

مقارنة بين طريقتي تحليل المركبات الرئيسية والمركبات الرئيسية للبيه لتقليل الابعاد الصورية

د.اسماء غالب الراوي**

اسيل مسلم عيسى*

drasmaa.ghalib@coadec.uobaghdad.edu.iq

no_ja_as_2012@yahoo.com

المستخلص :

يتناول البحث طريقتين لتقليل الابعاد وهي طريقة تحليل المركبات الرئيسية (PCA) في حال كون التراكيب خطيه وطريقة المركبات الرئيسية للبيه (KPCA) في حال كون المركبات لاخطية لمعالجة وتحليل الصور الرقمية وذلك للحصول على معلومات مفيدة. ومن ثم المقارنه بين الطريقتين ومعرفة اي الطرائق تكون مناسبة لتقليل الابعاد الصورية . وتم تطبيق الطرائق على مجموعة من صور الاقمار الاصطناعية لمنطقة في محافظة البصرة الذي يمثل مصب دجلة والفرات في شط العرب وأيضا القنوات المائية المتخللة لمحافظة البصرة والمسطحات المائية المنتشرة حول هذه القنوات. في هذا البحث تم التوصل الى ان الحزمة الصورية الرابعة افضل باستخدام طريقة PCA حيث كانت القيمه كامنة لها اكبر قيمة ،اما طريقة KPCA فقد اظهرت ان الحزمة الصورية الثالثة هي الافضل حيث اعطت اعلى قيمه كامنة . وبالمقارنة بين الطريقتين باستخدام معيار متوسط مربعات الخطأ (MSE) ،اظهرت النتائج ان طريقة المركبات الرئيسية للبيه (KPCA) هي الافضل .

الكلمات المفتاحية: الصور ،المعالجة الصورية ،الصور الرقمية، تقليل الابعاد، تحليل المركبات الرئيسية، تحليل المركبات الرئيسية للبيه .

This is an open access article under the CC BY 4.0 license
(<http://creativecommons.org/licenses/by/4.0/>)

Comparison Between The Method of Principal Component Analysis And Principal Component Analysis Kernel For Imaging Dimensionality Reduction

Abstract:

This paper tackles with two methods to dimensionality reduction, namely principal component analysis (PCA) in the case of linear combinations and kernel principal component analysis method in the case of nonlinear combinations to digital image processing and analysis for useful information .And then compare the two methods and know which methods are appropriate to imaging dimensionality reduction.

*باحثة / قسم الاحصاء / كلية الادارة والاقتصاد / جامعة سومر
**استاذ مساعد / قسم الاحصاء / كلية الادارة والاقتصاد / جامعة بغداد

The methods were applied to a group of satellite images of an area in the province of Basra, which represents the mouth of the Tigris and Euphrates in the Shatt al-Arab, as well as the water channels permeating Basra Governorate and the water bodies scattered around these channels. In this research, it is shown that the fourth image band is best when using the PCA method the value of it is eigen value was the biggest ,while the KPCA method showed that the third image band was the best, giving the highest latent value. Comparing the two methods using the mean error error (MSE) method, the results showed that the main KPCA method was the best.

Keywords: images, image processing ,digital image ,dimensionality reduction, principal component analysis ,kernel principal component analysis .

1-المقدمة (Introduction)

يعد علم الاحصاء من اهم العلوم المتداخلة مع العلوم الاخرى والذي يلعب دورا مهما في كثير من الدراسات والبحوث المختلفة . هنالك بعض الوسائل كالتقنيات الاستشعار عن بعد وتقنيات التحليل المجهرى وغيرها من التقنيات تلتقط عدد كبير من الصور متعددة الاطراف لغرض معين، وبما ان الصورة الرقمية يمكن ان تتمثل بمصفوفة من العناصر الصورية والتي تعرف بالصيغة $f(x,y)$ لذلك سنحصل على (N) من الابعاد التي تشكلها (M) من الصور المأخوذة لهدف معين وعند دراسة هذا العدد الكبير من الصور الملتقطة يمكن الاعتماد على احد اهم اهداف طرائق التحليل الاحصائي متعدد المتغيرات وهو تقليل الابعاد، ان عملية تقليل الابعاد في مجال معالجة الصور الرقمية تعتبر من اولى المهام المطلوب حلها . ان مفهوم تقليل الابعاد يعتمد على تحويل البيانات المتعددة الموجودة في المساحة ذات الابعاد العالية (High Dimensional Space) الى عرض ذو معنى اوضح ومفيد في المساحة ذات الابعاد الاقل (Low Dimensional Space)، ولحل هذه المشكلة يتم اللجوء الى طرائق متعدد المتغيرات الاحصائية والتي تكون المرحلة الاولى للمعالجة وبعدها يتم استعمال طرائق المعالجة الصورية من تحسين واستعادة وضغط وتقطيع وغيرها. وان لمفهوم تقليل الابعاد العديد من التقنيات القادرة على تنفيذ هذه المهمة، ويمكن ان تصنف هذه التقنيات الى صنفين هما تقنيات خطية لتقليل الابعاد (Linear Techniques for Dimensions Reduction) وهي التقنيات التي تعتمد على العلاقات الخطية بين المتغيرات ومنها التحليل العاملي (Factor Analysis) وطريقة تحليل المركبات الرئيسية ((Principal Component Analysis (PCA) والارتباط القويم وغيرها الكثير^[5]، اما الصنف الثاني فهو تقنيات غير خطية لتقليل الابعاد (Nonlinear Linear Techniques for

Dimensions Reduction) وفي الواقع ان اغلب المتغيرات تأخذ شكل المتغيرات غير الخطية ومنها طريقة تحليل المركبات الخطية اللبية (Kernel Principal Component Analysis (KPCA)) والتحليل المتناظر (Corresponding Analysis) وطريقة تحليل المركبات المستقلة (Independent Component Analysis (ICA)) وطريقة القياس متعدد الابعاد (Multidimensional Scaling) وغيرها^[5]. وفي بحثنا سنتناول تحليل المركبات الرئيسية (Principal Component Analysis (PCA)).

وبعض الطرائق تكون لا خطية في دراستنا سنتناول طريقة تحليل المركبات الخطية اللبية (Kernel Principal Component Analysis (KPCA)). وتم تطبيق هذه الطرائق لصور الاقمار الصناعية (LANDSAT-5) لمجموعة متغيرات الترابط الطيفية (correlation spectral) لستة حزم طيفية لمشهد مصب دجلة والفرات في شط العرب في محافظة البصرة ولقد اظهرت النتائج ان طريقة تحليل المركبات الرئيسية كانت الافضل في الحزمة الثانية والثالثة والخامسة والسادسة اما تحليل المركبات الرئيسية اللبية فهي الافضل في الحزمة الاولى والرابعة . ومن اهم الدراسات و البحوث التي اهتمت بهذه المواضيع هي:

في عام 2004 ناقش الباحثون (Changshui Zhang & Wang, Zhao, David) طريقة لتقليل الابعاد اللاخطية وهي طريقة الغمر الخطية الموضعية ((Locally Linear Embedding (LLE)) والتي تعتبر احد طرائق التقدير اللبية وتعمل على تكشف التوزيع الجوهرى للبيانات.

طبق في عام 2005 الباحثون (B. Scholkopf & M. O. Franz, K. Kwang In)^[8] نموذج تحليل المركبات الرئيسية اللبية (Kernel Principal Component Analysis (KPCA)) على فئات صور محددة وذلك بسبب العدد المحدود من الأمثلة التدريبية التي يمكن معالجتها.

في عام 2006 تناول الباحثان (الناصر و الراوي)^[2] احدى طرائق متعدد المتغيرات في تقليل الابعاد لمعالجة الصور الرقمية ،اذ استخدمنا خوارزميتان الاولى الخوارزمية تحويل (Karhunen-Loeve) وخوارزمية الثانية خوارزمية التحليل المتناظر وذلك من خلال استخلاص المعلومات المفيدة من مجموعة صور لمراحل انقسام الخلايا الحيوانية في علوم الحياة، وتم الاستنتاج انه بالإمكان تمييز مجموعة متعدد المتغيرات ككل من خلال تحليل متعدد المتغيرات .

استخدم في عام 2012 الباحثان (صالح و احمد)^[3] تحليل المركبات الرئيسية (Principal Component Analysis) لتقليل الابعاد الصورية وهي احد طرائق متعدد المتغيرات في معالجة

الصور الرقمية في تحسين النسخة. ولقد استخدم نوعان من الصور وهي صور مجهرية لخلية الحنطة وصور اقمار صناعية لمدينة اربيل. حيث بين انه يمكن استخدام تحليل المركبات الرئيسية في اظهار المعلومات المفيدة من مختلف الصور كصور الاقمار الصناعية وصور مجهرية .

(1-1) هدف البحث

يهدف البحث الى استعمال بعض الطرائق الاحصائية لتقليل الابعاد الصورية لبيانات متعدد المصادر في الصور الرقمية في حالة كون التراكيب خطيه او غير خطيه للبيانات لمعالجة وتحليل الصور وذلك من خلال تقليل الابعاد في البيانات ومعرفة اي الطرائق افضل من خلال استخدام مربع متوسط الخطأ MSE والتي تعطي صوره تحتوي على معلومات مفيدة لغرض استخدامها للمعالجة الصورية اللاحقة من تحسين وتقطيع الصور.

2- الجاب النظري

(2-1) المركبات الرئيسية (Principal Component Analysis (PCA))

تحليل المكون الرئيسي او ما يعرف (Karhunen-Loeve أو تحويل Hotelling) (2) ينتمي إلى التحويلات الخطية بناءً على التقنيات الإحصائية حيث يعمل على اختزال المعلومات المتمثلة بالتباين وحفظها في مركبات دون خسارة المعلومات. الفكرة الأساسية للمركبات الرئيسية هو تحويل المتغيرات المرتبطة خطياً والتي تحتوي على كمية عالية و مبعثرة من البيانات الى مركبات متعامدة غير مرتبطة وتكون مرتبة حسب مقدار التباين ، تحوي المركبة الاولى على اكبر نسبة تباين (Variance) من المعلومات اما الثانية فتكون ثاني اكبر نسبة تباين من المعلومات وهكذا اما الاخيرة فتكون ضوضاء ومشوه لأنها تحتوي اقل نسبة تباين (3). وهي أداة قوية لتحليل البيانات والتعرف على الأنماط والتي تستخدم غالباً في معالجة الإشارة والصورة اذ تعمل كتقنية لضغط البيانات ، تقليل أبعاد البيانات أو ارتباطها كذلك. تعتمد على التحليل متعدد المتغيرات أو الشبكات العصبية التي يمكنها إجراء PCA على مجموعة بيانات معينة.

الاسلوب الرياضي للمركبات الرئيسي يتطلب اولاً ايجاد مصفوفة variance-covariance للصور المتوفرة والتي تحسب وفق الصيغة الآتية :

$$\Sigma_{ij} = \frac{1}{MN} \sum_{i=1}^M \sum_{l=1}^N (X_i(\kappa, l) - \mu_i)(X_j(\kappa, l) - \mu_j) \quad \dots \dots \dots (1)$$

حيث ان

M, N : تمثل المفردات في الصورة .

$X_i(\kappa, l)$ تمثل المركبة i في موقع النقطة (κ, l) في الصورة.

$X_j(\kappa, l)$ تمثل المركبة j في موقع النقطة (κ, l) في الصورة.

$$\mu_j, \mu_i \text{ يمثلان الوسط الحسابي للمركبة } i = \frac{1}{MN} \sum_{i=1}^M \sum_{l=1}^N X_i(\kappa, l) \text{ و } \mu_j = \frac{1}{MN} \sum_{i=1}^M \sum_{l=1}^N X_j(\kappa, l)$$

لذلك فان مصفوفة التباين والتباين المشترك من الدرجة n تكتب بالصيغة الآتية :

$$\Sigma = \begin{bmatrix} c_{11} & c_{12} & \dots & c_{1n} \\ c_{21} & c_{22} & \dots & c_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ c_{n1} & c_{n2} & \dots & c_{nn} \end{bmatrix}$$

المصفوفة اعلاه هي مصفوفة متماثلة ومحددها لا يساوي صفر (2). لذلك يتم ايجاد الجذور الكامنة من خلال الصيغة الآتية

$$|\Sigma - \lambda_j I| = 0 \quad \dots \dots \dots (2)$$

where $\sum_{j=1}^k \lambda_j = k$

وبعدها يتم ايجاد الموجهات الكامنة من خلال المعادله كما يأتي :

$$(\Sigma - \lambda_j I)a_j = 0 \quad \dots \dots \dots (3)$$

و اخيرا يتم ايجاد المركبات الرئيسية كما يأتي :

$$F1_j = a_{1j}X_1 + a_{2j}X_2 + \dots + a_{kj}X_k \quad \dots \dots \dots (4)$$

ويمكن ان نمثل طريقة المركبات الرئيسية بالخوارزمية الآتية

الخطوة 1

ادخل الصورة لحساب مصفوفة البيانات $X_{M \times N}$ لعدد الصفوف M وعدد الاعمدة N .

الخطوة 2

احسب مصفوفة التباين والتباين المشترك Σ .

الخطوة 3

احسب الجذور الكامنة باستخدام المعادله $|\Sigma - \lambda_j I| = 0$.

الخطوة 4

احسب موجة الجذور الكامنة من خلال المعادلة $(\Sigma - \lambda_j I)a_j = 0$.

الخطوة 5

احسب المركبات الرئيسية $F1_j$.

الخطوة 6

النهاية

(1-2) المركبات الرئيسية اللبية (Kernel Principal Component Analysis) ((KPCA)) (5)

من المعروف ان المركبات الرئيسية تستخدم لتقليل الابعاد خطية ، فإذا كانت البيانات تحتوي على هياكل أكثر تعقيداً لا يمكن تمثيلها بصورة جيدة في فضاء جزئي خطي ، فان طريقة PCA تكون غير مجدية لذلك تستخدم المركبات الرئيسية اللبية KPCA بدلا من PCA لتقليل الابعاد غير الخطية . ان اشتاق تحليل المركبات الرئيسية اللبية يتم من خلال تسليط البيانات أولاً على فضاء المعالم عالي الابعاد (high-dimensional feature space) F حيث ان :

$$\phi: R^N \rightarrow F; x \rightarrow X$$

وبذلك يتم حساب مصفوفة التباين من خلال الاتي :

$$\Sigma_F = \frac{1}{M} \sum_{i=1}^M \phi(x_i) \phi(x_i)' \quad \dots \dots \dots (5)$$

نفترض ان البيانات في F يكون مركزها صفر لذلك فان $E(\phi(x)) = 0$. ثم بعد ذلك يتم حساب مكونات المركبات الرئيسية بواسطة حل مشكلة القيم الكامنة (Eigen value)

$$\Sigma_F v = \lambda v \quad \dots \dots \dots (6)$$

حيث ان v متجهات كامنة ، فإذا كان لدينا متجه الجذر v_i ومتجه الجذر v_j فانه

$$v_i v_j = \begin{cases} 0 & \text{if } i \neq j \\ 1 & \text{if } i = j \end{cases}$$

لذلك فان المتجهات الكامنة متعامدة، ويقابل كل متجه كامن قيمه جذر كامنة وهما يحددان ترتيب المركبات الرئيسية اللبية

$$F3_j = (v_i, \phi(x_i))$$

وهي تحقق نفس شروط دالة المركبات الرئيسية الاعتيادية ولذلك فان :

$$v = \sum_{i=1}^M \alpha_i \phi(x_i) \quad \dots \dots \dots (7)$$

حيث ان α_i يمثل معاملات $\phi(x_i)$. وعند التعويض معادلة (7) بمعادلة (6) ينتج ما يأتي :

$$\frac{1}{M} \sum_{i=1}^M \phi(x_i) \phi(x_i)' v = \lambda v \quad \dots \dots \dots (8)$$

$$\frac{1}{M\lambda} \sum_{i=1}^M \varphi(x_i) \varphi(x_i)' v = v$$

$$\sum_{i=1}^M \frac{\varphi(x_i)'}{M\lambda} \varphi(x_i) v = \sum_{i=1}^M \alpha_i \varphi(x_i)$$

وبضرب المعادلة (7) ب $\varphi(x_k)$ تصبح بالشكل الاتي :

$$\varphi(x_k) \Sigma_F v = \lambda \varphi(x_k) v \quad \dots \dots \dots (9)$$

وعند تعويض المعادلة (6) بالمعادلة (9) ينتج لنا :

$$\varphi(x_k) \left[\frac{1}{M} \sum_{j=1}^M \varphi(x_j) \varphi(x_j)' \right] \left[\sum_{i=1}^M \alpha_i \varphi(x_i) \right] = \lambda \varphi(x_k) \left[\sum_{i=1}^M \alpha_i \varphi(x_i) \right] \quad \dots \dots \dots (10)$$

$$\lambda \left[\sum_{i=1}^M \varphi(x_k) \alpha_j \varphi(x_j) \right] = \frac{1}{M} \sum_{i=1}^M \alpha_i (\varphi(x_k)) \sum_{j=1}^M \varphi(x_j) \varphi(x_j)' \varphi(x_i) \quad \dots \dots \dots (11)$$

من المعروف ان $\varphi(x_i) \varphi(x_j)$ هي صيغة لمصفوفة kernel من الدرجة $M \times M$ والتي يتم من خلالها ايجاد المعاملات لذلك يمكن تمثيل مصفوفة kernel بالصيغ التالية :

$$K_{ij} = \varphi(x_i) \varphi(x_j) \quad \dots \dots \dots (12)$$

فتصبح معادلة (11) بالشكل الاتي :

$$\lambda M K \alpha = K^2 \alpha \quad \dots \dots \dots (13)$$

وبضرب طرفي معادله (13) ب K^{-1} تصبح كما يأتي :

$$\lambda M \alpha = K \alpha \quad \dots \dots \dots (14)$$

$$\sum_{j=1}^M \alpha_i^k \alpha_j^k \varphi(x_i) \varphi(x_j) = 1 \Rightarrow \sum_{j=1}^M \alpha_i^k \alpha_j^k K_{ij} = 1 \Rightarrow \alpha^k K \alpha^k = 1$$

وبما ان α قيم الجذور الكامنة للمصفوفة K لذلك ينتج

$$\lambda_k \alpha^k \alpha^k = 1$$

وعند تعويض $\tilde{\alpha}$ بدل λM ونقلها للطرف الثاني تصبح المعادلة اعلاه بالصيغة الاتية :

$$K\alpha - \tilde{\lambda}\alpha = 0 \Rightarrow (K - \tilde{\lambda})\alpha = 0$$

$$|K - \tilde{\lambda}| = 0 \quad \text{والشرط ألامر لإيجاد المعادله اعلاه هو ان يكون:}$$

$$v\varphi(x) = \sum_{j=1}^M \alpha_j \varphi(x_j) \varphi(x) \quad \text{: ضرب المعادلة (7) ب } \varphi(x) \text{ فيصبح بالشكل الاتي :}$$

لذلك فان صيغة المركبات الرئيسية اللبية تكتب بالشكل الاتي :

$$F3_j = \sum_{i=1}^n \alpha_{ij} K(x_i, x_j) \quad \dots \dots \dots (15)$$

اما الدوال اللبية المستخدمة بالبحث فهي

$$1 - K(x_i, x_j) = (x_i x_j + h)^d$$

$$2 - K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2h^2}\right)$$

$$3 - K(x_i, x_j) = \sum_{i=1}^n \prod_{p=1}^P K(x_{ip} - x'_{ip})$$

وان h هي معلمة عرض الحزمه وتوجد مجموعة من الصيغ لإيجادها. ويمكن ان نمثل طريقة KPCA بالخوارزمية الاتية :

الخطوة 1

ادخل الصورة لحساب مصفوفة البيانات $X_{M \times N}$ لعدد الصفوف M وعدد الاعمدة N .

الخطوة 2

احسب h و احسب $K(x_i, x_j)$ باستخدام احد المعادلات الاتية :

$$1 - K(x_i, x_j) = (x_i x_j + h)^d$$

$$2 - K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2h^2}\right)$$

$$3 - K(x_i, x_j) = \sum_{i=1}^n \prod_{p=1}^P K(x_{ip} - x'_{ip})$$

الخطوة 3

احسب مصفوفة $K = [K(x_i, x_j)]$.

الخطوة 4

احسب $\lambda M \alpha = K \alpha$ ، حيث ان K مصفوفة قطرية وكذلك α قيم الجذور الكامنة للمصفوفة K وتحل بواسطة $\lambda_k \alpha^k \alpha^k = 1$

الخطوة 5


احسب المركبات الرئيسية للبية $F3_j = \sum_{i=1}^n \alpha_{ij} K (x_i, x_j)$

الخطوة 6

النهاية

3- الجانب العملي

لغرض تطبيق ما جاء بالجانب النظري في تقليل الابعاد الصورية وبقياسات (256×312) بكسل لكل صوره حيث اختيار صور لمصب دجلة والفرات في شط العرب في محافظة البصرة وأيضاً القنوات المائية المتخللة لمحافظة البصرة والمسطحات المائية المنتشرة حول هذه القنوات حيث تم اعتماد حزم النظام TM وكما موضح بالشكل (4) والتي تمثل الحزم الصورية الاصلية للقمر الصناعي (LANDSAT-5) وكالاتي :



شكل(4)

يمثل الحزم الصورية الاصلية


تم في البداية استخراج قيم الوسط لحسابي والتباين والانحراف المعياري لكل حزمة (Band) والتي تم كتابة بلغة برنامج matlab وكانت النتائج الاتية:

جدول (1)

المقاييس الاحصائية للصور الرقمية

Maximum	Minimum	Variance	Std. Deviation	Mean	
1	0	0.0879	0.2964	0.9027	Band 1
1	0	0.1623	0.4028	0.7962	Band 2
1	0	0.1965	0.4432	0.7314	Band 3
1	0	0.1153	0.3395	0.8671	Band 4
1	0	0.1777	0.4216	0.7689	Band 5
1	0	0.1968	0.4436	0.7307	Band 6

نلاحظ ان متوسط الحزم متقاربة وهذا يدل على ان شدة التدرج الرمادي للحزم متقاربة وان اقل شدة كانت للحزمة السادسة اي ان الحزمة مائلة للون الاسود اما اعلى قيمه للمتوسط هي الحزمة الاولى وهذا يدل على ان شدة التدرج الرمادي عالية اي ان الحزمة مائلة للبياض، اما في ما يتعلق في التباين فان الحزمة الاولى كان تباينها قليل اي ان التغيرات بالكثافة قليلة وبهذا فان مستويات التدرج الرمادي قليلة، اما الحزمة السادسة فان التغيرات في الكثافة تكون اعلى جميع الحزم وبهذا فان مستويات التدرج الرمادي عالية لذلك الكثافة تكون عالية .والإشكال اداه تبين التوزيعات التكرارات.



شكل (5)

يبين التوزيع التكراري للحزم الصورية الاصلية

اما في ما يتعلق بالجدول رقم (2) فانه يمثل مصفوفة الارتباطات بين الحزم الطيفية والذي له اهمية كبرى في معالجة الصور الرقمية ،يقاس الارتباط قوة العلاقة بين الحزم وكذلك يوضح

تكرار البيانات في الحزم الصورية وأيضا له خوارزمية المركبات الرئيسية والمركبات الرئيسية اللبية تعتمد على الارتباط ⁽⁴⁾. كما نلاحظ ان هنالك ارتباط بين الحزم الصورية وهذا يدل على ان البيانات مكرر في الحزم، وان الارتباط موجب عالي بين الحزمة الصورية السادسة والحزمتان الثالثة والخامسة يليه الارتباط موجب بين الحزمة الصورية الخامسة والحزمتان الثانية و الثالثة . اما الحزمة الصورية الاولى فان ارتباطها قليل مع جميع الحزم الصورية اي ان تكرار البيانات قليل .

جدول (2)

يبين الارتباط بين الحزم الطيفية


Band 6	Band 5	Band 4	Band 3	Band 2	Band1	
0.5408	0.5989	0.8387	0.5419	0.5419	1	Band 1
0.8333	0.9227	0.7739	0.8384	1	0.6491	Band 2
0.9981	0.9047	0.6461	1	0.8384	0.5419	Band 3
0.6449	0.7141	1	0.6461	0.7739	0.8387	Band 4
0.9031	1	0.7141	0.9047	0.9227	0.5989	Band 5
1	0.9031	0.6449	0.9981	0.8333	0.5408	Band 6

و بعد تطبيق ما جاء بالجانب النظري تم الحصول على القيم الكامنة لكل من طريقة المركبات الرئيسية وطريقة المركبات الرئيسية اللبية في جدول (3) مع اخذ اول خمس مركبات فقط بنظر الاعتبار تبين ان الحزمة الصورية الرابعة هي الافضل عند تطبيق طريقة PCA وذلك لكونها اخذت اعلى قيمة كامنة حيث بلغت قيمتها (26.3199) . و عند تطبيق طريقة KPCA فان الحزمة الصورية الثالثة هي الافضل وذلك لكونها اخذت اعلى قيمة والتي بلغت (11.6254) .

جدول (3)

يبين قيم الجذور الكامنة لكل طريقة

Eigen Values For P.C					
Band 1	Band 2	Band 3	Band 4	Band 5	Band 6
24.6403	23.8814	21.0981	26.3199	22.5182	21.0706
3.5959	8.0245	9.8062	5.1488	8.9254	9.8228
2.4153	5.5065	7.4579	3.7615	6.1324	7.4966
1.6604	3.8433	5.6619	1.7334	4.8575	5.6810
0.8347	2.3036	3.1727	1.2329	2.6910	3.1856
Eigen Values For kernel					
Band 1	Band 2	Band 3	Band 4	Band 5	Band 6
11.4109	8.9860	11.6254	11.5033	11.4029	11.4189
5.5309	1.3450	5.5870	5.5342	5.4472	5.3680
5.3580	1.2356	5.5512	5.4278	4.9936	4.7755
2.8641	0.9222	2.8836	2.8303	2.9037	2.8876
2.0341	0.4951	2.1554	2.0783	1.8542	1.8169



شكل (6) نتائج تطبيق خوارزميات تقليل الأبعاد

Band1 الصورة الناتجة من تطبيق P.C K. Band2 الصورة الناتجة من تطبيق P.C
 Band 3 الصورة الناتجة من تطبيق P.C K. Band 4 الصورة الناتجة من تطبيق P.C
 Band5 الصورة الناتجة من تطبيق P.C Band6 الصورة الناتجة من تطبيق P.C

اما الجدول اداة فيبين متوسط مربعات الخطاء لكل من طريقة P.C.A وطريقة K.P.C.A .

جدول (3)

يبين mse لكل طريقة

	Band 1	Band 2	Band 3	Band 4	Band 5	Band 6
P.C.A	7.9614	11.2177	12.4437	9.3277	11.7712	12.4533
KPCA	7.9567	11.7754	12.8374	8.3142	12.3700	12.8426

4-الاستنتاجات(Conclusions)

وفيما يلي الاستنتاجات التي تم التوصل اليها في متن هذا البحث :

1- من خلال تنفيذ تقنيات تقليل الأبعاد المعتمدة اتضح ان الاعتماد على تخفيض الأبعاد للصورة اعطت نتائج جيدة وأكثر وضوحاً من اساليب اخرى ، وان الآلية التي اعتمدت لتنفيذ الخوارزميات مكنتنا من دراسة صور طيفية ذات احجام عالية وإنتاج صور ثلاثية الأبعاد على عكس اساليب تخفيض تعتمد على تحويل الصور الى ثنائية الأبعاد.

2- ان تقنيات تقليل الابعاد المعتمدة اثبتت انها قادرة على زيادة تجانس العناصر الصورية المكونة للصور الناتجة، وأيضاً تميزت بمقدرتها على تقليل الاحجام الصورية بالإضافة الى مهمتها الرئيسية والمتمثلة بتقليل الابعاد مع الحفاظ على ابرز الخصائص الاحصائية واللونية للصورة قبل تخفيض احجامها وابعادها.

3- عند اختيار افضل حزمة صورية بالاعتماد على القيم الكامنة ان الطريقتان اعطت نتائج عالية ودقيقه في تحديد افضل حزمة صورية من بين الحزم الصورية الستة .فقد تم التوصل الى ان الحزمة الرابعة والتي تمتلك اعلى قيمة كامنة هي الافضل وهذا يدل على انها تحتوي على اهم الخواص المستقلة في الصور. كذلك عند تطبيق تحليل المركبات الرئيسية للبيانات فقد تم التوصل الى ان الحزمة الثالثة هي الافضل وهذا يدل على انها تحتوي على اهم الخواص المستقلة في الصور .

4- بيت النتائج باستخدام معيار MSE ان طريقة KPCA افضل من PCA ،حيث اثبتت نتائج تحليل المركبات الرئيسية للبيانات بأنها قادرة على اختزال كم كبير من المعلومات الفائضة في عدد محدد من العوامل التي تختزل مجمل التباينات. والتي تستخدم للتحليل كعزل المناطق المائية والمناطق الزراعية ونوع التربة وغيرها.

5- كذلك تم التوصل الى ان طريقة KPCA تكون جيدة في حالة كون البيانات لخطية حيث تعطي نتائج جيدة .

6- طريقة KPCA تكون صعبة حسابيا في حالة كون نقاط البيانات كبيره اي مصفوفة اللب من الدرجة $M \times M$ كبيره .

7- تقنية PCA تقنية لا تقل جودة عن تقنية KPCA فقد اثبتت نتائجها انها قادرة على اختزال كم كبير من المعلومات الفائضة في عدد محدد من العوامل التي تختزل مجمل التباينات للقنوات اللونية.

5- التوصيات (Recommendations)

- 1- تطبيق اساليب تخفيض ابعاد مختلفة اخرى مثل تقنية تقليص واختيار القيم المطلقة الصغرى (Least Absolute Shrinkage and Selection Operator(LASSO)) ومقارنة النتائج مع تقنية تحليل المركبات الرئيسية كأساليب خطية لتقليل الابعاد.
- 2- اعتماد اساليب غير خطية لتخفيض الابعاد الصورية ومقارنة النتائج مع تقنية تحليل المركبات الرئيسية كأساليب خطية وأخرى غير خطية لتخفيض الابعاد

المصادر

- 1- حسو ،مهي عبد الرحمن و صديق ،منى جعفر،(2010) ،" اختيار أفضل حزمة باستخدام خوارزمية تحليل المركبات الاساسية على بيانات الاستشعار عن بعد" مجلة الرافدين لعلوم الحاسوب والرياضيات وقائع المؤتمر العلمي الثالث في تقانة المعلومات ص[29-39].
- 2- حمزة، عبد المجيد الناصر و الراوي، أسماء غالب،(2006)،" استخدام بعض أساليب متعدد المتغيرات لتقليل الابعاد الصورية في تطبيقات علم الحياة ". المجلة العراقية للعلوم الاحصائية،المجلد 1427،العدد10،ص[1- 29].
- 3- صالح،وصفي طاهر و احمد ،زركار مغديد،(2012)،"استخدام تحليل المركبات الرئيسية لاستخلاص المعلومات وتحسين النسجة في معالجة الصور الرقمية" المجلد2،العدد 1.
- 4- Anuario De Psicologia, (1989)," Multidimensional Scaling"University of Umei, Swed .
- 5- Bajcsy, Peter; Groves, Peter,(2004)," Methodology for Hyperspectral Band Selection" Photogrammetric Engineering & Remote Sensing, Number 7 , pp. [793-802] .
- 6- Bernhard Scholkopf Alexander Smola and Klaus_Robert Muller ,(1996),"Nonlinear Component Analysis as a Kernel Eigenvalue Problem" .
- 7- Changshui Zhang, Jun Wang, Nanyuan Zhao, David Zhang (2004) " Reconstruction and analysis of multi-pose face images based on nonlinear dimensionality reduction" Pattern Recognition 37 ,pp[325 – 336].
- 8- Kwang In Kim, Matthias O. Franz, and Bernhard Scholkopf,(2005), " Iterative Kernel Principal Component Analysis for Image Modeling", Transactions on Pattern Analysis and Machine Intelligence ,27(9)[66-1351].
- 9- L.J.P. van der Maaten,(2007)," An Introduction to Dimensionality Reduction Using Matlab," Universiteit Maastricht .