Dimensionality Reduction using Hybrid Algorithms and Their Application to Remote Sensing Data

Maha Abdul Rahman Hasso

Mona Jaafar Siddiq

*College of Computer Science and Mathematics
University of Mosul, Mosul, Iraq*

Received on: 16/10/2012

Accepted on: 30/01/2013

ABSTRACT

In this work, A proposed Algorithm has been constructed for the selecting the best band and lessening high dimension of remote sensing data depending on multi algorithms, each on carried out and its results are studied irrespective of other, then combining them in the proposed algorithms, in the principle component analysis algorithm find covariance matrix for the processing bands . Then find Eigen vector by using Jacobs's method and this represents the highest value in Eigen vector. The algorithm was applied on many groups of multispectral image for the Mapper sensor. By applying it on the first group of images it concluded that the sixth band is the best one, because the value of its Eigen vector is the biggest one. when the algorithm was applied on the second group of images it concluded that the second band is the best one, and the value of its Eigen vector is the biggest one, when the algorithm was applied on the third group of images it concluded that the fifth band is the best, and the value of its Eigen vector is the biggest one (regarding separating the sixth infrared band in the three groups

By using wavelet transform algorithm for one level of analysis and selecting the best band according to the least value of mean square error , to show the result of selecting the best ,the k_means algorithm was used to classify images

By using K_mean classification algorithm in images .A new way was proposed to determine centers which is an important matter in accurate classifications and specifying initial centers by finding the maximum value and minimum value and finding the mean between them until getting the wanted number of centers. The algorithm was applied on three groups of multispectral images .the classification was done on total number of bands to product one band out of it.

A new algorithm was constructed depending on the previous three algorithms which applies the wavelet transform on multispectral images and finding the signal to noise ratio depending on variance of each band

And arranging it decendingly and then choosing the bands that have highest datas in order to select the best bands and apply the principle component analysis on it. After finding the Eigen vector from the algorithm and selecting the highest values from it, it will be classified.

From applying the proposed algorithm it has been clear that it is the best in accordance to applying .because it has shown high efficiency and accuracy in classification and in finding the best band.

Keywords: Remote Sensing Data, K-Mean algorithm, Signal, Noise Ratio.

اختزال البعدية باستخدام خوارزميات هجينة وتطبيقها على بيانات الاستشعار عن بعد

منى جعفر صديق

مهى عبد الرحمن حسو

كلية علوم الحاسوب والرياضيات، جامعة الموصل

تاريخ قبول البحث: 2013/01/30

تاريخ استلام البحث: 2012/10/16

الملخص

تم في هذا العمل بناء خوارزمية جديدة لغرض اختيار أفضل حزمة والتقليل من الأبعاد العالية لصور الاستشعار عن بعد اعتماداً على خوارزميات متعددة ثم تنفيذ كل خوارزمية لوحدها ودراسة نتائجها ثم دمجها في الخوارزمية المقترحة.

ففي خوارزمية تحليل المركبات الأساسية يتم إيجاد مصفوفة التباين المشترك Covariance للحزم المراد معالجتها ثم إيجاد متجه أيكن باستخدام نظرية جاكوبي وتمثل أعلى قيمة في متجه الأيكن (Eigen Vector) أفضل حزمة. وقد تم تطبيق الخوارزمية على مجاميع عدة من الصور متعددة الأطياف لمتحسس الخرائط الموضوعي (Thematic Mapper, TM)، وبطبيق الخوارزمية على المجموعة الأولى (TM) تبين أن الحزمة السادسة هي أفضل حزمة فقد كانت قيمة أيكن لها أكبر قيمة، أما المجموعة الثانية (SS) فقد كانت الحزمة الثانية هي الأفضل والتي تحمل أعلى قيمة أيكن وعند تنفيذ الخوارزمية على المجموعة الثالثة من الصور (PP) تبين أن الحزمة الخامسة هي الأفضل (مع الأخذ بنظر الاعتبار عزل الحزمة السادسة الحرارية في المجاميع الثلاثة).

تم تطبيق تحويل الموجة على الصور ولمستوي واحد من التحليل واختيار أفضل حزمة استناداً إلى أقل قيمة (MSE, Mean Square Error)، لبيان نتائج اختيار أفضل حزمة تم تبني خوارزمية K_means لتصنيف الصور.

تم في خوارزمية K-means ابتكار طريقة جديدة لتحديد المراكز والتي تمثل مسألة مهمة جداً في دقة التصنيف وهي تحديد مراكز بدائية بإيجاد أكبر قيمة لونية وأصغر قيمة لونية وإيجاد المعدل بينهما إلى أن يتم الحصول على عدد المراكز المطلوبة وقد تم تطبيق الخوارزمية على المجاميع الثلاثة من صور الاستشعار عن بعد حيث تم إجراء عملية التصنيف على عدد الحزم الكلي والحصول على حزمة واحدة منها.

كما تم بناء خوارزمية جديدة حيث اعتمدت على الخوارزميات المذكورة آنفاً وتتضمن تطبيق تحويل الموجة على الصور متعددة الأطياف وإيجاد نسبة الإشارة إلى الضوضاء (Signal to Noise Ratio) المعتمدة على التباين لكل حزمة وترتيبها تنازلياً ثم اختيار الحزم التي تحتوي على أعلى نسب من الصفات أي البيانات لاختيار أفضل الحزم وإدخالها في خوارزمية تحليل المركبات الأساسية وبعد إيجاد متجه أيكن من الخوارزمية واختيار أعلى قيم فيه يتم إدخالها في عملية التصنيف.

تبين من تطبيق الخوارزمية المقترحة أنها كانت الأفضل من ناحية التطبيق حيث أظهرت الخوارزمية كفاءة ودقة عاليتين في التصنيف وإيجاد أفضل حزمة.

الكلمات المفتاحية: بيانات الاستشعار عن بعد، خوارزمية k-mean، الإشارة، الضوضاء.

1- مقدمة

في السنوات الأخيرة أصبحت عملية استخلاص الخواص وبالأخص عملية اختيار أفضل حزمة من الأمور المهمة في معالجة الصور الفائقة البعدية والصور متعددة الأطياف (hyperspectral and Multispectral images) لبيانات الاستشعار عن بعد. وأخذت اهتمام العديد من الباحثين في التطبيقات التي تمتاز باحتوائها كميات هائلة من البيانات [1].

في الصور متعددة الأطياف أصبح من الضروري التقليل من عدد الحزم (Bands number) والتقليل من الأبعاد العالية (dimensionality reduction)، إن عملية اختيار أفضل حزمة تعني كبس أو تقليل عدد الحزم بدون

فقدان المعلومات المهمة. وتوجد طريقتان للتقليل من عدد الحزم الأولى هي اختيار الحزم (Band selection) ونقصد بها اختيار الحزمة التي تحوي المعلومات الأكثر والطريقة الثانية هي استخلاص الخواص (Feature Extraction) أو بمفهوم آخر كبس الحزم باستخدام التحويلات الرياضية [2].

2- الدراسات السابقة Literature Review

تعد عملية اختيار أفضل حزمة للصور المتعددة الأطياف من التطبيقات الحديثة ولاسيما مع زيادة حجم الصور والتطور الهائل في إمكانيات الأقمار الصناعية ففي عام 2005 قام Xiaoling وآخرون [2] باختيار حزمة بالاعتماد على خوارزمية تحليل المكونات غير المعتمدة (Independent Component Analysis) حيث تم حساب مصفوفة الأوزان (Matrix) (Weight) لكل الحزم ثم إيجاد معدل القيمة المطلقة لمصفوفة الوزن وترتيبها تنازلياً واختيار الحزمة التي تحتوي على أعلى قيمة من قيم معدل القيمة المطلقة. في عام 2006 قام Shilpa وآخرون [8] باستخدام خوارزمية اختيار الحزم غير المرشدة (Unsupervised Band Selection) حيث يتم إيجاد (High-Order Moments) لكل الحزم ثم إيجاد مقياس التشابه حسب قياس مسافة Jeffries Matusita بين الحزم الناتجة من الخطوة آفة الذكر، ثم يتم إجراء عملية التصنيف على الحزم المختارة بالاعتماد على قيمة عتبة.

3- تحليل المركبات الأساسية Principle Component Analysis

تحويل المركبات الأساسية يسمى أيضا تحليل المركبات الأساسية، و تحويل متجه أيكن، وتحويل هوتلينك أو ما يسمى بتحويل كارهونين لوف في مجال الاستشعار عن بعد وتمييز الأنماط، قُدِّم هذا التحويل أول مرة من قبل بيرسن (1901) وتمت عليه تحويلات عدة إلى أن تم تعميمه من قبل لوي (1963) ولا تزال هذه الطريقة اليوم إحدى أهم طرق المتغيرات المتعددة (Multivariate techniques) [3].

يعد هذا التحويل طريقة خطية قياسية لاختزال البعدية (Dimensionality Reduction) واستخلاص الصفات (Feature Extraction). حيث تستخدم هذه الطريقة في عملية اختيار حزمة (Band) واحدة من بين مجموعة من الحزم bands وتمثل أفضل حزمة تحتوي على عدد كبير من الصفات المستقلة، وكذلك في الإحصاء المتعدد المتغيرات (Multivariate Statistics)، وفي التوجيه الآلي (Machine Learning) والمعالجة الرقمية للصور والرؤية الحاسوبية (Computer Vision) حيث يمكن من خلاله حساب المئات من الخصائص [4][5].

وبسبب الترابط المتواجد أصلاً بين الصور المتعددة الأطياف المأخوذة بأجهزة الاستشعار عن بعد استخدم هذا التحويل على نطاق واسع في تطبيقات الاستشعار عن بعد وذلك باختزال البعدية (Dimensionality Reduction) للصور متعددة الأطياف الناتجة عن متحسسات الأقمار الصناعية [5]. إن مجموعة من الصور بحزم مختلفة يمكن إعادة ترتيبها بواسطة تحويل المركبات الأساسية (PCA) كمجموعة جديدة من الصور تدعى بالمركبات غير المترابطة إحداها مع الأخرى وهي مرتبة نسبة إلى مقدار التباين (Variance). إن الحزم الجديدة لمركبات (PCA) غير مترابطة وغير معتمدة على بعضها وهي عادة قابلة للتفسير أكثر من الصور الأصلية.

تحتوي حزمة (PCA) الأولى على أكبر نسبة تباين (Variance) بين المعلومات في حين أن حزمة (PCA) الثانية تحتوي على ثاني أكبر نسبة تباين بين المعلومات وهكذا. أما الحزمة الأخيرة فتحتوي على ضوضاء (Noise) لأنها تحتوي على أقل نسبة تباين. إن الفائدة المهمة لتحويل المركبات الأساسية هي أن معظم المعلومات ضمن الحزم المتمثلة بالتباين يمكن حفظها أو كبسها إلى عدد أصغر من الحزم بدون خسارة تذكر للمعلومات. [6]

يتطلب تطبيق تحويل المركبات الأساسية حساب مصفوفة (Variance/ Covariance Matrix) للخصائص وبعدها يتم حساب المركبات الأساسية بطريقتين أساسيتين هما طريقة الأس (Power Method) طريقة جاكوبي (Jacobi's Method). تعتمد طريقة الأس على حساب قيم أيكن (Eigen Values) الواحدة تلو الأخرى ابتداء من القيمة الأعلى المرتبطة بالمركبات الأساسية (Principal Component) التي تحتوي على معظم المعلومات ثم يتم حساب القيمة الأصغر فالأصغر وهكذا. لذا توفر طريقة الأس الفرصة لحساب قيم أيكن والمركبات الأساسية المرتبطة مع بعضها إلى مستوى مطلوب من قبل الباحث عن محتوى المعلومات في حين أن طريقة جاكوبي تحسب كل قيم أيكن دفعة واحدة ولهذا قد تتطلب زمن تنفيذ أكبر على الحاسبة، ولكن عند التنفيذ المتزامن لكليهما (طريقة الأس وطريقة جاكوبي) فإن طريقة جاكوبي تعمل بمقياس أفضل من طريقة الأس عندما يكون عدد المركبات الأساسية كبيراً وهكذا فإن الحالات التي تتطلب كمية أصغر نسبياً من المعلومات قد تعمل فيها طريقة الأس بشكل أسرع في حين عندما يكون المطلوب مستوى أعلى من المعلومات يتم استخدام طريقة جاكوبي [3] [6]. إن الهدف من تحويل المركبات الأساسية هو تحويل البيانات ذات الأبعاد العالية والمبعثرة الخصائص إلى بيانات تحتوي على الخصائص الأساسية وبصورة مرتبة. وكذلك يستخدم لاستخلاص مركبات الخصائص (Feature Components) القريبة من بعضها [3] [5]. والشكل (1) يوضح المخطط الانسيابي لخوارزمية تحليل المركبات الأساسية.

الشكل (1). المخطط الانسيابي لخوارزمية تحليل المركبات الأساسية

Wavelet Transform

4 - تحويل الموجة

لقي تحويل الموجة خلال السنوات القليلة الماضية اهتماماً واسعاً في الكثير من تطبيقات المعالجة الرقمية ومن هذه التطبيقات كبس الصور الرقمية ، وإزالة الضوضاء من الإشارات والصور الرقمية، وتقطيع الصور وتحسينها (Image Segmentation and Enhancement)، ومطابقة الصور (Image Matching)، التسجيل (Registration)، Restoratin، واستخلاص الخواص (Feature Extraction)، وتحليل إشارات القلب ECG وتمييز الحواف من الصور الرقمية (Edge Detection) ومعالجة إشارات الصوت وتمييزها (Speech Recognition) وتحليل إشارات الزلازل، كما قامت وكالة التحقيقات الفيدرالية الأمريكية (Federa Bureau of Investigation, FBI) باستخدام تحويل الموجة لكبس قواعد البيانات الضخمة المتعلقة ببصمات الأصابع [7].

إن ما يميز تحويل الموجة هو ملائمته للتطبيق على الحاسوب الرقمي وذلك لعدم احتوائه على عمليات تكامل أو اشتقاق بل يحوي عمليات الجمع والضرب وكذلك يمثل تحويل الموجة تحليلاً متغيراً من ناحية تقسيم

نافذة التردد بالنسبة إلى الزمن، مما يعطيه قوة في التحليل مقارنة بتحويل فورير الذي لا يشير إلى تغير التردد مع الزمن [8].

إن تحويل الموجة (Wavelet Transform) يعتبر من التحويلات الحديثة والمهمة التي استخدمها الباحثون في كثير من التطبيقات حيث أثبتت هذه التقنية ميزة وكفاءة عالية في معظم مجالات تطبيقات المعالجة الرقمية وفي تطبيقات الاستشعار عن بعد (Remote Sensing) المختلفة لما له من خاصية في كونه يحل الإشارة أو الصورة إلى مستويات متعددة التفاصيل وفي كلا المجالين الزمني والترددي (Frequency and Time Domain) وتعد هذه الخاصية من أهم خصائصه التي استخدمت في مجال معطيات الأقمار الصناعية وبياناتها . إن تحويل الموجة يقوم بتحليل الصورة الرقمية إلى عدة مستويات (Levels) وكل مستوى يقسم إلى أربع حزم فرعية (Subimages) بحيث يكون حجم كل حزمة مساوياً لربع حجم الصورة الأصلية في المستوى الأول من التحليل [9] والشكل (2) يمثل مخططاً لتحليل الصورة إلى مستويين.

الشكل (2). تطبيق تحويل الموجة على صورة لمستويين من التحليل

أ-الصورة الأصلية. ب- المستوى الأول من التحليل. ج-المستوى الثاني من التحليل

إن تحويل الموجة يستخدم مرشحين الأول مرشح لتمرير الترددات الواطئة فقط في الصورة (Low Pass Filter) والمرشح الثاني لتمرير الترددات العالية فقط في الصورة (High Pass Filter)، هذه المرشحات تطبق على الصورة بالاتجاهين الأفقي والعمودي . و الناتج من تحويل الموجة له أربعة أنواع [9][10]:

- 1- المعاملات التي تكون ناتجة عن إجراء عملية اللافوف الرياضي لمرشح التمرير العالي بالاتجاهين الأفقي والعمودي والتي تسمى بالخصائص القطرية (Diagonal Features, HH) من الصورة.
- 2- المعاملات التي تكون ناتجة عن إجراء عملية اللافوف الرياضي لمرشح التمرير الواطئ مع صفوف الصورة ثم إجراء عملية اللافوف الرياضي لمرشح التمرير العالي مع أعمدة الصورة و يشار إليها بالمعلومات العمودية (Vertical Information, LH.) من الصورة.
- 3 - المعاملات التي تكون ناتجة عن إجراء عملية اللافوف الرياضي لمرشح التمرير العالي مع صفوف الصورة بعد إجراء عملية اللافوف الرياضي لمرشح التمرير العالي مع أعمدة الصورة والتي تسمى بالخصائص العمودية (Horizontal Features, HL.) من الصورة.
- 4- المعاملات التي تكون ناتجة عن إجراء عملية اللافوف الرياضي لمرشح التمرير لواطئ بالاتجاهين الأفقي والعمودي والتي تسمى بالخصائص التقريبية (Approximate Features, LL) من الصورة [9][10] .

5- خوارزميات التصنيف Classification Algorithms

تعد عملية التصنيف واحدة من أهم العمليات الخاصة في معالجة وتحليل معطيات الاستشعار عن بعد التي تتطلب تقسيم الصورة إلى مناطق معزولة بحيث إن كل منطقة تشترك بخصائص معينة وتمثل عناصر مختلفة [11] وعليه يمكن تعريف التصنيف من وجهة نظر التحسس النائي بأنه عملية تقسيم الصورة المتعددة الحزم إلى أصناف مختلفة تمثل كل منها غطاءً أرضياً معيناً ويشترك جميع أعضاء الصنف الواحد الناتج عن التصنيف في خاصية واحدة على الأقل لا يملكها أعضاء الأصناف الأخرى حيث إن التشابه بين نقطتين ضمن صنف معين أكبر من التشابه بين نقطتين ضمن صنفين مختلفتين [11] [12].

وهناك نوعان من خوارزميات التصنيف المستخدمة هما التصنيف الموجه (Supervised Classification) والتصنيف غير الموجه (Unsupervised Classification). لكل نوع من أنواع التصنيف أعلاه أهمية خاصة وفق الظروف المتوفرة لتطبيقات الاستشعار عن بعد [13][14]، فالتصنيف الموجه يستخدم عندما تتوفر المعلومات الأولية عن الأصناف المتواجدة في منطقة الدراسة في حين أن التصنيف غير الموجه يستخدم في حالة عدم توفر تلك المعلومات.

في التصنيف الموجه يتم استنباط بعض الخصائص الإحصائية عن طبيعة النماذج الأولية التي تمثل الأصناف ومن أكثر خوارزميات التصنيف الموجه استخداماً هي خوارزميات الأرجحية القصوى (Maximum Likelihood Algorithm) وخوارزمية أقصر مسافة (Minimum Distance Algorithm)، أما في التصنيف غير الموجه فيتم حساب درجة التشابه بين المتجهات النمطية الداخلة للتصنيف وتعد المسافة الإقليدية هي المقياس المستخدم لحساب هذا التشابه وهذا النوع من التصنيف لا يحتاج إلى معلومات أولية إلا أنه يحتاج إلى تحديد عدد الأصناف مسبقاً وأكثر هذه الخوارزميات استخداماً هي خوارزمية العنقدة البسيطة (Simple Clustering Algorithm) وخوارزمية أقصى الأدنى (Maximin Clustering Algorithm) وخوارزمية K-means [12]، وسوف نتطرق إلى خوارزمية معدلات ك (K-Means) فقط كونها الأكثر دقة من خوارزميات العنقدة الأخرى.

K_Means Classifications Algorithm

6- خوارزمية التصنيف K-means

تعد خوارزمية (K-Means) من إحدى خوارزميات العنقدة التي تستخدم لتصنيف المميزات وذلك بإعطاء مجموعة من القيم ومحاولة تجزئتها إلى K من العناقيد استناداً إلى بعض مقاييس التشابه. وتحتاج إلى إدخال عدد الأصناف المتوقعة في البداية وهذه الخوارزمية مبنية على أساس جعل المسافة الضمنية (Intraset Distance) أقل ما يمكن وجعل المسافة الداخلية (Inter-set Distance) أكبر ما يمكن [15]. والمقصود بالمسافة الضمنية (Intraset Distance) والمسافة الداخلية (Inter-set Distance) هي إن المسافة الضمنية تمثل مدى التباعد بين أنماط الصنف الواحد وتعتمد دقة التصنيف على أقل مسافة ضمنية فكلما كانت أقل كان التصنيف أدق أما المسافة الداخلية (Interest Distance) فهي مدى التباعد بين كل صنف عن الآخر وفي هذه الحالة يعتمد التصنيف الأدق على المسافة الأبعد [16].

من مساوئ هذه الخوارزمية أنها تحتاج إلى وقت طويل وذلك لوجود مرحلة التكرار لتصحيح مراكز الأصناف أما من حيث الدقة فهي تعدّ الأفضل من بين خوارزميات التصنيف، وذلك تبعاً للآلية التي يتم فيها تحديد

مراكز الأصناف إذ إن عملية تحديث مركز الصنف لا تتم إلا بعد اختبار جميع الأنماط الموجود [17][18].
والشكل (3) يمثل المخطط الانسيابي لخوارزمية K_means.

الشكل (3). المخطط الانسيابي لخوارزمية k_means

6 - الخوارزمية المقترحة:

تتضمن الخوارزمية المقترحة الخطوات التالية:

الخطوة الأولى:- إدخال عدد الصور المتعددة الأطياف المطلوب قراءتها.

الخطوة الثانية:- قراءة الصور المتعددة الأطياف المطلوب معالجتها.

الخطوة الثالثة:- إجراء عملية تحويل الموجبة على الصور متعددة الأطياف ولمستوي واحد من التحليل.
الخطوة الرابعة:- حساب قيم نسبة الإشارة إلى الضوضاء للجزء LL للصور المتعددة الأطياف وذلك باستخدام المعادلة الآتية

$$SNR_{std} = 20\log_{10}\left[\frac{\max_value - \min_vaku e}{\sigma}\right] \quad \dots(1)$$

حيث تمثل σ الانحراف المعياري.

الخطوة الخامسة:- ترتيب قيم نسبة الإشارة إلى الضوضاء تنازلياً.
الخطوة السادسة:- تحديد أفضل الحزم وذلك عن طريق إيجاد 75% من البيانات الناتجة من تحويل الموجبة.
الخطوة السابعة:- تطبيق خوارزمية تحليل المركبات الأساسية على الحزم المحددة من الخطوة السابقة.
الخطوة الثامنة:- إيجاد أفضل الحزم وذلك عن طريق إيجاد 75% من بيانات متجه أيكن ثم إدخالها على عملية التصنيف. والشكل (4) يوضح المخطط الانسيابي للخوارزمية المقترحة.

الشكل (4). المخطط الانسيابي للخوارزمية المقترحة

7- النتائج والاستنتاجات

1- تم تطبيق خوارزمية تحليل المركبات الأساسية على صور الاستشعار عن بعد لغرض اختيار أفضل حزمة، وقد تم تطبيق الخوارزمية على ثلاث مجاميع لصور متعددة الأطياف. تبين من تطبيق تحليل المركبات الأساسية الذي يعتمد على طريقة جاكوبي في إيجاد متجه الأيكن Eigen vector، أن تطبيق PCA أظهرت كفاءة عالية ودقة في تحديد الحزمة الأفضل من بين الحزم الست المدخلة واعتماداً على قيم الأيكن وعند تطبيقها على المجموعة الأولى (TM) تبين أن الحزمة السادسة هي أفضل حزمة وذلك اعتماداً على قيم متجه الأيكن. والجدول (1) يوضح قيمة Eigen value لكل حزمة من الحزم:

جدول (1). قيم الأيكن لصور TM.

Band	Eigen Value
TM1	127.1215
TM2	10.6489
TM3	908.1359
TM4	48.0547
TM5	19.1278
TM6	20896.8049

أما عند تطبيق الخوارزمية على المجموعة الثانية من صور متعددة الأطياف لمنطقة شيخ إبراهيم في محافظة نينوى (SS) تبين أن الحزمة الثانية هي أفضل صورة وذلك لأنها تحوي أعلى قيمة في المتجه الأيكن (Eigen Vector) والجدول التالي يوضح قيمة Eigen value لكل حزمة من الحزم:

جدول (2). قيم الأيكن لصور SS.

Band	Eigen Value
S11	33.3547
S12	5630.9851
S13	35.4939
S14	1162.4913
S15	266.0042
S16	13.7956

أما عند تطبيق الخوارزمية على المجموعة الثالثة (PP) تبين أن الحزمة الخامسة هي أفضل حزمة وذلك لأنها تحوي أعلى قيمة في المتجه الأيكن (Eigen Vector). والجدول (3) يوضح قيم Eigen value لكل حزمة من الحزم:

جدول (3) قيم الأيكن لحزم PP.

Band	Eigen Value
P11	97.7605
P12	2.6718
P13	27.4449
P14	298.9302
P15	27691.9971
P16	7.7251

2- لوحظ عند تطبيق خوارزمية التحويل المويجي على صور الاستشعار عن بعد وقد لوحظ عند تطبيق هذه الخوارزمية لمريئات المتحسس (TM) لمنطقة الدراسة إن الحزمة الأولى أفضل حزمة وذلك لأنها تحوي أقل

قيمة من بين القيم (MSE) والجدول (4) يوضح قيم MSE و RMSE و PSNR لمربيات المجموعة الأولى TM.

جدول (4). يوضح قيم MSE و RMSE و PSNR لمربيات TM.

Bands	MSE	RMSE	PSNR
TM1	E-0288.2860	E-0142.8785	318.9474
TM2	E-0289.4315	E-0143.0711	318.3850
TM3	E-0289.7181	E-0143.1174	318.2550
TM4	E-0289.9212	E-0143.1498	318.1652
TM5	E-0271.4802	E-0143.8473	316.4277
TM7	E-0271.4766	E-0143.8427	316.4381

أما عند تطبيق خوارزمية تحويل الموجة على مربيات منطقة الشيخ إبراهيم في محافظة نينوى (SS) ظهرت الحزمة الثانية أفضل حزمة لأنها تحوي أقل قيمة من بين القيم (MSE). والجدول (5) يوضح قيم MSE و RMSE و PSNR لمربيات المجموعة الثانية SS.

جدول (5). يوضح قيم MSE و RMSE و PSNR لمربيات SS.

Bands	MSE	RMSE	PSNR
S11	E-0271.3892	E-0143.7272	315.2211
S12	E-0283.2212	E-0141.7948	315.7477
S13	E-0285.7091	E-0142.3894	316.4623
S14	E-0271.2733	E-0143.5683	314.4799
S15	E-0271.7031	E-0144.1268	315.5767
S17	E-0284.9485	E-0142.2245	316.6921

وعند تطبيق خوارزمية تحويل الموجة على المجموعة الثالثة (PP) ظهرت الحزمة الثانية أفضل حزمة لأنها تحوي أقل قيمة من بين القيم (MSE). والجدول (6) يوضح قيم MSE و RMSE و PSNR لمربيات المجموعة الثالثة PP.

جدول (6). يوضح قيم MSE و RMSE و PSNR لمربيات PP.

Bands	MSE	RMSE	PSNR
P11	E-0271.5060	E-0143.8807	315.8620
P12	E-0284.9591	E-0142.2269	315.7167
P13	E-0271.0177	E-0143.1902	316.2849
P14	E-0289.4610	E-0143.0759	314.6428
P15	E-0272.4786	E-0144.9785	314.1888
P17	E-0288.5292	E-0142.9205	315.4015

3- عند تطبيق خوارزمية K_means على الصور المتعددة الأطياف تم إجراء التصنيف على عدد الحزم المراد تصنيفها والحصول على حزمة واحدة والشكل (5) يمثل الصورة الناتجة من تطبيق خوارزمية K_means على صور متعددة الأطياف لمتحس الخرائط الموضوعي (TM).

شكل (5). تنفيذ خوارزمية Kmeans_Classification على صور TM.

والشكل (6) يمثل الصورة الناتجة من تطبيق خوارزمية K_means على صور منطقة شيخ إبراهيم في محافظة نينوى (SS).

الشكل (6). تنفيذ خوارزمية Kmeans_Classification على صور منطقة شيخ إبراهيم (SS).

وعند تطبيق خوارزمية K_means على المجموعة الثالثة من الصور المتعددة الأطياف (PP) تم الحصول على الشكل التالي يمثل الصورة الناتجة من التصنيف للمجموعة الثالثة من الصور (PP)

الشكل (7). تنفيذ خوارزمية Kmeans_Classification على صور المجموعة الثالثة PP.

4- عند تطبيق الخوارزمية المقترحة على صور الاستشعار عن بعد التي بنيت على أساس الخوارزميات الثلاثة السابقة حيث يتم تطبيق التحويل المويجي على عدد الحزم المدخلة واختيار أفضلها عن طريق حساب SNR المستند على الانحراف المعياري (معادلة 1) اختيار أفضل الحزم قياسياً التي تحوي على 75% من البيانات وتطبيق خوارزمية تحليل المركبات الأساسية وحساب أفضل متجه أبيض ثم تصنيف الصور باستخدام خوارزمية التصنيف K_means .

والجدول التالي يوضح قيم SNR والنسبة المئوية لكل حزمة من الحزم TM بعد إجراء عملية تحويل الموجة لها. والشكل (8) يوضح الناتج النهائي للخوارزمية المقترحة على صور الخرائط الموضوعية
جدول (7). يوضح قيمة SNR والنسبة المئوية لكل حزمة لصور TM.

Bands	SNR	Percentage
TM1	28.1172	16.3973
TM2	28.1923	16.4410
TM3	28.2925	16.4994
TM4	28.7510	16.7721
TM5	29.1158	16.9796
TM6	28.9976	16.9107

الشكل (9). يوضح الناتج النهائي للخوارزمية المقترحة على صور TM.

والجدول (8) يوضح قيم SNR والنسبة المئوية لكل حزمة من الحزم SS بعد إجراء عملية تحويل الموجة لها والشكل (10) يوضح الناتج النهائي للخوارزمية المقترحة على صور منطقة شيخ إبراهيم

جدول (8). يوضح قيمة SNR لكل حزمة والنسبة المئوية لصور SS

Bands	SNR	Percentage
S11	36.2781	17.1118
S12	35.6678	16.8239
S13	34.8963	16.4600
S14	37.8486	17.8526
S15	33.5343	15.8176
S16	33.7813	15.9341

الشكل (10). الناتج النهائي للخوارزمية المقترحة على صور SS.

والجدول (9) يوضح قيم SNR والنسبة المئوية لكل حزمة من الحزم PP بعد إجراء عملية تحويل الموجة لها

جدول (9). يوضح قيمة SNR والنسبة المئوية لكل حزمة لصور PP.

Bands	SNR	Percentage
P11	23.7644	17.2133
P12	23.0561	16.7003
P13	23.3656	16.2001
P14	23.9388	17.3396
P15	22.7285	16.4630
P16	22.2047	16.0836

أما الصورة الناتجة فتمثل تنفيذ الخوارزمية المقترحة على المجموعة الثالثة (PP).

الشكل (11). الناتج النهائي للخوارزمية المقترحة على صور PP.

نلاحظ بتطبيق الخوارزمية المقترحة أن الخوارزمية أظهرت دقة عالية في التصنيف بعد اختيار أفضل حزمة مدخلة التي تمثل أعلى نسبة من البيانات. كما هو واضح في الشكل (7) والشكل (11) والذي بين الاختلاف الكبير بين التصنيف فقط والتصنيف باستخدام الخوارزمية المقترحة.

المصادر

- [1] Hongjun, Sheng and Peijun, 2008, "A New Band Selection Algorithm For Hyperspectral Data Based on Fractal Dimension", The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. Vol. XXXVII. Part B7. Beijing.
- [2] El Hassan, 2007, "Digital Image Processing in Remote Sensing", College of Engineering, Research Center, King Saud University.
- [3] Mather Paul M., 1987, "Computer Processing Of Remotely-Sensed Image", Department of Geography, university of Nottingham England.
- [4] Pal M., 2002, "Factors Influencing The Accuracy Of Remote Sensing Classifications", University of Nottingham.
- [5] Bajcsy P., Groves P., 2004, "Methodology For Hyperspectral Band Selection", National Center for Supercomputing Applications (NCSA), University of Illinois at Urbana-Champaign, Published in Photogrammetric Engineering and Remote Sensing journal, Vol. 70, Number 7, July 2004, pp. 793-802.
- [6] Shumam, T., Turkan A.K.H. Al, 2001, "An Integrated Software for Remotely Sensed Data Classification", M.Sc. Thesis, College of Science, University of Mosul-Iraq .
- [7] Gonzalez Rafael C. and Woods Richard E., (2008), "Digital Image Processing", Prentice Hall, Inc., 3rd edition.
- [8] Mustafa, Firas Mahmood Mustafa, 1999, "Wavelet Filters and its Application in Denoising From Images", M.Sc.Thesis, college of Engineering, university of Mosul.
- [9] Qub'a, Abdul-Rahmam R.A.K, 2001, "Multispectral Image Fusion Using Wavelet Transform", M.Sc.Thesis, college of sciences, university of Mosul, Remote sensing Center.
- [10] AL- Ani, Fatin Aziz., 2005, "Image process by using EZW method ", M.Sc. Thesis, college of computer sciences and Mathematics, university of Mosul.
- [11] Al-Kuhla, Lubna Thanon Hmedi, 2004, "Integration between Conventional & Neural Network Approaches For Unsupervised Classification of Remotely Sensed Data", M.Sc. Thesis, College of Computers and Mathematical Science, University of Mosul, Remote Sensing Center.
- [12] Mumtaz1 K. and Duraiswamy K., 2010, "A Novel Density based improved k-means Clustering Algorithm", (IJCSE) International Journal on Computer Science and Engineering, India, Vol. 02, No. 02, 2010, pp 213-218.
- [13] Mikhled Alfaouri, Khaled Daqrouq, Jamal Al-Nabulsi, 2010, "K-mean Clustering and Arabic Vowels Formants Based Speaker Identification System", European Journal of Scientific Research, Vol. 42, No. 3, pp. 406-417.
<http://www.eurojournals.com/ejsr.htm> .
- [14] Shah Chintan A., Arora Manoj K., and Varshney Pramod k., 2004, "Unsupervised classification of hyperspectral data: an ICA mixture model based

- approach”, International Journal of Remote Sensing, VOL. 25, NO. 2, pp. 481–487. <http://www.tandf.co.uk/journal>.
- [15] Yadav Abhishak and Yadav Poonam, 2009, ”Digital image Processing”, University Science Press.
- [16] AL-Shamdeen, Muna Jaffer, 2011, “The Best Band Selections Using Hybrid Techniques Applied on Remote Sensing Data”, M.Sc. Thesis, college of computer sciences and Mathematics, university of Mosul.
- [17] PRATT William k., 2009, “Digital Image Processing“, 3rd edition, A Wiley–Interscience.
- [18] Al- Omari, Huda Abdullah Bashalim, 2004, "A Genetic Chromosome for Image Segmentation", M.Sc. Thesis, college of Computer Science & Mathematics, university of Mosul.