

## إستخدام تحليل المكونات الرئيسية لأستخلاص المعلومات وتحسين النسجة في معالجة الصور الرقمية

د.وصفي طاهر صالح/لثوية الادارة والاقتصاد/جامعة صلاح الدين-اربيل  
رزكار مغنيد أحمد\*/لثوية الادارة والاقتصاد/جامعة صلاح الدين-اربيل

### المستخلص

يتناول البحث استخدام إحدى طرق متعدد المتغيرات في معالجة الصور الرقمية وهي تحليل المكونات الرئيسية (Principal Component Analysis) (PCA) لأستخلاص المعلومات المفيدة و تحسين النسجة من خلال تقليل الأبعاد الصورية. وتم استخدام نوعين من الصور، الأول : صور مجهرية متعددة لنواة خلية الحنطة، والثاني : صورة من الأقمار الصناعية لمدينة أربيل، إذ تم الأستنتاج بأنه باستخدام تحليل (PCA) يمكن إظهار معلومات عن (مكونات الخلية ونواتها ... الخ) ومعلومات عن (التغيرات الحاصلة في الغطاء الأرضي والمباني والغابات للمدينة )، فسرت المركبة الاولى بنسبة (٩٧.٦٧%) (٩٩.٧٣) على التوالي من التباين الكلي اي صورة أكثر وضوحاً للخصائص والمعلومات وبنسبة خسارة (ضوضاء) (٢.٣٣%) (٠.٢٣%)، وساهمت قيم تحميلات المكونات في توضيح توزيع عناصر الصورة (pixel) بحيث ان العناصر ذات الخصائص المتشابهة تظهر بشكل عنقود متجانس، ويمكن معرفة وتحديد مناطق ذات الأهمية (ROI) وهذا يفيد المختصين لزيادة فهم وتفسير الصورة. الكلمات الدالة:تحليل المكونات الرئيسية، معالجة الصور الرقمية، تحسين النسجة، مناطق ذات الأهمية.

### Using Principal Component Analysis to Extract Information and Texture Enhancement in Digital Image Processing

#### Abstract

This paper tackles with one of the multivariate methods in digital image processing, namely (Principal Component Analysis) (PCA) to extract useful information and Texture Enhancement by reducing the dimensions of images. A Multivariate Microscope Image of cell nucleus of wheat and satellite image of Erbil was used. It was concluded that, (PCA) can show information on (components and nucleus cell ... etc.) and information on (changes developments in land cover, buildings and forests of the city), the first component interpreted (97.67%) (99.73), respectively of the total variance, giving clearer image of characteristics and information with a (2.33%) (0.23%) loss

\* طالب دكتوراه.

(noise).The loading values of PC'S assisted in clarifying the distribution of image elements (pixels) so that elements with similar characteristics appear homogeneous cluster, that enables to identify and determine regions of interest (ROI), this supports specialists to increase the understanding and interpretation of the image.

Key Word: Principal Component Analysis (PCA), Image Processing, Texture Enhancement, Region of Interest in Image (ROI).

## ١- المقدمة

إن قدرة الخالق تتجلى في نعم الله التي أنعمها على البشر، ومن النعم التي لا تحصى نعمة النظر، وقدرة الإنسان على تمييز العديد من الألوان والمناظر ضمن مدى الرؤيا البشري، إذ تمتلك العين البشرية جملة من الأعصاب المرتبطة بالدماغ والتي تصدر الإشارات إلى الدماغ بمجرد النظر إلى الصورة لتمييز عناصر الصورة إلى مناطق متعددة وهذه المناطق يمكن تمييزها أما عن طريق الاختلاف باللون، الشكل، أو النسجة و ينبع الاهتمام بطرق معالجة الصور الرقمية في مجالين تطبيقيين أساسيين:-  
الأول: تحسين المعلومات التصويرية في مجال تفسيرها من قبل الإنسان.

الثاني: تحليل الصور لاستخلاص معلومات معينة منها بهدف فهمها وتفسيرها [الأسمرى، ٢٠١٠].

تعد معالجة الصور الرقمية من الحقول المهمة حيث لاقت نجاحا كبيرا واهتماما في العديد من التطبيقات وفي مجالات مختلفة ، منها الطبية والعسكرية والصناعية ، بالإضافة الى مجال الاتصالات والفضاء [A.K. Jain, 1989].

ان وسائل التحليل المجهرى Microanalysis يمكن ان تزودنا بعدة صور لنفس العينة، أي تسجيل عدة اشارات لمناطق ذات الأهمية (ROI) (Region of Interest in Image) فعندما تسجل أكثر من صورة لنفس العينة فإنه يصبح من الصعب حتى على نظام الرؤيا الاعتيادية تفسير كل بيانات المجموعة الصورية وهذا يعود الى سبب أن المعلومات المتعلقة بكل عنصر صورة (Pixel) هي في الحقيقة تتألف من N من الأبعاد N-Dimensional اذ ان N تمثل عدد الصور . لكل عنصر صورة ممكن أن يمثل في هذا المجال بالموجه الذي إحداث ياته في N من القيم الرمادية (Gray Value) لـ N من الصور المختلفة [Bonnet, N & Trebbia,P.C. 1992].

$$f(x, y) = [I_1(x, y), I_2(x, y), \dots, I_N(x, y)] \dots \dots \dots (1)$$

ومن أهم الدراسات والبحوث التي أهتمت بهذا الموضوع هي:

في عام ١٩٧٩ تطرق كل من (Jenson, L.& Waltz, E.) الى طريقة (PCA) لتقليل المعلومات الفائضة التي تؤدي إلى وصف بيانات متعددة الأبعاد المرتبطة في أول مركبة رئيسية [Jenson, L. & Waltz, E., 1979].

في عام ١٩٨١ قدم (Heel, M.V & Frank, J.) التحليل المتناظر في تحليل صور مجهرية لخلايا سرطان البحر [Heel & Frank, 1981].

في عام ١٩٨٧ (Fuang, T & Ledrew, E.) أستخدما تحليل المركبات الرئيسية لكشف التغيرات الحاصلة في الغطاء الأرضي مع زمن متعدد لبيانات القمر الصناعي متعدد الأطياف [Fuang & Ledrew, 1987].

وفي عام ١٩٩٦ استخدم (Al-Ani, L.A.) صور الأقمار الصناعية متعددة الحزم لمنطقة الرمادي غرب العراق وقد طبق أسلوب (PCA) لتحسين الصور [Al-Ani, 1996].

وفي عام ١٩٩٧ بين كل من (Baronti, & S.Casini, A) انه يمكن استخدام تحليل المركبات الرئيسية لغرض تركيز معنوية المعلومات لمجموعة صور (ألواح زيتية من قماش وصور فوتوغرافية ) [Baronti & Casini, 1997].

وفي عام ٢٠٠٤ أقترح (Yokoo, T.) بعض الطرائق لتحليل متعدد المتغيرات الأحصائي في مجال بيانات التصوير لنشاط خلايا الدماغ ( Generalized Indicator Function Analysis ) [Yokoo, 2004].

وفي عام ٢٠٠٦ قدم كل من (الناصر والراوي) بحثهما ( استخدام بعض أساليب متعدد المتغيرات لتقليل الأبعاد الصورية في تطبيقات علوم الحياة) [الناصر والراوي، ٢٠٠٦]

فالهدف الرئيسي للبحث هي تطبيق إحدى طرق تحليل متعدد المتغيرات وهي تحليل المكونات الرئيسية (PCA) (Principal Component Analysis) في تحليل ومعالجة نوعين من الصور المتعددة لتقليل أبعاد البيانات الصورية (Data Reduction) وتحسين النسجة (Texture Enhancement) واستخلاص المعلومات المهمة التي يمكن تفسيرها من قبل المختصين.

## ٢- الجانب النظري

### ٢-١ تعاريف ومصطلحات

#### ١- الصورة Image

الصورة في عملية معالجة الصور الرقمية تعني أنها دالة ذات بعدين two-dimensional (function)  $f(x,y)$  حيث  $x$  ،  $y$  هما إحداثيات مستوية، وتسمى قيمة الدالة  $f$  عند أي زوج من الإحداثيات بالمستوي الرمادي (gray level) أو الشدة (intensity) عند هذه النقطة، ويمكن تمثيل  $f(x,y)$  بمكونين أساسيين:

- (١) كمية الضوء الساقطة على المنظر الذي ننظر اليه، ونمثلها بـ  $i(x,y)$  (illumination).  
 (٢) كمية الضوء الصادرة من ذلك المنظر ونمثلها بـ  $r(x,y)$  (reflectance).  
 ومن خلال التعابير الرياضية فإن :

$$f(x,y)=i(x,y)*r(x,y).....(2)$$

حيث أن:

$$0 < f(x,y) < \infty , 0 < i(x,y) < \infty , 0 < r(x,y) < 1$$

تتحدد طبيعة  $i(x,y)$  بطبيعة مصدر الضوء بينما تتحدد طبيعة  $r(x,y)$  بخصائص الأجسام المصورة [الأسمرى، ٢٠١٠].

## ٢- عنصر الصورة Pixel

كل مساحة صغيرة يشغلها رقم في الصورة الرقمية يطلق عليها النقطة الصورية (وهي أصغر وحدة في الصورة الرقمية)، وتدل هذه النقطة على الأحداثيات الحيزية (Spatial Coordinate) وأن حجم المساحة التي تشغلها النقطة الصورية تسمى بالدقة الحيزية لعنصر الصورة (Pixel Spatial Resolution) ويتراوح ذلك من (نانومتر- وحدة قياس مجهرية) في صور المجهر الى عشرات الكيلومترات في صور الأقمار الصناعية، وان كل مربع صغير من المصفوفة التي تشكل الصورة الرقمية يحتوي على معلومة مهمة يحدد قيمة السويات الرمادية عند تلك النقطة، إن عناصر مصفوفة كهذه تسمى عناصر الصورة (image element , pixel) [عمار، ١٩٩٢].

## ٣- أنواع الصور الرقمية [عبدالقادر، ٢٠٠٣]

### أ- الصور الثنائية Binary Images

تمثل هذه الصور بخلية واحدة فقط فكل وحدة صورية لها تكون قيمتها ( 1 أو 0 ) أي أبيض أو اسود وتخزين الصورة على هيئة مصفوفة ثنائية الأبعاد من الأصفار والواحدات.

### ب- الصور ذات التدرج الرمادي Gray – level Images

ظهرت هذه الصور بعد ظهور الصور الثنائية ، وهي صور أحادية اللون أيضاً لكنها تتكون من تدرجات رمادية تعطي معلومات عن شدة الإضاءة فقط ولا توجد فيها معلومات لون عدد الخلايا المستخدمة ( Bit ) لتمثيل كل وحدة صورية تبين عدد مستويات شدة الإضاءة ، والصور الشائعة التي تستخدم ( 8 bits ) بإمكانها عرض ( 256 ) تدرجاً لونياً.

### ج- الصور الملونة Color Images

تتكون كل وحدة صورية من جمع الألوان الأساسية الثلاثة (الأحمر - الأخضر - الأزرق) ودمج شدة الإضاءة لهذه الألوان الثلاثة يتم الحصول على اللون المطلوب (RGB)، ويعرف بالصور الملونة (24 bit color image).

#### د- الصور متعددة الأطياف (Multispectral images)

تحتوي هذه الصور على معلومات خارج حدود الرؤية الطبيعية للإنسان إذ تتضمن الأشعة تحت الحمراء (infrared)، والأشعة فوق البنفسجية (ultraviolet) والأشعة السينية (x-ray) فضلا عن بيانات الرادار (radar data) وغيرها.

#### ٤- بعض المقاييس الأحصائية لوصف للصور الرقمية [الأسمرى، ٢٠١٠]

##### أ- الوسط الحسابي للصورة Mean of Image

هي عبارة عن معدل شدة التدرج الرمادي للصور فإذا كانت الصورة رمادية شدته بين (٠-٢٥٥) فإن قيمة المتوسط القريب من الصفر تعني أن الصورة قريبة من السواد (Dark) و القيمة القريبة من (٢٥٥) تعني أن الصورة السطوع (Brightness).

##### ب- الانحراف المعياري للصورة Standard Deviation of Image

هو عبارة (عن درجة التباين للصورة) وهي احد الخصائص المهمة في معالجة الصور الرقمية ويتوقف على عاملين:

١- الاختلاف في كمية الأشعة المنعكسة من الأشكال.

٢- مقدار التعرض للضوء والمحاليل المستخدمة لإظهار الصور.

إن الصور ذات التباين العالي تدل على (وجود فروق كبيرة في المستويات الرمادية من ثم تغيرات كبيرة في الكثافة في الصورة)، والصور ذات التباين المنخفض تدل على (وجود فروق صغيرة في المستويات الرمادية من ثم تغيرات صغيرة في الكثافة في الصورة).

##### ج- المدرج التكراري للصورة Histogram of Image

المدرج التكراري للصورة تكون كالأتي (المحور X : تمثل المستويات الرمادية للصور والتي تقع مداها بين ٠-٢٥٥) و(المحور Y: تمثل التكرارات لعناصر الصورة pixel) حيث يفيدنا شكل التوزيع التكراري في تحديد خصائص الصورة مثل السطوع (Brightness) والسواد (معتمة) (Dark) أو التباين العالي (High Contrast) وكذلك يعطينا معلومات عن المدى التي تتجمع فيه وحدات الصورة، ويستخدم (الألتواء-Skewness) في تحليل الصور الرقمية لمعرفة مدى تماثل منحنى التوزيع التكراري للصورة أي (التواء موجب أو سالب أو متماثل) وكذلك تستخدم التقلطح (Kurtosis) في

الصور الرقمية لمقارنة انحراف قمة منحني التوزيع التكراري عن قمة المنحنى الطبيعي (مفلطح أو مدبب أو معتدل).

### ٥- الارتباط بين الصور Correlation between images

إذا كان لدينا صورة رقمية  $f(x,y)$  ذات قياس  $M \times N$ ، افترض أننا نرغب في تحديد ما إذا كانت هذه الصورة تحتوي على منطقة مشابهة لمنطقة ما ولتكن  $w(x,y)$  ذات قياس  $J \times K$  حيث أن  $J < M$  و  $K < N$ . إن إحدى الطرائق التي تستعمل في أغلب الأحيان لحل هذه المسألة هي إقامة ترابط بين  $f(x,y)$  و  $w(x,y)$  ويعطى الترابط بين هاتين المعادلتين الحقيقيتين بالمعادلة الآتية:

$$R(m,n) = \frac{\sum_x \sum_y [f(x,y) - \bar{f}(x,y)][w(x-m,y-n) - \bar{w}]}{[\sum_x \sum_y [f(x,y) - \bar{f}(x,y)]^2 \sum_x \sum_y [w(x-m,y-n) - \bar{w}]^2]^{1/2}} \dots\dots\dots(3)$$

حيث أن:  $m=0,1,2,\dots,M-1$  و  $n=0,1,2,\dots,N-1$

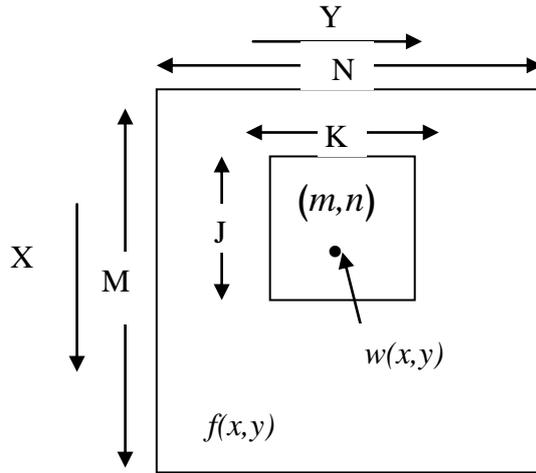
$w$ : هو متوسط الشدة للنافذة (تحتسب هذه القيمة مرة واحدة).

$\bar{f}(x,y)$ : هي متوسط القيمة لـ  $f(x,y)$  في المنطقة المتطابقة مع  $w(x,y)$ ، وتؤخذ المجاميع ضمن الأحداثيات المشتركة بين كل من  $f$  و  $w$ .

إن الأجراء موضح في الشكل (١) فمن أية قيمة لـ  $(m,n)$  داخل  $f(x,y)$  نطبق المعادلة (٣) للحصول على قيمة واحدة لـ  $R$ ، ومع تغير  $(m,n)$  تتحرك  $w(x,y)$  في أرجاء منطقة الصورة ونحصل بالتالي على الدالة  $R(m,n)$  بعدها تدل القيمة العظمى لـ  $R(m,n)$  على الموضع الذي طبقت فيه  $w(x,y)$  الصورة  $f(x,y)$  على أفضل وجه. [المولى، ٢٠٠٧] و [عمار، ١٩٩٢].

### ٦- تحسين النسجة Texture Enhancement

يعتبر النسيج من المعلومات المكانية (Spatial Informartion) المهمة في تطبيقات معالجة الصور الرقمية، ويعبر عنه بمقدار التباين في تدرجات اللون الرمادي في وحدة مساحة الصورة، وعندما يكون التباين قليلاً يقال أن النسجة ناعمة أو متجانسة بينما يطلق على النسجة بأنها خشنة عندما يكون التباين كبيراً لتميز الظواهر التي تشكلها ومن صفات الظواهر المكانية حجم الظاهرة والظل وتدرجات اللون الرمادي للصورة [Lillesand & Kiefer 1987].

الشكل (١) الأرتباط بين  $w(x,y)$  و  $f(x,y)$  في نقطة معينة  $(m,n)$ 

## ٢-٢ مفهوم تحليل المكونات الرئيسية في معالجة الصور الرقمية

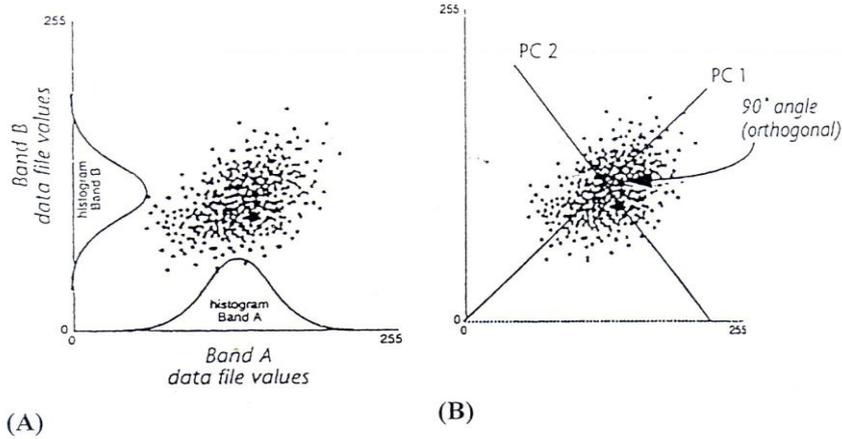
إن تقنية تحليل المكونات الرئيسية هي عبارة عن وسيلة رياضية تستخدم في كثير من الدراسات الأحصائية للتبسيط من مجموعات البيانات الهائلة عبر تحويل عدد من المتغيرات ذات الارتباط العالي إلى عدد أقل من المتغيرات لا يرتبط بعضها ببعض وتسمى المكونات الرئيسية، إن المبدأ الأساسي المستخدم لإجراء هذا التحويل هو تحويل البيانات خطياً من نظام إحداثيات إلى نظام إحداثيات آخر بحيث يكون التباين الأعظم لأي إسقاط للبيانات على المحور الأول لنظام الإحداثيات الجديد ويسمى هذا المحور المكون الأساسي الأول، كما يقع التباين الأعظم الذي يليه على المحور الثاني الجديد [Richards & Jia, (2006)]، وفي معالجة الصور الرقمية يمكننا استخدام تحليل (PCA) لتقليل المعلومات المكونة في مجاميع الصور إلى معلومات صورية مختزلة في موجهات المركبات الرئيسية تحتوي على خصائص إحصائية والذي يؤدي بدوره سهولة عملية تفسير الصورة [الناصر والراوي ، ٢٠٠٦]، عليه يمكن تطبيق تقنية (PCA) في معالجة بعض أنواع الصور الرقمية نذكر منها:

الصور الرقمية ذات الحزم الطيفية المتعددة (Multi-spectral Image).

الصور الرقمية ذات النطاق الطيفي الفردي ولكنها مأخوذة لنفس الموقع في أوقات مختلفة.

الصور الملونة (RGB).

صور الرنين المغناطيسي (MRI).



الشكل (٢) آلية تطبيق تقنية (PCA) (A): توزيع بيانات الحزمتين (B): تطبيق تقنية (PCA)

عندما يتم رسم الشكل الانتشاري (Scatter Plot) للأعداد الرقمية لأي حزمتين من الطيف فإن معظم النقاط تقع على الخط القطري (Diagonal Line) أو قريباً منه كما هو موضح في الشكل (٢) وهذا يدل بالمعنى الإحصائي أن هناك ارتباط عالٍ بين بيانات الحزمتين ويستتبع ذلك أيضاً وجود تكرار في البيانات، وتستخدم تقنية المكونات الرئيسية لإعادة توزيع البيانات على محاور جديدة وبالتالي تخفيض الكمية الهائلة من البيانات الزائدة، فتصبح بيانات الحزم الطيفية غير مرتبطة مما يسهل عملية تفسير وتصنيف (Classification) الصور الرقمية [El Hassan, 2007].

## ٢-٣ الأساس الرياضي Mathematical Bases

[Gonzales & Woods 2,008] و [عمار، ١٩٩٢]

كمدخل للمسألة افترض أن أبعاد الصورة  $f(x,y)$  هي  $N \times N$  قد ارسلت  $M$  من المرات على قناة إتصال ما ، ولأن أي قناة فيزيائية معرضة لإضطرابات عشوائية فإن مجموعة الصور المستقبلية  $\{f_1(x,y), f_2(x,y), \dots, f_m(x,y)\}$  تمثل مجموعة إحصائية تتحدد خواصها بخصائص القناة وطبيعة الاضطراب، إن مجموعة الصور المرسله لنفس المشهد عن طريق محبس فضائي أو ميكروسكوب أو شريط سينمائي تعطي مثالا لهذه المجموعة. في هذه الحالة تتخضع دقة الصور بواسطة الاضطرابات الجوية أو الألكترونية والضجيج الكهربائي بين المرسل والمستقبل، يمكن التعبير عن كل عينة صورة  $f_i(x,y)$  بمتجه ذي بعد واحد  $X_i$  لمتجه الأبعاد  $N^2$ -Dimensional Vector كما يلي:

$$X_i = \begin{pmatrix} X_{i1} \\ X_{i2} \\ \cdot \\ \cdot \\ \cdot \\ X_{iN^2} \end{pmatrix} \dots\dots\dots(5)$$

حيث أن:

$x_{ij}$ : تشير إلى  $j$ th من المركبات للمتجه  $i$ .

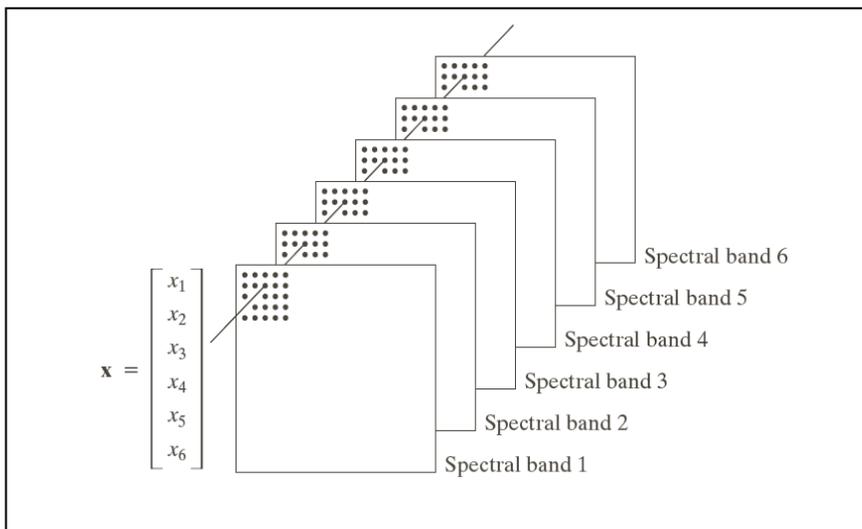
إن إحدى الطرائق لبناء هذا المتجه هي أن تشكل  $N$  مركبة الأولى من  $x_i$  من الصف الأول من  $f_i(x,y)$  أي أن:

$$[x_{i1}=f(0,0), x_{i2}=f(0,1), x_{i3}=f(0,2), \dots, x_{iN}=f(0,N-1)]$$

والمجموعة الثانية من الـ  $N$  مركبة من الصف الثاني، وهكذا، كمثال لذلك في الشكل (٣) نلاحظ الحصول على ستة عناصر موافقة لنفس العنصر لتشكيل متجه العنصر كأفترض إذا كان لدينا (٦) صور رقمية.

هناك طريقة أخرى وهي أن نستعمل أعمدة  $f(x,y)$  بدلاً من الصفوف، لذلك بالإمكان تحديد متوسط المتجه بالمعدل حيث أن:

$$m_x = E(X) \dots\dots\dots(6)$$



الشكل(3)الحصول على ستة عناصر موافقة لنفس العنصر لتشكيل متجه العنصر

وتعرف مصفوفة التباين والتباين المشترك للمتجهات X كما يأتي:

$$C_x = E\{(x - m_x)(x - m_x)'\} \dots \dots (7)$$

يمكن تقريب المعادلات أعلاه إلى صورة معاينة بما يأتي:

$$m_x \cong \frac{1}{\mu} \sum_{i=1}^{\mu} x_i$$

$$C_x \cong \frac{1}{\mu} \sum_{i=1}^{\mu} (x - m_x)(x - m_x)'$$

$$C_x \cong \frac{1}{\mu} \left[ \sum_{i=1}^{\mu} (x_i x_i') \right] - m_x m_x'$$

حيث أن:

X لها حجم  $N^2$ .

$C_x$  ستكون مصفوفة  $N^2 \times N^2$ .

عناصر  $C_{ij}$  لـ  $C_x$  تمثل (التباين بين نقاط الصورة).

عناصر القطر  $C_{ii}$  تمثل (التباين لكل صورة).

لنفرض أن  $a_i$  و  $\lambda_i$  ،  $i=1,2,3,\dots,N^2$  تمثل (المتجهات المميزة والقيم المميزة) لـ  $C_x$ ، إن مصفوفة

لـ  $C_x$  تعطي بالشكل الآتي:

$$A = \begin{bmatrix} a_{11} & a_{12} & a_{13} & \dots & a_{1N^2} \\ a_{21} & a_{22} & a_{23} & \dots & a_{2N^2} \\ \vdots & \vdots & \vdots & \dots & \vdots \\ \vdots & \vdots & \vdots & \dots & \vdots \\ a_{N^2 1} & a_{N^2 2} & a_{N^2 3} & \dots & a_{N^2 N^2} \end{bmatrix}$$

التحويل صفوفها هي المتجهات المميزة (Eigen Vector)

حيث ان:

$a_{ij}$ : هي المركبة  $i$  للمتجه المميز رقم  $j$ .

A : مصفوفة  $N \times N$  ومتعامدة أي أن  $(A^{-1} = A')$  والصفوف لـ A هي N من المتجهات المميزة

القياسية (Normalized Eigen Vector) لـ  $C_x$ .

عند تطبيق تحويل المكونات الرئيسية (تحويل هوتيلينغ) ببساطة من ضرب متجه صورة ممرکز  $(x - m_x)$  بـ

A للحصول على متجه صورة (Eigen Image) جديد لـ y أي:

$$\dots \dots \dots (8) Y = A(X - m_x)$$

للمعادلة (8) عدة خواص مهمة في معالجة الصور الرقمية:

$$1)) m_y = 0$$

$$\begin{aligned}
m_y &= E(y) \\
&= E\{A(x - m_x)\} \\
&= AE\{x\} - Am_x \\
&= 0
\end{aligned}$$

$$2)) C_y = AC_x A'$$

بالتعويض سيكون لدينا:

$$\begin{aligned}
C_y &= E\{(Ax - Am_x)(Ax - Am_x)'\} \\
&= E\{A(x - m_x)(x - m_x)'A'\} \\
&= AE\{(x - m_x)(x - m_x)'\}A' \\
&= AC_x A'
\end{aligned}$$

علماً ان:

$$C_y = AC_x A' = \begin{bmatrix} \lambda_1 & 0 & \dots & 0 & 0 \\ 0 & \lambda_2 & \dots & 0 & 0 \\ \vdots & \vdots & \dots & \cdot & \cdot \\ \vdots & \vdots & \dots & \cdot & \cdot \\ 0 & 0 & \dots & \cdot & \lambda_{N^2} \end{bmatrix}$$

إن أهمية هذه الخاصية هي أن عناصر  $y$  غير مترابطة لأن قيم حدود خارج القطر الرئيسي تساوي الصفر وحيث أن  $\lambda_1, \lambda_2, \dots, \lambda_{N^2}$  (تباين المركبات الرئيسية) هي قيم مميزة لـ  $C_y$  ترتب بالشكل (  $\lambda_1 > \lambda_2 > \dots > \lambda_i$  ) تمثل تباين الصورة، عليه فان أصغر قيمة مميزة ستحتوي فقط على المعلومات الخاصة بـ (الضوضاء-Noise) في الصورة، تسمى مجموعة عناصر القطر لمصفوفة التباين والتباين المشترك أثراً (Trace) يمثل مجموعة كل الجذور المميزة لمصفوفة التباين، لذلك فان نسبة مجموع اول جذور لأثر أول مصفوفة تباين سيكون مقياس النسبة المئوية للطاقة ممثلاً بأول متجه مميز [Otsu, 1984 أي:

$$T.V = \sum_{i=1}^{N^2} \lambda_i = \sum_{i=1}^{N^2} S_{xi}^2 \dots\dots\dots(9)$$

حيث أن:

$S_{xi}^2$  : تمثل تباينات حزمة الطيف اللوني الأصلية للتحويل المتعامد.

إن مسألة إيجاد المكون الأساسي (  $PC_i$  ) بأعلى تباين يمكن صياغتها بالشكل التالي [C. Radhakrishna rao, 1973]:

$$\begin{aligned}
&Max(a'X'Xa)\dots\dots\dots(10) \\
&s.t. \quad a'a = 1
\end{aligned}$$

حيث أن:

$$V(PC_i) = (a'X'Xa) \dots (11)$$

ويمكن وضع المعادلة السابقة الخاضعة للشرط  $(a'a=1)$  باستخدام صيغة معادلة لاكرانج و كما يأتي [N.R. Draper & Smith, 1980]:

$$\begin{aligned} L &= \text{Objevtive function} - \lambda (\text{Constant}) \dots (12) \\ &= f(a) - \lambda[g(a)] \quad , g(a) = a'a - 1 \\ &= a'x'xa - \lambda(a'a - 1) \end{aligned}$$

و بعد أخذ المشتقة الجزئية نسبةً إلى a :

$$\frac{\partial L}{\partial a} = 2x'xa - 2\lambda a$$

و بمساواة المشتقة بالصفر :

$$(x'x)a - \lambda a = 0 \dots (13)$$

و بالضرب المسبق بقيم a في العلاقة (13) ينتج :

$$\begin{aligned} a'x'xa - \lambda a'a &= 0 \\ a'x'xa - \lambda &= 0 \end{aligned}$$

خاصة وإن:  $a'a = 1$

$$\therefore a'x'xa = \lambda$$

وهذا ما يوضح أن تباين المكون الأساسي وهو الجذر المميز له يساوي معامل لاكرانج و هكذا يمكن ترتيب المكونات الأساسية حسب تباينها بحيث:  $\lambda_1 > \lambda_2 > \dots > \lambda_m > 0$  ، إن القيد المفروض على المكونات الأساسية  $(a'a=1)$  (يعني بعبارة أخرى أن المتجهات  $a_i$  و  $a_j$  - لكل قيم  $i, j = 1, 2, \dots, m, \dots, i \neq j$  متعامدة، هذه الخاصية يمكن أن تتحقق إذا جعلنا  $a_{ij}$  هي قيم المتجهات المميزة المرافقة للجذور المميزة.

ويمكن إعادة بناء X من Y في المعادلة (٨) بأستعمال العلاقة التالية علماً أن المصفوفة A هي مصفوفة NxN ومتعامدة أي أن  $(A^{-1} = A')$ :

$$\begin{aligned} Y &= A(X - m_x) \\ Y &= AX - Am_x \\ AX &= Y + Am_x \quad * A' \\ A'AX &= A'Y + A'Am_x \\ X &= A'Y + m_x \dots (14) \end{aligned}$$

وافترض اننا بدلاً من استعمال جميع المتجهات المميزة (Eigen Vector)  $C_x$  ل A من الـ K منتجاً مميزاً المتعلقة بالقيمة المميزة الكبرى، سيكون المتجه Y عندئذ بـ -K بعداً وإعادة البناء التي أعطيت بالمعادلة (١٤) سوف لن تكون دقيقة.

لتكن:

$$\hat{X} \cong A'_K Y + m_x \dots \dots \dots (15)$$

تمثل التقريب (Approximate) لـ  $X$  الذي حصلنا عليه بمصفوفة التحويل  $AK$  المؤلف من أول متجه مميز من  $C_x$  و عليه فإن متوسط مربع الأخطاء (MSE) بين  $X$  و  $\hat{X}$  يعطى بالصيغة الآتية:  
تمثل التقريب (Approximate) لـ  $X$  الذي حصلنا عليه بمصفوفة التحويل  $AK$  المؤلف من أول متجه مميز من  $C_x$  و عليه فإن متوسط مربع الأخطاء (MSE) بين  $X$  و  $\hat{X}$  يعطى بالصيغة الآتية:

$$MSE = \sum_{j=1}^{N^2} \lambda_j - \sum_{j=1}^K \lambda_j \dots \dots \dots (16)$$

$$= \sum_{j=K+1}^{N^2} \lambda_j$$

من المعادلة (١٦) نرى أن (MSE=0) في حالة (K=N<sup>2</sup>) أي (إذا كانت جميع المتجهات المميزة مستعملة في التحويل) علماً أننا لئلا نأخذ جميع المتجهات المميزة في التحليل بل نعتمد على المتجهات المميزة الكبرى (المعنوية-الأكبر من الواحد الصحيح-) التي تفسر التباين الكلي لصور المكونات لأن فيها المعلومات الضرورية والمهمة وان خاصية تحزيم (Packing) الطاقة لتحويل المركبة الرئيسية هذا تظهر نفسها كإزدياد هام في التباين في الصور الأولى مع تباين يتناقص على وتيرة واحدة بشكل رتيب (Monotonically) مع تناقص تباينها، فإن من شكل المعادلة (١٦) يبين أن الخطأ يخفض إلى حده الأدنى بإختيار متجهات مميزة متعلقة بالقيم المميزة الكبرى، وهكذا فإن تحويل المكونات الرئيسية تح ويل أمثل بمعيار مربع الأخطاء الصغرى (Least square-error).

### ٣- الجانب التطبيقي

في مجال معالجة الصور الرقمية تعد الصور مصادر البيانات ذات بعدين كما اشرنا سابقاً وقد تم في هذا البحث استخدام نوعين من الصور للتطبيق هما:

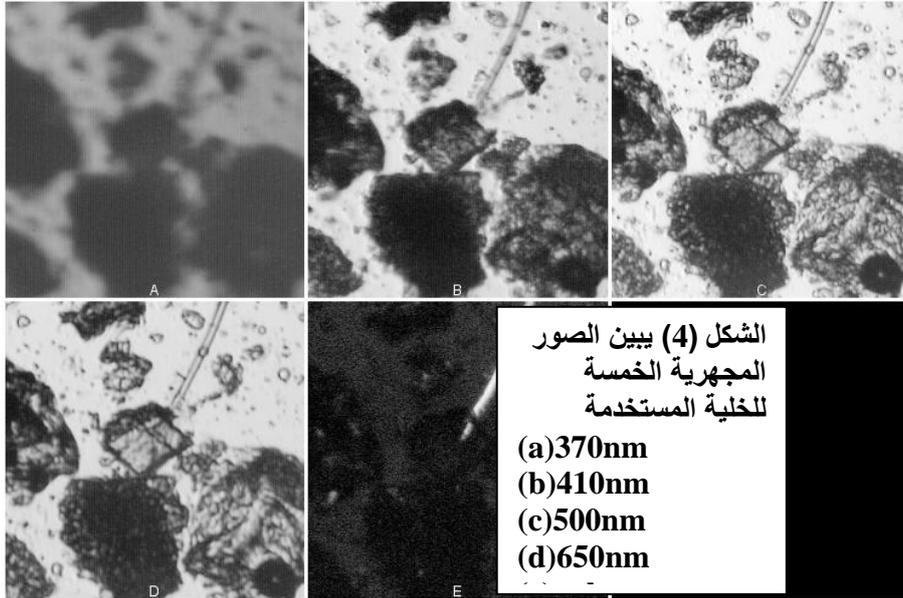
#### ٣-١ التطبيق على صور مجهرية متعددة

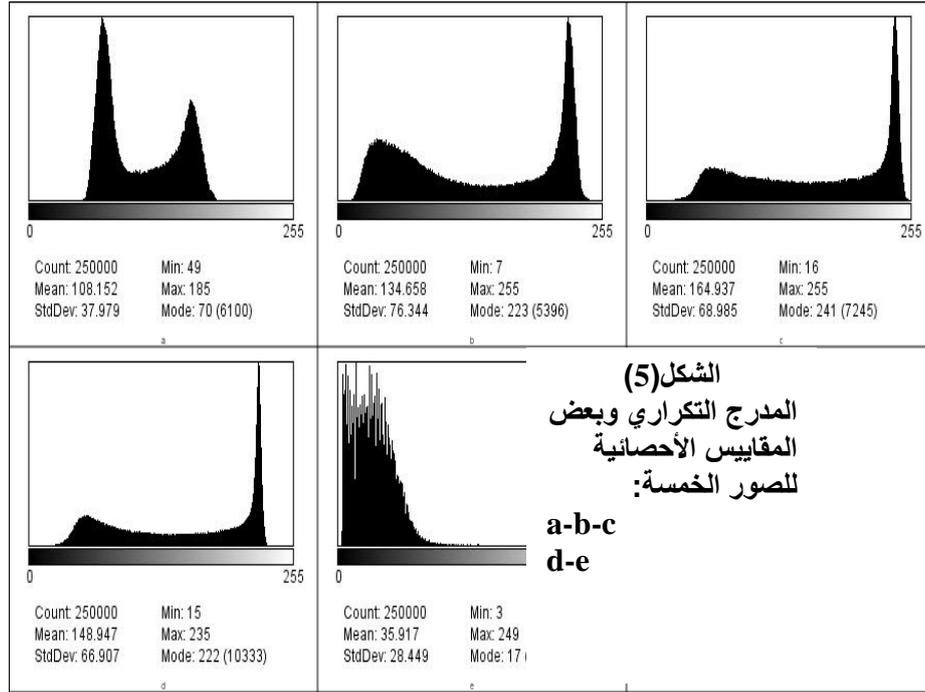
التطبيق على صور مجهرية متعددة (Multivariate Microscope Image) لنواة خلية الحنطة (wheat Cells) إخذت لنفس الموقع وواقع (٥) صور بأستخدام كاميرة خاصة من نوع (DAGE MTI CCD72 TV) وتم قياس كل صورة (500 x 500 pixels) و خزنها بنوع TIFF(8bit) وتم أخذ الصور من موقع جامعة [McMaster University,2010]، كما هو موضح في الشكل (٤) والمشهد في جميع الصور له أبعاد (٠.٥٥ مليمتر × ٠.٥٥ مليمتر).

وتم استخدام برنامج (V:7.6-Matlab) للتحليلات الأحصائية للصور الرقمية و تطبيق الخوارزمية المقترحة.

### ٢-٣ الأحصاء الوصفي للصور المجهرية المتعددة

يمكن ان نلاحظ في الشكل (٥) بأن التوزيعات التكرارية للصور (b,c,d) متشابه فيما بينهم ومختلفة مع التوزيعات التكرارية للصور (a,e) وهي واضحة عند ملاحظة الصور في الشكل (٤) وكذلك يعطينا معلومات عن المدى التي تتجمع فيه وحدات الصورة فمثلاً نلاحظ الشكل (e) بأن مدى التوزيع التكراري له تقع وتتركز في المنطقة القاتمة (Dark) من السلم الرمادي وهكذا لبقية الصور وبشكل عام لا يمكن استخلاص المعلومات بالعين المجردة بدون معالجتها.





ويمكن ايجاد بعض المقاييس الأحصائية للصور الخمسة كما هو موضح في الجدول (١) والتي يمكن تفسيرها كالآتي:

### جدول (١)

#### المقاييس الأحصائية للصور الرقمية المتعددة

Statistical measurement	Image a	Image b	Image c	Image d	Image e
Mean	108.15	134.66	164.94	148.95	35.92
S.E of Mean	0.08	0.15	0.14	0.13	0.06
Median	96.00	130.00	178.00	162.00	32.00
Mode	70.00	223.00	241.00	222.00	17.00
Std. Deviation	37.98	76.34	68.99	66.91	28.45
Variance	1442.38	5828.39	4758.94	4476.58	809.32
Skewness	0.29	-0.03	-0.32	-0.27	3.19
Kurtosis	-1.52	-1.66	-1.42	-1.51	16.91
Range	136.00	248.00	239.00	220.00	246.00
Minimum	49.00	7.00	16.00	15.00	3.00
Maximum	185.00	255.00	255.00	235.00	249.00

حيث نلاحظ ان الوسط الحسابي للصور (b,c,d) لها متوسطات متقاربة (١٤٨.٩٥، ١٦٤.٩٤، ١٣٤.٦٦) من حيث شدة التدرج الرمادي وأن الصورة (e) له أقل متوسط (٣٥.٩٢)

أي الصورة قريبة من السواد (Dark)، بالنسبة للانحراف المعياري للصور يمكن ملاحظة أن أقل قيمة للانحراف المعياري هي للصورة (e) (٢٨.٤٥)، وأعلى قيمة له هي للصورة (b) حيث بلغت (٧٦.٣٤) وأن الصور ذات التباين العالي تدل على (وجود فروق كبيرة في المستويات الرمادية من ثم تغيرات كبيرة في الكثافة في الصورة)، والصور ذات التباين المنخفض تدل على (وجود فروق صغيرة في المستويات الرمادية من ثم تغيرات صغيرة في الكثافة في الصورة)، نلاحظ أن الصورة (e) له التواء موجب (S.K=3.19) والصور الأخرى لديهم التواء سالب ضعيف وقريبة من الصفر، ويمكن ملاحظة تفلطح الصور ايضاً ان الصورة (e) له تدبب كبير (١٦.٩١) مقارنة بالصور الأخرى.

### ٣-٣ تحليل الارتباط للصور المجهرية المتعددة

إن لتحليل الارتباط في معالجة الصور الرقمية أهمية كبيرة لمعرفة (نوع وقوة) العلاقة بين الصور الرقمية من جهة و اعتماد تحليل المكونات الرئيسية (PCA) اساساً على مصفوفة الارتباط من جهة اخرى، وان تحليل (PCA) لايعمل دائماً على خفض عدد كبير من المتغيرات الأصلية إلى عدد صغير من المتغيرات المحولة، وفي الواقع إذا كانت المتغيرات الأصلية غير مرتبطة فإن (PCA) لا يضيف شيئاً، وأفضل النتائج يمكن الحصول عليها من التحليل هو عندما تكون المتغيرات الأصلية عالية الارتباط إيجابياً أو سلبياً [ابوعمة، ٢٠٠٠].

عليه تم ايجاد مصفوفة الارتباط بين جميع الصور المجهرية المتعددة ورسم الشكل الانتشاري (Scatter Plote) لجميع الحالات الممكنة بين الصور الخمسة كما هو موضح في الجدول (٢) والشكل (٦):

#### جدول (٢)

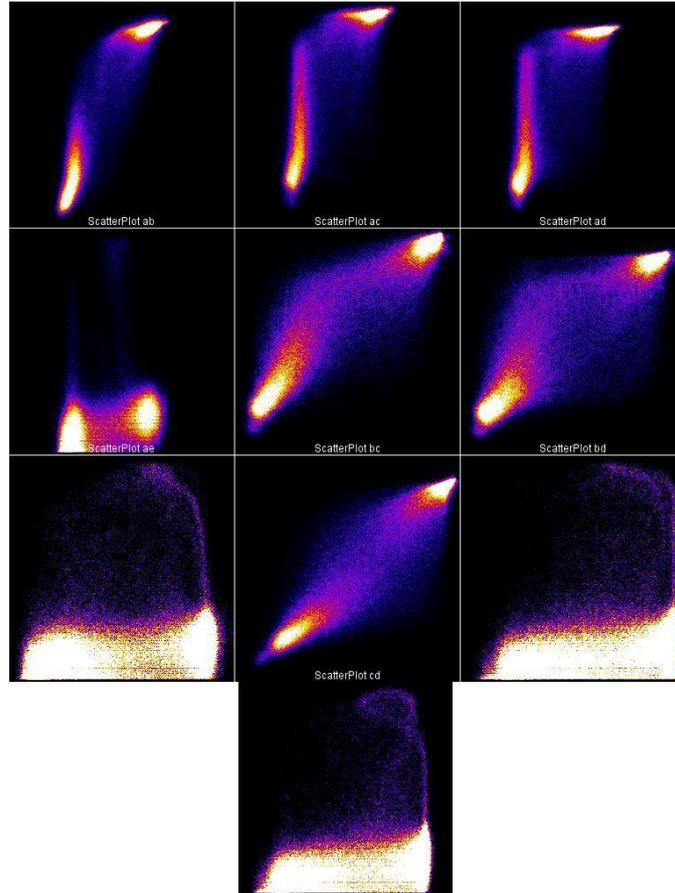
مصفوفة الارتباط بين الصور الرقمية الخمسة (n=25000)

	image a	image b	image c	image d	image e
image a	1				
image b	0.763**	1			
image c	0.486**	0.595**	1		
image d	0.499**	0.534**	0.703**	1	
image e	-0.281**	0.033*	0.160**	0.169**	1

\*\* Correlation is significant at the 0.01 level (2-tailed)

\* Correlation is significant at the 0.05 level (2-tailed)

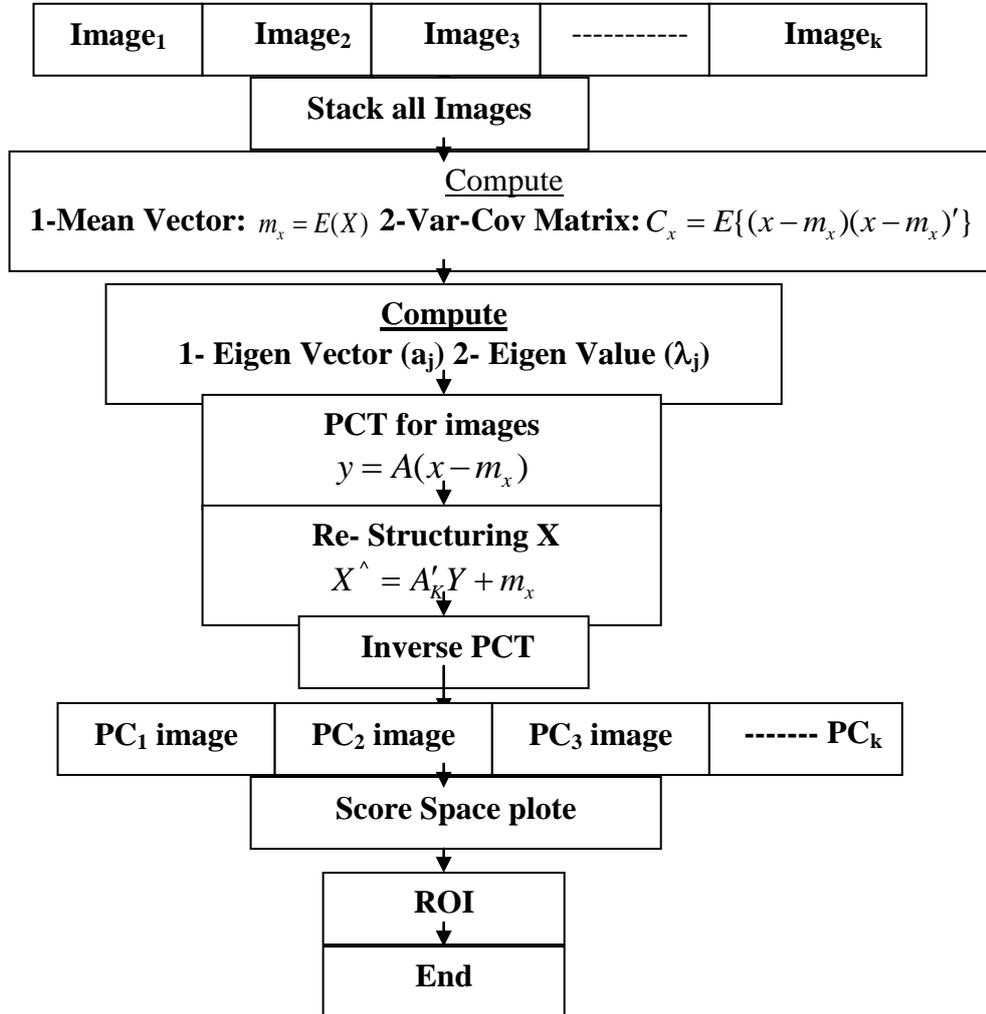
نلاحظ في الشكل (٦) الشكل الانتشاري (Scatter Plot) للأعداد الرقمية لكل الحالات بين الصور الرقمية الخمسة فإذا وقعت معظم النقاط على الخط القطري (Diagonal Line) أو قريباً منه كما هو موضح في الأشكال (cd,bd,bc) وهذا يدل بالمعنى الإحصائي أن هناك ارتباط عالٍ بين بيانات الصورتين ويستنتب من ذلك أيضاً وجود تكرار في البيانات، ونلاحظ أيضاً بان علاقة الصورة (e) مع جميع الصور الأخرى ضعيفة و تنتشر القيم بشكل عشوائي أي بدون اتجاه، وبالنسبة للجدول (٢) نلاحظ بان الصور (ab) و (dc) لهما أعلى قيمة ارتباط (٠.٧٦٣) و (٠.٧٠٣) على التوالي والصور (eb) لهما أقل قيمة ارتباط (٠.٠٣٣) وهي علاقة معنوية أيضاً.



الشكل (٦) الشكل الانتشاري لتوضيح العلاقة بين جميع التوافيق الخمسة للصور الخمسة

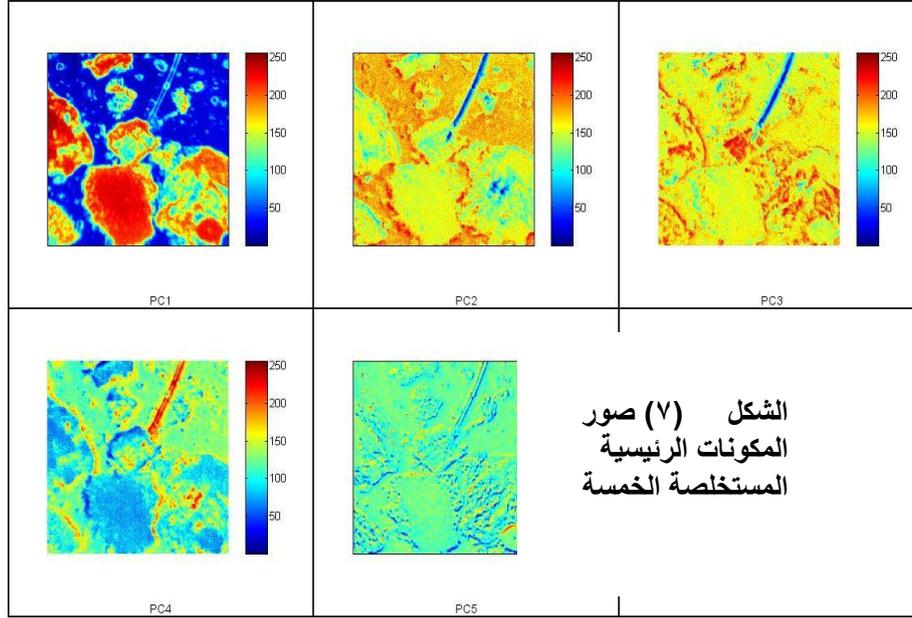
## ٣-٤ خوارزمية تطبيق تحليل المكونات الرئيسية على الصور الرقمية

Input Images(For Exapl :Multivariate Microscope Image)

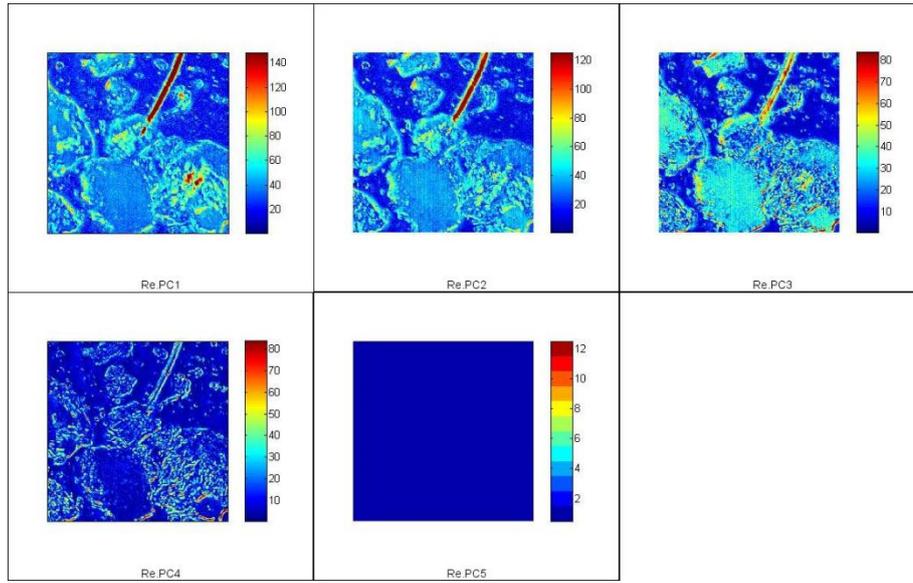


مخطط (١) خوارزمية PCA في استخلاص المعلومات من الصور الرقمية  
(الخوارزمية من إعداد الباحث)

وتم الحصول على النتائج التالية:



نلاحظ في الشكل (٧) صور المكونات المستخلصة حيث تم استخدام صور التركيب ذات الملونة الكاذبة (False Color Composite image) للصور لأظهار خصائص الصور والنسجة بشكل واضح والاستفادة منه في عملية التصنيف (Classification) وكما يمكن بصرياً ملاحظة الصورة (PC1) فيظهر معلومات عن (مكونات وتراكيب الخلية و تحديد حافات نواتها ...الخ) قد تكون مخفية في أي صورة وحيدة للصور المتعددة عن نظيراتها حيث انها تحتوي على كل المتغيرات والمعلومات الموجودة في الصور الأخرى، أما صور المكونات الأخرى فإن معلوماتها لا تكون ذات قيمة في تحليل الصور الرقمية وتحتوي على الضوضاء فقط، ومن الممكن تقدير درجة التحسين لكل الصور المستخلصة وذلك بطرحها من الصور الرئيسية (حيث أن عملية الطرح يبين الأختلاف بين الصورتين ) فإذا كانت درجة التحسين قليلة فإن الصور الناتجة تكون ذات مستوى تدرج رمادي ثابت (مستوية) وبالعكس إذا كانت درجة التحسين عالية تكون ناتج عملية الطرح صورة ذات معالم تمثل المناطق في الخلية التي شملها التحسين كما هو موضح في الشكل (٨) حيث يمكن ملاحظة الصورة (Re.PC1) و (Re.PC5).



الشكل (٨) يبين عملية الطرح بين صور المكونات الرئيسية المستخلصة والصور الأصلية (Residual).

نلاحظ في الجدول (٣) استخلاص صور المكونات الرئيسية و القيم المميزة لها المرتبة ترتيباً تنازلياً و نسبة تفسير التباين الكلي لكل المكونات على حده، حيث أن المكون الرئيسي الأول يفسر أكبر نسبة من التباين الكلي (٩٧.٦٧%) مقارنة بالمكونات الأخرى حيث:

$$V(PC1) = \frac{4.884}{6} * 100 = 97.67\%$$

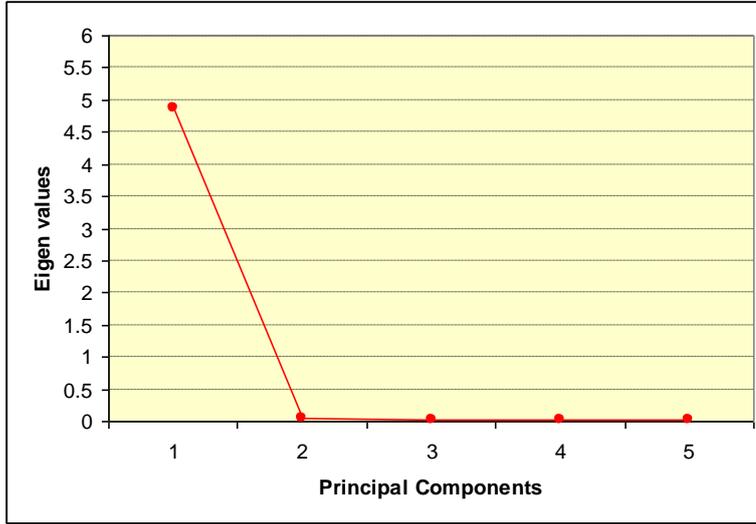
جدول (٣)

تفسير التباين الكلي للمكونات المستخلصة

Total Variance Explained			
PC'S	Initial Eigen values		
	Total	% of Variance	Cumulative %
1	4.884	97.68	97.68
2	0.044	0.87	98.55
3	0.033	0.65	99.20
4	0.023	0.45	99.66
5	0.017	0.34	100.000

Extraction Method: Principal Component Analysis.

وان القيمة المميزة لها اكبر من الواحد الصحيح ( $\lambda = 4.884$ ) وذلك بالاعتماد على معيار (Kaiser) والذي ينص على (ان المكونات الرئيسية التي قيمها المميزة أكبر من الواحد الصحيح تبقى في التحليل [أموري، ٢٠٠٥]).



شكل (٩) المكونات الرئيسية المستخلصة حسب القيم المميزة لها

نلاحظ في الشكل (٩) بأن المكون الرئيسي الأول فقط قيمته المميزة أكبر من الواحد الصحيح اي أستأثر بمعظم البيانات وان القيم المميزة للمكونات الأخرى هي أقل من الواحد الصحيح أي أن توزيعها متماثل وأقل تأثيراً وتفسيراً للتباين وبالنسبة للجدول (٤) مصفوفة التحميل التي يمكن تفسيرها بانها تمثل العلاقة بين المكونات الرئيسية المستخلصة و الصور الرقمية الخمسة ويمكن توضيح المعادلة الأولى كالآتي:

$$PC_1 = -0.365a - 0.495b - 0.576c - 0.525d - 0.121e$$

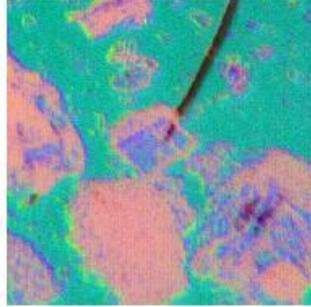
حيث نرى بأن الصورتين (d,c) لهما التأثير الأكبر في المكون الأول بحيث بلغت قيمة تحمليهما (٠.٥٧٦ و ٠.٥٢٥) على التوالي وهكذا لبقية المكونات.

جدول (٤) مصفوفة قيم التحميل للصور الخمسة 5x500x500

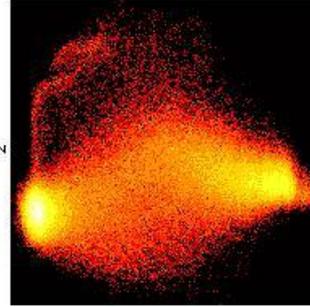
Loading Matrix for 5x500x500 image					
Images(Var.)	PC 1	PC 2	PC 3	PC 4	PC 5
a	-0.365	0.067	-0.335	-0.831	0.245
b	-0.495	0.652	-0.382	0.428	0.013
c	-0.576	-0.176	0.309	-0.101	-0.729
d	-0.525	-0.317	0.414	0.226	0.634
e	-0.121	-0.663	-0.690	0.256	-0.072

ويمكن ملاحظة صور فضاء النتيجة (Score Space) بين تحميلات المكونات الرئيسية المستخلصة (PC'S Score) حيث يفيدنا في توضيح توزيع عناصر الصورة (pixel) بحيث العناصر ذات الخصائص المتشابهة والقريبة من بعضها تظهر بشكل عنقود (Cluster) متجانس ويمكن معرفة وتحديد مناطق ذات الأهمية (ROI) للخلايا و هذه الخاصية يمكن أن يفيد المختصين لمعرفة توزيع ما في داخل الخلايا، وأثبتت استقلالية كل المكونات فيما بينهم بينما كان سابقاً العلاقة بينهم (الصور قبل المعالجة) موجودة ولكن هنا بعد المعالجة نجد شكل انتشار التحميلات ليس لديه اتجاه (ارتباط) كما هو موضح في الشكلين (١٠) و (١١).

The PC's viewed as a composite RGB image

Associations: Red =  $T_1$  Green =  $T_2$  Blue =  $T_3$ 

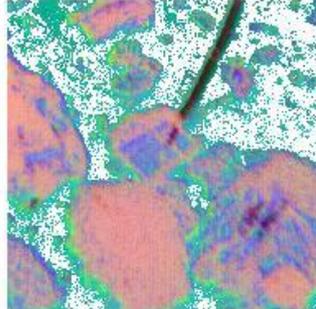
Score space

 $T_1$ 

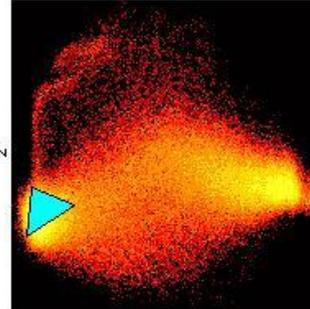
الشكل (١٠) يبين الشكل الانتشاري بين تحميلات (PC1-PC2) و صورة ذات تركيبة ملونة للمكونات المستخلصة معاً

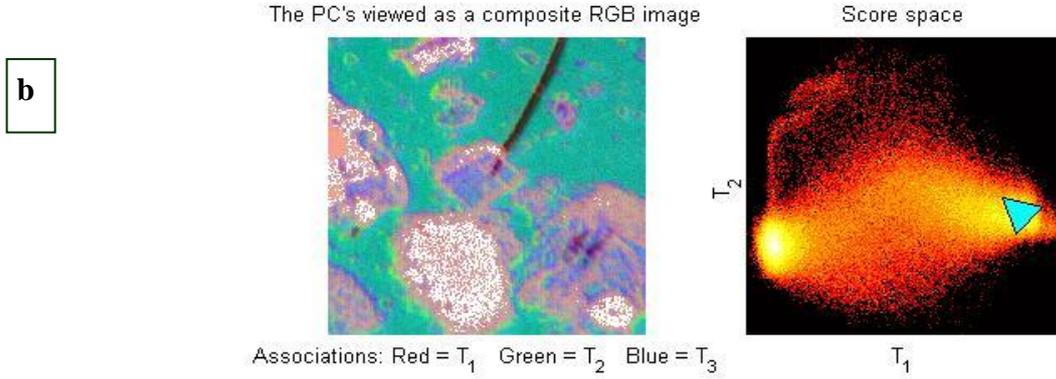
The PC's viewed as a composite RGB image

a

Associations: Red =  $T_1$  Green =  $T_2$  Blue =  $T_3$ 

Score space

 $T_1$

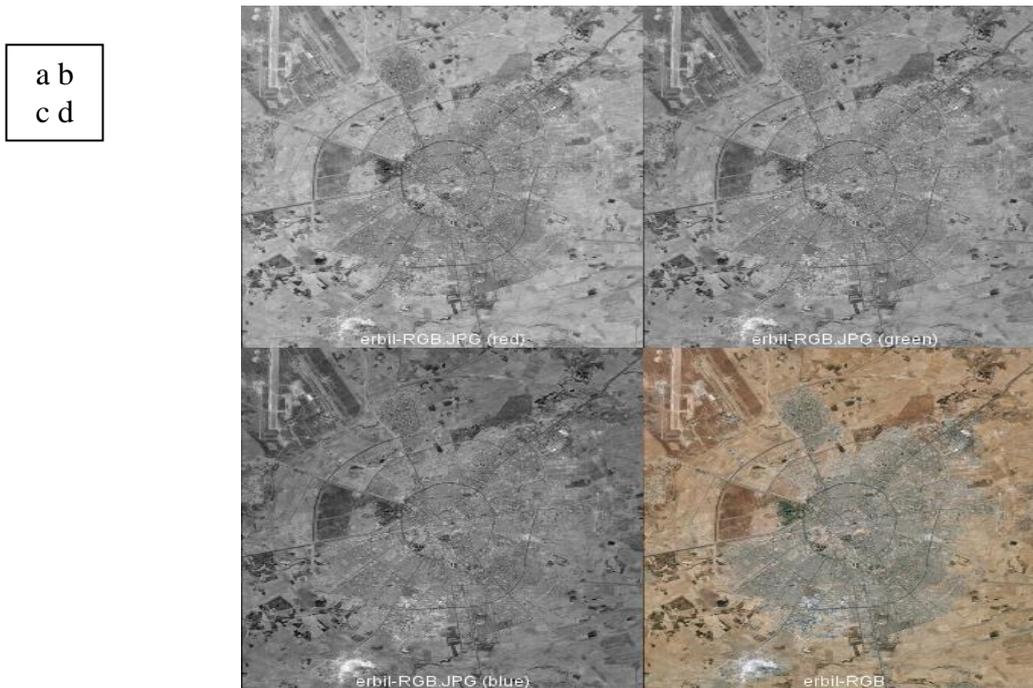


الشكل (١١) تحديد منطقتين ذات كثافة عالية في الصورة باستخدام القناع (Mask)

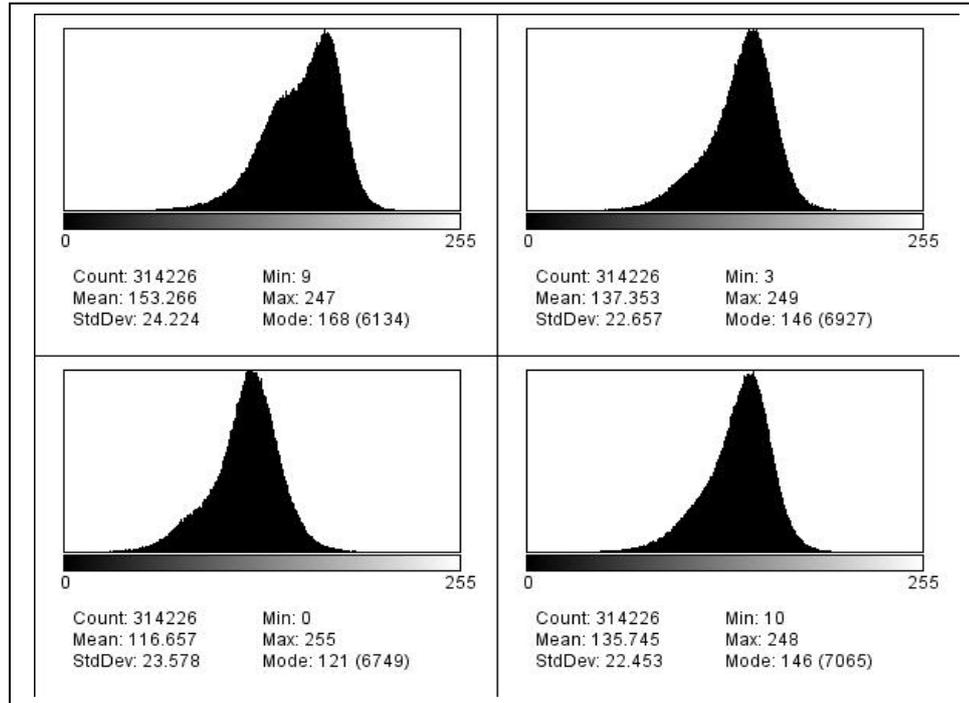
ROI<sub>1</sub>(a) ROI<sub>2</sub>(b)

### ٣-٥ التطبيق على صور الأقمار الصناعية لمدينة أربيل

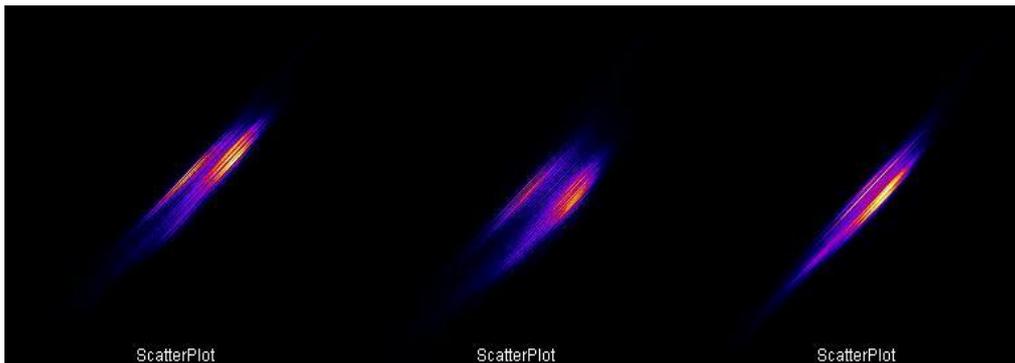
التطبيق الثاني هي على صورة ملونة (RGB) لمدينة أربيل مأخوذة من الأقمار الصناعية لعام ٢٠٠٥ قياس الصورة (529x594) بكسل و خزنها بنوع (JPG) وتم الحصول عليها من (مديرية بلدية أربيل) و شركة (MapCom) الخاصة بأعمال نظم المعلومات الجغرافية (GIS) في مدينة أربيل كما هو موضح في الشكل (١٢).



الشكل (١٢) (a) Red-band (b) Green-band (c) Blue-band (d) صورة ملونة RGB



الشكل (١٣) التوزيع التكراري وبعض المقاييس الإحصائية لصور مدينة اربيل



الشكل (١٤) الشكل الأنتشاري يبين العلاقة بين الصور الثلاثة (RG-RB-GB)

نلاحظ في الشكل (١٤) بأنه يوجد إرتباط عالٍ بين بيانات الصور الثلاث ويستتبط من ذلك أيضاً وجود تكرار في البيانات ويمكن ملاحظة ذلك في مصفوفة العلاقات كما هو موضح في الجدول (٥) وأقوى العلاقات هي بين الصورتين (GB).

## جدول (٥)

مصفوفة الأرتباط بين الصور الرقمية الثلاثة (n=314226)

	image R	image G	Image B
image R	1		
image G	0.906**	1	
image B	0.706**	0.935**	1

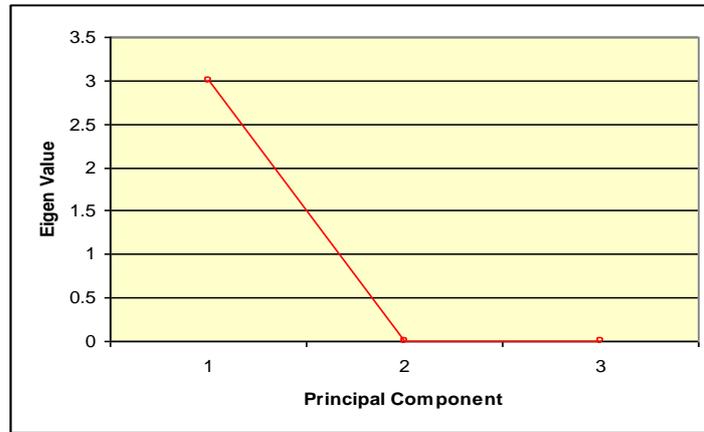


الشكل (١٥) صور المكونات الرئيسية المستخلصة الثلاثة:

PC1-PC2

جدول (٦) تفسير التباين الكلي للمكونات المستخلصة ومصفوفة التحميلات للصور R-G-B

PC'S	Initial Eigen values			Images (Var.)	PC 1	PC 2	PC 3
	Total	% of Variance	Cumu. %				
1	2.9919	99.73	99.730	Red	-0.646	0.668	0.368
2	0.0080	0.265	99.995	Green	-0.581	-0.118	-0.806
3	0.0002	0.008	100	Blue	-0.495	-0.734	0.465



الشكل (١٦) المكونات الرئيسية المستخلصة حسب القيم المميزة لها

- نلاحظ في الشكل (١٥) صور المكونات المستخلصة لمدينة أربيل خاصة صورة (PC1) حيث يمكن ملاحظة بعض المعلومات المهمة المصنفة والظاهرة لنسجة الصورة بشكل أوضح لمدينة أربيل، حيث نلاحظ قطاع المباني والأنشاءات (اللون الأبيض) والصخور والترية (اللون الأصفر والاحمر) والماء (ازرق فاتح) من هذه المعلومات يمكن ان نستفيد من صور المكونات الرئيسية:
١. لمعرفة التغيرات الحاصلة على الغطاءات الأرضية للمدن خاصة عند مقارنة الصور لفترات زمنية متفاوتة مثلاً (٢٠٠٠-٢٠١١).
  ٢. من الناحية الاقتصادية يمكن ان يفيدنا في معرفة التغيرات الحاصلة على التخطيط العمراني للمدينة.
  ٣. من الناحية الجغرافية يمكن دراسة التغيرات الحاصلة في نوعية التربة و الصخ و النباتات الطبيعية والغابات.

## ٤- الأستنتاجات

من خلال هذه الدراسة تم التوصل إلى أهم الأستنتاجات الآتية:

١. باستخدام تحليل (PCA) يمكن ضغط حجم البيانات واستخلاص معلومات أكثر وضوحاً عن (مكونات وتراكيب الخلية و تحديد حافات نواتها ... الخ) قد تكون مخفية في أي صورة وحيدة للصور المتعددة الأصلية وقد تم الحصول على صورة المكون الأول بنسبة تفسير (٩٧.٦٧%) من التباين الكلي اي صورة أكثر وضوحاً للخصائص والمعلومات وبنسبة خسارة (ضوضاء) (٢.٣٣%) أما صور المكونات الأخرى فإنها تحتوى على معلومات غير ضرورية
٢. للتطبيق الثاني (صور الأقمار الصناعية لمدينة أربيل) تم الحصول على صورة المكون الأول بنسبة تفسير (٩٩.٧٣%) للتباين الكلي وبنسبة خسارة (ضوضاء) (0.27%) والحصول على معلومات مفيدة عن التغيرات الحاصلة على الغطاءات الأرضية للمدينة و التخطيط العمراني لها وكذلك نوعية التربة والنباتات الطبيعية والغابات.
٣. تكون صور المكونات الرئيسية المستخلصة أقل ارتباطاً فيما بينهم مما يؤدي إلى تقليل الضجيج (الضوضاء)
٤. أن تحليل (PCA) في معالجة الصور الرقمية تؤدي الى تحسين المعلومات المكانية (Spatial) informartion وكذلك تحسين خصائص النسجة (Texture Enhancement) كما هو موضح في الشكلين (٧) (١٦).
٥. الأستفادة من رسم قيم تحميلات المكونات المستخلصة مع بعضها في توزيع عناصر الصورة (البكسل) (pixel) حيث العناصر ذات الخصائص المتشابهة تتمركز في منطقة قريبة من بعضها كعنقود (Cluster) متجانس أي المسافة بينها قليلة ويمكن معرفة وتحديد مناطق ذات الأهمية (ROI) للخلايا و هذه الخاصية يمكن أن يفيد المختصين لمعرفة مكونات داخل الخلايا وتوزيعها.

## ٤- التوصيات

يوصي البحث ببعض التوصيات منها:

١. تطبيق طرق تحليل متعدد متغيرات أخرى مثل التحليل العنقودي (Cluster-Analysis) والتحليل التمييزي (Discriminate Analysis) ومقارنته بتحليل المكونات الرئيسية (PCA).
٢. أجراء بحوث عن صور الأقمار الصناعية لمدينة أربيل أو أي مدينة أخرى في البلد لفتترات زمنية متفاوتة للمقارنة والحصول على معلومات عن الواقع الأقتصادي و العمراني و الزراعي والجغرافي للمدينة والتخطيط للمستقبل.

## المصادر

١. أبو عمه، عبدالرحمن محمد (٢٠٠٠): "الأساس في الطرق الأحصائية المتعددة المتغيرات". جامعة الملك سعود، النشر العلمي والمطابع. الرياض، المملكة العربية السعودية، ص[96].
٢. الأسمرى، عوض بن خزيم (٢٠١٠): "مقدمة في معالجة الصور الرقمية". جامعة الملك سعود، النشر العلمي والمطابع. الرياض، المملكة العربية السعودية، ص[52-32-1].
٣. المولى، محمد ناظم داود (٢٠٠٧): "تقطيع صور أورام الدماغ ممثلة بالخوارزميات الجينية". رسالة ماجستير غير منشورة، كلية علوم الحاسبات والرياضيات، جامعة الموصل، العراق، ص [٧٢].
٤. حمزة، عبدالمجيد الناصر و الراوي، أسماء غالب (٢٠٠٦): "إستخدام بعض أساليب متعدد المتغيرات لتقليل الأبعاد الصورية في تطبيقات علوم الحياة". المجلة العراقية للعلوم الأحصائية، المجلد ١٤٢٧، العدد ١٠، ص[٢٩ - ١].
٥. عبدالقادر، نجم عبدالله (٢٠٠٤): "كشف الوجه وتحديده في الصور الملونة". رسالة ماجستير غير منشورة، كلية علوم الحاسبات والرياضيات، جامعة الموصل، العراق، ص [٩].
٦. عمار، معن (١٩٩٢): "معالجة الصور الرقمية". المنظة العربية للتربية والثقافة والعلوم، المركز العربي للتعريب والترجمة والتأليف والنشر. دمشق، سوريا، ص[42].
٧. كاظم، أموري هادي (٢٠٠٥): "مقدمة في القياس الأقتصادي". مطبعة دار أبن أثير للطباعة والنشر، جامعة الموصل، العراق. ص[331-177-174]
8. A.K., Jain, (1989), "Fundamentals Of Digital Image Processing" Prentice\_Hall of India, New Delhi.
9. AL-ANI, L.A. "Classification of Digital Satellite Images", Ph.D. Thesis, College of Science, Al-Nahrain University 1996.
10. Baronti, S. & Casini, A. (1997), "Segmentation of Multispectral Image of Works of Art Through Principal Component Analysis". 9th International Conference, ICIA97, Florence, Italy, V.11.
11. Bonnet, N & Trebbia, P.C. (1992), "Multi-Dimensional Data Analysis and Processing in Electron-Induced Microanalysis". Scanning Microscopy Supplement, V.6, P.163-177.
12. C. Radhakrishna rao; (1973): "Linear statistical Inference and its applications", 2nd ed., John Wiley and Sons.

- 13.El Hassan, I.M.(2007), “Digital Image Processing in Remote Sensing”, Final Research Report No. 6/427, King Saud University,College of Engineering-Research Center.P.[115].
  - 14.Fuang, T. & Le Drew,E. (1987),“Application of Principal Component Analysis to Change Detection” ,Photogrammetric Engenering and Remot Sensing.V.53, No.12 P.1649-1658.
  - 15.Gonzales, Rafel C., and Woods, Richard E(2008), “Digital Image Processing ” , Pearson Prentice Hall, New Jersey,USA.P.842-847
  - 16.Heel, M.V & Frank,J. (1981), “Use of Multivariat Statistics in Analysis the Image of Diological Macromolesules” .Ultramicroscopy.V.6, P.187-194.
  - 17.<http://www.macc.mcmaster.ca/>. in 2010.
  - 18.Jenson, L & Waltz,E. (1979), “Principal Component Analysis and Canonical Analysis in Remote Sensing”, America Society of Photogramuetry.
  - 19.Lillesand T. M, Kiefer R. W, (1987), “Remote Sensing and Image Interpretation” 2ND edition , John Wily and Sons.
  - 20.N.R. Draper; H. Smith,( 1980) “Applied regression analysis”, John Wiley & Sons Inc., New York, U.S.A..
  - 21.Otsu, N.(1984),“Karhunen-Loeve Line Fitting and Alinearity Meature”. IEEE,Trans.Comm.V.8, P.486-489.
  - 22.Richards, J. A. and X. Jia,(2006) “Remote Sensing Digital Image Analysis ” ,Springer-Verlag, Berlin, Germany.P.[317-321]
- Yakoo, T. “Multivariat Statistical Analysis Functional Neuro Imageing Data” Ph.D. Thesis, Mountsinai Graduate School of Biological Sciences Doctoral Program, New York University,2004. <http://www.camelot.MSSM.ed>.