



## تصنيف الصور الطيفية باستخدام خوارزمية فك المزج الطيفي غير الخطي وخوارزمية التصنيف بالاعتماد على الزاوية الطيفية.

انس رامز الفحام\*1، ياسر عملة2، عيد العبود3

1 قسم هندسة الالكترونيات والاتصالات، كلية الهندسة الميكانيكية والكهربائية، جامعة البعث، حمص، سوريا، anas9127anas@gmail.com

2 قسم هندسة الالكترونيات والاتصالات، كلية الهندسة الميكانيكية والكهربائية، جامعة البعث، حمص، سوريا، Yaser.emleh@gmail.com

3 قسم هندسة الالكترونيات والاتصالات، كلية الهندسة الميكانيكية والكهربائية، جامعة البعث، حمص، سوريا، eado78@gmail.com

الباحث الممثل: انس رامز الفحام، الايميل: anas9127anas@gmail.com

نشر في: 30 حزيران 2022

**الخلاصة** – الاستشعار عن بعد هو العلم الذي يبحث في المعلومات المكتسبة من سطح الأرض عن طريق تحسس وتسجيل ومعالجة وتحليل الطاقة المنبعثة أو المنعكسة عن المواد المصورة و يتم التقاط صور الاستشعار عن بعد إما جويًا من خلال طائرات تحمل منصات تصوير أو فضائياً عن طريق الأقمار الصناعية ولكن نتيجة للارتفاعات الكبيرة والتكلفة الباهظة للكاميرات ذات الدقة العالية والتشابه الكبير في الشكل الخارجي للمشاهد المصورة تم اللجوء إلى تشكيل ما يدعى المكعبات الطيفية Datacubes باستخدام تقنية التصوير الطيفي التي تعتمد على إنتاج مجموعة من الصور ثلاثية الأبعاد يبعدان مكانيين (جغرافيين) وبعد ثالث يمثل الأطوال الموجية المختلفة. ينتج عن عملية التصوير الطيفي مجموعة من البيكسلات التي تمثل مزيج من المواد والمكونات النقية وتدعى في هذه الحالة (البيكسل الممزوج) حيث يساهم كل مكون من مكونات الصورة بنسبة محددة في تكوين البيكسل الممزوج ويمكن تمييز هذه المكونات عن طريق خوارزمية فك المزج الخطي غير الخطي بشكل آلي. تم في هذا البحث دراسة خوارزمية فك المزج غير الخطي وتطبيقها على المكعبات الطيفية الناتجة عن صور الاستشعار عن بعد بهدف تصنيف محتويات هذه الصور والتعرف على مكوناتها وحساب نسبتها كما تم مقارنة نتائج خوارزمية فك المزج مع نتائج خوارزمية التنسيب بالاعتماد على قياس الزاوية الطيفية وأظهرت لنا النتائج تفوق خوارزمية فك المزج التي قدمت لنا نتائج ممتازة حيث كانت نسبة الخطأ في تصنيف الطرقات والشوارع الموجودة في الصورة هي 1.3% ونسبة الخطأ الخاصة بالكتل الصخرية والمساحات المائية هي 2.59%، 0% على الترتيب.

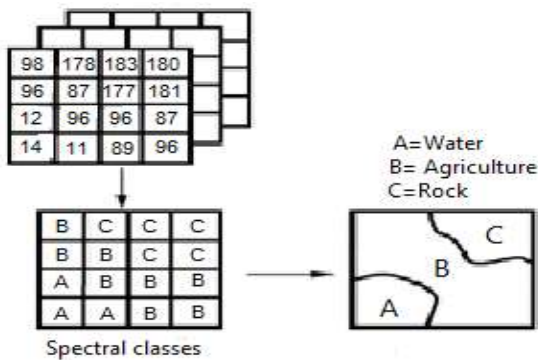
**الكلمات المفتاحية**- المكعب الطيفي، تصنيف الصور الطيفية، عناصر نقية، بيكسل ممزوج، خوارزمية التنسيب بالاعتماد على قياس الزاوية الطيفية، خوارزمية فك المزج غير الخطي.

### 1. المقدمة

تعتبر عملية التصنيف من أهم التقنيات التي يمكن تطبيقها على صور الاستشعار عن بعد وهي تهدف إلى عزل العناصر المتشابهة وحساب نسبتها اعتماداً على ما يدعى التصوير والتحليل الطيفي وهو التقاط مجموعة من الصور عند الأطوال الموجية المختلفة يطلق عليها اسم الصور الطيفية مما يؤدي بالنتيجة إلى توليد المكعبات الطيفية التي يتم تشكيلها عن طريق سلسلة من الصور المنفصلة ذات الطول الموجي المفرد.

تحوي الصور الملتقطة على مجموعة من البيكسلات التي من الممكن أن تضم معلومات تتعلق بعنصر واحد فقط أو معلومات خاصة بعناصر مختلفة وفي هذه الحالة سيكون لدينا طيف مختلط يتأثر بالطيف النقية الخاصة بكل عنصر من عناصر البيكسل ندعوه في هذه الحالة البيكسل الممزوج [23].

نعرف التصنيف بأنه جعل كل العناصر التي لها استجابة متشابهة للأطوال الموجية المختلفة ضمن مجموعة واحدة أي جعل جميع البيكسلات التي لها أعداد رقمية متقاربة ضمن صنف واحد وبالتالي فإن التصنيف الآلي يعتمد على العدد الرقمي في عملية التصنيف كما يبين الشكل (1):



الشكل 1: يوضح آلية التصنيف اعتماداً على قيمة الأعداد الرقمية [23]

ويقصد بالتصنيف النوعي تمييز العناصر الموجودة في الصورة وتحديد نوع كل منها أما التصنيف الكمي فهو تحديد نسبة هذه العناصر.

تم تطبيق التصنيف في هذا البحث على مكعب طيفي يمثل صورة جوية مؤلف من 225 حزمة من خلال تطبيق خوارزميات التحليل الطيفي وهي خوارزمية

الاعتماد سوى على جزء صغير من المكعب الطيفي (صورتين أو ثلاث صور) [1].

وفي عام 2013 تم استخدام خوارزميات تحليل طيفي أكثر تعقيداً حيث قام Rashmi S, Addamani S, Venkat S, and Ravikiran S بالاعتماد على خوارزمية Minimum Distance to mean التي تعتمد على تحديد مراكز فئات التصنيف بعد أن يتم حساب متوسطات القيم الرقمية لكل صنف من الأصناف الناتجة عن طريق اختيار المناطق ذات الأهمية ROIs وبتحديد مركز كل فئة من فئات التصنيف تتم عملية التصنيف وفقاً للمسافة الطيفية بين مواقع وحدات الصورة ومراكز فئات التصنيف وتجب الإشارة إلى أن هذا الأسلوب قد لا يعطي نتائج تصنيف جيدة إذا كانت الفروق الطيفية بين الظواهر في الصورة قليلة كما الحال في الصور التي يكون فيها المشهد المصور قريباً من نظام التصوير [12] وهذا ما بدأ به Soo Hyun Park, Hoyoong Lee, Sang Ha Noh في عام 2014 حيث قاموا بكشف أجزاء محددة من المشهد الطيفي وذلك من خلال الاعتماد على ثلاث صور طيفية (a,b,c) يتم إخضاعها للعلاقة التالية  $(a-b)/c$  ومن ثم مقارنة النتيجة مع عتبة محددة يتم الحصول عليها من خلال أخذ المتوسط الحسابي لقيم البيكسل في الحزم الثلاث و كل قيمة أكبر من العتبة يتم اعتبارها بأنها كشف صحيح وكل قيمة أصغر من العتبة يتم اعتبارها كشف خاطئ [14].

وفي العام ذاته اعتمد كل من Wang-Hee Lee, Moon S Kim, Hoonsoo Lee, Stephen R Delwiche على خوارزمية جديدة وأكثر دقة تعتمد على حساب المقدار الإحصائي F-value وذلك لإيجاد أفضل نسبة انعكاس للأطوال الموجية من أجل كشف مناطق محددة في المشهد، حيث يتم حساب F-value من العلاقة:

$$F \text{ value} = \frac{\text{variance of the group means (Mean Square Between)}}{\text{mean of the within group variances (Mean Squared Error)}}$$

ومن ثم إيجاد التردد المناسب مع قيمة f-value وبالتالي تحديد الطول الموجي المناسب الذي يتم عنده تمييز العنصر المطلوب [18].

وفي دراسة أخرى ابتكر Madhura M, and Venkatachalam S عام 2015 خوارزمية تعتمد على تحديد المدى الطيفي لفئات التصنيف في الصورة، حيث يتم تحديد أعلى وأدنى قيمة رقمية لكل صنف من الأصناف المستخدمة في المناطق ذات الأهمية وبالتالي يمكن رسم حدود كل فئة من فئات التصنيف حسب موقعها على الرسم البياني كصندوق box يحيط بالقيم الرقمية فيها وعليه فإن كل خلية صورة تقع داخل صندوق فئة معينة تصنف من هذه الفئة و كل خلية صورة تقع خارج صناديق فئات التصنيف تصنف على أنها مجهولة (غير معروفة) ولا تنتمي للظواهر الجغرافية التي تمثلها ROI وتتم مقارنة قيمة وحدات الصورة مع الحددين الأعلى والأدنى لكل صنف حيث يتم تحديد القيم العليا عن طريق جمع المتوسط الحسابي للأعداد الرقمية مع ضعفي الانحراف المعياري للبيانات المتقاربة في العدد الرقمي أما تحديد القيمة الدنيا فيتم عن طريق طرح ضعفي الانحراف المعياري من المتوسط الحسابي للبيانات. وبالتالي فإن قيمة وحدات الصورة التي تقع بين هاتين العتبتين سيتم تخصيصها لهذا الصنف ولكن لوحظ في بعض الحالات وجود تداخل بين فئات التصنيف [9].

حاول Raval U, Chaita Jani في عام 2016 إيجاد خوارزمية تصنيف أكثر دقة تدعى خوارزمية K-means والتي تعتمد على اختيار عدد من العناصر كمراكز لعناقيد أولية ثم يتم حساب المسافة بين كل مركز والعناصر الأخرى ليتم تخصيص هذه العناصر للعناقيد الأقرب بناء على قيمة مسافة مرجعية وستنكرر هذه العملية إلى أن تصبح المسافة أقل من قيمة العتبة عندئذ تنتهي عملية التصنيف.

يتم الاعتماد على مجموعة من الخوارزميات لقياس المسافات بين العناصر ومن أهمها Euclidean distance الموضحة وفق المعادلة (1):

التسبب بالاعتماد على قياس الزاوية الطيفية، خوارزمية فك المزج الطيفي غير الخطي بهدف تصنيف العناصر النقية المذكورة وحساب نسبة كل منها في الصورة.

ساهم البحث في تحسين تقنية تحليل وتصنيف الصور الجوية نتيجة وجود النقاط التالية:

- اعتماد البحث على نظام التصوير الطيفي القادر على دراسة استجابة المشاهد المصورة للشعاع الوارد عند كل طول موجة بشكل منفصل ونتيجة لذلك يمكن تحليل خصائصها الضوئية (الانعكاس والتشتت والامتصاص...) التي تميز كل عنصر عن العناصر الأخرى وهذا ما يجعلها تتفوق على نظم التصوير العادية (RGB).
- قدم نتائج ممتازة من حيث دقة التصنيف مقارنة بخوارزميات التصنيف الطيفي التقليدية التي تعتمد في عملها فقط على قيمة العدد الرقمي للبيكسل دون دراسة الخصائص الضوئية لمكونات المشهد المصور.
- نتيجة لاستخدام خوارزمية فك المزج غير الخطي عالج البحث الأخطاء الناتجة عن خوارزمية التحليل الطيفي الأخرى التي تتعامل مع ظاهرة الانعكاس (انعكاس وحيد ومباشر أو غير مباشر) عن كل عنصر دون أن تأخذ بعين الاعتبار ظاهرة التشتت الداخلي والامتصاص التي يمكن أن تحدث أثناء عملية انتشار الضوء في العينة وبالنتيجة ساهمت الخوارزمية في تحديد مكونات كل بيكسل بشكل دقيق و تحسين دقة التصنيف بشكل واضح.
- بالإضافة إلى ذلك تتميز خوارزمية فك المزج غير الخطي التي اعتمدها البحث بقدرتها على تصنيف الصور الطيفية دون وجود معلومات مسبقة عن المشهد المصور فهي لا تحتاج في عملها تحديد نقاط ذات أهمية (Region Of Interest) وبالتالي فهي تعرف على أنها Unsupervised Classification Algorithms على عكس خوارزميات التصنيف الطيفي التقليدية والخوارزميات المعتمدة على الشبكات العصبونية التي تعتمد على نقاط وأشعة مرجعية قائمة على وجود معلومات مسبقة عن المشهد ونتيجة لذلك فهي توصف بأنها supervised Classification Algorithms.
- اعتمد البحث على برنامج حديث ومتخصص في معالجة الصورة (ENVI5.0) قادر على تنفيذ الخوارزميات المدروسة بسرعة ودقة وكفاءة أفضل.

## 2. الدراسات السابقة:

بدأ الباحثون في السنوات القليلة الماضية بدراسة التصوير الطيفي واستخدموا مجموعة من الخوارزميات والطرق لتحليل الصور الناتجة والتعرف على مكوناتها ونقدم فيما يلي مجموعة من الدراسات المرجعية في هذا المجال:

بدأ كل من Villa A, Chanussot J, Benediktsson J, and Jutten C عام 2011 بالكشف الطيفي اعتماداً على خوارزمية Threshold function development والتي تعتمد على إيجاد معادلة مستقيم محدد بنقطتين هما مركز العناقيد التابعة لمنطقتين مختلفتين بالاعتماد على طولين موجيين حيث يفصل المستقيم بين العينات المعبرة عن المنطقتين المختلفتين [17] وتابع Arngren, Morten; Larsen, Jan Larsen, Rasmus, العام ذاته دراسة التصوير الطيفي من خلال خوارزمية نسب الحزم band ratio والتي تعتمد بشكل أساسي على حساب نسبة الانعكاس للبيكسل محدد عند طولين موجيين حيث أن  $\text{band ratio} = \frac{\text{نسبة الانعكاس عند الطول الموجي الأول}}{\text{نسبة الانعكاس عند الطول الموجي الثاني}}$  ويتم تحديد التباين بين المناطق المدروسة من خلال عتبات يتم تحديدها من خلال المتوسط الحسابي لبيكسلات كل منطقة من المناطق المدروسة وفي كلا الحالتين لم يتم

تتميز هذه الخوارزمية عن خوارزمية التحليل الخطي بأنها تتعامل مع الانعكاس المباشر وغير المباشر [15]

وبالإضافة إلى ذلك قام كل من Jie Chen ,Longbin Yan ,Min Zhao في عام 2021 بدراسة التصنيف الطيفي اعتماداً على الشبكات العصبونية كأدوات تصنيف حيث تم الاعتماد على خوارزمية Long short-term memory network(LSTM) والتي تتميز بوجود تغذية عكسية على عكس الشبكات العصبونية ذات التغذية الأمامية وتتكون وحدة LSTM من Cell,input gate, outputgate, forget gate تقوم الخلية بتخزين قيم البيانات بينما تقوم البوابات الثلاث بتنظيم دخول وخروج المعلومات من الخلية cell.

تحتاج الخوارزميات المعتمدة على الشبكات العصبونية وجود معلومات مسبقة عن المشاهد المصورة لذلك تصنف على أنها supervised classification [22].

الجدول 1: الخوارزميات التي تم استخدامها:

| توصيف الخوارزمية                                       | منهجية الخوارزمية  | اسم الخوارزمية                     |
|--|--|------------------------------------|
| تمييز كل نوع من العناصر التي تحويها الصورة بشكل منفصل  | تعتمد على إيجاد معادلة مستقيم محدد بنقطتين هما مركز العناقيد التابعة لمنطقتين مختلفتين بالاعتماد على طولين موجيين فقط  | Threshold function development     |
| تمييز نوع واحد من العناصر التي تحويها الصورة           | يتم حساب (نسبة الانعكاس عند الطول الموجي الأول / نسبة الانعكاس عند الطول الموجي الثاني) ويتم تحديد التباين بين المناطق المدروسة من خلال عتبات يتم تحديدها من خلال المتوسط الحسابي لبيكسلات كل منطقة من المناطق | band ratio algorithm               |
| تمييز عنصر مدروس واحد من عناصر الصورة وحساب نسبته فيها | إيجاد نسبة الحزم التي تملك أعلى قيمة F-value التي تعطي بالعلاقة:<br><br>F value = variance of the group means (Mean Square Between) / mean of the within group variances (Mean Squared Error)                  | Endmember extraction F-value using |

$$d = \sqrt{\sum_{j=1}^k \sum_{i=c_j} (x_i - z_j)^2} \dots (1)$$

حيث أن  $C_j$  هو العنقود رقم  $j$  و  $Z_j$  هو مركز العنقود  $C_j$  أما  $X_i$  فهو الدخل [13].

مما سبق نستنتج أن معظم الدراسات المذكورة تعتمد على استخدام جزء من الطيف وتهدف في النهاية إلى التمييز بين منطقتين من المشهد المصور لذلك بدأت الدراسات الحديثة باستخدام خوارزميات تعمل على استخدام كامل الطيف بهدف تحسين دقة التصنيف وكشف عدد أكبر من العناصر النقية ويأتي في مقدمتها خوارزمية التحليل الطيفي الخطي Linear unmixing التي درسها الباحثون Athanasia maria tompolidi, Olga sykioti, Olga sykioti, and Issak Parcharidis في عام 2020 وهي تدرس استجابة المشاهد المصورة للشعاع الوارد وفق العلاقة (2):

$$y_i = \sum_{j=1}^p p_{ij} a_i + W \dots (2)$$

حيث أن  $P_{ij}$  تعبر عن طيف العنصر النقي  $j$  في الحزمة الطيفية  $i$ ,  $z_j$  هي مساهمة العنصر النقي  $j$  في الطيف الكلي.

$P$ : يمثل العناصر النقية (endmember),  $W$  هو الخطأ الناتج عن الضجيج المضاف بما يتضمن ضجيج المستشعر [2].

كما عمل كل من Antonio Plaza and Javier Plaza بدراسة فك المزج الطيفي الخطي لصور طيفية جوية وتوصلا إلى النتائج التالية:

بلغ الخطأ بين نسبة مساهمة العناصر النقية الحقيقية والمقاسة 11.9% بالنسبة للتربة , 15.3% بالنسبة للأعشاب, 16.9% بالنسبة للأشجار.

تكمن المشكلة الأكبر في خوارزمية التحليل الخطي بأنها تفترض وجود انعكاس وحيد عن كل عنصر دون أخذ الانعكاس غير المباشر والإمتصاص و التشتت بعين الاعتبار ويقصد بغير المباشر أي الانعكاس الناتج عن عنصرين.

وبهدف التخفيف من تأثير الاخطية واعتماد نموذج التوزيع الطبيعي لتخفيف أثر التغير المستمر للعناصر النقية قام الباحثون Yaunchao Su, Hairong Qi, Paulo Gamba, Hairong Qi, Xiang Xu, Jun Li, Antonio plaza عام 2020 بدراسة (BNMM) Bilinear Mixing Model والتي تعطي بالعلاقة (3):

$$Y = EA + DB + N \dots (3)$$

حيث أن:

$y = [y_1 \dots \dots \dots y_n]$  هي مصفوفة الصور الطيفية المؤلفة من  $n$  بيكسل ,  $E = [e_1 \dots \dots \dots e_c]$  هي مصفوفة العناصر النقية التي عددها  $C$ .

$A = [a_1 \dots \dots \dots a_n]$  هي مصفوفة المساهمة للعناصر النقية.

$$D = [d_1 \dots \dots \dots d_l] , B = [b_1 \dots \dots \dots b_l]$$

$D$  هي مصفوفة العناصر النقية الافتراضية و  $B$  هي مصفوفة الارتباط بين مصفوفات المساهمات.

$N$ : هي مصفوفة الضجيج.

|                                      |   |
|--------------------------------------|---|
| تعتمد على معرفة مسبقة للمشاهد المصور | بها ويعتبر الصنف الذي يحقق القيمة العظمى في وحدة الخرج هو الصنف الذي تنتمي إليه القيمة المطبقة في الدخل |
|--------------------------------------|---|

### 3. منهجية البحث

تم تطبيق خوارزميات البحث على مكعب طيفي لصورة جوية وتم ذلك بالاعتماد على إدخال التعليمات البرمجية الخاصة بخوارزميات التنسيب بالاعتماد على قياس الزاوية الطيفية وخوارزمية فك المزج الطيفي غير الخطي إلى برنامج متخصص في معالجة الصور الطيفية (ENVI 5.0) ليتم إظهار النتائج على شكل صور مصنفة.

#### 3.1 التصنيف بالاعتماد على قياس الزاوية الطيفية Spectral Angle Mapper (SAM):

في هذه الخوارزمية يتم تمثيل كل طيف من خلال أشعة طيفية تنتج عن أخذ قيمة البيكسل في كل حزمة فنحصل على شعاع يعبر عن البيكسل والهدف من ذلك هو تحديد قياس الزاوية الطيفية التي تفصل بين هذه الأشعة فكما كانت هذه الزاوية صغيرة فهذا يشير إلى أن الطيفين أكثر تشابهاً وكما زاد قياس الزاوية الطيفية كلما زاد مقدار الاختلاف بين الأطياف .


يتم اختيار شعاع مرجعي اعتماداً على وجود معلومات مسبقة عن المشاهد المصور حيث يتم اختيار نقاط ذات أهمية (ROI) تعبر عن كل عنصر نقي معرف من قبل المستخدم ويمثل كل فئة تصنيف بهدف مقارنته مع الأشعة الناتجة عن بيكسلات الصورة ويتم تنسيب البيكسلات إلى الفئات ذات الشعاع المرجعي الذي يصنع أقل زاوية طيفية مع شعاعها.

وتعطى الزاوية الطيفية بالمعادلة (4):

$$a = \cos^{-1} \left[ \frac{\sum_{i=1}^{nb} t_i r_i}{\sqrt{\sum_{i=1}^{nb} t_i^2} * \sqrt{\sum_{i=1}^{nb} r_i^2}} \right] \dots (4)$$

حيث: a هي الزاوية الطيفية, nb هي عدد الحزم,  $t_i$  تمثل طيف البيكسل المدروس,  $r_i$  تمثل البيكسل المرجعي [12].


الشكل (20) يمثل الزاوية الطيفية بين شعاع بيكسل مرجعي يمثل عنصر معين (التربة مثلاً) وشعاع يمثل بيكسل من بيكسلات الصورة.



الشكل 2: الزاوية الطيفية بين شعاعين [20]


يبين الشكل التالي المخطط الصندوقي لخوارزمية SAM:

|  |   |                                      |
|--|---|--------------------------------------|
| تتميز أكثر من عنصر موجود في الصورة اعتماداً على وجود مناطق ذات أهمية ولكن هذه الخوارزمية قد لا تعطي نتائج تصنيف جيدة إذا كانت الفروق الطيفية بين الظواهر في الصورة قليلة             | يعتمد أسلوب هذا النوع من التصنيف على تحديد مراكز فئات التصنيف تتم عملية التصنيف وفقاً للمسافة الطيفية بين مواقع وحدات الصورة ومراكز فئات التصنيف  | Minimum Distance to mean             |
| تعتبر هذه الخوارزمية قادرة على تمييز مجموعة من العناصر التي تحويها الصورة اعتماداً على وجود مناطق ذات أهمية ولكن مع دقة تصنيف غير كافية بسبب وجود عدد كبير من البيكسلات غير المصنفة. | تعتمد على تحديد المدى الطيفي لفئات التصنيف في الصورة، حيث يتم تحديد أعلى وأدنى قيمة رقمية لكل صنف من الأصناف المستخدمة وبالتالي فإن كل خلية صورة تقع داخل صندوق فئة معينة تصنف من هذه الفئة و كل خلية صورة تقع خارج صناديق فئات التصنيف تصنف على أنها مجهولة (غير معروفة) | parallepiped classification          |
| تتميز هذه الخوارزمية بالمرونة من خلال تحديد عدد الأصناف المدروسة دون الحاجة لوجود مناطق ذات أهمية لكنها لات تهتم بالتركيب الداخلي لبيكسلات لمكونات الصورة                            | تعتمد على اختيار عدد من العناصر كمراكز لعناقيد أولية ثم يتم حساب المسافة بين كل مركز والعناصر الأخرى ليتم تخصيص هذه العناصر للعناقيد الأقرب بناء على قيمة مسافة مرجعية  | K-means                              |
| تفترض الخوارزمية وجود شعاع منعكس واحد فقط عن كل عنصر يدخل في تركيب البيكسل وبالتالي فهي تهتم بالانعكاس الخطي فقط   | تعتمد على دراسة تفاعل الشعاع الضوئي مع التركيب الداخلي لمكونات المشاهد المصور   | Spectral linear unmixing             |
| تتعامل مع الانعكاس المباشر والانعكاس الناتج عن أكثر من عنصر  | تعتمد على دراسة تفاعل الشعاع الضوئي مع التركيب الداخلي لمكونات المشاهد المصور   | Bilinear spectral unmixing           |
| تعتبر من نوع supervised classification لأنها تحتاج إلى تطبيق قيم مرجعية  | تتميز بأن الطبقات المخفية تقسم إلى أصناف بحيث تملك كل وحدة مخفية تابعاً غوصياً خاصاً  | Long short-term memory network(LSTM) |



الشكل 4: نموذج المزج الخطي [2]

ويبين الشكل (5) مشهداً يحوي مجموعة من الأشجار مع تربة والأعشاب مع الأطياف النقية الخاصة بها:



الشكل 5: أطيف نقية لمشهد يمثل اشجار مع تربة وأعشاب [11]

وتعطي معادلة فك المزج الخطي بالعلاقة التالية:

$$Y = \sum_{m=1}^M a_m * s_m + W \dots (5)$$

M: هو العدد الكلي للعناصر النقية.

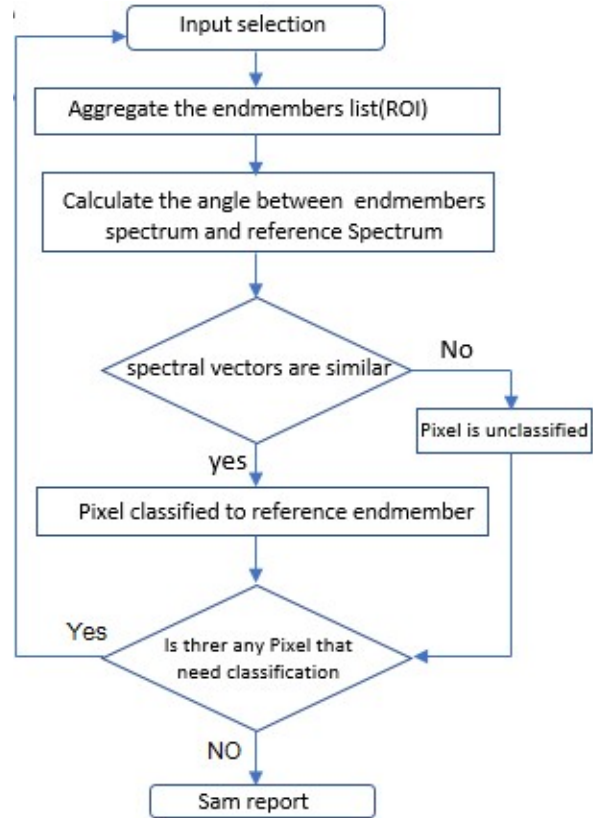
am: هي مساهمة العنصر m في البيكسل والذي يخضع لانعكاس وحيد مباشر.

Sm: هو الطيف الخاص بالعنصر m.

W: شعاع الضجيج.

من جهة أخرى تتعامل خوارزمية فك المزج غير الخطي مع النماذج الأكثر تعقيداً وذلك عندما لا تكون المواد الداخلة في تركيب السطح موزعة بشكل منتظم إنما تكون موزعة بشكل عشوائي وبناءً على ذلك فإن الإشعاع الساقط سينعكس عن عناصر متعددة وبالتالي فإن الطيف الناتج لن يملك علاقات خطية بين المواد المساهمة في تركيبه [10].

بالإضافة إلى ذلك فإنه بالإمكان أن يكون لدينا عدة أشكال للنموذج غير الخطي منها عندما يكون الخليط متماسكاً وبالتالي فإن العناصر المختلفة تكون قريبة من بعضها إلى حد كبير جداً ويكون الطيف الناتج في هذه الحالة متعلقاً بكثافة المواد من جهة وبارامترات الوسط من جهة أخرى وبالإضافة إلى ذلك يتم الحصول على النموذج غير الخطي عندما يكون الوسط مكوناً من عدة طبقات عندئذ سيكون لدينا تداخلات متعددة بين الأشعة المنعكسة عن الطبقات المختلفة.



الشكل 3: مخطط خوارزمية SAM [8]

من أهم ميزات هذه الخوارزمية هي السرعة والبساطة ولكن مشكلتها تكمن في أن جميع وحدات الصورة تتم مقارنتها مع شعاع مرجعي واحد لكل صنف وهذا ما يقيد عملية التصنيف [5].

### 3.2 خوارزمية فك المزج غير الخطي Non linear Spectral unmixing :

من الممكن أن تكون وحدة الصورة عبارة عن مزيج من المواد والعناصر النقية endmembers وتدعى في هذه الحالة وحدة الصورة الممزوجة mixed pixel حيث يساهم كل عنصر من العناصر بنسبة محددة في تكوين mixed pixel.

تم في هذا البحث دراسة آلية عمل خوارزمية فك المزج الطيفي spectral unmixing والتي تمكننا من خلالها من تحليل مكونات mixed pixel وبالتالي إمكانية تمييز محتويات الصور وتصنيفها وحساب نسبتها بشكل ممتاز.

تفترض خوارزمية فك المزج الخطي وجود انعكاس وحيد ومباشر عن كل عنصر نقي وتقوم بحساب مساهمة هذا العنصر في البيكسل الكلي (الممزوج)

وذلك بعد معرفة الطيف النقي الخاص به ويقصد بالطيف النقي أي معرفة قيمة البيكسل لهذا العنصر عند كل طول موجة من خلال اختيار مناطق ذات أهمية في حال توفر معلومات مسبقة عن المشهد المصور أو من خلال استخدام خوارزميات لتحديد عناصر نقية ابتدائية مثل خوارزمية Pixel Purity Index.

يوضح الشكل التالي نموذج المزج الخطي:

Y: هو الطيف الكلي للبيكسل الممزوج الذي يمثل قيمة هذا البيكسل عند كل طول موجي [19]

حساب البارامترات:

أولاً: معامل الامتصاص:

يتفاعل الشعاع الضوئي الوارد المتمثل بالأطوال الموجية مع العينات المدروسة حسب البنية الفيزيائية حيث أن كل عينة تستجيب لكل طول موجي بشكل مختلف عن بقية الأطوال الموجية مما يجعل كل مادة تتميز عن بقية المواد بمعامل امتصاص ومعامل تشتت خاص بها يتم معرفته من خلال أسقاط الأطوال الموجية عليها وقياس الضوء النافذ باستخدام مستشعرات خاصة وفق قانون بيرز لامبيرت، المعادلة (8):


$$I = I_n * e^{(-A\lambda D)} \dots (8)$$

حيث أن D: هو مسافة النفاذية من المادة، Aλ: معامل الامتصاص، I: شدة الضوء النافذ، I<sub>n</sub>: شدة الضوء الساقط [6].

وبالتالي يمكننا معرفة Aλ وفق المعادلة (9):

$$A = \sum_0^{\lambda} A\lambda \dots (9)$$

فيما يلي مثال لمعامل الامتصاص الخاص بالماء الممزوج بالتربة والذي يأخذ قيم مختلفة عند كل طول موجي:



الشكل 7: معامل الامتصاص المميز للماء الممزوج بالتربة [7]

ثانياً : حساب طيف العنصر النقي m:


لحساب معامل albedo المذكور في المعادلة (5) لابد من معرفة الطيف النقي الخاص بكل عنصر نقي ويتم ذلك بالاعتماد على خوارزمية Pixel purity index وفق ما يلي :

تستخدم هذه الخوارزمية بالاعتماد على مؤشر لإيجاد السمة الطيفية

السائدة في البيكسل في الصور المتعددة الاطيف ويتم إيجاد المؤشر من خلال إسقاط الأشعة بشكل متكرر (N تكرار) في فراغ ذي (N بعد) على شعاع عشوائي أولي يعبر عن بكسلات الصورة الأكثر نقاءً في المشهد ليتم بعد ذلك تسجيل بيكسلات الصورة الصافية في كل إسقاط وهي التي تقع عند نهايات الشعاع ومن ثم يتم تسجيل عدد التكرارات وتكون قيمة البيكسل هي عدد التكرارات التي تكون فيها وحدة الصورة صافية.

تعتبر العلاقة (10) عن الية عمل خوارزمية PPI:

$$Is(R) = \begin{cases} 1 & \text{if } r \in S \\ 0 & \text{otherwise} \end{cases} \dots (10)$$



الشكل 6: أشكال المزج غير الخطي [18]

الصورة (A) السطح مكون من مجموعة من المواد المختلفة وبالتالي فإن الشعاع الضوئي الساقط سيملك انعكاس وحيد عن كل مادة من المواد السابقة، هذا سيقود إلى المزج الخطي عندما يتم استقبال الأشعة المنعكسة من قبل الحساس.

الصورة (B): يحوي هذا المشهد على مواد ذات ظلال وبالتالي سيتفاعل الضوء الساقط مع مجموعة من المواد المختلفة المتداخلة غير المتجانسة وهذا ما سيسبب المزج غير الخطي إلى جانب المزج الخطي .

تم في هذا البحث تطبيق خوارزمية فك المزج غير الخطي على مكعب طيفي لصور جوية وتعتبر نموذجاً متطوراً عن خوارزمية فك المزج الخطي التي تفترض وجود انعكاس خطي وحيد عن العينة المدروسة مما يؤثر بشكل مباشر على دقة التصنيف بينما تدرس خوارزمية فك المزج غير الخطي معاملات الامتصاص والتشتت الداخلي التي تتغير بتغير الطول الموجي الوارد وتعتمد عليها في تحديد نسبة مساهمة كل عنصر نقي في تشكيل البيكسل الممزوج.

تعتمد خوارزمية فك المزج الطيفي بشكل أساسي على معامل albedo الذي نعرفه كما يلي:

هو مقياس الانعكاس المنتشر للإشعاع من إجمالي الإشعاع الوارد ويتم قياسه على مقياس من 0 يتوافق مع الجسم الأسود الذي يمتص كل الإشعاع الساقط إلى 1 المقابل للجسم الذي يعكس كل الإشعاع الساقط بمعنى آخر يمكن وصف معامل Albedo بأنه قدرة جسم ما على عكس الضوء الساقط عليه من مصدر ضوئي وهو مصطلح أكثر خاصية من الانعكاسية.

لكل طول موجي معامل Albedo خاص به موافق لمعامل الامتصاص والطيف النقي الخاص بكل عنصر.

يعطى Albedo البيكسل النقي بالمعادلة (6):

$$\rho(\lambda) = 1 - \left[ \frac{\sqrt{m^2(A + A_0)^2 + (1 + 4A_\lambda A_0 m(1 - m))} - m(A_\lambda + A_0)}{1 + 4A_\lambda A_0 m} \right]^2$$

Aλ: معامل الامتصاص عند الطول الموجي، A0: معامل الامتصاص عند اللون الأبيض،

m: هو الطيف عنصر نقي [19]

ويكون Albedo للبيكسل الممزوج بالمعادلة (7):

$$\rho(\lambda)_{mix} = 1 - \left[ \frac{\sqrt{Y^2(A + A_0)^2 + (1 + 4A_\lambda A_0 Y(1 - Y))} - Y(A_\lambda + A_0)}{1 + 4A_\lambda A_0 Y} \right]^2$$

am: هي مساهمة العنصر m في البيكسل والذي يخضع لانعكاس وحيد مباشر.


Sm: هو الطيف الخاص بالعنصر m.

Sk: هو الطيف الخاص بالعنصر k.

bmk: هو المساهمة الناتجة عن الانعكاس المزدوج للعنصرين m,k.

⊗: هو الجداء الخارجي [19].

يعبر الشكل التالي عن الجداء الخارجي للأشعة المعبرة عن العناصر النقية:




الشكل 9: الجداء الخارجي للأشعة المعبرة عن العناصر النقية [21]

وبنتيجة معادلة فك المزج غير الخطي استطعنا معرفة مساهمة كل عنصر نقي في الطيف الكلي وبالتالي إمكانية معرفة نسبته في الصورة.

حيث  $Is(R)$  هو تابع يعبر عنه بالقيمة 1 إذا وقع البيكسل في نهاية أحد الأشعة (skewer) وبالقيمة 0 إذا لم يقع [3].

نعرف أيضاً القيمة  $N_{ppi}(R)$  التي تعبر عن عدد المرات التي يقع فيها البيكسل على نهاية أحد هذه الأشعة (المسقط العمودي للبيكسلات البعيدة التي تقع في نهاية الأشعة) وبالتالي فإن البيكسلات التي تملك أكبر قيمة  $N_{ppi}$  سيتم تصنيفها على أنها البيكسلات الأكثر نقاء.

ويمكننا تفعيل عتبة  $t$  وإعطاؤها القيمة 1 و كل بيكسل يملك قيمة  $N_{ppi}$  أكبر من  $t$  سيتم تصنيفه على أنه عنصر نقي.



الشكل 8: آلية عمل خوارزمية PPI [3]

من الرسم نلاحظ ما يلي :

$e1$  تعامد امتداد الشعاع الثالث فقط وبالتالي  $N_{ppi}(e1)=1$ .

$e2$  تعامد امتداد الشعاع الأول والثاني وبالتالي  $N_{ppi}(e2)=2$ .

$e3$  تعامد امتدادات الأشعة كلها وبالتالي  $N_{ppi}(e3)=3$ .

أما بقية البيكسلات في الصورة فهي لاتعتمد أي محور من المحاور السابقة المذكورة.

وبالتالي فإنه بنتيجة هذه الخوارزمية يتم تحديد العناصر النقية وبالتالي معرفة العدد الرقمي الذي يمثلها في كل حزمة وبالننتيجة معرفة الطيف  $m$  الخاص بها.

ثالثاً: حساب نسبة مساهمة العناصر النقية fractional abundance:

بعد حساب قيمة albedo نستخدمه في المعادلة التالية لحساب مساهمة كل عنصر نقي  $am$  من العناصر النقية في الطيف الكلي وفق المعادلة (11)

$$\alpha(\lambda)_{mix} = \sum_{m=1}^M a_m * \alpha(\lambda)_m \dots (11)$$

$\alpha(\lambda)_{mix}$ : هي قيمة albedo للطيف الكلي.


$\alpha(\lambda)_m$ : هي قيمة albedo لطيف بيكسل واحد [19].

بعد حساب  $am$  نعوضها في المعادلة (12) من أجل حساب  $bmk$  وهي معادلة النموذج غير الخطي :

$$Y = \sum_{m=1}^M a_m * s_m + \sum_{m=1}^M \sum_{k=1}^M b_{mk} * s_m \otimes s_k \dots (12)$$

حيث أن :

$M$ : هو العدد الكلي للعناصر النقية.




الشكل 11: عينات المكعب الطيفي لصورة جوية

حيث ميزنا الطرقات باللون الأخضر والكتل الصخرية باللون الأزرق والمناطق المعبرة عن وجود والمسطح المائي باللون الأحمر.

#### 4.1 تطبيق خوارزمية spectral angle mapper (SAM):

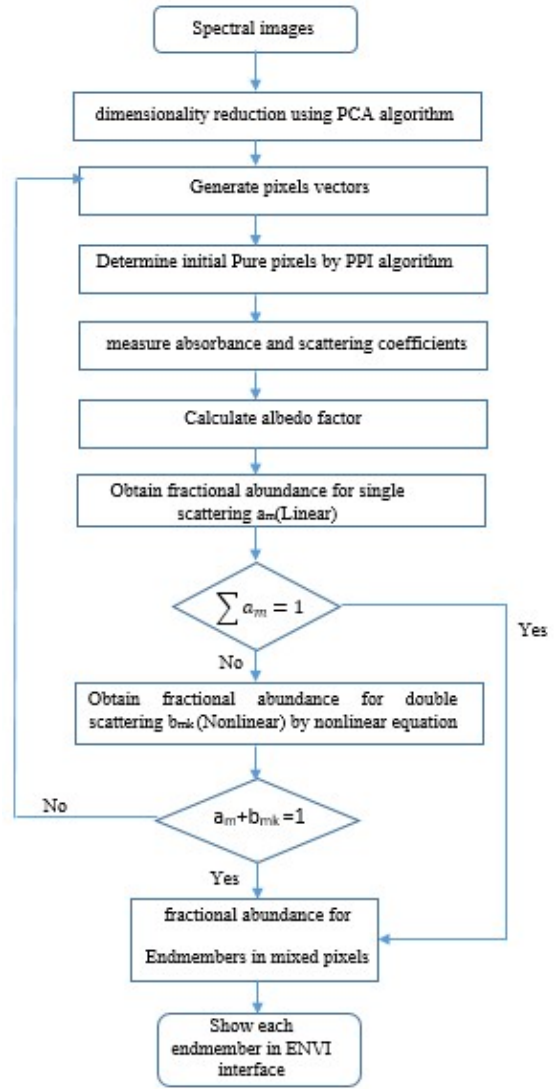
تم القيام بدراسة تغير الزاوية الطيفية وتأثيره على دقة التصنيف لذلك ناقشنا الحالات التالية:

##### 4.1.1 من أجل زاوية 0.03 راديان:



الشكل 12: يبين نتيجة التصنيف باستخدام زاوية 0.03 راديان

نلاحظ أن أغلب عناصر المشهد لم يتم تصنيفها حيث بلغت نسبة العناصر غير المصنفة 90.32% ويقصد بالعناصر غير المصنفة بأنها البيكسلات التي تظهر باللون الأسود والتي عجزت الخوارزمية عن ضمها لتصنيفها المناسب.



الشكل 10: مخطط خوارزمية فك المزج غير الخطي

#### 4. النتائج والمناقشة:


قمنا باختيار مكعب طيفي تم التقاط حزمه من الأقمار الصناعية وعددها (225 bands) مع العلم أن الصورة الفوتوغرافية للمشهد ذات الأبعاد (512×614) أي (314368) بيكسل حيث يحوي المشهد على

مسطح مائي ونسبته (1.7%) من الصورة وفي الجانب الأيمن من الصورة تظهر طرق وأبنية المدينة ونسبتها (14.66%) من الصورة أما في القسم الأيسر نشاهد كتل صخرية ونسبتها (6.16%).

فيما يلي نبين بعض أجزاء المكعب الطيفي الموافق لهذا المشهد:




4.1.2 من أجل زاوية 0.05 راديان:



الشكل 13: يبين نتيجة التصنيف باستخدام زاوية 0.05 راديان

نلاحظ وجود نسبة كبيرة من العناصر غير المصنفة من أجل هذه الزاوية حيث تبلغ نسبة هذه العناصر 63.97% من عدد بيكسلات الصورة وهي نسبة كبيرة تعبر عن عدم كفاءة الخوارزمية عند هذه الزاوية.


4.1.3 من أجل زاوية 0.1 راديان:



الشكل 14: نتيجة التصنيف باستخدام زاوية 0.1 راديان

نلاحظ أنه لا تزال هناك نسبة كبيرة من المناطق غير المصنفة والتي تبلغ نسبتها 20.85% من الصورة وبالتالي سنلجأ إلى زيادة الزاوية الطيفية.


4.1.4 من أجل زاوية 0.15 راديان:



الشكل 15: يبين نتيجة التصنيف باستخدام زاوية 0.15 راديان

نلاحظ انخفاض عدد المناطق غير المصنفة بشكل ملحوظ حيث أصبحت نسبتها 8.01% من الصورة.

4.1.5 من أجل زاوية 0.2 راديان:



الشكل 16: يبين نتيجة التصنيف باستخدام زاوية 0.2 راديان

نلاحظ من الصورة أننا تمكنا من تصنيف جميع بيكسلات الصورة لتصبح نسبة العناصر غير المصنفة معدومة.


الجدول 2: يبين نسبة المناطق غير المصنفة من أجل القيم المختلفة للزاوية الطيفية:

| الزاوية الطيفية | نسبة المناطق غير المصنفة |
|-----------------|--------------------------|
| 0.03 راديان     | 90.32%                   |
| 0.05 راديان     | 63.97%                   |
| 0.1 راديان      | 20.85%                   |
| 0.15 راديان     | 8.01%                    |



الشكل 18: يبين الانعكاس الناتج عن البحيرة

يمثل لنا الشكل السابق نتيجة خوارزمية فك المزج عند القناة اللونية الأولى التي تمثل الانعكاس الناتج عن المسطحات المائية والتي يكون الانعكاس عندها اعظماً




الشكل 19: يبين الانعكاس الناتج عن الطرقات والشوارع

يمثل لنا الشكل السابق نتيجة خوارزمية فك المزج عند القناة اللونية الثانية الممثلة للعنصر النقي الخاص بالطرقات.

|    |            |
|----|------------|
| %0 | 0.2 راديان |
|----|------------|

يبين الشكل العلاقة بين الزاوية الطيفية ونسبة وحدات الصورة غير المصنفة باستخدام SAM:



الشكل 17: يبين علاقة الزاوية الطيفية بعدد العناصر غير المصنفة

نلاحظ انخفاض نسبة العناصر غير المصنفة مع زيادة قيمة الزاوية الطيفية.

الجدول 3: يبين نسبة العناصر المصنفة باستخدام خوارزمية SAM:

| العنصر        | النسبة الصحيحة | نسبة وحدات الصورة بعد استخدام SAM (0.2 راديان) |
|---------------|----------------|--|
| الكتل الصخرية | %6.16          | %7.57  |
| المسطح المائي | %1.7           | %1.87  |
| طرقات المدينة | %14.66         | %14.10   |

#### 4.2 تطبيق خوارزمية non-linear spectral unmixing

أما بتطبيق non Linear unmixing على المكعب الطيفي المذكور فنحصل على النتائج التالية التي تبين لنا الانعكاس الناتج عن كل عنصر من عناصر الصورة على حدى ليظهر هذا العنصر بشكل أكثر لمعناً.



الشكل 22: تمييز الطرقات

حيث أن اللون الأبيض هو الذي يمثل الطرقات في المشهد واللون الأسود يمثل باقي عناصر الصورة وتكون عدد وحدات الصورة الممثلة للون الأبيض 46683 أي 14.85% من عدد البيكسلات الكلي. أما عدد وحدات الصورة للون الأسود هو 267684 أي 85.15% من عدد البيكسلات الكلي وبالتالي فإن نسبة الطرق في الصورة هي 14.85%، وبالطريقة ذاتها يمكننا حساب نسبة البحيرة والكتل الصخرية.

الجدول 4: يبين نسبة العناصر المصنفة باستخدام non linear spectral unmixing :


| العنصر        | النسبة الصحيحة | نسبة وحدات الصورة بعد استخدام Linear unmixing |
|---------------|----------------|---|
| الكتل الصخرية | 6.16%          | 6.32%   |
| المسطح المائي | 1.7%           | 1.7%  |
| طرقات المدينة | 14.66%         | 14.85%  |

## 5. الاستنتاجات:

تزداد دقة التصنيف وتتناقص نسبة العناصر غير المصنفة مع زيادة قياس الزاوية الطيفية.

تعمل خوارزمية non Linear unmixing على مستوى كل بيكسل بشكل منفرد عندما يتكون من أكثر من عنصر وينتج عن ذلك تمييز هذه العناصر كل على حدى اعتماداً على بصمتها الطيفية مما يتيح إمكانية تصنيفها وحساب نسبتها.


وبناءً على ذلك وانطلاقاً من النتائج التي حصلنا عليها تبين لنا ان خوارزمية non Linear unmixing هي الخوارزمية الأكثر دقة.



الشكل 20: الانعكاس الناتج الكتل الصخرية

يظهر الشكل الانعكاس المميز للعنصر النقي الخاص بالكتل الصخرية.

وعند إظهار نتيجة التصنيف بصورة\* RGB نحصل على الشكل التالي:

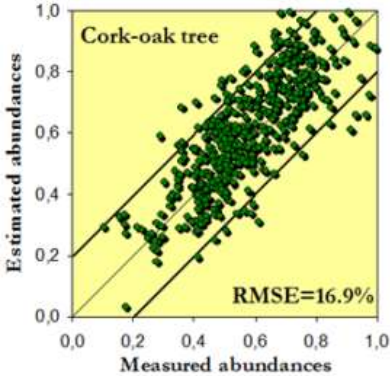
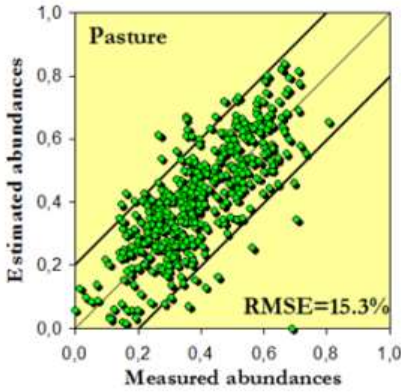
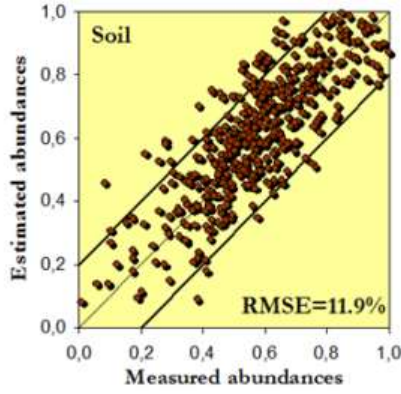


الشكل 21: يبين نتيجة تطبيق Linear unmixing بصورة RGB

نلاحظ بأن معلومات المشهد أصبحت أكثر وضوحاً من خلال هذا الخوارزمية وظهرت لدينا المشاهد ذات الطبيعة الواحدة بشكل أفضل.

بالإضافة إلى ذلك يمكننا أيضاً إنجاز تصنيف كمي لهذه المحتويات عن طريق تحديد قيمة بيكسلات الصورة التي تنتمي لصنف محدد ثم تحديد بقية البيكسلات التي تملك القيمة نفسها وذلك من خلال تطبيق خوارزمية تعريب Threshold Reflectance Graph (TRG).

على سبيل المثال قمنا بمعرفة نسبة البيكسلات الممثلة للطرق وفق مايلي:



الجدول 5: نسبة الخطأ في SAM

| العنصر        | النسبة الصحيحة | نسبة بعد SAM ( 0.2 راديان ) | نسبة الخطأ |
|---------------|----------------|-----------------------------|------------|
| الكتل الصخرية | %6.16          | %7.57                       | %22.8      |
| المسطح المائي | %1.7           | %1.87                       | %10        |
| طرق المدينة   | %14.66         | %14.10                      | %3.8       |

الجدول 6: نسبة الخطأ في non linear unmixing

| العنصر        | النسبة الصحيحة | النسبة بعد nonLinear unmixing | نسبة الخطأ |
|---------------|----------------|-------------------------------|------------|
| الكتل الصخرية | %6.16          | %6.32                         | %2.59      |
| المسطح المائي | %1.7           | %1.7                          | %0         |
| طرق المدينة   | %14.66         | %14.85                        | %1.3       |

الشكل 23: نتيجة تطبيق خوارزمية linear unmixing وفق Antonio plaza and Javier plaza [11]

## 6. الخاتمة:

تم في هذا البحث دراسة وتحليل الصور الطيفية من خلال مجموعة من خوارزميات التحليل الطيفي أهمها خوارزميات فك المزج وخوارزمية التصنيف بقياس الزاوية الطيفية وتميزت خوارزمية فك المزج غير الخطي التي اعتمدها البحث بالنقاط التالية:

أولاً: تأخذ خوارزمية فك المزج غير الخطي بعين الاعتبار عوامل الامتصاص والتشتت التي تنفرد بها كل مادة وذلك على مستوى كل بيكسل بشكل منفرد بالإضافة إلى أنها تدرس الانعكاس المباشر والانعكاس المتعدد (غير المباشر) مما يساعد ذلك بمعرفة نسبة المواد الداخلة في تركيب كل بيكسل بشكل دقيق بخلاف خوارزمية فك المزج الخطي التي تدرس الانعكاس المباشر (الخطي) فقط.

ثانياً: تميزت خوارزمية فك المزج غير الخطي عن خوارزمية التصنيف بقياس الزاوية الطيفية بأنها لا تحتاج لتوفر معلومات مسبقة عن المشهد المصور حيث أنها تعتمد على خوارزمية Pixel purity index في تحديد

ومن جهة أخرى يبين الشكل (23) نتائج خوارزمية فك المزج الخطي التي طبقها كل من Antonio Plaza, Javier Plaza على مكعب طيفي لصورة جوية والتي أظهرت نسبة خطأ 11.9% في تحديد نسبة العناصر النقية الموافقة للتربة ونسبة خطأ 15.3% للعناصر النقية الموافقة للأعشاب و نسبة خطأ 16.9% للعناصر النقية الموافقة للأعشاب [11] وبالتالي وبالمقارنة مع نتائج الجدول (6) نلاحظ التحسن الذي أظهرته خوارزمية فك المزج غير الخطي حيث أنها تميزت بنسبة خطأ أقل.

between vertex component analysis and orthogonal subspace projection for endmember extraction, Proceedings of the SPIE, Vol. 6565 1-12.

- [4] Dalla M, Chanussot J, Plaza 2014, An Overview on Hyperspectral Unmixing, International Journal of Advanced Computer Science and Applications, Vol.13,14-31.
- [5] El\_Rahman S-2016, Performance of Spectral Angle Mapper and Parallelepiped Classifiers in Agriculture Hyperspectral Image, (IJACSA) International Journal of Advanced Computer Science and Applications, Vol.7, 55-63.
- [6] Fang Q, Albdlaty R, 2016-Hyperspectral imaging and data analysis of skin erythema post radiation therapy treatment, McMaster university-biomedical engineering, Hamelton montaria, P182.
- [7] Gao C, Xu M, Xu H, Zhou W, 2021-Retrieving Photometric Properties and Soil Moisture Content of Tidal Flats Using Bidirectional Spectral Reflectance, remote sense, Vol 13, 1-20.
- [8] Gogineni R, Chaturvedi A, 2019-Hyperspectral image classification: processing and analyzing of hyperspectral data, 1-25.
- [9] Madhura M, and Venkatachalam S, 2015- Comparison of Supervised Classification Methods On Remote Sensed Satellite Data: An Application In Chennai, South India, International Journal of Science and Research, Vol. 4, 1407-1411.
- [10] Mou W, Min Z, Jie C, Susanto R, Nonlinear Unmixing of Hyperspectral Data via Deep Autoencoder Networks, 2019 - IEEE Geoscience and Remote Sensing Letters Vol. 16, 11467-1471.
- [11] Plaza A, Plaza J, Parallel Implementation of Linear and Nonlinear Spectral Unmixing of Remotely Sensed Hyperspectral Images- High-Performance Computing in Remote Sensing. Vol.8183, 1-10.
- [12] Rashmi S, Addamani S, Venkat S, and Ravikiran S-2014, Spectral Angle Mapper Algorithm for Remote Sensing Image Classification, IJSET - International Journal of Innovative Science, Engineering & Technology, Vol. 1, 201-205.
- [13] Raval U, and Jani C, 2016-Implementing & Improvisation of K-means Clustering Algorithm, International Journal of Computer Science and Mobile Computing, Vol. 5, 191-203.

العناصر النقية الابتدائية وبالتالي تعتبر هذه الخوارزمية من انواع التصنيف غير الإشرافي Unsupervised classification أما خوارزمية SAM فهي تحتاج تحديد مناطق ذات أهمية (Region Of Interest) يتم إدخالها إلى الخوارزمية قبل أن تبدأ عملها لتعتبر البيكسلات الممثلة لهذه المناطق أشعة مرجعية تحسب من خلالها الزاوية الطيفية بينها وبين بيكسلات الصورة لتحديد البيكسلات النقية وبالتالي تعتبر من خوارزميات التصنيف الإشرافي (Supervised classification) وهذه ما يميز خوارزمية فك المزج غير الخطي حيث أنها لا تحتاج تدخل بشري.

يبين الجدول التالي أهم نقاط الاختلاف التي تميز خوارزمية فك المزج غير الخطي.

الجدول 7: مقارنة خوارزمية فك المزج غير الخطي مع الخوارزميات الأخرى.

| نقاط المقارنة            | Linear Unmixing   | Nonlinear Unmixing  | Spectral angle mapper   |
|--------------------------|---|---|---|
| اختيار مناطق ذات أهمية   | لا تحتاج اختيار نقاط ذات أهمية [11]                           | لا تحتاج اختيار نقاط ذات أهمية  | تحتاج اختيار نقاط ذات أهمية ومعرفة مسبقة بالمشهد المصور [5]   |
| التفاعل مع الشعاع الضوئي | تتعامل فقط مع الانعكاس المباشر الناتج عن العينة المدروسة [11] | تدرس امتصاص وتشتت الضوء بالإضافة إلى أخذ الانعكاس المزدوج بعين الاعتبار | تعتمد في عملها على قيمة البيكسل لتحديد الصنف الذي ينتمي إليه مما يزيد من احتمال ظهور الخطأ عند الأعداد الرقمية المتقاربة والعائدة لمواد مختلفة [12] |

## Reference:

- [1] Arngren M, Larsen J, Larsen R, 2011- Hyperspectral image analysis of food quality, department of informatics and mathematical modeling, technical university of Denmark, vol.255, 521-534.
- [2] Athanasia-Maria Tompolidi, Olga Sykioti, Konstantinos Koutroumbas and Issaak Parcharidis, 2020, Spectral Unmixing for Mapping a Hydrothermal Field in a Volcanic Environment Applied on ASTER Landsat-8/OLI, and Sentinel-2 MSI Satellite Multispectral Data: The Nisyros (Greece) Case Study, remote sensing, vol. 40, 1-25.
- [3] Chao-Cheng Wu, Weimin L, Hsuan R and Chein-I Chang 2016- A comparative study and analysis

- [19] Yücel Çimtay, Hakkı Gökhan İlk, A novel bilinear unmixing approach for reconsideration of subpixel classification of land cover, 2018- Computers and Electronics in Agriculture, Vol. 152, 126-140.
- [20] Yue J, Haikuan F, Qingjiu T, Chengquan Z , 2020- A robust spectral angle index for remotely assessing soybean canopy chlorophyll content in different growing stages, Content courtesy of Springer Nature, Vol. 26, 16-104.
- [21] Yang B, Wang B, Wu z, 2018 Unsupervised Nonlinear Hyperspectral Unmixing Based on Bilinear Mixture Models via Geometric Projection and Constrained Nonnegative Matrix Factorization, vol. 10, 1-34.
- [22] Zhao M, Yan L, Chen J, 2021- LSTM-DNN based autoencoder network for nonlinear hyperspectral image unmixing, IEEE Journal of Selected Topics in Signal Processing, vol. 15, 295-309.
- [23] Zhicheng W, Lina Z, Lianru G, Andrea M, Bing Z and Michael K, 2020- Hyperspectral Nonlinear Unmixing by Using Plug-and-Play Prior for Abundance Maps, the Special Issue Advances in Hyperspectral Data Exploitation, vol, 17, 26-33.
- [14] Soo Hyun Park, Hoyoung Lee, Sang Ha Noh, 2014- Multispectral Wavelength Selection to Detect 'Fuji' Apple Surface Defects with Pixel-sampling Analysis, Journal of Biosystems Engineering Vol. 39, 166-173.
- [15] Su Y, Xu X, Li J, Qi h, Gamba P, Plaza A, 2020- Deep Autoencoder With Multitask Learning for Bilinear Hyperspectral Unmixing IEEE Transactions on geoscience and remote sensing, vol. 207, 1-15.
- [16] Tao T, Gang Q, 2011- Multispectral Method for Apple Defect Detection using Hyperspectral Imaging System, University of Maryland college park P66.
- [17] Villa A, Chanussot J, Benediktsson J, and Jutten C, 2011- spectral Unmixing for the Classification of Hyperspectral Images at a Finer Spatial Resolution, IEEE JOURNAL OF OF SELECTED TOPICS IN SIGNAL PROCESSING, Vol. 5, 521-533.
- [18] Wng-Hee Lee, Moon S Kim, Hoonsoo Lee, Stephen R Delwiche, Hyperspectral near-infrared imaging for the detection of physical damages of pear, 2014- Journal of Food Engineering, Vol. 130, 1-7.

# Spectral imaging classification by non linear spectral unmixing algorithm and spectral angle mapper classification

Anas Ramez Al-Fahham<sup>1\*</sup>, Yaser Emleh<sup>2</sup>, and Ied Al-Abbod<sup>3</sup>.

<sup>1</sup>Department of communication and electronics engineering, faculty of mechanical and electrical engineering, aL-Baath university ,Homs, Syria, anas9127anas@gmail.com

<sup>2</sup>Department of communication and electronics engineering, faculty of mechanical and electrical engineering, aL-Baath university ,Homs, Syria, Yaser.emleh@gmail.com

<sup>3</sup>Department of communication and electronics engineering, faculty of mechanical and electrical engineering, aL-Baath university ,Homs, Syria, eado78@gmail.com

\*corresponding author: Anas Ramez Al-Fahham,email: anas9127anas@gmail.com.

Published online: 30 June 2022

**Abstract**— Remote sensing is the science that searches for the information by sensing, recording, processing and analyzing the energy emitted or reflected from the surface of Earth. Remote sensing images are captured by aircraft carrying imaging platforms, or by satellite, But due to the high altitudes, the high cost of high-resolution cameras, and the great similarity in the appearance of the scenes we created spectral cubes using spectral imaging technology that depends on producing a group of three-dimensional images with two spatial dimensions (geographic) and a third dimension represents the different wavelengths. Spectral imaging results are a set of pixels that represent a mixture of pure materials and components called (mixed pixel), these components can be distinguished by non linear spectral unmixing automatically. In this paper, the non-linear unmixing algorithm was studied and applied to the spectral cubes resulting from remote sensing images in order to classify the contents of these images, identify their components and calculate the ratio of them, The results of unmixing algorithm were also compared with the results of spectral angle mapper algorithm and showed us that spectral unmixing algorithm is more superior because it presents excellent results, for example error percentage for roads is 1.3% , for rocks and water is 2.59%, 0% respectively.

**Keywords**-Datacube. Classification, Endmembers, Mixed pixel, spectral angle mapper, non linear spectral unmixing.