

## الكشف المبكر للأمراض الجلدية باستخدام

### خوارزميات فك المزج الطيفي الخطي وغير الخطي

م. انس الفحام      الاستاذ الدكتور ياسر عملة      الدكتور عيد العبود  
جامعة البعث / كلية الهندسة الميكانيكية والكهربائية /

#### الملخص

يعتبر كشف الأمراض اعتماداً على تقنيات التصوير المختلفة من أهم الطرائق التي توصل إليها العلم الحديث وتعتبر تقنية التصوير وفك المزج الطيفي أكثرها تطوراً لما تحقّقه من دقة في الكشف المبكر عن الأمراض وانخفاض في الكلفة بالإضافة إلى أنها آمنة ولا تسبب تأثيرات جانبية للمناطق المصورة على اعتبار أن التصوير يتم في المجال المرئي والجزء الأول من الأشعة تحت الحمراء.

تعتمد تقنية التصوير الطيفي بشكلٍ أساسي على النقاط مجموعة من الصور للمشاهد ذاته عند الأطوال الموجية المختلفة مشكّلةً بذلك ما يدعى بالمكعب الطيفي المؤلف من بعدين مكانيين وبعد ثالث يعبر عن الطول الموجي حيث يتيح لنا ذلك رسم القيم الطيفية لعناصر الصورة كتابع لطول الموجة وبالتالي سيكون لكل عنصر صورة قيمة محددة مرتبطة بطول الموجة مما يسهل ملاحظة الفرق بين مكونات المشهد المصوّر نتيجة الخصائص الفريدة (الانعكاس-الامتصاص) لكل مادة من المواد المصوّرة.

ينتج عن عملية التصوير الطيفي مجموعة من عناصر الصورة التي تمثل مزيج من المواد والمكونات النقية وتدعى في هذه الحالة (عناصر الصورة الممزوج) ويساهم كل مكون من مكونات الصورة بنسبة محددة في تكوين عنصر الصورة الممزوج ويمكن تمييز هذه المكونات عن طريق مجموعة من الخوارزميات الآلية ثم تصنيفها وحساب نسبتها في الصورة من خلال خوارزميات التصنيف.

قمنا في هذا البحث بتطبيق خوارزميات فك المزج الطيفي الخطي وغير الخطي على الصور الطيفية الممثلة لأمراض جلدية بهدف معرفة العناصر النقية المكونة لعناصر الصورة الممزوجة بشكلٍ آلي حيث أن كل عنصر نقي يعبر عن منطقة أو مرض معين من المشهد ومن ثم تصنيف العناصر النقية المذكورة وحساب نسبة كل منها في الصورة.

**كلمات مفتاحية:** فك مزج خطي، فك مزج غير خطي، تصنيف، عنصر الصورة الممزوج، تصوير طيفي.

## Early detection of skin diseases using linear and non linear spectral unmixing algorithms

### Abstract

Detecting diseases based on different imaging techniques is one of the most important methods that modern science has reached, spectral imaging technology is considered the most advanced because of it is very accurate in early detection of diseases and has low cost, in addition it is safe and does not cause harmful effects because the imaging is in the visible range and the first part of the infrared.

Spectral imaging technology depends mainly on capturing a group of images of the same scene for different wavelengths and forming a spectral cube which consisting of two spatial dimensions and the third dimension represents the wavelength, this allows us to plot the spectral values of the pixels as a function of the wavelength and each pixel will have a specific value related to the wavelength, this makes it easy to notice the difference between the elements of the scene due to the unique properties (reflection-absorption) of each of the photographed materials.

Spectral imaging process produce a group of pixels that represent a mixture of pure materials and components called in this case (mixed pixel) , each component of the image contributes in a specific proportion in forming of the mixed pixel, these components can be distinguished through a set of automated algorithms then classify endmembers and calculate the proportion of them in the image through classification algorithms.

In this research, we applied linear and nonlinear spectral unmixing algorithms on spectral images which represent skin diseases in order to know the endmember which form mixed pixels automatically where each endmember expresses a specific area or disease from the scene and then classify the mentioned endmember and calculate the proportion of each of them in the image.

### Keywords:

Linear unmixing, Non Linear unmixing, Classification, Mixed pixel, Spectral imaging.

## 1. المقدمة:

تعتبر تقنية التصوير الطيفي من أهم وأحدث الطرق التي يمكن استخدامها في الكشف المبكر عن الأمراض التي تصيب الأنسجة الحية وذلك من خلال التقاط مجموعة من الصور للمناطق المدروسة عند كل طول موجي والحصول على ما يدعى بالمكعب الطيفي الذي يعبر عن الإحداثيات المكانية لعناصر الصورة بالإضافة إلى خصائصها الطيفية التي يقصد بها الاستجابة التي يبديها عنصر الصورة عند كل طول موجي وهذا ما يسمى البصمة الطيفية.

من جهة أخرى تحوي الصور الملتقطة على مجموعة من عناصر الصورة التي تضم معلومات تتعلق بمادة واحدة فقط أو معلومات خاصة بمواد مختلفة وفي هذه الحالة سيتأثر طيفها الكلي بالطيوف النقية الخاصة بكل مادة من المواد الداخلة في تركيبها و ندعوه في هذه الحالة عنصر الصورة الممزوج [1].

يتم الاعتماد على الخصائص البصرية (الامتصاص والانعكاس والتشتت و...) للعينات المصورة والتي تميز كل مادة عن غيرها فعلى سبيل يملك كل نسيج حي معامل امتصاص خاص به تتغير قيمته مع تغير الطول الموجي المسلط عليه وهذا ما يساعد بشكل كبير في فصل عناصر الصورة عن بعضها عند تنفيذ خوارزميات التصنيف [2].

تهدف هذه الدراسة بشكل أساسي إلى تحليل مكونات الصورة على مستوى عنصر الصورة الذي يمكن أن يكون مؤلفاً من أكثر من مادة نقية وتم ذلك عن طريق خوارزميات فك المزج الطيفي التي استطعنا من خلالها تصنيف محتويات الصور الطيفية وحساب نسبة كل منها حيث تم في البداية استخدام خوارزمية تحديد العناصر النقية N-Finder ومن ثم تطبيق خوارزميات فك المزج الطيفي لعزل مكونات كل عنصر صورة وتصنيفها كما قمنا بالمقارنة بين النموذج الخطي وغير الخطي واستنتجنا أن النموذج غير الخطي هو الأكثر دقة لأنه يناقش جميع الحالات التي يتعرض لها الشعاع الضوئي أثناء مروره في النسيج الحي.

## 2. مشكلة البحث:

من أهم المشاكل التي تواجه عملية تصنيف عناصر الصورة هو وجود عناصر الصورة الممزوجة المكونة من أكثر من مادة نقية (نمط) وبالتالي يكون الطيف الخاص بها ناتج عن الأطياف النقية الخاصة بكل مادة وهذا ما ندعوه المزج الطيفي. يعالج البحث مشكلة المزج الطيفي التي تسبب تشكل الأطياف الممزوجة المرتبطة بعلاقة خطية أو غير خطية مع المواد النقية الداخلة في تركيب عنصر الصورة وذلك حسب نوع نموذج المزج الطيفي المتشكل. قمنا في البحث بدراسة أطياف عناصر الصورة الممزوجة وإيجاد نسبة المواد النقية الداخلة في تركيبها ومن ثم إيجاد نسبتها في الصورة وذلك عن طريق خوارزمية فك المزج الطيفي غير الخطي التي تعالج مشكلة المزج الخطي وغير الخطي معاً.

## 3. هدف البحث:

يهدف البحث بشكل أساسي إلى الكشف المبكر عن الأورام الخبيثة التي تصيب الأنسجة الحية مثل أنسجة الجلد والعين والتميز بينها وبين الأمراض الحميدة وذلك من خلال تحليل الصور الطيفية الملتقطة لهذه الأنسجة باستخدام خوارزميات فك المزج الطيفي التي تعمل على استخراج المكونات النقية المعبرة عن هذه الأمراض ثم العمل على تصنيفها وحساب نسبتها في الصورة.

## 4. أهمية البحث:

تكمن أهمية البحث في تشخيص الأمراض الجلدية بأمان دون وجود تأثيرات جانبية على النسيج الحية من خلال تقنية التصوير وفك المزج الطيفي التي تعتمد على المجال المرئي والمجال الأول من الأشعة تحت الحمراء في عملية التصوير وهذا ما سيساعد في الكشف المبكر عن الأورام الجلدية بمراحلها دون الحاجة للتدخل الجراحي أو التحليل الكيميائي مما يساهم في تقليل المخاطر الناتجة عن الاختبارات الطبية (أخذ الخزعات على سبيل المثال) وبالتالي تخفيض الأعباء الاقتصادية المرتبطة بذلك.

## 5. مراحل البحث:

اقترحنا في بحثنا خوارزمية فك المزج الطيفي غير الخطي من أجل كشف الأمراض الجلدية وتحديد موقعها ونسبتها في الصورة.

تحتاج خوارزمية فك المزج غير الخطي لتحديد مكونات نقية ابتدائية من الصورة تعبر عن مناطق مصابة ويتم ذلك بالاعتماد على خوارزمية N-Finder ثم قمنا بدراسة الخصائص البصرية للعينات المدروسة (الامتصاص والتشتت) التي تدخل في معادلة معامل Albedo المعبر عن الانعكاس النهائي الناتج عن عنصر الصورة بعد عمليات الامتصاص والتشتت المذكورة ليتم استخدامه في حساب مساهمات مكونات الصورة النقية ( الأمراض المدروسة) في كل عنصر صورة ممزوج.

قمنا بتطبيق خوارزمية فك المزج غير الخطي وخوارزمية فك المزج الخطي على العينات الحيوية وأظهرت النتائج تفوق خوارزمية فك المزج غير الخطي بشكل واضح لأنها تأخذ بعين الاعتبار نموذجي المزج الخطي وغير الخطي معاً.

## 6. الدراسات المرجعية:

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

تم في عام 2011 دراسة الكشف الطيفي اعتماداً على خوارزمية استثمار تابع العتبة (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 [3]، وتابع مجموعة من الباحثين في العام ذاته دراسة التصوير الطيفي من خلال خوارزمية نسب الحزم (band ratio) والتي تعتمد بشكل أساسي على حساب نسبة الانعكاس لعنصر الصورة

عند طولين موجيين حيث أن:

$$\text{band ratio} = (S_{\lambda 1}/S_{\lambda 2}) \dots \dots (1)$$

$S_{\lambda 1}$ : نسبة الانعكاس عند الطول الموجي الأول.

$S_{\lambda 2}$ : نسبة الانعكاس عند الطول الموجي الثاني.

ويتم تحديد التباين بين المناطق المدروسة من خلال عتبات يتم تحديدها من خلال المتوسط الحسابي لعناصر الصورة الممتلئة لكل منطقة من المناطق المدروسة وفي كلا الحالتين لم يتم الاعتماد سوى على جزء صغير من المكعب الطيفي (صورتين أو ثلاث صور) [4].

وفي عام 2013 تم استخدام خوارزميات تحليل طيفي أكثر تعقيداً حيث قام مجموعة من الباحثين بالاعتماد على خوارزمية أقرب مسافة إلى الوسط (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 (Regions Of Interest (ROI) وتحديد مركز كل فئة من فئات التصنيف تتم عملية التصنيف وفقاً للمسافة الطيفية بين مواقع عناصر الصورة ومراكز فئات التصنيف [5]. 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 وهذا ما بدأ الباحثون 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 عناصر الصورة في الحزم الثلاث و كل قيمة أكبر من العتبة يتم اعتبارها بأنها كشف صحيح وكل قيمة أصغر من العتبة يتم اعتبارها كشف خاطئ.

تم تطبيق هذه الدراسة على عينات من التفاح فكانت دقة الكشف للكدمات 80.70% أي ما يعادل نسبة خطأ 19.3% ودقة الكشف لمرض الجرب 89.98% أي ما يعادل نسبة خطأ 10.02% [6].

وفي العام ذاته تم اعتماد 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:

$$F \text{ value} = \frac{\text{variance of the group means (Mean Square Between)}}{\text{mean of the within group variances (Mean Squared Error)}} \dots \dots \dots (2)$$

ومن ثم إيجاد التردد המתناسب مع قيمة f-value وبالتالي تحديد الطول الموجي المناسب الذي يتم عنده تمييز العنصر المطلوب [7].

وفي دراسة أخرى عام 2015 تم ابتكار خوارزمية تعتمد على تحديد المدى الطيفي لفئات التصنيف في الصورة [8]، 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 للمناطق التي تمثلها (ROI) وتتم مقارنة قيمة عناصر الصورة مع الحدين 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 عناصر الصورة التي تقع بين هاتين العتبتين سيتم تخصيصها لهذا الصنف ولكن لوحظ في بعض الحالات وجود تداخل بين فئات التصنيف [8].

حاول الباحثون عام 2016 إيجاد خوارزمية تصنيف أكثر دقة تدعى خوارزمية التصنيف باستخدام عدد K من المتوسطات (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 وستتكرر هذه العملية إلى أن تصبح المسافة أقل من قيمة العتبة عندئذ ستنتهي عملية التصنيف. يتم الاعتماد على مجموعة من المعايير لقياس المسافات بين العناصر ومن أهمها المسافة الإقليدية (Euclidean distance) الموضحة وفق المعادلة التالية:

$$d = \sqrt{\sum_{j=1}^k \sum_{i=c_j} (x_i - z_i)^2} \dots (3)$$

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

أظهرت هذه الدراسة أن دقة الكشف 84.3% أي ما يعادل نسبة خطأ 15.7% من أجل خوارزمية K-means التقليدية، 90.6% أي ما يعادل نسبة خطأ 9.4% من أجل خوارزمية K-means المحسنة [9].

قام الباحثون في عام 2018 بدراسة خوارزمية فك المزج الطيفي الخطي Spectral Linear Unmixing والتي كانت بدايةً لخوارزمية فك المزج الطيفي غير الخطي التي اقترحها البحث [10].

مما سبق نستنتج أن معظم الدراسات (حتى عام 2015) تعتمد على استخدام جزء من الطيف وتهدف في النهاية إلى التمييز بين منطقتين من المشهد المصور لذلك بدأت الدراسات الحديثة المعتمدة على خوارزميات مثل خوارزمية K-means و خوارزميات فك المزج الطيفي باستخدام كامل المجال الطيف بهدف تحسين دقة التصنيف وكشف عدد أكبر من العناصر النقية.

تم استخدام جميع الدراسات المرجعية المذكورة سابقاً في تصنيف محتويات الصور الطيفية ولكن جميع هذه الدراسات اعتمدت في التصنيف على العدد الرقمي لعناصر الصورة دون الأخذ بعين الاعتبار الخصائص البصرية للعينات المدروسة وسلوك الشعاع الضوئي (ظواهر الامتصاص والتشتت والانعكاس) وبالتالي لن تتمكن من كشف المكونات النقية المشكّلة لعناصر الصورة الممزوجة والتي تساهم في تشكيل الطيف الكلي لها والعدد الرقمي المعبر عنها.

قمنا في بحثنا بفك مزج عناصر الصورة واستخراج مكوناتها النقية المعبرة عن الأورام والأمراض المختلفة بهدف تصنيفها وحساب نسبتها في الصورة.

## 7. فك المزج الطيفي Spectral unmixing:

عند سقوط الشعاع الضوئي على المشهد المصور فإنه سيتأثر بالخصائص البصرية للمواد فإما أن ينعكس مباشرة وإما أن يتم امتصاصه بشكل جزئي أو كلي كما أنه من الممكن أن يصطدم بأكثر من عنصر نقي قبل أن ينعكس بشكله النهائي.

يحدث المزج الخطي عندما ينعكس الشعاع الضوئي بشكل مباشر عن كل مكون نقي من مكونات الصورة وبالتالي فإن الطيف النهائي سيرتبط بعلاقة خطية مع الطيف النقية المشكّلة له.

أما المزج غير الخطي فإنه يحدث عندما يخترق الشعاع الضوئي العينة المدروسة فيتم امتصاصه أو يتعرض للتشتت بحسب الخصائص البصرية المميزة لهذه العينة في هذه



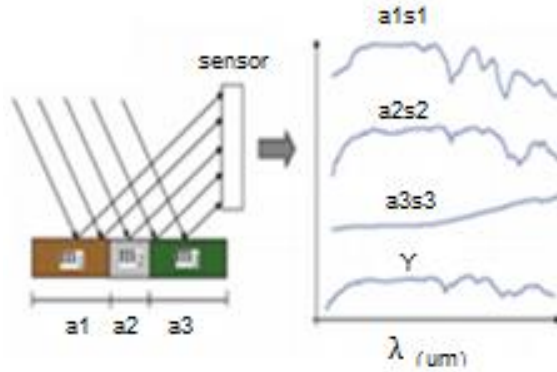
الحالة يتعلق الطيف الكلي بالانعكاسات المباشرة و الانعكاسات الثنائية والثلاثية للشعاع الضوئي.

وبما أنه من الممكن أن يكون عنصر الصورة عبارة عن مزيج من المواد والعناصر النقية (endmembers) ويدعى في هذه الحالة عنصر الصورة الممزوج (mixed pixel) حيث تساهم كل مادة بنسبة محددة في تكوين (mixed pixel) [11]. تم في هذا البحث دراسة آلية عمل خوارزميات فك المزج الطيفي spectral unmixing والتي تمكّننا من خلالها من تحليل مكونات (mixed pixel) وبالتالي إمكانية تمييز محتويات الصور وتصنيفها وحساب نسبتها بشكل ممتاز .

### 7.1 فك المزج الطيفي الخطي (LU): Linear unmixing algorithm

تفترض خوارزمية فك المزج الخطي وجود انعكاس وحيد ومباشر عن كل مادة نقية وتقوم بحساب مساهمتها في عنصر الصورة الممزوج وذلك بعد معرفة الطيف النقي الخاص بها ويقصد بالطيف النقي أي معرفة قيمة عنصر الصورة الممثل لهذه المادة 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 الخوارزمية المعتمدة على مؤشر نقاوة عنصر الصورة (Pixel Purity Index)، وخوارزمية N-Finder.

يوضح الشكل التالي نموذج المزج الخطي:



الشكل (1): نموذج المزج الخطي

وتعطى معادلة فك المزج الخطي بالعلاقة التالية:

$$Y = \sum_{m=1}^M a_m * s_m + W \dots (4)$$

Y: هو الطيف الكلي.

M: هو العدد الكلي للعناصر النقية.


a<sub>m</sub>: هي مساهمة العنصر m في عنصر الصورة التي تخضع لانعكاس وحيد مباشر.

S<sub>m</sub>: هو الطيف الخاص بالعنصر m [12].

## 7.2 خوارزمية فك المزج غير الخطي (NLU) Non linear Spectral unmixing :

اقترح البحث خوارزمية فك المزج غير الخطي التي تتعامل 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 كما يبين الشكل (2).

بالإضافة إلى ذلك فإنه يمكن أن يكون لدينا عدة أشكال للنموذج غير الخطي منها عندما يكون الخليط متماسكاً وبالتالي فإن المواد المختلفة تكون قريبة من بعضها إلى حد كبير جداً ويكون الطيف الناتج في هذه الحالة متعلقاً بكثافة المواد من جهة وبارامترات الوسط كما 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 (2): أشكال المزج غير الخطي

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.

### 7.3 حساب معاملات خوارزمية NLU (المقترحة):

7.3.1 استخراج العناصر النقية الابتدائية باستخدام حوارزمية N-Finder:

اعتمدنا في البحث على خوارزمية N-Finder التي تم دراستها عام 2011 والتي تهدف إلى إيجاد عناصر الصورة النقية الابتدائية في المشهد [13].

يبدأ الإجراء باختيار مجموعة أولية من عناصر الصورة واعتبارها عناصر نقية (رؤوس الهرم) ثم البحث عن مجموعة أخرى لزيادة أبعاد الهرم واعتبار عناصر الصورة التي تعطي حجم هرم أعظمي كعناصر نقية من خلال التعويض في المعادلة التالية:

$$Vk(E_1^{(k)}, E_2^{(k)}, E_3^{(k)}, E_4^{(k)}) = \frac{\left| \det \begin{bmatrix} 1 & 1 & \dots & \dots & 1 \\ E_1^{(k)} & E_2^{(k)} & \dots & \dots & E_4^{(k)} \end{bmatrix} \right|}{(p-1)!} \dots (5)$$

حيث:

$V_k$ : حجم الهرم المتشكل من عناصر الصورة النقية وهو الحجم الأعظمي في الحزمة K.

E: تمثل العدد الرقمي المعبر عن كل عنصر نقي من عناصر الصورة.

K: تعبر عن رقم الحزمة الطيفية .

P: تعبر عن عدد عناصر الصورة في القطاع (يتم تحديده بشكل تقريبي بحيث يغطي منطقة مدروسة) [13].

يتم في هذه الخوارزمية تحديد العناصر النقية وفق مراحل منفصلة و عمليات تكرارية كما يلي:

1- تقسيم الصورة إلى مجموعة من القطاعات المتساوية و يتم التعبير عن كل قطاع بمصفوفة أبعادها  $i * j$  حيث يكون عدد عناصر الصورة في كل قطاع وفق العلاقة:

$$B \leq L * 0.05 \dots (6)$$

B: هو عدد عناصر الصورة في القطاع.

L: عدد عناصر الصورة الكلي.

2- اختيار عناصر صورة نقية من أحد القطاعات ( مواقع 4 عناصر صورة تمثل رؤوس الهرم) بحيث تكون عناصر الصورة المختارة عناصر نقية تمثل منطقة مدروسة وحيدة ونحدد من خلالها الحجم الأعظمي للهرم وذلك وفق المعادلة (5).

يتم تمثيل كل عنصر صورة في القطاع بشعاع خاص  $X(i,j)$  إذ يتم إدخال هذا الشعاع في العلاقة (5) وفق ما يلي:

$V(X(i,j), E_k^{(1)}, E_k^{(2)}, \dots, E_p^{(4)})$  ونحسب حجم الهرم الناتج عن ذلك  $(E_k^{(1)}, X(i,j), E_k^{(2)}, \dots, E_k^{(4)})$  و نستمر في ذلك حتى تقييم جميع عناصر الصورة في القطاع وعندما يحقق العدد الرقمي لأحد عناصر الصورة حجم هرم يساوي المقدار المعبر عن العلاقة (5) عندئذ يكون عنصر الصورة  $X(i,j)$  هو العنصر النقي الجديد في القطاع المحدد [13].

3- بالنظر إلى القطاعات الأخرى تقوم الخوارزمية بالتعامل معها على أنها مجموعة من المصفوفات يتم تشكيل أربع عناصر صورة نقية تمثل رؤوس الهرم في القطاع الجديد تحقق المعيار الرياضي التالي (معيار فروبينوس) :

$$\|fk\|_h = \sqrt{\sum_1^m \sum_1^n \|Xij\|^2} \dots (7)$$

حيث أن:  $f_k$ : معيار فروبينوس في الحزمة الطيفية k في القطاع h.

k: رقم الحزمة الطيفية.

ثم يتم تخمين العنصر النقي في القطاع الجديد وفق العلاقة التالية:

$$dn_k - (dn_k^*) < \Delta \dots (8)$$

$dn_k$ : هو العدد الرقمي للعنصر النقي في القطاع القديم في الحزمة  $k$

$dn_k^*$ : العدد الرقمي للعنصر النقي في القطاع الجديد في الحزمة  $K$ .

$K$ : رقم الحزمة.

$$\Delta = \frac{1}{k-1} \sum_1^k |f_k - f_{k-1}| \dots (9)$$

وبالتالي كل عنصر صورة تحقق الشرط السابق يتم اعتباره عنصر نقي مرشح لتشكيل رؤوس الهرم الجديد.

4- نحصل بنتيجة الخوارزمية على مصفوفة تحوي الأعداد الرقمية للعناصر النقية

في كل حزمة من الحزم وبالتالي نكون قد حددنا موضع كل عنصر نقي بحسب


ترتيبه (الصف والعمود) في المصفوفة الناتجة وبعد معرفة موضع عنصر

الصورة النقية فإنه من السهل معرفة بصمته الطيفية أو ما يدعى شعاعه

الطيفي.

يبين الشكل (3) آلية الحصول على العناصر النقية المتوضعة على رؤوس هرم

باستخدام خوارزمية N-Finder.



الشكل (3): خوارزمية N-Finder

7.3.2 حساب معامل ألبيدو Albedo factor:

تعتمد خوارزمية فك المزج الطيفي بشكل أساسي على معامل albedo الذي نعرفه بأنه 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 [14].

يعطى Albedo لعنصر الصورة النقي بالمعادلة التالية:

$$\partial(\lambda) = 1 - \left[ \frac{\sqrt{m^2(\mu_s + \mu_a)^2 + (1 + 4\mu_s\mu_a m(1 - m))} - m(\mu_s + \mu_a)}{1 + 4\mu_s\mu_a m} \right]^2 \dots (10)$$

$\mu_a$ : معامل الامتصاص،  $\mu_s$  معامل التشتت،  $m$ : هو الطيف عنصر نقي [14]

ويكون Albedo لعنصر الصورة الممزوج بالمعادلة التالية:

$$\partial(\lambda)_{mix} = 1 - \left[ \frac{\sqrt{Y^2(\mu_s + \mu_a)^2 + (1 + 4\mu_s\mu_a Y(1 - Y))} - Y(\mu_s + \mu_a)}{1 + 4\mu_s\mu_a Y} \right]^2 \dots (11)$$

$Y$ : هو الطيف الكلي [14]

قمنا في بحثنا بدراسة بعض الأمراض الجلدية من خلال تقنية التصوير الطيفي التي تعتمد على تسليط الأطوال الموجية المختلفة على العينة المدروسة وباعتبار أن الجلد يتكون من مجموعة مختلفة من الطبقات (القرنية والبشرة والأدمة) فإن هناك مجموعة من الطرق البصرية الموصى بها تكون فعالة في التشخيص الطبي للأمراض الحيوية حيث أن تخمين كروموفورات الأنسجة مثل الميلانين وتركيز الدم وأكسجة الدم هي الخطوة الأولى لتحديد إصابتها بمرضٍ ما مثل السرطان والالتهابات المختلفة.

من أهم الكروموفورات التي يتم الاعتماد عليها في الطبقات السطحية هو الميلانين والهيموغلوبين المؤكسج والهيموغلوبين غير المؤكسج والبييلوروبين ونسبة الماء والتي نحصل من خلالها على خصائص الامتصاص البصري عند طول موجي محدد. إن التغير الذي يبيده أي كروموفور مما سبق نتيجة وجود حالة مرضية معينة يصاحبه ذلك تغير في طريقة انتشار الأشعة الساقطة عليه عند كل طول موجي ونتيجة لذلك سيزودنا التحليل الطيفي بمعلومات مفيدة حول تقييم الحالات غير السليمة وبناءً على ذلك لابد من معرفة خصائص انتشار الضوء في الأنسجة وخصائص امتصاصه.

### 7.3.3 تحديد معاملات الامتصاص والتشتت:

ومن أجل تحديد عامل Albedo المذكور سابقاً فإنه لابد من تحديد معاملات الامتصاص والتشتت وفق ما يلي:  
أولاً: معامل الامتصاص:

$$I = I_0 * e^{-\mu_a l} \dots (12)$$

حيث أن  $l$ : هي شدة الضوء الوارد للعينة  $I_0$ : شدة الضوء النافذ.  $\mu_a$ : معامل الامتصاص.  $l$ : سماكة العينة [2]. كما يمكن تعريف معامل الامتصاص بالعلاقة التالية:

$$\mu_a = \ln(10) \sum C_i \varepsilon_i \dots (13)$$

حيث أن  $C$  هو تركيز المادة  $\text{mol} * \text{cm}^{-1}$  و  $\varepsilon$ : هو الامتصاصية المولية  $\text{mol}^{-1} * \text{cm}^{-1}$  يكون أ رمز الطبقة التي يمر الضوء من خلالها.

ونتيجةً لذلك فإنه عندما يمر الضوء في الجلد ضمن مجموعة من الطبقات ( القرنية والبشرة والأدمة) فإنه سيخضع للامتصاص حسب كل الخصائص البصرية لكل طبقة.

$$\mu_a = \ln(10) [C_{m\text{epi}} * \varepsilon_{m\text{epi}} + C_{\text{epi}\text{bili}} * \varepsilon_{\text{epi}\text{bili}} + C_{\text{der}\text{oh}} * \varepsilon_{\text{der}\text{oh}} + C_{\text{der}\text{dh}} * \varepsilon_{\text{der}\text{dh}} + \dots] \dots (14)$$

$C_{m\text{epi}}$ : هو تركيز الميلانين في طبقة البشرة.

$\varepsilon_{m\text{epi}}$ : الامتصاصية المولية للميلانين في طبقة البشرة.

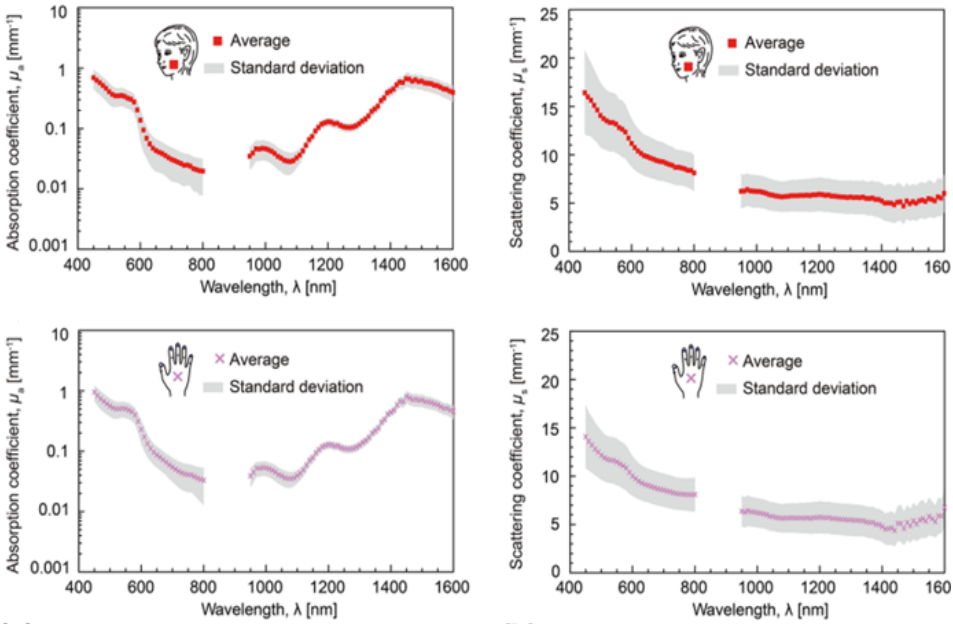
$C_{\text{bili}\text{epi}}$ : تركيز البلوروبين في البشرة.

$\varepsilon_{\text{bili}\text{epi}}$ : الامتصاصية المولية للبلوروبين في طبقة البشرة.

$C_{der\ oh}$ : تركيز الهيموغلوبين المؤكسج في الأدمة .  
 $E_{der\ oh}$ : الامتصاصية المولية للهيموغلوبين المؤكسج في الأدمة.  
 $C_{der\ dh}$ : تركيز الهيموغلوبين غير المؤكسج في الأدمة.  
 $E_{der\ dh}$ : الامتصاصية المولية للهيموغلوبين غير المؤكسج في الأدمة.  
يتغير معامل الامتصاص حسب طبيعة المادة التي يتفاعل معها الضوء وذلك حسب البارامترات الموجودة وهذا ما يميز كل مادة عن المواد الأخرى بامتلاكها معامل امتصاص خاص بها.  
ثانياً: معامل التشتت:  
تتميز المواد عن بعضها بمعاملات التشتت أيضاً والتي تختلف من مادة إلى أخرى حسب طبيعتها ويعطى معامل التشتت بالعلاقة التالية:

$$I = I_0 * e^{-\mu_s l} \dots (15)$$

ا: هي شدة الضوء الوارد للعينة  $I_0$ : شدة الضوء النافذ.  $\mu_s$ : معامل التشتت.  $l$ : سماكة العينة [2].  
يبين الشكل (4) مثالاً عن قيم معاملات الامتصاص والتشتت الخاصة ببعض المناطق الجلدية كتابع لطول الموجة:



الشكل (4): معاملات الامتصاص والتشتت لبعض المناطق الجلدية



بعد حساب قيمة albedo نستخدم المعادلة التالية لحساب مساهمة كل عنصر نقي  $a_m$  من العناصر النقية في الطيف الكلي وفق المعادلة التالية:

$$\alpha(\lambda)_{mix} = \sum_{m=1}^M a_m * \alpha(\lambda)_m \dots (16)$$

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

$\alpha(\lambda)_m$ : هي قيمة albedo لطيف عنصر الصورة النقي [14].

بعد حساب  $a_m$  نعوضها في المعادلة (17) من أجل حساب  $b_{mk}$  وهي معادلة النموذج غير الخطي:

$$Y = \sum_{m=1}^M a_m * s_m + \sum_{m=1}^M \sum_{m=1}^M b_{mk} * s_k \otimes s_m \dots (17)$$

حيث أن:

$Y$ : هو الطيف الكلي

$M$ : هو العدد الكلي للعناصر النقية.

$a_m$ : هي مساهمة العنصر  $m$  في عنصر الصورة الذي يخضع لانعكاس وحيد مباشر.

$S_m$ : هو الطيف الخاص بالعنصر  $m$ .

$S_k$ : هو الطيف الخاص بالعنصر  $k$ .

$b_{mk}$ : هو المساهمة الناتجة عن الانعكاس المزدوج للعنصرين  $m, k$ .

وبالتالي تصبح لدينا العلاقة المعبرة عن الطيف الكلي كما يلي:

$$Y = a_1s_1 + a_2s_2 + \dots + a_Ms_M + b_{11}(s_1 \otimes s_1) + b_{21}(s_1 \otimes s_2) + b_{22}(s_2 \otimes s_2) + b_{31}(s_3 \otimes s_1) + b_{32}(s_3 \otimes s_2) + (b_{33}(s_3 \otimes s_3) + b_{mk}(s_m \otimes s_k) + \dots \dots \dots (18)$$

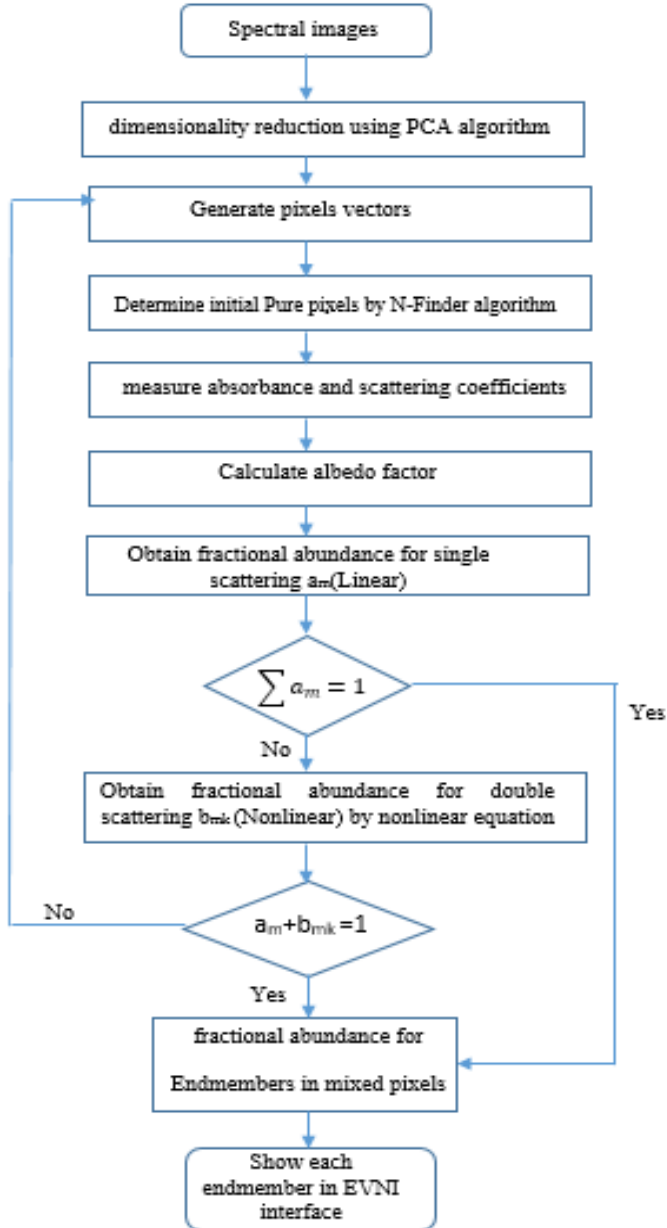
حيث يكون:

$$b_{11}=a_1*a_1; b_{21}=a_2*a_1; b_{22}=a_2*a_2; b_{31}=a_3*a_1; b_{33}=a_3*a_3$$

وبالتالي فإننا ونتيجة خوارزمية فك المزج غير الخطي تمكنا من حساب مساهمة كل عنصر من عناصر المواد المدروسة.

يمثل الشكل (5) المخطط الصندوقية لخوارزمية فك المزج غير الخطي (NLU) التي اقترحها البحث والتي تبدأ بتخفيض أبعاد المكعب الطيفي باستخدام خوارزمية تحليل المركبات الأساسية (PCA) ثم تحديد العناصر النقية الابتدائية من خلال تطبيق

خوارزمية N-Finder والانتقال لحساب معامل Albedo وذلك بالاعتماد على الخصائص البصرية للعينة المدروسة ليتم استخدامه في معادلة فك المزج غير الخطي التي تقوم بحساب نسبة مكونات عنصر الصورة الممزوج.



الشكل (5): خوارزمية فك المزج غير الخطي (NLU) المقترحة

## 8. المناقشة:

تم تطبيق خوارزميات فك المزج الطيفي الخطي (LU) وفك المزج غير الخطي (NLU) التي اقترحها البحث على مكعبات طيفية تمثل عينات جلدية لمتطوعين ذكور ببشرة بيضاء تتراوح أعمارهم بين 50-60 عاماً من أحد المخابر البحثية التابع لجامعة برمينغهام ببيريطانيا على الموقع الإلكتروني التالي:

<http://homepages.inf.ed.ac.uk/rbf/CVonline/Imagedbase.html>


حيث تم اختيار مكعبات طيفية خاصة بعينات تحوي مجموعة من الأمراض الجلدية (أورام والتهابات جلدية).

قمنا بتطبيق خوارزمية فك المزج الخطي على المكعبات الطيفية المذكورة حيث استخدمنا علاقة فك المزج الخطي (المعادلة (4)) بعد تخفيض أبعاد المكعب الطيفي اعتماداً على تقنية تحليل المركبات الأساسية وحصلنا على نسبة عناصر الصورة المعبرة عن كل مرض من الأمراض المدروسة.


من جهة أخرى تم العمل على تطبيق خوارزمية فك المزج غير الخطي التي اقترحها البحث اعتماداً على المخطط الصندوقي المبين في الشكل (5) وحصلنا أيضاً على نسبة عناصر الصورة المعبرة عن الأمراض ثم قمنا بمقارنة نتائج الخوارزميتين وحساب نسبة الخطأ الموافقة لكل منهما.

### 8.1 نتائج تطبيق (LU,NLU) على العينة (1):

تم تطبيق خوارزميات البحث على المكعب الطيفي الممثل للمشهد التالي والذي يعبر عن جلد مصاب بسرطان جلدي حاد وسرطان مرحلة أولى (خفيف) بالإضافة إلى وجود مناطق تعاني من التهاب جلدي:



الشكل (6): عينة جلدية مصابة بسرطان جلدي حاد وسرطان مرحلة أولى والتهاب جلدي ويظهر لنا الشكل (7) أجزاء من المكعب الطيفي للصورة في الشكل (6) عند عدد من الأطوال الموجية.



الشكل (7): أجزاء من المكعب الطيفي للعينة المدروسة

يوضح الجدول (1) معاملات الامتصاص والانعكاس الموافقة للعينة المدروسة والتي استطعنا من خلالها تحديد معامل (albedo) الموافق.


الجدول(1): معاملات الامتصاص والانعكاس ومعامل (albedo) لمجموعة عناصر صورة عشوائية عند الطول الموجي 550nm:

$\theta(\lambda)$	$\mu_s(\text{mm}^{-1})$	$\mu_s(\text{mm}^{-1})$	Pixel location
0.54	9.22	0.84	100.54
0.74	8.24	0.084	25.23
0.69	14.32	0.071	200.60
0.95	11.12	0.54	150.120
0.36	15.69	0.096	300.65
0.7	14.25	0.24	250.150
0.85	10.11	0.87	144.80
0.14	9.66	0.46	170.140
0.98	13.65	0.07	220.180
0.47	15.8	0.64	112.246
0.78	8.9	0.71	147.256
0.51	12.58	0.42	125.36
0.63	14.69	0.97	145.78
0.21	9.68	0.77	189.65
0.54	11.65	0.64	241.35
0.23	17.2	0.29	126.41
0.95	10.65	0.59	51.74
0.85	12.54	0.44	212.312

### 8.1.1 كشف المناطق المصابة بالسرطان الحاد باستخدام NLU, LU:

تم تطبيق خوارزميتي فك المزج الطيفي الخطي وغير الخطي على المكعب الطيفي الممثل للصورة المبينة في الشكل (6) :

يبين الشكل (8) نتيجة تطبيق خوارزمية فك المزج الطيفي الخطي حيث تكون نتيجة الخوارزمية هي عبارة عن صورة (RGB) ناتجة عن القنوات النقية الخاصة بكل مرض من الامراض المدروسة.



الشكل (8) نتيجة تطبيق خوارزمية LU

الصورة (a) تمثل العينة RGB

الصورة (b) تمثل نتيجة خوارزمية فك المزج الخطي.


الصورة (c) تمثل القناة النقية الموافقة للورم الحاد.

الصورة (d) تمثل القناة النقية الموافقة للورم مرحلة أولى.

الصورة (e) تمثل القناة النقية الموافقة للالتهاب الجلدي.

نلاحظ من الشكل (8) أنه تم تمثيل الأمراض المختلفة من خلال صورة تدرج الرمادي (gray scale) ويكون الانعكاس أعظماً من أجل عناصر الصورة المعبرة عن المرض الذي تمثله هذه القناة.

أما نتيجة تطبيق خوارزمية فك المزج الطيفي غير الخطي فإنها تظهر في الشكل(9):



الشكل (9) نتيجة تطبيق خوارزمية (NLU)

الصورة (a) تمثل العينة RGB

الصورة (b) تمثل نتيجة خوارزمية فك المزج غير الخطي.

الصورة (c) تمثل القناة النقية الموافقة للورم الحاد.

الصورة (d) تمثل القناة النقية الموافقة للورم مرحلة أولى.


الصورة (e) تمثل القناة الموافقة للالتهاب الجلدي.

يوضح الشكل (10) إجراء مقارنة واضحة بين خوارزميتي فك المزج الخطي وغير الخطي

حيث تم إظهار المناطق المصابة بالسرطان الحاد الناتجة عن تطبيق الخوارزميتين

باستخدام عملية تعريب (Thresholding) على القنوات الموافقة للورم الحاد عند قيمة

عتبة 255 من أجل القناة نقية في الشكل (8-c) والقناة النقية في الشكل (9-c).



الشكل(10): المناطق المصابة بالسرطان الحاد بعد تطبيق عتبة قيمتها 255 على القنوات النقية

الموافقة للسرطان الحاد

A: تعتیب المناطق الممثلة للسرطان الحاد باستخدام (LU) بعد تطبیق عتبة قيمتها 255 على القناة الموافقة للسرطان الحاد في الشكل (8-c).


B: تعتیب المناطق الممثلة للسرطان الحاد باستخدام (NLU) بعد تطبیق عتبة قيمتها 255 على القناة الموافقة للسرطان الحاد في الشكل (9-c).

حيث تظهر عناصر الصورة المصابة بالسرطان باللون الأسود وبقية عناصر الصورة باللون الأبيض.

### 8.1.2 حساب نسبة مكونات الصورة باستخدام NLU:

قمنا بتحديد المناطق المختلفة الممثلة لكل مرض (السرطان الحاد، سرطان من الدرجة الأولى، التهاب جلدي) حيث تم تمثيل المناطق المصابة بالسرطان الحاد والسرطان من الدرجة الأولى والالتهاب الجلدي كما يبين الشكل (11).


كما تم إظهار الطيف الخاص لكل مرض (spectral-profile) في الشكل (12) وهو يمثل قيمة عناصر الصورة المصابة عند كل طول موجي من أجل (144) صورة طيفية تم التقاط كل منها عند طول موجي معين ضمن المجال (380-1100nm) وهذا ما يدعى بالبصمة الطيفية حيث أن اللون الأحمر للسرطان الحاد واللون الأخضر للسرطان من الدرجة الأولى واللون الأصفر للالتهاب الجلدي أما اللون الأسود يمثل باقي عناصر الصورة (الجلد السليم).



الشكل (11) المناطق الممثلة للأمراض المختلفة باستخدام (NLU)

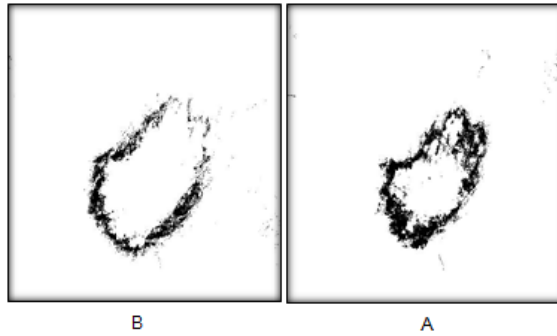


ويبين الشكل (12) الاستجابة الطيفية Z-profile لكل منطقة من المناطق المدروسة:



الشكل (12) (Spectral-profile)

في الشكل (13) تم تمييز المناطق المصابة بالسرطان مرحلة أولى والمناطق المصابة بالتهاب جلدي من خلال إجراء تعتیب (Thresholding) عند القيمة 255 على القنوات الموافقة للسرطان مرحلة أولى والالتهاب الجلدي المبينة في نتيجة خوارزمية NLU التي يظهرها الشكل (9).



الشكل (13): نتيجة التعتیب للمناطق المصابة بالسرطان الحاد في العينة 1 عند القيمة 255  
A: عناصر الصورة الممثلة للمناطق المصابة بسرطان مرحلة أولى بنتيجة تطبيق عتبة 255 على القناة الخاصة بسرطان المرحلة الأولى في الشكل (9-d).  
B: عناصر الصورة الممثلة للمناطق المصابة بالتهاب جلدي بنتيجة تطبيق عتبة 255 على القناة الخاصة بالالتهاب الجلدي في الشكل (9-e).

تم في الجدول (2) مقارنة نسبة السرطان الحاد الناتجة عن خوارزمية فك المزج غير الخطي وخوارزمية فك المزج الخطي مع النسبة الحقيقية وحساب نسبة الخطأ لكل خوارزمية من خلال العلاقة التالية:

$$(19) \dots \dots \dots = \frac{\text{القيمة الحقيقية} - \text{القيمة المقاسة}}{\text{القيمة الحقيقية}}$$

الجدول (2): مقارنة نتيجة خوارزمية (NLU,LU) مع النسب الحقيقية:

نسبة عناصر الصورة الحقيقية المصابة بالسرطان الحاد	نسبة عناصر الصورة المصابة بالسرطان الحاد بنتيجة خوارزمية NLU	نسبة الخطأ باستخدام NLU	نسبة عناصر الصورة المصابة بالسرطان الحاد بنتيجة خوارزمية LU	نسبة خطأ LU
%14.84	%15.21	2.4%	%9.72	34.5%

نلاحظ من خلال نتائج الجدول (2) أن نسبة الخطأ الناتجة عن تطبيق خوارزمية فك المزج الخطي هي أقل بكثير من نسبة الخطأ الناتجة عن تطبيق خوارزمية فك المزج الخطي.

كما يظهر لنا الجدول (3) نسبة عناصر الصورة المعبرة عن السرطان مرحلة أولى والالتهاب الجلدي نتيجة تطبيق خوارزمية فك المزج الطيفي غير الخطي.


الجدول (3): نسبة عناصر الصورة المعبرة عن الحالات المدروسة نتيجة تطبيق NLU:

نسبة عناصر الصورة المعبرة عن الأمراض	النسبة الحقيقية	نتيجة خوارزمية NLU
نسبة عناصر الصورة المصابة بالسرطان (مرحلة أولى)	7.52%	7.11%(error=5.4%)
نسبة عناصر الصورة المصابة بالالتهاب الجلدي	5.65%	5.46%(error=3.3%)

نلاحظ من خلال الجدول (2) والجدول (3) أن خوارزمية فك المزج الطيفي غير الخطي تملك دقة ممتازة مع نسبة خطأ 2.4% من أجل السرطان الحاد ونسبة خطأ 5.4% من أجل السرطان مرحلة أولى، 3.3% من أجل الالتهاب الجلدي وبالمقابل كانت نسبة الخطأ الناتجة عن خوارزمية فك المزج الخطي كبيرة جداً (34.5%).

### 8.1.3 المنحنيات المكانية (Spatial profile) للعينة الأولى:

تم في الشكل (14) إجراء مقارنة بين خوارزمية NLU,LU مع القيم الحقيقية وذلك اعتماداً على القيم المكانية (Spatial profile) والتي تعبر عن مكان توضع كل عنصر صورة مصاب بالسرطان الحاد ولاحظنا بنتيجة هذه المقارنة أن مكان توضع عناصر الصورة الناتجة عن خوارزمية NLU قريب إلى حد كبير من القيم الصحيحة وهذا ما يعبر عن دقة هذه الخوارزمية بسبب التطابق الواضح بين المنحني المعبر عنها (الأحمر) والمنحني المعبر عن التوضع الحقيقي (الأسود) مع ملاحظة ابتعاد المنحني المعبر عن نتيجة خوارزمية LU الذي يظهر باللون البنفسجي عن القيم الحقيقية كما يبين الشكل (14).



الشكل (14) المنحني المكاني (Spatial profile)

- اللون الأسود يوضح التوضع المكاني الحقيقي لعناصر الصورة.
- اللون الأزرق يوضح التوضع المكاني الناتج عن التصنيف الخطي.
- اللون الأحمر يوضح التوضع المكاني الناتج عن التصنيف غير الخطي.


## 8.2 نتائج تطبيق (LU,NLU) على العينة (2):

تحوي العينة المبيّنة في الشكل (15) على منطقة جلدية مصابة بسرطان حاد وسرطان مرحلة أولى والتهاب جلدي:




الشكل(15): صورة لمنطقة جلدية مصابة

### 8.2.1 كشف المناطق المصابة بالسرطان الحاد باستخدام LU,NLU:



الشكل(16): نتيجة تطبيق خوارزمية LU,NLU على العينة2

حيث يمثل الشكل (16-A) نتيجة تطبيق خوارزمية فك المزج الخطي LU بينما يبيّن الشكل (16-B) نتيجة تطبيق خوارزمية فك المزج غير الخطي NLU. وبتطبيق التعتیب (thresholding) على المناطق المصابة بالسرطان الحاد عند قيمة عتبة 255 للقناة المعبرة عن السرطان الحاد نحصل على الشكل (17):



الشكل(17): نتيجة تطبيق عتبة قيمتها 255 لتمييز المناطق المصابة بالسرطان الحاد

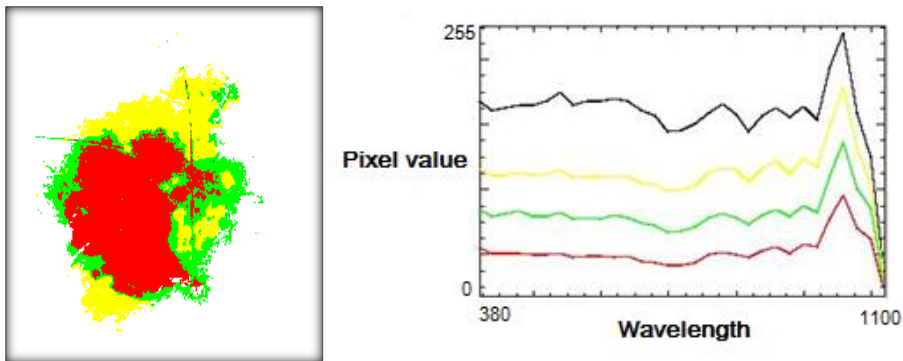
A: المناطق المصابة بالسرطان الحاد بتعتيب نتيجة خوارزمية LU عند قيمة عتبة 255 من أجل القناة الموافقة للسرطان الحاد.

B: المناطق المصابة بالسرطان الحاد بتعتيب نتيجة خوارزمية NLU عند قيمة عتبة 255 من أجل القناة الموافقة للسرطان الحاد.

## 8.2.2 حساب نسبة مكونات الصورة باستخدام (NLU):

تم تمييز مكونات الصورة حيث أن السرطان الحاد باللون الأحمر والسرطان مرحلة أولى باللون الاخضر والالتهاب الجلدي باللون الأصفر.

يبين الشكل (18) مكونات الصورة مع البصمة الطيفية الخاصة بها ( spectral profile) بعد تطبيق خوارزمية فك المزج غير الخطي:



الشكل(18): تصنيف مكونات الصورة باستخدام NLU مع البصمات الطيفية

ويبين الشكل (19) عزل كل عنصر نقى على حدى بعد تطبيق (thresholding) على نتيجة خوارزمية (NLU):



الشكل (19): عناصر الصورة الممتلئة للحالات المدروسة نتيجة تطبيق تعتیب على نتيجة (NLU) عند عتبة 255 من أجل كل قناة لونية موافقة.

تم في الجدول (4) مقارنة نسبة السرطان الحاد الناتجة عن خوارزمية فك المزج غير الخطي وخوارزمية فك المزج الخطي مع النسبة الحقيقية وحساب نسبة الخطأ وفق المعادلة (19) لكل خوارزمية ونلاحظ تفوق خوارزمية فك المزج غير الخطي على خوارزمية فك المزج الخطي.

الجدول (4): مقارنة نتيجة خوارزمية LU, NLU مع النسب الحقيقية:

نسبة عناصر الصورة المصابة بالسرطان الحاد بعد LU	نسبة عناصر الصورة المصابة بالسرطان الحاد بعد LU	نسبة الخطأ بعد NLU	نسبة عناصر الصورة المصابة بالسرطان الحاد بعد NLU	نسبة عناصر الصورة المصابة بالسرطان الحاد
26.35%	29.87%	2.11%	23.14%	23.64%

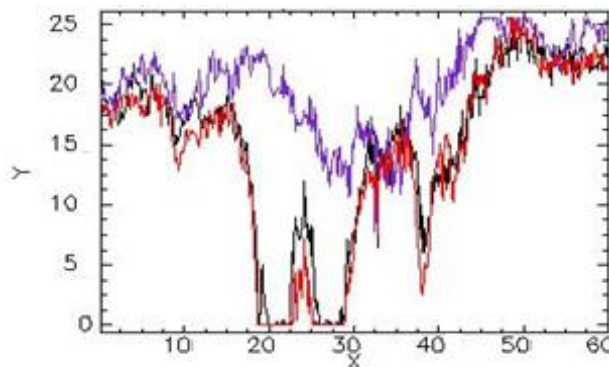
وقمنا من خلال الجدول (5) بحساب نسبة عناصر الصورة المعبرة عن السرطان مرحلة أولى والالتهاب الجلدي ومقارنتها مع النسبة الحقيقية من خلال تطبيق خوارزمية فك المزج الطيفي غير الخطي.

**الجدول (5):** نسبة عناصر الصورة المعبرة عن الأمراض المختلفة نتيجة تطبيق NLU:

نتيجة NLU	النسبة الحقيقية	نسبة عناصر الصورة المعبرة عن الأمراض
8.52%(error=6.3%)	9.1%	نسبة عناصر الصورة المصابة بالسرطان (مرحلة أولى)
7.67%(error=5.5%)	7.27%	نسبة عناصر الصورة المصابة بالالتهاب الجلدي

### 8.2.3 المنحنيات المكانية (Spatial profile) للعينة الثانية:


يبين الشكل (20) مقارنة المنحنيات المكانية (spatial profile) التي تمثل التوضع الصحيح لعناصر الصورة المصابة بالسرطان مع توضع عناصر الصورة المصابة بعد تطبيق خوارزمتي فك المزج الخطي وغير الخطي:



الشكل (20): المنحني المكاني Spatial profile

- اللون الأسود يوضح التوضع المكاني الحقيقي لعناصر الصورة.
- اللون الأزرق يوضح التوضع المكاني الناتج عن التصنيف الخطي.
- اللون الأحمر يوضح التوضع المكاني الناتج عن التصنيف غير الخطي

يبين الشكل (21) مجموعة من العينات الجلدية المصابة بسرطان جلدي تم تطبيق خوارزمية (NLU) عليها مع نسبة خطأ الخوارزمية في الكشف التي تم حسابها من خلال المعادلة (19):



الشكل (21) نسبة خطأ خوارزمية NLU على عينات جلدية

## 9. الاستنتاجات والملاحظات:

من خلال النتائج التي حصلنا عليها من تطبيق خوارزمية NLU على العينات الجلدية لاحظنا أن الخوارزمية تملك نسبة خطأ قليلة جداً (حوالي 7%) كما رأينا في جداول النتائج (1-2-3-4) مقابل نسبة خطأ كبيرة لخوارزمية فك المزج الخطي وهذا ما يثبت كفاءتها في عملية الكشف باستخدام فك المزج الطيفي غير الخطي.

وبالمقارنة مع الخوارزميات التي تم ذكرها في الدراسات المرجعية وجدنا أن دقة الكشف بالنسبة للخوارزميات المعتمدة على أجزاء من المجال الطيفي مثل خوارزمية نسب الحزم (Band ratio) التي تم تطبيقها على عينات من التفاح (دقة الكشف للكدمات 80.70% أي ما يعادل نسبة خطأ 19.3% ودقة الكشف لمرض الجرب 89.98% أي ما يعادل نسبة خطأ 10.02%) [6].

أما بالنسبة للدراسات المرجعية المعتمدة على كامل المجال الطيفي مثل خوارزمية التصنيف بالاعتماد على عدد  $k$  من المتوسطات (K-means) فكانت دقة الكشف 84.3% أي ما يعادل نسبة خطأ 15.7% من أجل خوارزمية K-means التقليدية، 90.6% أي ما يعادل نسبة خطأ 9.4% من أجل خوارزمية K-means المحسنة. [9].



تم من خلال الجدول (6) إجراء مقارنة نسبة الخطأ لكل من خوارزمية فك المزج الطيفي الخطي وغير الخطي وخوارزمية K-means، خوارزمية نسب الحزم.

الجدول (6): مقارنة نسبة الخطأ للخوارزميات:

الخوارزمية	نسبة الخطأ
فك المزج الطيفي غير الخطي (NLU)	<7%
فك المزج الخطي (LU)	34.5%
K-means	9.4%
نسب الحزم (band ratio)	19.3% للكدمات 10.02% لمرض الجرب

من خلال النتائج التي وجدناها في الجدول (6) نلاحظ أن خوارزمية فك المزج الطيفي غي الخطي هي الأكثر دقة.

## 10. الخاتمة:

تمكنا من خلال هذا البحث من تحليل المكعب الطيفي لصور حيوية تمثل أمراض جلدية حيث تم استخدام خوارزميتي فك المزج الطيفي الخطي وغير الخطي لتحديد الأماكن المصابة بالسرطان الجلدي وبعد مقارنة نتائج الخوارزميتين توصلنا إلى أن خوارزمية فك المزج غير الخطي هي الأكثر دقةً وذلك لأنها تدرس حالات الانعكاس المباشر وغير المباشر التي يتعرض لها الشعاع الضوئي أثناء مروره في النسيج الحي على عكس خوارزمية فك المزج الطيفي الخطي التي تدرس الانعكاس المباشر فقط واستطاعت خوارزمية فك المزج غير الخطي تصنيف المناطق المصابة وحساب نسبتها في الصورة بدقة حيث وضعنا من خلال النتائج أن نسبة الخطأ لم تتجاوز 7%.

المراجع:

- [1] 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.
- [2] Fang Q, Albdlaty R, 2016-Hyperspectral imaging and data analysis of skin erythema post radiation therapy treatment, McMaster university-biomedical engineering, Hamelton montaria, P182.
- [3] 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.
- [4] 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.
- [5] Rashmi S, Addamani S, Venkat S, and Ravikiran S-2014, Spectral Angle Mapper Algorithm for Remote Sensing Image Classification, **IJISSET - International Journal of Innovative Science, Engineering & Technology**, Vol. 1, 201-205.
- [6] 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.
- [7] Wng-Hee Lee, Moon S Kim, Hoonsoo Lee, Stephen R Delwiche, 2014-Hyperspectral near-infrared imaging for the detection of physical damages of pear, **Journal of Food Engineering**, Vol. 130, 1-7.
- [8] 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.

- [9] 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.
- [10] Tianxiao M, Runkui L, Jens C, Xianfeng S, 2018- Linear spectral unmixing using endmember coexistence rules and spatial correlation, **International Journal of Remote Sensing**, Vol.35, 3913- 3536.
- [11] 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.
- [12] Mou W, Min Z, Jie C, Susanto R,2019- Nonlinear Unmixing of Hyperspectral Data via Deep Autoencoder Networks, **IEEE Geoscience and Remote Sensing Letters** Vol. 16, 11467-1471.
- [13] Xiong W, Chein C, Kalpakis K, 2011- Fast Algorithms to Implement N-FINDR for Hyperspectral Endmember Extraction, **Proc.of Spie** Vol 7695, 1-12.
- [14] Yücel Çimtay, Hakkı Gökhan İlk,2018- A novel bilinear unmixing approach for reconsideration of subpixel classification of land cover, **Computers and Electronics in Agriculture**, Vol. 152, 126-140.

