

تقدير معلمات انموذج الاشارة الجيبية ذو البعدين بتوظيف خوارزمية

Deferential Evaluation واستخدام النهج المتسلسل في التقدير

أ.د. ظافر حسين رشيد / قسم الاحصاء / كلية الادارة والاقتصاد / جامعة بغداد
م. اواث سردار وادي / قسم الاحصاء / كلية الادارة والاقتصاد / جامعة صلاح الدين

تاریخ التقديم: 25/1/2017

تاریخ القبول: 11/5/2017

المستخلص :

يعد تقدير المعلمات غير المعلومة في انموذج الاشارة الجيبية ذو البعدين 2-D Sinusoidal Signal Model من المسائل المهمة والصعبة، وذلك لأهمية هذا الانموذج في نمذجة صور النسجات الرمادية المتماثلة . لذا تم في هذا البحث اقتراح توظيف خوارزمية Deferential Evaluation واستخدام النهج المتسلسل لتقدير الترددات غير المعلومة والاسعة للمركبات الجيبية ذات البعدين عندما تتأثر الاشارة بالضوضاء noise ، وتم استخدام اسلوب المحاكاة لاجام عينات مختلفة ومستويات مختلفة للانحراف المعياري وذلك لمعرفة اداء هذه الطريقة في تقدير معلمات انموذج الاشارة الجيبية ذو البعدين وتم استخدام هذا الانموذج لنمذجة صورة نسيجية رمادية متماثلة وتقديرها باستخدام الطريقة المقترحة لبيان مدى كفاءة هذا الانموذج في نمذجة هذا النوع من الصور الرمادية ، وتم التوصل الى كفاءة انموذج الاشارة الجيبية ذو البعدين في نمذجة هذا النوع من الصور الرمادية وكفاءة الطريقة المقترحة في تقدير معلمات الانموذج .

المصطلحات الرئيسية للبحث / انموذج الاشارة الجيبية ذو البعدين – طريقة مقدرات Deferential المتسلسلة ، الصور النسيجية الرمادية المتماثلة . Evaluation



مجلة العلوم
الاقتصادية والإدارية
العدد 102 المجلد 24
الصفحات 331-343

*البحث مستقل من اطروحة دكتوراه .



1 - المقدمة :

أن المشكلة الرئيسية في هذا البحث هي تقدير المعلمات لانموذج الاشارة الجيبية ذو البعدين 2-D Sinusoidal Signal Model [4][6][7][9] :

$$y(m, n) = \sum_{k=1}^p [A_k \cos(m\lambda_k + n\mu_k) + B_k \sin(m\lambda_k + n\mu_k)] + X(m, n) \quad \dots(1)$$

$$m = 1, 2, \dots, M, \quad n = 1, 2, \dots, N.$$

A_k, B_k : تمثل المعلمات الحقيقية غير المعلومة وتعرف بالسعة . amplitudes

λ_k, μ_k : تمثل الترددات غير المعلومة ، وأن $(\lambda_k, \mu_k) \in (0, \pi)$.

p : عدد مركبات الاشارة وتكون معلومة او غير معلومة .

$y(m, n); m = 1, 2, \dots, M, n = 1, 2, \dots, N$ } : تمثل البيانات المشاهدة للعينة .

علما أن الحد الأول في المعادلة (1) من الطرف اليمين يمثل مركبة الاشارة Signal component ، أما الحد الثاني فيمثل مركبة الضوضاء noise component ، وان هذا الانموذج هو توسيع لانموذج الاشارة الجيبية ذو البعدين الواحد [10].

يعد الكشف عن مركبات اشارة في وجود الضوضاء من المسائل المهمة في معالجة الاشارات الاحصائية والتي تلقى اهتماما كبيرا في ادبيات عمليات الاشارات وذلك لأن نماذج الاشارة الجيبية لها تطبيق واسع في تحليل النسجة texture analysis [9] ، وأن اول من لاحظ أن هذه النماذج كفؤة جدا لنموذج 2-D Francos et al [1] وقام بتقدير الترددات غير المعلومة عن طريق اختيار اشد القمم في دالة (I (λ, μ)) Periodogram function للاشارات المشاهدة $y(m, n)$.

تظهر مشكلة تقدير معلمات انموذج الاشارة الجيبية ذي البعدين عندما تكون عدد مركبات الاشارة $P \geq 2$ ، وذلك لصعوبة ايجاد التقديرات باستخدام طرائق العدبية ، وكذلك عندما تكون $p = 2$ ولكن المسافة بين ازواج الترددات (λ_1, μ_1) و (λ_2, μ_2) صغيرة جدا ، لذلك تعاني اغلب طرائق التقدير من عدم امكانية الفصل بين ازواج الترددات ، ومن هنا ظهرت الحاجة لايجاد طريقة لتقدير معلمات انموذج الاشارة الجيبية ذو البعدين عندما يكون عدد مركبات الاشارة كبيرا وقد اقترح Prasad et al [9] طريقة متسلسلة لتقدير معلمات انموذج الاشارة الجيبية ذي البعدين عندما يكون توزيع الخطأ من حقل عشوائي مستقر ويتبع التوزيع الطبيعي بمتوسط صفر وبيان محمد وتعتمد هذه الطريقة على خوارزمية Downhill في ايجاد

دالة الهدف ، ومن هنا جاءت فكرة هذا البحث ، والهدف منه هو تقدير المعلمات غير المعلومة في انموذج الاشارة الجيبية ذي البعدين وذلك بتوظيف خوارزمية Defferential Evoluation في ايجاد minimization دالة الهدف والتي تمتاز بانها لا تحتاج الى مقدرات اولية لعرض التقدير كما في الطرائق الاخرى ، وانما تعتمد على اسلوب البحث المباشر الذي يحتاج فقط الى تحديد الحد الادنى والاعلى للمعلمات المطلوب تقديرها ، وكذلك قمنا باستخدام اسلوب او النهج المتسلسل في تقدير معلمات انموذج الاشارة الجيبية ذو البعدين البالغ عددها $4p$ ، والذي جعل من الطريقة المقترحة سهلة التطبيق والاستخدام في تقدير المعلمات عندما يكون عدد مركبات الاشارة كبير ، وذلك لأننا نقوم بتقدير اربع معلمات في كل مرحلة بدلا من تقدير $4p$ من المعلمات في وقت واحد ، وبذلك تكون قد اخترلنا مسائل الامثلية ذات البعدين $2p$ الى p من مسائل الامثلية ذات البعدين الواحد. وقد قمنا في هذا البحث باستخدام انموذج الاشارة الجيبية ذي البعدين لنموذج صور النسجات الرمادية المتماثلة ومن ثم استخدام الطريقة المقترحة لغرض تقدير معلمات الانموذج ومن خلال ذلك يتم استخلاص النسجة الاصلية من النسجة التي تحتوي على الضوضاء ، ولتوسيع هذه الطريقة وبيان افضليتها تم استخدام اسلوب المحاكاة وتحليل بيانات النسجة الحقيقة . ولبعض التطورات النظرية لانموذج الاشارة الجيبية ذو البعدين يمكن الرجوع الى المصادر الآتية :

Kundu & Nandi [2-4] , Nandi [5] , Nandi, Kundu & Srivastava [6] , Nandi, Prasad & Kundu [7] , Prasad , Kundu & Mitra [9] , Zhang & Mandrekar [12].



2- طريقة مقدرات المتسلسلة Deferential Evaluation

أغلب طرائق التقدير التكرارية المستخدمة في تقدير معلمات انموذج الاشارة الجيبية ذي البعدين المعطى في الصيغة (1) تتطلب قيم بدائية لغرض الحصول على المقدرات ، سواء باستخدام الاسلوب المتسلسل او غير المتسلسل في التقدير ، ولكن ايجاد هذه القيم البدائية يكون حاسماً للغاية لأنه قد يؤدي إلى الوصول الى local minimum بدلاً من global minimum في حالة عدم دقة اختيار هذه القيم ، ومن الصعب ايجاد القيم البدائية في حالة كون عدد مركبات الاشارة $2 \leq p$ ، وكذلك عندما تكون ازواج الترددات مغلقة مع بعضها بعضًا [9] . لذلك قمنا باقتراح توظيف خوارزمية Deferential Evaluation وبشكل متسلسل لتقدير معلمات انموذج الاشارة الجيبية والتي تمتاز بانها لا تحتاج الى تقدير اولي اي انها لا تتطلب ايجاد قيم بدائية لغرض التقدير ، ويمكن تلخيص خطواتها بالشكل الاتي :

1- كما في الطريقة المتسلسلة [9] نفرض أن الانموذج ذو الصيغة (1) يحتوي على اربع معلمات، فيكون الانموذج بالشكل الاتي :

$$y(m,n) = [A \cos(m\lambda + n\mu) + B \sin(m\lambda + n\mu)] + X(m,n) \quad \dots (2)$$

وان عمل هذه الطريقة يبدأ بتقليل الدالة :

$$Q_1(A, B, \lambda, \mu) = \sum_{m=1}^M \sum_{n=1}^N [y(m,n) - A \cos(m\lambda + n\mu) - B \sin(m\lambda + n\mu)]^2 \quad \dots (3)$$

بالنسبة للمعلمات (A, B, λ, μ) ويمكن تحقيق ذلك بسهولة باستخدام تقيية Sparable regression [9] ، كما في طريقة المربعات الصغرى عندما تكون μ ثابتة فإن : $\hat{B}(\lambda, \mu)$ و $\hat{A}(\lambda, \mu)$ يجعل المعادلة (3) اقل ما يمكن عندما :

$$[\hat{A}(\lambda, \mu) \quad \hat{B}(\lambda, \mu)]^T = (U_1^T U_1)^{-1} U_1^T Y \quad \dots (4)$$

اذأن :

$$MN \times 2 \quad U_1$$

$$U_1 = \begin{bmatrix} \cos(\lambda + \mu) & \dots & \cos(\lambda + N\mu) & \cos(2\lambda + \mu) & \dots & \cos(M\lambda + N\mu) \\ \sin(\lambda + \mu) & \dots & \sin(\lambda + N\mu) & \sin(2\lambda + \mu) & \dots & \sin(M\lambda + N\mu) \end{bmatrix}^T \quad \dots (5)$$

Y : يمثل متجه البيانات من الدرجة $MN \times 1$

$$Y = [y(1,1) \quad \dots \quad y(1,N) \quad y(2,1) \quad \dots \quad y(2,N) \quad \dots \quad y(M,1) \quad \dots \quad y(M,N)]^T \quad \dots (6)$$

وبعد ايجاد $\hat{A}(\lambda, \mu)$ و $\hat{B}(\lambda, \mu)$ وتعويضها في المعادلة (3) نحصل على المعادلة الاتية :

$$R_1(\lambda, \mu) = Q_1(\hat{A}(\lambda, \mu), \hat{B}(\lambda, \mu), \lambda, \mu)$$

$$= \sum_{m=1}^M \sum_{n=1}^N [y(m,n) - \hat{A}(\lambda, \mu) \cos(m\lambda + n\mu) - \hat{B}(\lambda, \mu) \sin(m\lambda + n\mu)]^2 \quad \dots (7)$$

2- استخدام خوارزمية Deferential Evaluation [11] في ايجاد Minimizing لدالة R_1 في الصيغة (7) لغرض تقدير المعلمات μ, λ وذلك من خلال الخطوات الاتية :

- تعريف المتجهات التي تمثل الحد الادنى والاعلى للمعلمات المطلوب تقديرها وفق هذه الخوارزمية وهي λ, μ ، وبما أن $(\lambda, \mu) \in (0, \pi)$ من خلال فرضيات الانموذج لذلك تكون المتجهات كالاتي :

$$lower = (0,0)$$

$$upper = (\pi, \pi)$$

اذأن القيمة الاولى في المتجه الأول والثانى تمثل الحد الادنى والاعلى للمعلمة λ ، والقيمة الثانية في المتجهين تمثل الحد الادنى والاعلى للمعلمة μ .



**تقدير معلمات انموجن الاشارة الجيبية ذو البعدين بتوظيف خوارزمية
 واستخدام النهج المتسلسل في التقدير Deferential Evaluation**

- يتم تهيئة المجتمع البدائي لمتجه المعلمات المطلوب تقديرها:

$$X_{i,G} = \begin{bmatrix} \lambda_{1,i,G} \\ \mu_{2,i,G} \end{bmatrix}, \quad i = 1, 2, \dots, N_p$$

من خلال توليد قيم عشوائية بشكل منظم بين الحد الادنى والاعلى للمعلمات ، يكون حجم هذا المجتمع N_p ،
 علماً أن G تمثل الاجيال . فيكون المجتمع البدائي كالتالي :

Individual 1	Individual 2	...	Individual N_p
$x_{1,G}$	$x_{2,G}$...	$x_{N_p,G}$
$\lambda_{1,1,G}$	$\lambda_{1,2,G}$...	$\lambda_{1,N_p,G}$
$\mu_{2,1,G}$	$\mu_{2,2,G}$...	$\mu_{2,N_p,G}$
$f(x_{1,G})$	$f(x_{2,G})$...	$f(x_{N_p,G})$

- وحساب دالة الهدف R_1 لكل فرد Individual في المجتمع والتي يرمز لها $f(x_i, G), i = 1, \dots, N_p$
- لتكوين الجيل اللاحق من الأفراد فأن كل متوجه من متوجهات المعلمات او كل Individual في المجتمع السابق البالغ عددها N_p يخضع الى ستراتيجيات التطوير وهي الطفرة Mutation ، اعادة التركيب Recombination والاختيار Selection وكالاتي :
 - * الطفرة Mutation : متوجه المعلمات $X_{i,G}$ يتم اختيار ثلاثة متوجهات من المجتمع بشكل عشوائي باستبعاد المتوجه المراد ايجاد قيمه في المجتمع اللاحق ، ويرمز لهذه المتوجهات الثلاثة : $x_{r1,G}, x_{r2,G}, x_{r3,G}$ وأن $i, r1, r2, r3$ تكون محددة مسبقاً.
 - * اضافة الفرق الموزون بين المتوجهين $x_{r3,G}, x_{r2,G}$ الى المتوجه الثالث الذي تم اختياره عشوائياً وذلك من خلال [11] :

$$v_{i,G+1} = x_{r1,G} + F(x_{r2,G} - x_{r3,G})$$

F : يمثل عامل الطفرة وهو ثابت من $[0,2]$.

. donor vector $v_{1,G+1}$ هو المتوجه الذي يطلق عليه

* اعادة التركيب Recombination :

يتم اعادة تركيب الحلول الناجحة من الجيل السابق وذلك من خلال :

- تطوير المتوجه $u_{i,G+1}$ الذي يمثل trial vector من خلال عناصر المتوجه

($x_{i,G}$) الذي يمثل المتوجه المراد ايجاد قيمه في الجيل اللاحق، target vector

وعناصر المتوجه ($v_{i,G+1}$) donor vector ، وذلك من خلال ادخال عناصر المتوجه

في المتوجه trial vector باحتمال CR وذلك من خلال المعادلة الآتية [11] :

$$u_{j,i,G+1} = \begin{cases} v_{j,i,G+1} & \text{if } rand_{j,i} \leq CR \text{ or } j = I_{rand} \\ x_{j,i,G} & \text{if } rand_{j,i} > CR \text{ and } j \neq I_{rand} \end{cases}$$

$$i = 1, \dots, N_p$$

$$j = 1, \dots, D$$



$$rand_{j,i} \sim U[0,1]$$

: عدد عشوائي صحيح من $[1, 2, \dots, D]$ يضمن لنا بأن تكون قيم :

$$v_{i,G+1} \neq x_{i,G}$$

* Selection :

لغرض الاختيار يتم في هذه المرحلة مقارنة دالة الهدف لكل من متوجه $(x_{i,G})$ ومتوجه $(u_{i,G+1})$ ، والمتوجه الذي يمتلك اقل دالة هدف هو المتوجه الذي يتم قبوله ويمثل i في Individual Trial ، المجتمع اللاحق، ويمكن تمثيل ذلك من خلال المعادلة [11] :

$$x_{i,G+1} = \begin{cases} u_{i,G+1} & \text{if } f(u_{i,G+1}) \leq f(x_{i,G}) \\ x_{i,G} & \text{otherwise} \end{cases}$$

$$i = 1, 2, \dots, N_p$$

وبذلك يتم تكوين اعضاء الجيل اللاحق $G+1$ ، وتستمر عمليات الطفرة Mutation ، اعادة التركيب Recombination ، والاختيار Selection لغاية تحقق معيار التوقف وبذلك تكون قد حصلنا على مقدرات المعلمات λ, μ والتي يرمز لها $\hat{\lambda}_{DE}, \hat{\mu}_{DE}$ والتي تجعل المعادلة R_1 في الصيغة (7) اقل ما يمكن ، اما للحصول على تقدير المعلمات A, B فيتم تعويض $\hat{\lambda}_{DE}, \hat{\mu}_{DE}$ في المعادلة (4) فنحصل على $\hat{A}_{DE}, \hat{B}_{DE}$ وبذلك تكون مقدرات المرحلة الأولى وفق طريقة خوارزمية DE المتسلسلة كالتالي :

$$\hat{\theta}_{1DE} = (\hat{A}_{1DE}, \hat{B}_{1DE}, \hat{\lambda}_{1DE}, \hat{\mu}_{1DE})$$

وبعد الحصول على مقدرات معلمات المرحلة الأولى يتم تصحيح البيانات لغرض استخدامها في الحصول على مقدرات المرحلة الثانية وذلك من خلال المعادلة الآتية :

$$y_{DE}^{(1)}(m, n) = y(m, n) - \hat{A}_{1DE} \cos(m\hat{\lambda}_{1DE} + n\hat{\mu}_{1DE}) - \hat{B}_{1DE} \sin(m\hat{\lambda}_{1DE} + n\hat{\mu}_{1DE}) \dots (8)$$

ومن ثم تقدير المعلمات $A_2, B_2, \lambda_2, \mu_2$ باستخدام نفس خطوات طريقة DE التي قمنا باستخدامها لغرض الحصول على تقديرات المرحلة الأولى من خلال جعل R_1 اقل ما يمكن ، ولكن في هذه المرحلة يتم تقليل الدالة R_2 ، وهي ناتجة من الدالة R_1 ولكن بعد التعويض عن $y(m, n)$ في الصيغة (7) بقيم $y_{DE}^{(1)}(m, n)$ وبذلك تكون المعادلة كالتالي :

$$R_2 = \sum_{m=1}^M \sum_{n=1}^N \left[y_{DE}^{(1)}(m, n) - \hat{A}(\lambda, \mu) \cos(m\lambda + n\mu) - \hat{B}(\lambda, \mu) \sin(m\lambda + n\mu) \right]^2 \dots (9)$$

اذ يتم ايجاد $\hat{A}(\lambda, \mu), \hat{B}(\lambda, \mu)$ من خلال الصيغة (4) ولكن بعد التعويض عن $y(m, n)$ بقيم $y_{DE}^{(1)}(m, n)$ وبتطبيق اجراءات التطوير لخوارزمية DE التي استخدمت في ايجاد مقدرات المرحلة الأولى نحصل على مقدرات المرحلة الثانية للمعلمات $A_2, B_2, \lambda_2, \mu_2$ والتي يرمز لها $\hat{\theta}_{2DE} = (\hat{A}_{2DE}, \hat{B}_{2DE}, \hat{\lambda}_{2DE}, \hat{\mu}_{2DE})$ وبالاستمرار على الخط نفسه يتم ايجاد البيانات المصححة :

$$y_{DE}^{(2)}(m, n), \dots, y_{DE}^{(k-1)}(m, n), \quad m = 1, \dots, M, n = 1, \dots, N$$



وذلك من خلال :

$$y_{DE}^{(2)}(m,n) = y_{DE}^{(1)}(m,n) - \hat{A}_{2DE} \cos(m\hat{\lambda}_{2DE} + n\hat{\mu}_{2DE}) - \hat{B}_{2DE} \sin(m\hat{\lambda}_{2DE} + \hat{\mu}_{2DE})$$
$$\vdots$$
$$y_{DE}^{(k-1)}(m,n) = y_{DE}^{(k-2)}(m,n) - \hat{A}_{(k-1)DE} \cos(m\hat{\lambda}_{(k-1)DE} + n\hat{\mu}_{(k-1)DE}) -$$
$$\hat{B}_{(k-1)DE} \sin(m\hat{\lambda}_{(k-1)DE} + \hat{\mu}_{(k-1)DE})$$

ويتم الحصول على تقدير المعلمات للمرحلة k حيث أن ($k = 3, \dots, p$) من خلال تقليل الدالة R_k الناتجة من الدالة R_1 وذلك من خلال التعويض عن $y(m,n)$ بقيم $y_{DE}^{(k-1)}(m,n)$ تكون مساوية إلى :

$$R_k(\lambda, \mu) = \sum_{m=1}^M \sum_{n=1}^N \left[y_{DE}^{(k-1)}(m,n) - \hat{A}(\lambda, \mu) \cos(m\lambda_k + n\mu_k) - \hat{B}(\lambda, \mu) \sin(m\lambda_k + n\mu_k) \right]^2 \dots (10)$$

يتم تقدير المعلمات μ, λ في المرحلة k وذلك باستخدام نفس خطوات خوارزمية DE التي تم استخدامها في المرحلة الأولى ولكن يجعل المعادلة $R_k(\lambda, \mu)$ أقل ممكناً ، علماً أن كل من $\hat{A}(\lambda, \mu), \hat{B}(\lambda, \mu)$ يتم ايجادها باستخدام المعادلة (4) ولكن بعد التعويض عن $y(m,n)$ بقيم $y_{DE}^{(k-1)}(m,n)$ ، وبذلك نحصل على مقدرات المرحلة k للمعلمات $A_k, B_k, \lambda_k, \mu_k$ والتي يرمز لها $\hat{\theta}_k = (\hat{A}_{kDE}, \hat{B}_{kDE}, \hat{\lambda}_{kDE}, \hat{\mu}_{kDE})$ ، علماً اننا تمكننا من فصل تغير معلمات كل مرحلة أي تغير اربعة معلمات في كل مرحلة من مراحل التقدير وبشكل متسلسل وذلك لكون المركبات في الانموذج ذي الصيغة (1) متعمدة.

3- النتائج العددية : Numerical Results :

سوف يتم في هذا المبحث تحليل نتائج المحاكاة العددية لإثبات كيفية عمل طريقة التقدير ازاء حجم عينات مختلفة ومستويات مختلفة للتباين، وتم كتابة البرنامج باستخدام لغة R-3.3.2-win ، وتم الحصول على تقدير المعلمات اما لرسم الصورة النسيجية المقدرة فقد تم استخدام برنامج Mat lab ، وتم افتراض الانموذج الاتي :

$$y(m,n) = \sum_{k=1}^2 [A_k \cos(m\lambda_k + n\mu_k) + B_k \sin(m\lambda_k + n\mu_k)] + X(m,n) \dots (11)$$

وان القيم الافتراضية للمعلمات هي [9] :

$$A_1 = 4, B_1 = 4, \lambda_1 = 1.8, \mu_1 = 1.1, A_2 = 1, B_2 = 1, \lambda_2 = 1.7, \mu_2 = 1$$

وأن انموذج الخطأ هو :

$X(m,n) = e(m,n) + 0.25e(m-1,n) + 0.25e(m,n-1) + 0.25e(m+1,n) + 0.25e(m,n+1)$ وأن $e(m,n)$ هي متغيرات عشوائية مستقلة تتبع التوزيع الطبيعي بمتوسط صفر ومستويات مختلفة للتباين $(\sigma = 0.25, 0.5, 0.75)$ ، وحجم عينة ($M = N = 40$) ومن ثم ($M = N = 50$) ، علماً انه تم استخدام ($M = N$) وذلك لأننا نستخدم انموذج الاشارة الجيبية ذو البعدين لنمذجة الصور النسيجية الرمادية المتماثلة ، ولغرض الحصول على التمايز تم اختيار قيم ($M = N$) ، وبذلك يكون عدد المشاهدات الكلية هي $MN = 1600, 2500$ مشاهدة على التوالي ، وقد تم استخدام عامل الطفرة $F = 1.2$ والذي تم تحديده بعده تجريب بعض القيم الأخرى ضمن المدى [0,2] وذلك لأن هذه القيمة اعطت نتائج افضل ، وتم تكرار تجربة المحاكاة بعد تكرار 200= L تجربة وتسجيل كل من معدل تقدير المعلمات ومتوسط مربعات الخطأ للمعلمات المقدرة وفق الطريقة المقترنة للتجارب البالغ عددها 200 تجربة في الجدولين (1) و(2) وكانت النتائج كالتالي:



**تقدير معلمات انموج الأشارة الجيبية ذو البعدين بتوظيف خوارزمية
 واستخدام النهج المتسلسل في التقدير Deferential Evaluation**

جدول رقم (1) يمثل معدل التقديرات والتحيز ومتواسط مربعات الخطأ للمعلمات المقدرة في المركبة $k=1$ وفق الطريقة المقترحة للتقدير ولحجوم عينات ($M=N=40,50$)، ومستويات مختلفة للانحراف المعياري عندما يتبع توزيع الضوابط التوزيع الطبيعي.

Scale	M,N	SDE	A1=4	B1=4	$\lambda_1=1.8$	$\mu_1=1.1$
$\sigma = 0.25$	40	Mean	3.412439	4.317738	1.803744	1.103760
		Bise	-0.58756	0.317738	0.003744	0.00376
		MSE	0.3456822	0.10128437	1.404057e-05	1.416502e-05
	50	Mean	4.326278	3.695012	1.798744	1.098752
		Bise	0.326278	-0.30499	-0.00126	-0.00125
		MSE	0.1067099	0.09337214	1.588879e-06	1.566520e-06
$\sigma = 0.50$	40	Mean	3.413606	4.318996	1.803756	1.103769
		Bise	-0.58639	0.318996	0.003756	0.003769
		MSE	0.3458243	0.10301886	1.420518e-05	1.428890e-05
	50	Mean	4.325809	3.693892	1.798764	1.098731
		Bise	0.325809	-0.30611	-0.00124	-0.00127
		MSE	0.1072948	0.09512526	1.565726e-06	1.649917e-06
$\sigma = 0.75$	40	Mean	3.412423	4.318321	1.803774	1.103732
		Bise	-0.58758	0.318321	0.003774	0.003732
		MSE	0.3491321	0.10340857	1.442434e-05	1.412411e-05
	50	Mean	4.328672	3.694478	1.798718	1.098760
		Bise	0.328672	-0.30552	-0.00128	-0.00124
		MSE	0.1104682	0.09616813	1.737153e-06	1.621543e-06

جدول رقم (2) يمثل معدل التقديرات والتحيز ومتواسط مربعات الخطأ للمعلمات المقدرة في المركبة $k=2$ وفق الطريقة المقترحة للتقدير ولحجوم عينات ($M=N=40,50$)، ومستويات مختلفة للانحراف المعياري عندما يتبع توزيع الضوابط التوزيع الطبيعي.

Scale	M,N	SDE	A2=1	B2=1	$\lambda_2=1.7$	$\mu_2=1$
$\sigma = 0.25$	40	Mean	1.128595	0.6383698	1.691318	0.9912964
		Bise	0.128595	-0.36163	-0.00868	-0.0087
		MSE	0.016799091	0.1312793	7.584787e-05	7.617421e-05
	50	Mean	1.092414	0.8691903	1.698214	0.9981929
		Bise	0.092414	-0.13081	-0.00179	-0.00181
		MSE	0.008730636	0.017359811	3.372505e-06	3.401064e-06
$\sigma = 0.50$	40	Mean	1.129523	0.6357024	1.691137	0.9913237
		Bise	0.129523	-0.3643	-0.00886	-0.00868
		MSE	0.017800748	0.1350425	8.027115e-05	7.696643e-05
	50	Mean	1.0883657	0.8693327	1.698222	0.9982303
		Bise	0.088366	-0.13067	-0.00178	-0.00177
		MSE	0.0086388183	0.018086983	3.771106e-06	3.710003e-06
$\sigma = 0.75$	40	Mean	1.1316922	0.6330448	1.691218	0.9911549
		Bise	0.131692	-0.36696	-0.00878	-0.00885
		MSE	0.020098495	0.1396276	8.135018e-05	8.172351e-05
	50	Mean	1.0911548	0.8680252	1.698313	0.9980822
		Bise	0.091155	-0.13197	-0.00169	-0.00192
		MSE	0.010074220	0.019355928	4.346327e-06	4.908456e-06



4- تحليل نتائج المحاكاة:

1- من خلال الجدول (1) و(2) نلاحظ أن التحيز للمعلمات الخطية في المركبة الأولى (A_1, B_1) والمركبة الثانية (A_2, B_2) أكبر من التحيز للمعلمات غير الخطية (λ_1, μ_1) و (λ_2, μ_2) على التوالي .

2- بشكل عام نلاحظ من خلال الجدول (1) و (2) أن اغلب قيم متوسط مربعات الخطأ تتناقص بازدياد حجم العينة.

3- من خلال الجدول (1) و (2) نلاحظ ان اداء الطريقة المقترنة قد كان فعالاً في تقدير معلمات انموجذ الشارة الجيبية ذو البعدين ، اذ اعطت هذه الطريقة معدل تقديرات للمعلمات مقارب جداً لقيم المعلمات الحقيقية .

4- نسجات حقيقة رمادية متماثلة :An Original Symmetric Gray Scale Texture:

سوف يتم في هذه الفقرة نبذة صورة نسيجية رمادية متماثلة حقيقة^[8] في الشكل (1) باستخدام الانموجذ (1) وتقديرها باستخدام الطريقة المقترنة ، ومن الواضح في هذه الحالة أن عدد المركبات p غير معروف ويجب معرفته قبل تقدير معلمات الانموجذ ولكن من خلال المصادر التي تم اعتمادها في هذا البحث فإن عدد مركبات الصورة في الشكل (1) تساوي 86 اي أن ($p=86$) مرکبة^[8] ، وبذلك يكون عدد المعلمات المطلوب تقديرها في الانموجذ لهذه الصورة هو ($4p=344$) معلمة والتي يرمز لها ($A_1, B_1, \lambda_1, \mu_1, \dots, A_{86}, B_{86}, \lambda_{86}, \mu_{86}$) ومن خلال استخدام الطريقة المقترنة في التقدير فإن المعلمات المقدرة للصورة في الشكل (1) تكون على التوالي كما في الجدول الآتي :

جدول رقم (3) يمثل قيم المعلمات المقدرة للصورة في الشكل (1) باستخدام الطريقة المقترنة

k	\hat{A}_k	\hat{B}_k	$\hat{\lambda}_k$	$\hat{\mu}_k$
1	0.4664708	0.3032966	0.02360148	0.000731128
2	-0.1196741	-0.1687316	0.5587925	0.0002532243
3	-0.1116676	-0.1100356	6.537841e-05	0.5561425
4	0.03583631	-0.08135087	0.5551037	0.5554451
5	-0.0405733	0.07895748	0.0007089978	1.116522
6	-0.04933183	0.006669871	1.107321	0.001180289
7	-0.04674692	0.005361172	0.5574958	1.109275
8	0.04173106	0.0108996	0.0005828038	1.67011
9	-0.03523131	0.004230933	1.67776	0.0004526201
10	0.02357709	0.0212238	0.1520569	0.002639514
11	-0.002230292	-0.02766526	0.0009774553	2.78289
12	-0.02313956	-0.01905958	0.0005854562	2.959411
13	-0.02757178	0.0007141254	1.10871	0.5573762
14	-0.02145297	0.0170462	2.247978	1.415547e-05
15	0.01939986	-0.008326378	0.0002518899	2.220297
16	0.001517915	0.0179863	1.106575	1.103266
17	0.003762875	0.02050261	0.0132198	0.003513563
18	-0.01536695	-0.005730528	2.872318	0.001487793
19	0.0008179254	0.0158419	0.004277794	1.299532
20	-0.01277654	-0.005984896	0.00400618	0.7358433
21	0.01210231	-0.006655321	0.2409386	0.0004045112
22	0.009118116	-0.009849211	0.5449686	2.778349
23	0.009994622	-0.006271698	0.0002006294	2.409196
24	0.006171477	-0.009565848	0.5526126	2.964702
25	0.009536605	-0.006454618	0.0003149421	1.847562
26	-0.01027551	0.004339265	0.4728281	0.0009588005
27	0.009911027	0.003887324	2.371903	0.5616097
28	0.002424998	0.009715069	2.730118	0.5611614
29	-0.002352457	0.009205742	1.810115	0.5562254
30	0.005266952	0.007922711	3.011073	0.01222467
31	0.004139659	0.007632843	0.5512206	2.204452
32	0.006848146	0.005020049	2.391677	0.009058705



تقدير معلمات انموجذ الاشارة الجيبية ذو البعدين بتوظيف خوارزمية
 واستخدام النهج المتسلسل في التقدير Deferential Evaluation

33	-0.002454002	0.007895972	0.004240453	0.3708277
34	-0.006320518	-0.004380648	2.219911	0.555057
35	0.004489704	-0.006230137	0.0003480076	2.78266
36	0.005597859	0.005095123	2.733567	0.004425051
37	0.005527586	-0.005412474	0.002730651	0.9119638
38	0.006748721	0.002875073	1.237719	0.006469982
39	0.001611342	0.006995006	1.678505	1.109983
40	-0.002705308	0.006820968	0.6750298	0.01087895
41	-0.004432538	0.004668405	0.5619482	1.292808
42	0.004721143	0.0042416	1.105989	1.664529
43	0.002392244	-0.005711983	0.5663688	0.7506984
44	-0.002311681	0.005732613	0.006446883	2.580905
45	0.003900684	0.004653877	0.008625215	1.033085
46	-0.0007116499	-0.005653073	0.5463398	0.5464678
47	-0.00168582	-0.005131927	1.108548	2.769564
48	-0.0005274679	-0.005542024	2.887821	0.5629213
49	-0.005302707	-0.0005643469	2.31498	1.113734
50	2.437464e-05	-0.005907504	0.01794137	3.052665
51	0.002120276	0.004798296	0.5416655	2.399578
52	0.005195049	0.0004298635	0.01160186	1.193141
53	0.003723019	-0.003718405	2.106435	0.002897044
54	0.00442694	0.002068255	0.5509298	1.652958
55	0.002178404	-0.004565658	1.455738	0.004113576
56	-0.004038642	0.002643009	0.5718929	0.3504554
57	0.004429182	0.002020476	3.022365	0.5499385
58	0.004790944	0.001040213	0.03018467	0.564601
59	0.003579619	-0.002885752	1.650619	1.681448
60	0.004510163	-0.0005245935	0.5680369	1.826244
61	0.004115544	0.001828496	0.5563125	0.9136101
62	0.0006027968	-0.004201604	1.076041	0.02475085
63	0.001893998	0.003826673	2.864049	1.091396
64	-0.002610472	-0.003501482	2.687549	1.098544
65	0.004022073	0.0005371821	0.9026085	0.5610106
66	0.003730784	-0.001602418	0.0002814097	1.621924
67	-0.0002251853	0.003876645	1.863427	0.004887461
68	-0.003566143	-0.001880721	1.642309	0.01404024
69	0.00372472	0.001154721	2.054463	0.5709554
70	0.002736752	-0.002800541	0.2537134	3.020129
71	-0.003750876	-0.0004565678	2.613645	0.00963758
72	0.003568773	-0.001033892	0.2812308	0.5551775
73	3.622198e-05	0.003703372	0.5441282	2.573411
74	0.003046235	0.002049052	0.5270617	2.806096
75	-0.002600729	0.00217048	0.1236983	1.114101
76	0.003204569	0.0008886699	0.5212961	3.13876
77	-0.003265682	0.0001271901	0.5070429	1.124013
78	0.002113372	0.002407867	0.01010863	1.949056
79	-0.0003062487	-0.00310419	0.5521369	1.472892
80	0.001770537	-0.002562965	1.136777	1.821197
81	0.003106226	4.368884e-05	2.162862	1.141487
82	-0.002068865	0.002271684	1.989076	1.126303
83	-0.001569108	0.002589861	0.6227746	3.043146
84	-0.002588975	0.001477543	8.175486e-06	1.430689
85	-0.000144888	-0.002981811	1.124416	2.957055
86	0.003008946	0.000303508	1.154122	2.179059



تقدير معلمات انموذج الاشارة الجيبية ذو البعدين بتوظيف خوارزمية واستخدام النهج المتسلسل في التقدير Deferential Evaluation

عما ان خطوات خوارزمية نمذجة الصورة النسيجية الرمادية المتماثلة باستخدام انموذج الاشارة الجيبية ذي البعدين وتقديرها باستخدام الطريقة المقترحة هي :

1- قراءة الصورة في الشكل (1) وتحويلها الى مصفوفة من درجة $N \times M$ عما ان الصورة التي تم نمذجتها وتقديرها في هذا البحث هي بحجم 50×50 .

2- نمذجة الصورة النسيجية الرمادية المتماثلة باستخدام انموذج الاشارة الجيبية ذي البعدين المعطى وفق الصيغة (1).

3- تقدير عدد مركبات الاشارة P من خلال معيار BIC^[9] اذا كان غير معروف ولكن في هذا البحث تم افتراض ان P معلومة من خلال المصدر رقم [8].

4- تقدير معلمات الانموذج $A_k, B_k, \lambda_k, \mu_k, k = 1, \dots, p$ من خلال الطريقة المقترحة.

5- ايجاد قيم $\hat{y}(m, n)$ التقديرية من خلال الصيغة الآتية :

$$\hat{y}(m, n) = \sum_{k=1}^p [\hat{A}_k \cos(m\hat{\lambda}_k + n\hat{\mu}_k) + \hat{B}_k \sin(m\hat{\lambda}_k + n\hat{\mu}_k)] \dots (12)$$

$m = 1, \dots, M, n = 1, \dots, N$

وذلك من خلال تعويض قيم المعلمات المقدرة من الجدول (3) في الصيغة (12) المذكورة اعلاه.

6- رسم قيم $\hat{y}(m, n)$ فتحصل على الصورة النسيجية المقدرة في الشكل (2).



الشكل (1) يمثل الصورة النسيجية الاصلية

الشكل (2) يمثل الصورة النسيجية المقدرة



من خلال البيانات الحقيقية والتي تمثل الصورة النسيجية الرمادية المتماثلة في الشكل (1) والصورة النسيجية الرمادية المتماثلة المقدرة في الشكل (2) والتي تم تقاديرها باستخدام الطريقة المقترحة في هذا البحث نلاحظ أن انموذج الاشارة الجيبية ذو البعدين كفؤ جدًا في نمذجة صور النسجات الرمادية المتماثلة ، إذ يتطابق النسيج المقدر مع النسيج الأصلي بشكل معقول، كما يدل ذلك على جودة التقدير لهذه الطريقة المقترحة في تقدير معلمات هذا الانموذج . وأن الانموذج من الممكن تقاديره بدرجة عالية وذلك لأننا نقوم بتقدير معلمات الانموذج بشكل متسلسل ، والا فانه كاد أن يكون مهمة صعبة في حالة تقادير كافة المعلمات في وقت واحد .

5- الاستنتاجات:

1-في هذا البحث تم اقتراح طريقة كفؤة لتقدير المعلمات في انموذج الاشارة الجيبية ذي البعدين والتي تمتاز بانها لا تحتاج الى القيم البدائية لغرض تقادير معلمات الانموذج وهذا ما يميزها على كافة طرائق التقدير العددية الأخرى التي لا تعمل بدون اعطاء قيم بدائية والتي يصعب تخمينها في حالة كون عدد مركبات الاشارة $p \geq 2$.

2-من خلال نتائج المحاكاة تبين أن طريقة مقدرات Deferential Evaluation المتسلسلة قد اعطت نتائج مرضية جدا في تقادير معلمات انموذج الاشارة الجيبية ذي البعدين من حيث اعطائها معدل تقديرات قريب من القيم الحقيقية للمعلمات .

3-من خلال البيانات الحقيقية التي تمثل الصورة النسيجية الرمادية المتماثلة و الصورة النسيجية الرمادية المتماثلة المقدرة تم التوصل الى كفاءة انموذج الاشارة الجيبية ذو البعدين في نمذجة هذا النوع من الصور الرمادية ، والذي كان واضحًا من خلال رسم الصورة المقدرة في الشكل (2) والتي لا يمكن تمييز الفرق بصرياً بينها وبين الصورة الحقيقية في الشكل (1) ، والذي يدل على جودة التقدير لهذه الطريقة المقترحة في تقادير معلمات انموذج الاشارة الجيبية ذي البعدين .

6- التوصيات والدراسات المستقبلية :

1. اقتراح تطوير الطريقة التي تم اقتراها من قبلنا في هذا البحث لتقدير معلمات انموذج الجيبية ثلاثي البعد والذي يمكن استخدامه لنمذجة الصور النسيجية الملونة ، وفي عمليات الاشارات الاحصائية .

2. تطبيق الطريقة المقترحة التي تم تناولها في هذا البحث في مجالات أخرى مثل الصور الطبية التي تنطبق عليها الموصفات المذكورة والتي يمكن للانموذج أن يمتها أو على صور بيانات الزلازل .

3. استخدام خوارزمية Deferential Evaluation في ايجاد مقدرات حصينة لمعلمات انموذج الاشارة الجيبية ذي البعدين ومقارنتها مع طرائق أخرى .

References:

- 1- Francos, J. M., Meiri, A. Z. and Porat, B. (1993)," A united texture model based on a 2-D Wold like decomposition", IEEE Transactions on Signal Processing, Vol. 41, pp. 2665-2678.
- 2- Kundu , D ., and Nandi , S .(2006) , "On discrete-domain multidimensional sinusoidal models" , Statistics, Vol. 40, No. 2, PP.129–147.
- 3- Kundu, D. and Nandi, S.(2003), "Determination of Discrete Spectrum in a Random Field", Statistica Neerlandica, Vol. 57, No. 2, pp. 258-283.
- 4- Kundu, D. and Nandi, S.(2012) , " Statistical signal processing, Frequency estimation", Springer Briefs in Statistics, Springer, New Delhi.
- 5- Nandi, S. (2012), " Estimation of parameters of two-dimensional sinusoidal signal in heavy-tailed errors", Journal of Statistical Planning and Inference, Vol. 142, pp. 2799-2808.



- 6- Nandi, S., Kundu, D., and Srivastava, R.K.(2013)," Noise space decomposition method for two- dimensional sinusoidal model", Comput. Statist. Data Anal., Vol. 58, pp. 147-161.
- 7- Nandi, S., Prasad, A., &Kundu, D. (2010)," An efficient and fast algorithm for estimating the parameters of two-dimensional sinusodial signals", Jorunal of Statistical Planning and Inference, Vol. 140, pp.153–168.
- 8- Prasad, A., & Kundu, D. (2009)," Modeling and estimation of symmetric color textures", Sankhya Series B, Vol.71, pp. 30–54.
- 9- Prasad, A., Kundu, D. & Mitra, A. (2012)," Sequential estimation of two dimensional sinusoidal models", Journal of Probability and Statistical Science, Vol. 10, No. 2, pp. 161-178.
- 10-Prasad, A., Kundu, D. and Mitra, A. (2008), "Sequential estimation of the sum of sinusoidal model parameters", Journal of Statistical Planning and Inference, vol.138, pp. 1297 - 1313.
- 11-Storn, R., and Price, K. (1997), “Differential Evolution - A Simple and Efficient Heuristic for Global Optimization over Continuous Spaces”, Journal of Global Optimization, Vol. 11, Issue.4, pp. 341–359.
- 12-Zhang, H., & Mandrekar, V. (2001),"Estimation of hidden frequencies for 2D stationary processes", Journal of Time Series Analysis, Vol. 22, pp. 613–629.



Estimation of parameters of two-dimensional sinusoidal signal model by employing Deferential Evaluation algorithm and the use of Sequential approach in estimation

Abstract:

Estimation the unknown parameters of a two-dimensional sinusoidal signal model is an important and a difficult problem , The importance of this model in modeling Symmetric gray- scale texture image . In this paper, we propose employment Deferential Evaluation algorithm and the use of Sequential approach to estimate the unknown frequencies and amplitudes of the 2-D sinusoidal components when the signal is affected by noise. Numerical simulation are performed for different sample size, and various level of standard deviation to observe the performance of this method in estimate the parameters of 2-D sinusoidal signal model , This model was used for modeling the Symmetric gray scale texture image and estimating by using proposed method, we have conclude that the 2-D Sinusoidal signal model can be effectively used to model symmetric gray- scale texture image and The efficiency of the proposed method to estimate model parameters.

Keywords: Two dimension sinusoidal signal model, sequential Deferential Evaluation estimators method, Symmetric gray scale texture image.