images Using Machine Learning Technology

Eng.Zeina Lutfi

Dr.Adel Khadour Ali

### Abstract

Shadow detection and recovering hidden objects under the shadows is one of the important techniques needed to increase the clarity of highly discriminating satellite images. The currently used techniques to remove shadows suffer from the edge effect of the detected shadows, and the use of training limited to a set of data leads to color inconsistency in the shadow area. In this research, a new method structure was proposed based on the diving pyramid network in which a series of clustering operations are performed, and image features are grouped hierarchically for monitoring and prediction respectively. SRD Standard Reference Data was used that contains one and a half million images (devoid of Shadow / shadow images). Results were evaluated using image enhancement factors, such as Structural Similarity Index Measure In Shadow Area (SSIM-S) and PSNR The Peak-Signal-To-Noise In Shadow Area and when using the Dive and Neighbor Pyramid Network. The closest proposed method yielded the best results especially for SSIM-S and PSNR- S values.

**Keywords:** Shadow Detection, Shadow Recovery, Image enhancement factors, Structural Similarity Index Measure (SSIM- S), The Peak-Signal-To-Noise Ratio PSNR- S

## 1 مقدمة:

اللون LAB هو تعديل الإضاءة بشكل أكثر دقة من أي فضاء لوني آخر. ويتمثل هذا الفضاء اللوني كما يلي:  
الرمز L: وهو عنصر يمثل الإضاءة.  
الرمز A: (ألفا) وهو يشير إلى تدرج الألوان من الأخضر إلى الأحمر.  
الرمز B: (بيتا) يشير إلى تدرج الألوان من الأزرق إلى الأصفر.  
بعد تحويل الصورة من الفضاء اللوني RGB إلى الفضاء اللوني LAB، يتم حساب القيم المتوسطة لبكسلات الخلفية في مكونات الفضاء اللوني LAB للصورة لكل مكون لهذا الفضاء اللوني.

تصنّف بكسلات خلفية الصورة على أنها بكسلات غير مظلمة عند تحقق الشرط التالي:  
- ناتج جمع [(القيمة المتوسطة لبكسلات الخلفية في المستوي A والقيمة المتوسطة لبكسلات الخلفية في المستوي B أصغر أو تساوي 256)].

### 2-3 طريقة Wang:

قدم الباحثون تقنيات أخرى لإزالة الظل، باستخدام نهج التعلم fly learning الذي يقوم بعملية مسح ثنائية الاتجاه للصورة من المنطقة المضاءة (نقطة البداية) ومنطقة الظل (نقطة النهاية). حيث تبدأ بتعيين نقطتي البداية والنهاية كنقطة حدية (yb, xb) وشعاع الاتجاه Dv. تتألف هذه التقنية من دخليين الأول: الظل والثاني: المنطقة المضاءة المقابلة لبكسل الظل. إن هذا التقابل يسبب ظهور أثر حافة للظل بشكل واضح وذلك بسبب اختلاف الإضاءة. بعد اكتشاف الظل تمت إعادة بنائه من خلال تقدير تغييرات إضاءة الظل غير المنتظمة، مما يؤدي إلى عملية اكتشاف جيدة ولكن بقيت عملية إعادة البناء ليست دقيقة [3].

تعتبر الظلال ظاهرة شائعة في الطبيعة. وكشفها وإعادة بنائها أمر ضروري لأنها قد تعيق تحقيق مهام معينة جيولوجياً وعسكرياً وتخفّض أداء العديد من أجهزة الرؤية الحاسوبية. كما أنّ اهتمام معظم التقانات يتركز بمطابقة محتويات الصورة فقط وعند إعادة بناء الظل فإنها تسبب نوعين من التشوهات: 1. عدم تناسق الألوان في مناطق الظل مقارنةً مع المناطق المجاورة لها. 2. وجود أثر حواف الظل الفاصلة مع الجوار. نذكر من هذه التقانات ما يلي:

### 2-1 طريقة Mikic:

تعتمد هذه التقنية على تقنيات التجزئة لتمييز الظل الذاتي للأجسام في الصور الساتلية عن الظلال الملقاة، وذلك من خلال حساب المتوسط  $\mu$  والتباين  $\sigma$  لمكونات الألوان الثلاثة للفضاء اللوني RGB لكل بكسل من خلفية الصورة. يتم اتخاذ قرارات تصنيف كل بكسل من خلال النظر إلى الإحصائيات الخاصة لبكسلات الخلفية، واستخدام قواعد بسيطة إحصائية عند تغطية هذه البكسلات بالظل. بالإضافة إلى مميزات اللون، تم اعتماد معلومات الجوار لإنتاج تصنيف أكثر سلاسة [1].

$$\mu_{SH}^R \mu_{SH}^G \mu_{SH}^B \quad (1)$$

- والمتباين للبكسل المظلل (SH) Shadow Pixel

$$\sigma_{SH}^R \sigma_{SH}^G \sigma_{SH}^B$$

ولنفس البكسل مضاء (IL) Illuminated Pixel

### 2-2 طريقة Guo:

تعتمد هذه الطريقة في إزالة الظلال على تحويل الصورة إلى الفضاء اللوني LAB لاكتشاف الظلال ومحاولة إعادة بنائها من صورة RGB وعلى أساس هذه التقنية يتم حساب القيمة المتوسطة لبكسلات الخلفية، الهدف من عملية تحويل الفضاء اللوني RGB إلى الفضاء

#### 4-2 طريقة Qu:

قناع ظل من الصورة المظللة. يتعلم إطار العمل على إنتاج أقنعة الظل في نفس الوقت يتعلم إزالة الظلال، لزيادة الأداء العام كان الحل تخفيض مجموعة البيانات غير المرتبطة مسبقاً [6].

من الملاحظ أنّ معظم الباحثون يفتقرون إلى أزواج الصور عالية الجودة (الخالية من الظل/الظل) لإزالة الظل والتعلم المشترك حول اكتشاف الظل وإزالته (الظل/الخالي من الظل/القناع).

بدلاً من تدريب صورة الظل مباشرة على الشبكة العصبونية تتعرف الشبكة المقترحة على الظل أولاً وتنتج قناع ظل عالي الجودة من الصورة الأصلية وتقوم بإعادة بناء هذا الظل. على الرغم من أن هذه الصور يتم تصنيعها باستخدام الشبكة العصبونية إلا أنها لا تزال تتمتع بتوزيع مشابه للمشهد الطبيعي الحقيقي.

#### 3- التعلم الآلي (التلقائي):

هو أحد فروع الذكاء الصناعي، ويتعلق ببناء ودراسة النظم التي يمكن أن تتعلم من البيانات المدخلة. جوهر التعلم التلقائي هو التمثيل والتعميم، تمثيل حالات البيانات وتوابع التقييم بشكل صحيح على هذه الحالات هو جزء من التعلم التلقائي، أما التعميم فهو المحافظة على أداء النظام بشكل جيد حتى على البيانات غير المعروفة مسبقاً.

#### 3- أنواع وأصناف التعلّم التلقائي:

##### 3-1 تعلم خاضع للإشراف (supervised):

يتم فيه التدريب على أمثلة نعلم نتيجتها، وتهدف خوارزميات التعلم الخاضع للإشراف إلى تعميم توابع تربط المدخلات مع المخرجات بحيث يتم استخدامها فيما بعد لتوليد مدخلات جديدة [8].

##### 3-2 تعلم غير خاضع للإشراف (unsupervised):

يتم فيها التدريب على أمثلة لا نعلم نتيجتها، الهدف منه هو كشف هيكل البيانات وليس تعميم ربط المدخلات مع المخرجات كما يحدث في التعلم الخاضع للإشراف [8].

اقترح الباحثون أيضاً شبكة عصبونية تلقائية لإزالة الظل في الصور DeshadowNet باستخدام شبكتين عصبونيتين تعملان على التوازي. تستخرج أحدهما معاملات الظل لصورة الدخل، وتقوم الثانية بالتنبؤ. تولد هاتان الشبكتان المتكاملتان ميزات متعددة للحصول على الظل غير اللامع بتفاصيل دقيقة. ولتقييم أداء هذه التقنية، تم بناء أول معيار قياسي يعتمد على 3088 زوجاً من الصور [4].

وفقاً لصورة الظل، يمكن إيجاد كل بكسل متنبئ به للصورة وخالي من الظل IS من خلال المعامل Non Ins Image Shadow ويكسلات الظل غير اللامعة Shadow Sm Matte. حسب العلاقة [4]:

$$IS = Sm \cdot Ins \quad (2)$$

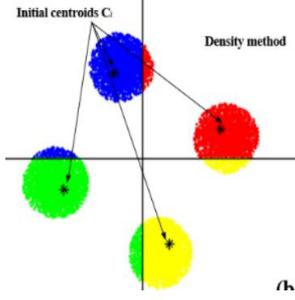
#### 5-2 طريقة Wang:

اتخذ بعض الباحثين تقنية للتعلم المشترك تقوم باكتشاف الظلال والإزالة من خلال شبكة عصبونية (ST-CGAN) Stacked Conditional Generative Adversarial Network، تتكون ST-CGAN من اثنتين من شبكات GAN Generative Adversarial Network حيث يتم تكديس الثانية على الأولى. يتم تدريب صورة الظل RGB المدخلة x. ثم تدريب المولد G1 على إخراج قناع الظل المقابل (x,z) حيث z الضجيج أو الظل الموجود في صورة الدخل [5].

تم استخدام قاعدة بيانات تحوي على 1870 صورة ثلاثية (صورة ظل، صورة قناع الظل، وصورة خالية من الظل) مقابلة ل 135 مشهداً. تُظهر النتائج فعالية جيدة من حيث الكشف وإعادة بناء الظلال [5].

#### 6-2 طريقة Hu:

تعتمد في إزالة الظل على بيانات غير مترابطة، للحصول على عينات تدريب أكثر ضمن إطار عمل عميق جديد يتعلم تلقائياً Mask-Shadow GAN لإنتاج



الشكل (1) استخراج مركز الفضاء اللوني

- نعيد إسناد النقاط إلى المجموعات وذلك حسب المسافة الأقصر بين نقطة البيانات والمركز.  
✓ شرط التوقف:

- عدم تغير مواضع مراكز المجموعات.

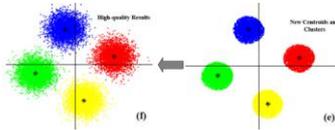
هدف الخوارزمية:

- تصغير تابع الهدف والمعرف في هذه الحالة بالعلاقة:

$$J = \sum_{j=1}^k \sum_{i=1}^n \|x_i^{(j)} - c_j\|^2 \quad (5)$$

حيث  $x_i^{(j)}$  هي نقطة البيانات و  $c_j$  هي مركز المجموعة.

على الرغم من أن الخوارزمية تنتهي دوماً إلا أنها لا تحقق بالضرورة الحل الأمثل استناداً إلى تصغير تابع الهدف. الخوارزمية أيضاً حساسة بشكل كبير إلى التموضع البدائي العشوائي لمراكز المجموعات، وبالتالي يمكن تنفيذ الخوارزمية عدة مرات للحد من هذه المشكلة كما هو موضح في الشكل 2.



الشكل (2) الحصول على التمييزية المكانية من الكثافة ونقاطها الوسطى

أعطى استخدام هذه الخوارزمية لتمييز بكسلات الظل من بكسلات اللا ظل في الصورة التي نعالجها تدريب صحيح بنسبة 68.45% مقارنةً مع نتائج كانت مدربة سابقاً لتصنيف أغراض مختلفة عن الظل واللا ظل. وذلك

توجد عدة خوارزميات تستخدم التعلم التلقائي، نذكر منها:

➤ **K-means clustering** التصنيف بتقليل المسافة الإقليدية بين نقطة البيانات ومركز الكتلة:

هذه واحدة من أبسط خوارزميات التعلم التلقائي غير الخاضعة للإشراف (unsupervised) والتي تحل مشكلة الclustering. تعتمد هذه الخوارزمية على طريقة بسيطة لتصنيف البيانات إلى عدة مجموعات (clusters) وعددها k.

خطوات عمل هذه الخوارزمية:

الخطوة الأولى:

- وضع مراكز المجموعات بشكل عشوائي.

$$c_i = \text{random value} ; \text{ where } i = 1, \dots, k \quad (3)$$

- إسناد كل نقطة بيانات إلى المجموعة التي يكون مركزها أقرب لهذه النقطة من المراكز الأخرى كما هو موضح بالشكل 1.

$$d(x_i, x_j) = \sqrt{(x_{i1} - x_{j1})^2 + (x_{i2} - x_{j2})^2 + \dots + (x_{im} - x_{jm})^2} \quad (4)$$

حيث  $X_i$ : هي مجموعة النقاط التي تنتمي للمجموعة i.

- وبالتالي نحصل على تصنيف مبدئي للبيانات ضمن مجموعات محددة وعددها k.

الخطوة الثانية:

نعيد حساب مراكز المجموعات بحيث يتوضع مركز كل مجموعة على متوسط نقاط البيانات التي تنتمي لتلك المجموعة.

$$c_i \text{ new} = \frac{1}{c_i \text{ old}} \sum_{j \in c_i \text{ old}} x_j ; \forall i \quad (5)$$

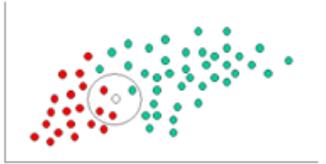
$$p(\text{red}) = \frac{\text{number of red}}{\text{total number of objects}}$$

$$P(\text{GREEN}) = 2/3$$

$$P(\text{RED}) = 1/3$$

بعد القيام بوضع الاحتمالات الأسبقية يمكننا أن نصنف أي غرض جديد وبما ان الأغراض متجمعة بشكل جيد من المنطقي أن نفترض أن العينات (الخضراء أو الحمراء) تقع في محيط العينة التي تنتمي لها العينة الجديدة X .

لقياس هذا الاحتمال يمكن أن نرسم دائرة حول العينة الجديدة (الظل في الصورة المدخلة) التي تضم عدد من العينات بغض النظر عن الصف الذي تنتمي له (يتم تحديد هذا العدد مسبقاً). ثم نحسب عدد العينات ضمن الدائرة المنتمين إلى كل الصفوف كما موضح في الشكل 4:



الشكل (4) رسم دائرة حول العينة الجديدة التي تضم عدد من العينات بغض النظر عن الصف الذي تنتمي له [10]

وبالتالي يمكن حساب الاحتمال:

$$\text{likelihood of } X \text{ given green} = \frac{\text{number of green in the vicinity of } X}{\text{total number of green cases}} = \frac{1}{40} \quad (8)$$

$$\text{likelihood of } X \text{ given red} = \frac{\text{number of red in the vicinity of } X}{\text{total number of red cases}} = \frac{3}{20}$$

نلاحظ أن  $\frac{3}{20} > \frac{1}{40}$ ، ولكن الاحتمالية الأسبقية: احتمال أن العينة الجديدة تنتمي للصف الأخضر أكبر من احتمال انتمائه للصف الأحمر (احتمال الأخضر ضعف احتمال الأحمر)

وبالتالي التصنيف النهائي حسب تقنية Naïve Bayes يتم من خلال دمج النتائج السابقة وفق العلاقة التالية [16]:

لأن هذه الخوارزمية تخضع للتعلم غير الخاضع للإشراف بينما لتمييز بكسلات الظل من بكسلات اللا ظل في الصورة تحتاج للتعلم الخاضع للإشراف طالما أن الهدف معلوم في بيانات التدريب [9] .

➤ Naïve Bayes ( النظرية البايزية):

تعتمد هذه الخوارزمية على النظرية البايزية وتستخدم بشكل خاص عندما تكون أبعاد الدخل عالية. على الرغم من بساطة هذه الخوارزمية إلا أنها في كثير من الحالات تفوق تقنيات التصنيف الأكثر تعقيداً.

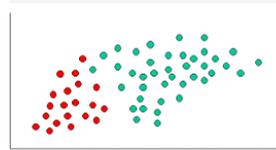
يمكن لهذه التقنية التعامل مع عدد من المتغيرات المستقلة المستمرة أو المنقطعة.

نفترض Naïve Bayes أن الاحتمالات الشرطية للمتغيرات المنفصلة إحصائياً مستقلة ويمكننا التعبير عنها بالمعادلة [10]:

$$P(X | C_j) = \prod_{k=1}^d P(X_k | C_j)$$

$$P(C_j | X) = P(C_j) \prod_{k=1}^d p(x_k | C_j) \quad (6)$$

وليكن لدينا الشكل التالي:

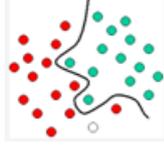


الشكل (3) تصنيف العينات حسب النظرية البايزية [16]

نلاحظ أنه يمكن تصنيف هذه العينات (الظل واللا ظل) إلى خضراء وحمراء، نتحصر مهمتنا بتصنيف حالات الظل الجديدة لكي نقرر إلى أي العينات تنتمي لكل صف بناء على الصفوف الموجودة لدينا سابقاً.

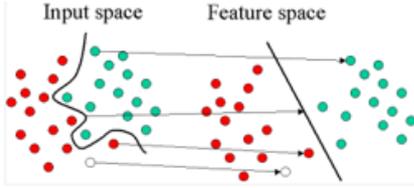
نفترض أن عدد العينات الخضراء هو ضعف عدد العينات الحمراء، وبالتالي احتمال أن تكون العينات الجديدة خضراء هو ضعف احتمال أن تكون حمراء (الاحتمال الاستباقي) أي نستخدم نسبة الأخضر والأحمر غالباً للتنبؤ بالنتائج [10]:

$$p(\text{green}) = \frac{\text{number of green}}{\text{total number of objects}} \quad (7)$$



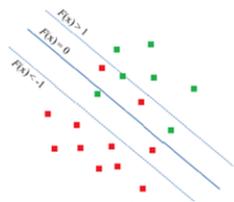
الشكل (6) خط القرار صنف العينات الخضراء إلى يمينه والعينات الحمراء إلى يساره [17]

تسمى هذه الحالة بمصنفات Hyperplane والتي يقوم بحلها ما يعرف ب SVM. وكما هو موضح في الشكل (7) نلاحظ أن العينات الأصلية المصنفة تغير مجالها باستخدام توابع رياضية تسمى Kernels وهي تعرف عملية تغيير المجال ب Transformations بحيث تم التصنيف خطأً وبالتالي بدلاً من بناء منحنى معقد للفصل استطعنا أن نجد الفصل الأمثل بين العينات وبطريقة بسيطة.



الشكل (7) التصنيف الخطي بدلاً من منحنى معقد لفصل العينات [11]

لقد تم الفصل من خلال إضافة هامش على جانبي خط القرار بحيث تتوزع على هذا الهامش العينات الجديدة التي لم تُصنف بعد بشكل صحيح عن طريق خط فصل عادي وبالتالي هذه العينات يمكن أن تكون حمراء أو خضراء كما هو موضح في الشكل (8).



الشكل (8) إضافة هامش على جانبي خط القرار بحيث تتوزع على هذا الهامش العينات الجديدة [11]

أعطى استخدام هذه الخوارزمية لتمييز بكسلات الظل عن بكسلات اللا ظل في الصورة التي نعالجها تدريب صحيح بنسبة 87.42 %، مقارنةً مع نتائج كانت مدربة

$$\begin{aligned} & \text{posterior probability of } X \text{ being GREEN} \\ &= \frac{4}{6} * \frac{1}{40} = \frac{1}{60} \end{aligned} \quad (9)$$

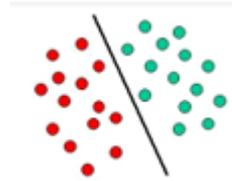
$$\begin{aligned} & \text{posterior probability of } X \text{ being RED} \\ &= \frac{2}{6} * \frac{3}{20} = \frac{1}{20} \end{aligned}$$

وبالتالي يتم تصنيف العينة الجديدة على أنها حمراء لأن الاحتمال النهائي لها أعلى.

أعطى استخدام هذه الخوارزمية لتمييز بكسلات الظل عن بكسلات اللا ظل في الصورة التي نعالجها تدريب صحيح بنسبة 69.89 % مقارنةً مع نتائج كانت مدربة سابقاً لتصنيف أغراض مختلفة عن الظل واللا ظل. وذلك لأنها تُستخدم للمشاكل الخطية [10].

#### Binary SVM (Binary Support Vector Machine) ناقلات الدعم الثنائي:

تعتمد هذه التقنية على مفهوم خط القرار الذي يحدد حدود القرار. خط القرار يقوم بتصنيف مجموعة العينات التي لها درجات انتماء مختلفة للصفوف، في الشكل التالي نريد تصنيف العينات الخضراء والحمراء كما هو موضح في الشكل (5):



الشكل (5) مفهوم خط القرار [17]

صنّف خط القرار العينات الخضراء إلى يمينه والعينات الحمراء إلى يساره كما هو مبين في الشكل (5). أي عينة جديدة تكون على يمين خط القرار يجب أن تكون خضراء، وإذا كانت على يساره يجب أن تكون حمراء. الشكل السابق هو تصنيف خطي ولكن في معظم حالات التصنيف يكون من الصعب ان نحدد خط القرار الفاصل بين العينات بدقة كما في الشكل (6):

حيث يمثل  $Y$  المتغير الهدف، و  $x$  هي متغيرات الدخل المستخدمة في المهمة [12].

من أجل المقارنة بين التقانات السابقة والطريقة المقترحة تم تدريب طريقة إعادة بناء الظل المقترحة والطرائق التي تم ذكرها على مجموعة بيانات SRD.

تتم عملية تقييم النتائج باستخدام مقياس مؤشر التشابه الهيكلي Structural Similarity Index Measure (SSIM) ومقياس نسبة الإشارة الأعظمية على الضجيج PSNR Peak-Signal-To-Noise Ratio لمناطق الظل

العالية الدقة التي تم بناؤها وفق العلاقة التالية [13]:

$$PSNR(f, g) = 10 \log_{10} (255^2 / MSE(f, g))$$

where

$$MSE(f, g) = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (f_{ij} - g_{ij})^2 \quad (11)$$

تقترب قيمة PSNR من اللانهاية مع اقتراب MSE من الصفر وهذا يشير أن قيمة PSNR الأعلى تقابل جودة صورة أعلى. أما القيمة الصغيرة لـ PSNR تشير إلى اختلافات رقمية عالية بين الصور. المقياس SSIM هو مقياس الجودة بين صورتين وقد استخدم طرائق تجميع الأخطاء التقليدية بدلاً من إدراك الجودة للنظام البصري البشري (HVS) Human Visual System.

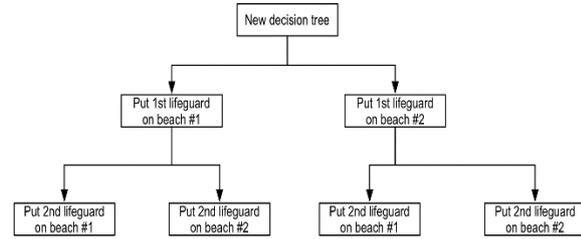
يعتبر متوسط الخطأ التربيعي (MSE) Mean Square Error من المعايير الشائعة التي تم استخدامها لقياس أداء الطرائق المستخدمة في معالجة الصور والتنبؤ ومع ذلك، فإن اختيار معيار مناسب يمكن على أساسه مقارنة العديد من النماذج المتنبأ بها لا يزال مهمة صعبة للعديد من المحللين لأن بعض المعايير قد تؤثر على حجم النموذج للمعلمات المقدره بينما يمكن للمعايير الأخرى التركيز بشكل أكبر على العينة [14].

وتم تصميم SSIM بواسطة نمذجة أي تشوه للصورة كمجموعة من ثلاثة عوامل هي فقدان الارتباط وتشوه السطوح وتشوه التباين. تم تعريف SSIM على أنه [13]:

سابقاً لتصنيف أعراض مختلفة عن الظل واللا ظل. وهي أعلى نسبة بين الخوارزميات السابقة وذلك لأنها تعالج مشكلة التصنيف غير الخطي بطريقة فعالة [11].

### شجرة القرار Decision Tree :

شجرة القرار هي التمثيل البسيط لأمثلة التصنيف كما هو موضح في الشكل (9)، والتعلم عن طريق شجرات القرار إحدى التقانات الأكثر نجاحاً في التعلم الخاضع للإشراف.



الشكل (9) تمثيل شجرة القرار

الهدف من هذه الطريقة هو بناء نموذج يتنبأ بقيمة المتغير الهدف بناء على دخل يحوي على عدة متغيرات. كل عقدة داخلية تمثل واحدة من متغيرات الدخل أما الفروع فتمثل القيم الممكنة لهذه المتغيرات. أما الأوراق فتمثل قيمة المتغير الهدف طالما أن متغيرات الدخل ممثلة في المسار من الجذر إلى الأوراق.

يمكن أن تُعلم الشجرة عن طريق تقسيم المجموعة الرئيسية لعدة مجموعات اعتماداً على اختبار قيمة السمات، وتكرر هذه العملية في كل مجموعة فرعية مشتقة بطريقة عوديه. تنتهي العودية عندما يكون للمجموعة الفرعية في العقدة نفس قيمة المتغير الهدف، أو عندما لا يستطيع التقسيم أن يضيف أي قيمة للمتوقعات.

عملية بناء الشجرة من الأعلى للأسفل Top To Down هي مثال على الخوارزمية الGreedy وهي الاستراتيجية الأكثر شيوعاً لتدريب شجرات القرار من البيانات. تأتي البيانات بالصيغة التالية:

$$(x, Y) = (x_1, x_2, \dots, x_k, Y) \quad (10)$$

- شبكة تجميع وتركيب السمات CAN context aggregation network الشبكة الأساسية في هذا البحث، وهي مُصمّمة لمعالجة الصور وإزالة الانعكاس والذي يُفسّر في الصور الساتلية على أنه ظل وتعمل على تحسين جودة مناطق الظل بشكل كبير، ووجود تسلسل التجميع الهرمي الغوسي لهذه الشبكة يساهم في معرفة سمات الصورة (اللون والتشبع والسطوع) المختلفة بشكل أفضل.

- بالإضافة إلى استخدام خوارزمية Generative Adversarial Network GAN وهي شبكة عصبونية مبدأ عملها هو توليد أفنعة ظل للصورة المُقابلة الحاوية للظل من خلال مجموعة قاعدة البيانات التي يتم العمل عليها SRD، ليصبح بالإمكان تركيب الظلال الجديدة للصورة المُدخلة وتوسيع قواعد البيانات لديها من خلال أفنعة الظل المولدة في كل عملية إدخال جديدة للصورة [18]. تحتوي الصور الخالية من الظل والصور التي تحتوي على الظل على نفس السمات، كما أنّ عملية إزالة الظل على وجه التحديد تحتاج فقط إلى تدريب الظل لأنّ السمات هي نفسها، وبالتالي تحتاج الشبكة إلى التركيز على السمات منخفضة المستوى، والتي تختلف عن غيرها.

- بنية شبكتنا هي استخدام التقنيتين السابقتين معاً والتجميع الهرمي الغوسي. حيث يُؤدّد قناع الظل من الشبكة GAN مع حفظه على سمات الصورة من خلال الشبكة CAN والتجميع الهرمي الغوسي.

- تحقق هذه الطريقة نتائج أفضل بكثير عند استخدام التعلم الخاضع للإشراف على قناع الظل المولّد. بالإضافة إلى ذلك تمت مقارنة نتائج الشبكة المُقترحة مع نتائج الدراسات السابقة باستخدام معاملات تحسين جودة الصورة، مثل معامل مؤشر التشابه الهيكلي في منطقة الظل Structural Similarity Index Measure In Shadow Area (SSIM-S) ومعامل ذروة نسبة الإشارة

$$SSIM(f, g) = l(f, g)c(f, g)s(f, g) \quad (12)$$

$$l(f, g) = \frac{2\mu_f\mu_g + C_1}{\mu_f^2 + \mu_g^2 + C_1}$$

$$c(f, g) = \frac{2\sigma_f\sigma_g + C_2}{\sigma_f^2 + \sigma_g^2 + C_2} \quad (12)$$

$$s(f, g) = \frac{\sigma_{fg} + C_3}{\sigma_f\sigma_g + C_3}$$

المصطلح الأول  $L(f, g)$ : وهو دالة مقارنة السطوع التي تقيس القرب بين متوسطي سطوع الصورتين ( $\mu_f$  و  $\mu_g$ )، أكبر قيمة لهذا المعامل تساوي 1 فقط إذا كانت  $\mu_f = \mu_g$ .

المصطلح الثاني  $C(f, g)$ : له وظيفة مقارنة التباين وهي تقيس مدى قرب تباين الصورتين. يتم قياس التباين من خلال الانحراف المعياري  $\sigma_f$  و  $\sigma_g$ . وهذا المعامل أكبر قيمة له تساوي 1 فقط إذا كانت  $\sigma_f = \sigma_g$ .

المصطلح الثالث  $S(f, g)$ : هو دالة مقارنة البنية التي تقيس معامل الارتباط بين الصورتين  $f$  و  $g$  الصورة المظلمة والصورة بعد إزالة الظل على التوالي. حيث أن  $\sigma_{fg}$  هو التباين بين  $f$  و  $g$ . القيم الموجبة لمؤشر SSIM موجودة بين [0,1]. حيث تعني القيمة 0 عدم وجود ارتباط بين الصور. حيث  $C_1, C_2, C_3$ : هي ثوابت لضمان الاستقرار عندما يصبح المقام 0. وتعطى كما يلي [16]:

$$C_1 = (K_1 * L)^2 \quad C_2 = \frac{C_1}{2} \quad K_1 = 0.01$$

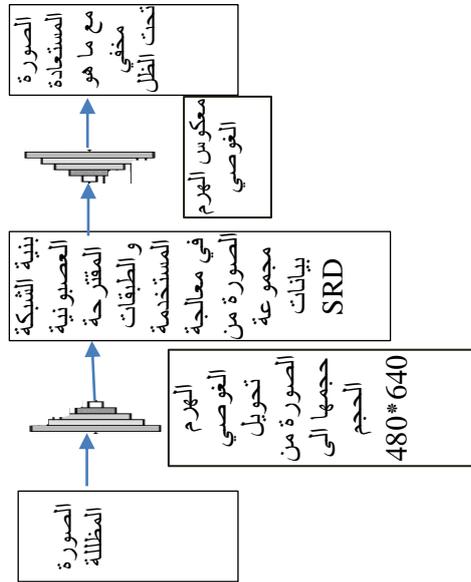
$$C_2 = (K_2 * L)^2 \quad K_2 = 0.03$$

$$L = 255.$$

تعتبر مقاييس التقييم هذه الأكثر عمومية وبالتالي لتدريب الشبكة على مناطق الظلال بشكل خاص والحفاظ على التفاصيل المنخفضة المستوى نقوم باستخدام تقنية هرمية للتمييز المكاني واستخراج المميزات منها. بالإضافة إلى هذا نستخدم أيضاً قناع ظل الحقيقة الأساسي Ground Truth Shadow Mask.

#### 4- بنية ومراحل عمل الطريقة المقترحة :

يبين الشكل (7) بنية الطريقة المستخدمة وهي:



الشكل (7) بنية الشبكة المقترحة

الجدول (1) نتائج تطبيق Mikic على صور مظلمة

Picture	Method				
	Mikic				
	Shadow	non-shadow	RMSE	SSIM-S	PSNR-S
763×766	21.21	15.88	20	80	19
1000×1000	19.39	14.52	19.85	82	19.5
1026×768	19.43	14.55	19	85	20
1920×1080	18.97	14.2	19	88	20.25
2200×1400	19.10	14.3	18	89	21

الجدول (2) نتائج تطبيق Hu على صور مظلمة

Picture	Method				
	Hu				
	Shadow	non-shadow	RMSE	SSIM-S	PSNR-S
763X766	12.19	9.45	20	88	21
1000X1000	12.25	9.5	18.8	88.52	22.23
1026X768	11.61	9	18	88.9	23
1920X1080	11.32	8.78	17.78	89	23.56
2200X1400	10.96	8.5	17.5	90	24

إلى الضجيج في منطقة الظل -PSNR The Peak- وعند استخدام Signal-To-Noise In Shadow Area شبكة تجميع الهرم الغوسي حققت الطريقة المقترحة أفضل نتائج وخاصةً لقيم المعاملات، PSNR-S و SSIM-S.

تعمل الطريقة المقترحة على استخراج سمات الصور الناتجة عن التدريب الذي تم إجراؤه على مجموعة بيانات SRD بحيث لا يتم استخدام عمليات تخفيض معدل أخذ العينات، والحفاظ على التفاصيل منخفضة المستوى بشكل جيد. على الرغم من أن مهمة إزالة الظل مشابهة لمهمة تخفيض المستوى إلا أنها تحتاج عملياً إلى اكتشاف وتحديد مناطق الظل مسبقاً.

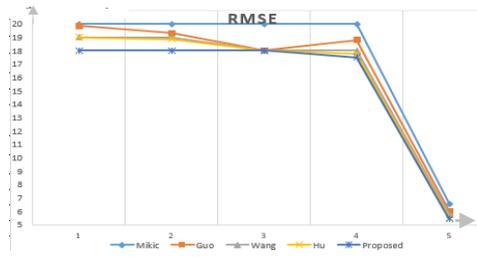
نقوم بتدريب جميع نماذجنا باستخدام إطار عمل مكتبة البايثون لتحسين أداء الشبكة، وخلال التدريب نقوم بتغيير حجم الصورة الأصلية عشوائياً والمحافظة على الدقة الأصلية بدلاً من اقتصاص الصورة. ودرنا الشبكة على أكثر من 100 فترة من أجل تركيب الظل و 150 فترة لإزالة الظل. للاختبار نقوم بتقييم جميع الصور بحجمها الأصلي. يستغرق الأمر عدة دقائق لشبكتنا لإنشاء صورة خالية من الظل على وحدة معالجة رسومات NVIDIA GPU.

وكذلك تدريب الشبكة على تركيب صور الظل من الأفتعة المقابلة في مجموعة البيانات فستنتج الشبكة أيضاً الظلال الجديدة وفقاً للأفتعة التي تقوم بتوليدها من خلال الشبكة GAN وهذا أسهل بكثير جمع البيانات المطلوبة لتركيب الظل مقارنة بثلاثيات من (الظل/ بلا الظل/ القناع). وبالتالي فإننا نصمم شبكتنا بحيث نتعرف على الظل أولاً وتنتج ظلاً عالي الجودة. على الرغم من أن هذه الصور تمّ تصنيعها باستخدام الشبكة العصبونية إلا أنها تبقى مطابقة من حيث السمات مع الصورة المُدخلة.

الأمريكية بأبعاد  $766 \times 763$  ، والصور التي يقدمها لمواقع تحتوي على مجموعة من الظلال في ريف دمشق بأبعاد هذه الصور وعددها صورتين بأبعاد  $1000 \times 1000$  . وصورة من الساتل WorldView-3 لمنطقة نيو يورك بأبعادها  $768 \times 1026$  وصورة من ساتل ال-WorldView-3 لمنطقة شنغهاي في الصين بأبعادها  $1080 \times 1920$  وأخيراً صورة من ساتل ال-WorldView-4 لمنطقة في طوكيو اليابان بأبعادها  $1400 \times 2200$  [15] ،

إن الطريقة المقترحة تقيّد في إنشاء صور خالية من حدود وآثار الظلال وإعادة بناء منطقة الظل بأفضل جودة. وبالنظر إلى الجداول (1، 2، 3، 4، 5) على التوالي كانت نسبة التحسين بالنسبة للمعامل RMSE 12% بالمقارنة مع الخوارزميات السابقة ونسبة التحسين بالنسبة للمعامل PSNR-S 9% بالنسبة للخوارزميات السابقة.

حيث أخذت الطريقة المقترحة بعين الاعتبار جمال الصورة ووصلت لنتيجة جيدة خاصة اننا نتعامل مع صور ساتليه



الشكل (8) منحنى تغير جذر مربع الخطأ التربيعي للطرائق السابقة والطريقة المقترحة



الشكل (9) منحنى تغير مؤشر التشابه الهيكلية للطرائق السابقة والطريقة المقترحة

الجدول (3) نتائج تطبيق خوارزمية شدل على صور مظلة

Picture	Method				
	Wang				
	Shadow	non-shadow	RMSE	SSIM-S	PSNR-S
763X766	21.20	14.23	20	85	18
1000X1000	21.15	14.2	18	85.88	18.55
1026X768	20.86	14	18	86.5	19.58
1920X1080	20.68	13.88	18	87.55	20.32
2200X1400	19.71	13.23	18	88	20

الجدول (4) نتائج تطبيق طريقة Guo على صور مظلة

Picture	Method				
	Guo				
	Shadow	non-shadow	RMSE	SSIM-S	PSNR
763X766	24.38	23.9	19.5	80.45	22
1000X1000	23.97	23.5	19.3	82.5	22.56
1026X768	23.66	23.2	18.5	86	23
1920X1080	23.36	22.9	17.45	89	23.55
2200X1400	22.75	22.3	17.23	90	24.5

الجدول (5) نتائج تطبيق الخوارزمية المقترحة على صور مظلة

Picture	Method				
	Proposed				
	Shadow	non-shadow	RMSE	SSIM-S	PSNR-S
766×763	9.51	7.06	6.56	88.5	30.33
1000×1000	9.43	7	6	93.8	31
768×1026	8.82	6.55	5.75	94	31.88
1080×1920	8.39	6.23	5.55	94.8	32.2
1400×2200	8.24	6.12	5.44	94.55	32

### تقييم النتائج:

الطريقة المقترحة فيها حد أدنى من آثار حدود الظل وتوفر تناسقاً أفضل للون. كما تشير النتائج المبينة في الأشكال (8,9,10)

على التوالي أنّ الشبكة المقترحة تعطي صور عالية الجودة وخالية من حدود الظلال اعتماداً على السمات المحصلة من هذه الصور. كما تُظهر النتائج المطبقة على الصور المحصلة من مجموعة بيانات الاختبار من الساتل WorldView-2 لمنطقة في سان أنطونيو الولايات المتحدة



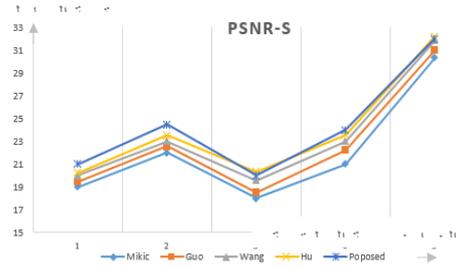
**RMSE=5.75, PSNR=31.88, SSIM-S=94.**  
 (a) الصورة المظلمة أبعادها  $768 \times 1026$  لمنطقة نيو  
 يورك وصورة من الساتل **WorldView-3**



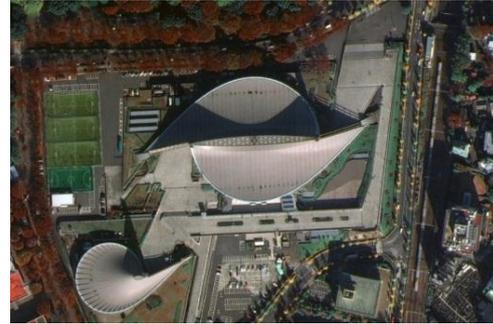
(b) الصورة المعالجة الخالية من الظلال بعد المعالجة  
 بالطريقة المقترحة ومعاملات هذه الصورة

### الخاتمة:

لقد كان الهدف الرئيسي منذ البداية هو إنشاء نموذج إزالة الظلال للحصول على صور خالية من آثار الظلال وحدوده، واقترحنا يتضمن استخدام شبكة عصبونية جديدة تبدأ بشبكة **CAN** و **GAN** والتجميع الهرمي الغوصي. تم في هذا البحث تقديم طريقة جيدة تعتمد على مجموعة البيانات المعيارية لمعرفة السمات الأكثر صلة باكتشاف الظلال من الصورة الواحدة. ولاحظنا أن هذه الطريقة تعمل بشكل أفضل على العديد من قواعد البيانات.



الشكل (10) منحنى تغير جذر مربع الخطأ التربيعي  
 للطرائق السابقة والطريقة المقترحة المختبرة وطريقتنا



(b) الصورة المعالجة الخالية من الظلال بعد المعالجة  
 بالطريقة المقترحة ومعاملات هذه الصورة  
**RMSE=5.44, PSNR=32, SSIM-S=94.55.**



(a) الصورة المظلمة لمنطقة في طوكيو اليابان أبعادها  
**1400 × 2200** من الساتل **WorldView-4**

Identification and Encrypted Transmission System”, Entropy JOURNAL.

[13]- Alain Horé And Djemel Ziou, , “Image quality metrics: PSNR vs. SSIM”, 2010, International Conference on Pattern Recognition, IEEE DOI 10.1109/ICPR.2010.579.

[14]- Hoang Pham,” A New Criterion for Model Selection”,2019, Mathematics , doi:10.3390/math7121215.

[15] [apollomapping.com](http://apollomapping.com).

[16] [Naive Bayes Classifier Explained Step.](#)

[17] [https://en.wikipedia.org/wiki/Support-vector\\_machine#Bayesian\\_SVM](https://en.wikipedia.org/wiki/Support-vector_machine#Bayesian_SVM).

Received	2021/4/13	إيداع البحث
Accepted for Publ.	2021/8/2	قبول البحث للنشر

## References

## المراجع

[1]- Mikic, I., Cosman, P, Kogut, G, and Trivedi, 2000, “Moving shadow and object detection in traffic scenes. In ICPR”, volume 1, 321–324. IEEE.

[2]- Murali S, Govindan V , ”Shadow Detection and Removal from a Single Image Using LAB Color Space”, 2013, CYBERNETICS AND INFORMATION TECHNOLOGIES , Volume 13, No 1.

[3]-Gong H and Cosker D,2014,”Interactive Shadow Removal and Ground Truth for Variable Scene Categories”, Media Technology Research Centre Department of Computer science University of Bath UK.

[4]- Qu, L.; Tian, J.; He, S.; Tang, Y.; and Lau, R. W. 2017. Dshadownet: A multi-context embedding deep network for shadow removal. In CVPR, 4067–4075.

[5]- Wang, J.; Li, X.; and Yang, J. 2018.” Stacked conditional generative adversarial networks for jointly learning shadow detection and shadow removal In CVPR”, 1788–1797.

[6]- Hu, X.; Jiang, Y.; Fu, C.-W.; and Heng, P.-A. 2019. “Mask-shadowgan: Learning to remove shadows from unpaired data”. ICCV.

[7]- Yashavant S. Inglel Prof. Anil Mokhadé, 2013, “Use of Linear Regression in Machine Learning for Ranking”, Vol. 1, Issue 5, ISSN2321-0613.

[8]- Khah S, Marteau P, Bechet N,2018,” Intrusion detection in network systems through hybrid supervised and unsupervised machine learning process: a case study on the ISCX dataset”, IEEE International Conference on Data Intelligence and Security.

[9]- Kristina P. Sinaga and Miin-Shen Yang, 2020, “Unsupervised K-Means Clustering Algorithm”, IEEE, License4.

[10]- Daniel Berrar,” Bayes Theorem and Naive Bayes Classifier”,2019, Encyclopedia of Bioinformatics and Computational Biology, Volume 1, Elsevier, pp. 403-412.

[11]- Paoletti M, Haut M, Tao X, Miguel J and Antonio Plaza, 2020, “ A New GPU Implementation of Support Vector Machines for Fast Hyperspectral Image Classification”, Remote Sens 1257; doi:10.3390/rs12081257.

[12]-Liu S, Yang Z, Yi Li and Shuiqing Wang,2020, “Decision Tree-Based Sensitive Information