

انموذج cox للمخاطرة النسبية

The cox proportional risk model

أ.د. عواد كاظم شعلان الخالدي
 prof.Dr.Awad Kadim Al-Khalidy
alkhalidyawad16@gmail.com
 جامعة وارث الانبياء (ع)
 Warith Al-Anbiyaa University

م.م. رواء نوري حسين الشيكلي
 Rawaa Nouri Hussain Al-Sheikhly
Rawaa.n@uokerbala.edu.iq
 جامعة كربلاء المقدسة
 Holy kerbala university

المستخلص: تحليل البقاء هو طريقة حديثة للتحليل كونها قائمة على ان الوقت حتى حدوث الحدث قيد الدراسة هو المتغير المعتمد , ويكون فيها الوقت العامل الاساسي لتحليل البيانات حسب موضوع الدراسة وشفاء المرضى في مجال الطب يهدف البحث الى كيفية تقدير معادلات نماذج البقاء حيث نعتمد على انموذج تجريبي الذي نحصل منه على مقدرات لمعادلات معلمات نماذج البقاء اللاخطية بأقل تباين ممكن وذلك حسب طريقة التقدير للانموذج لدراسة تأثير عوامل المخاطرة من خلال بناء انموذج بقاء لا خطي وايجاد مصفوفة المعلومات و تكون مصفوفة متماثلة ومعرفة غير سالبة (أي أن قيمها الذاتية جميعها موجبة) وايجاد مصفوفة هسه أو هيسيان هي مصفوفة مربعة من مشتقات جزئية للدرجة الثانية لدالة ذات قيمة رقمية ، أو حقل عددي لأنموذج cox محدد بثلاث معلمات. فضلاً عن ايجاد مقدرات الامكان الاعظم لمعلمات التركيبة الخطية لدالة المخاطرة النسبية من خلال تعظيم دالة الامكان لأوقات البقاء , واشتقاق أسلوب نيوتن –رافسن The Newton-Raphson Procedure وهو احدى طرق التحليل العددي التكرارية التي تستخدم في حل المعادلات الرياضية اللاخطية المعقدة للتوصل الى جذور لهذه المعادلات وقد قام الباحث بزيارات متعددة الى مدينة الامام الحسين الطبية كونها مختصة بفيروس كورونا في محافظة كربلاء المقدسة بهدف الحصول على بيانات دقيقة ويومية عن الحالات المصابة في 3 اشهر للمرضى بفيروس كورونا عن قيم (3) عوامل من عوامل المخاطرة الخطرة على المصابين حسب رأي عدد من الاطباء المختصين بأمراض الجهاز التنفسي وهي نتائج الفحوصات التي تم اجراءها للمرضى المصابين والراقدين في المراكز التخصصية والمشفى والبالغ عددهم (126) مريضاً وهم عينة عشوائية من عدد المرضى الكلي في مدينة الامام الحسين (ع) الطبية في شهر 3 و4 و5 لعام 2020 وبعضهم موزعين على المشافي الاخرى ثم تم ايجاد قيم المعلمات الاولية بطريقة المربعات الصغرى الاعتيادية في برنامج excel ومن ثم تم تطبيق طريقة نيوتن رافسن لإيجاد المعالم الغير معروفة لمشتقات دوال المخاطرة في انموذج cox بعد اشتقاقها وايجاد قيم المشتقات ومن مصفوفة المعلومات نحصل على مصفوفة التباين والتباين المشترك للمعلمات المقدرة وهي قيم المعلمات المقدرة النهائية والتي منها تم ايجاد قيمة y المقدرة ومن ثم ايجاد قيمة متوسط الخطأ التربيعي

الكلمات المفتاحية: انموذج , cox دالة المخاطرة, المتغيرات التوضيحية

Abstract: Survival analysis is a modern method of analysis as it is based on the fact that the time until the occurrence of the event under study is the dependent variable, and that time is the main factor for analyzing data according to the subject of the study and the recovery of patients in the field of medicine. From it we obtain estimations for the equations of the parameters of the nonlinear survival models with the least possible variance, according to the estimation method of the model to study the influence of risk factors by building a nonlinear survival model and finding the information matrix that is a symmetric matrix and non-negative knowledge (that is, its eigenvalues are all positive) and finding a Hessian matrix or Hessian is a square matrix of partial derivatives of the second degree of a function with a numeric value, or a scalar field of the cox form It is defined by three parameters. As well as finding the capabilities of the greatest possibility for the parameters of the linear structure of the relative risk function by maximizing the possibility function for the survival times, and deriving the Newton-Raphson Procedure, which is one of the iterative numerical analysis methods that are used in solving complex nonlinear mathematical equations to find roots for these equations. The researcher made multiple visits to Imam Al-Hussein Medical City as it is specialized in the Corona virus in the holy governorate of Karbala with the aim of obtaining accurate and daily data on the infected cases in 3 months for patients with the Corona virus on the

values of (3) risk factors for the infected, according to the opinion of a number of specialized doctors respiratory diseases. These are the results of the examinations that were carried out for the infected patients and those lying in the specialized centers and hospitals, amounting to (126) patients, and they are a random sample of the total number of patients in the Imam Hussein (peace be upon him) Medical City in the months of 3, 4 and 5 of the year 2020, and some of them are distributed to other hospitals, then the values of The initial parameters are in the ordinary least squares method in the excel program, and then the Newton-Raffson method was applied to find the unknown parameters of the derivatives of the risk functions in the cox model after their derivation and finding the values of the derivatives. The estimated value of y and then finding the value of the mean squared error

Keywords: cox model, risk function, explanatory variables

Introduction

يستعمل أسلوب COX لنمذجة الوقت الى حدث معين لقيم المتغيرات التوضيحية والتي تكون ثابتة مع الزمن او تعتمد على الوقت اذ تحتوي البيانات على حالات مراقبة وحالات غير مراقبة ولهذا متغير الحالة يكون متغيراً ثنائياً و يستعمل ايضا واحد او اكثر من المتغيرات التوضيحية للتنبؤ بالحدث , وايضا لا يعتمد على قيم اوقات الحدث وإنما يعتمد على ترتيب اوقات حدوث الحدث. نحصل على تباين مقدرات الإمكان الأعظم الجزئية عن طريق اخذ المشتقة الثانية للوغاريتم دالة الامكان الاعظم الجزئية بالنسبة للمعاملات غير المعروفة للحصول على مصفوفة المعلومات اذ إن قطر ها الرئيس يمثل تباين معاملات النموذج المخاطرة اي التباين والتباين المشترك ثم حساب المعكوس لمصفوفة المعلومات بالبيانات التي تم الحصول عليها لإيجاد المعالم المقدرة

1- مقدمة البحث

2- منهجية البحث

Problem of Research

مشكلة الدراسة هي إيجاد متوسط الخطأ التربيعي بعد تقدير معاملات العوامل المؤثرة على أوقات البقاء في نماذج البقاء اللاخطية بأقل تباين ممكن

2-1 مشكلة البحث

Objective of Research

يهدف البحث الى تقدير معاملات أنموذج البقاء للتركيز على العوامل المهمة حيث نعتد على أنموذج تجريبي الذي نحصل منه على مقدرات لمعاملات نماذج البقاء اللاخطية بأقل تباين ممكن وذلك حسب طريقة التقدير للأنموذج لدراسة تأثير عوامل المخاطرة

2-2 هدف البحث

الجانب النظري :

Information Matrix

مصفوفة المعلومات تكون مصفوفة متماثلة ومعرفة غير سالبة (أي أن قيمها الذاتية جميعها موجبة) تكون مصفوفة المعلومات في حالة النماذج الخطية عبارة عن قيم مجاميع المتغيرات التوضيحية غير معتمدة على متجه معاملات الانموذج الخطي $\hat{\beta}$ بينما مصفوفة المعلومات في حالة النماذج اللاخطية تكون معتمدة على متجه معاملات الانموذج غير الخطي $\hat{\beta}$, إذ أن عناصر المصفوفة X في النماذج اللاخطية عبارة عن مشتقات جزئية بالنسبة لمعاملات الانموذج أي أن عناصر المصفوفة X دوال لمعاملات غير معروفة. وبما أنه توجد علاقة بين مصفوفة المعلومات ومصفوفة التباين والتباين المشترك للمعلومات المقدرة $[\sigma^2(X'X)^{-1}]$ فإن تحقيق أمثلية التصميم للنماذج غير الخطية تأتي من خلال جعل دالة من مصفوفة المعلومات أقل ما يمكن وتختلف هذه الدالة باختلاف طبيعة التصميم التي يتم التعامل معها وفي هذه الحالة تسمى دالة مصفوفة المعلومات بمقياس الأمثلية وتكون بحسب الصيغة أدناه :

3- مصفوفة المعلومات

$$I(\theta) = E \left(\frac{\partial}{\partial \theta} \ln f(x, \theta) \right)^2$$

إذ إن:

$I(\theta)$: مصفوفة المعلومات الخاصة بالأنموذج .

$f(x, \theta)$: الدالة الاحتمالية.

4- مصفوفة Hessian (Toman, Blaza, 1991)

مصفوفة هيس أو هيسيان هي مصفوفة مربعة من مشتقات جزئية من الدرجة الثانية لدالة ذات قيمة رقمية ، أو حقل عددي . يصف الانحناء المحلي Local Curvature لوظيفة للعديد من المتغيرات. تم تطوير مصفوفة هيس في القرن التاسع عشر من قبل عالم الرياضيات الألماني لودفيج أوتو هيسه Ludwig Otto Hesse وسميت لاحقاً باسمه. استخدمت هيس في الأصل مصطلح "المحددات الوظيفية.." .

نفترض الدالة $f: R^n \Rightarrow R$ هي دالة تأخذ متجه المدخلات $x \in R^n$ ومخرجات الدالة $f(x) \in R$ إذا كانت المشتقات الجزئية من الدرجة الثانية للدالة f موجودة ومستمرة على منطلق الدالة أذن مصفوفة Hessian للدالة f هي مصفوفة مربعة من الدرجة $n \times n$ وفق الصيغة:

$$H_{i,j} = \frac{\partial^2 f(x)}{\partial x_i \partial x_j} \quad 2$$

$$H = \begin{bmatrix} \frac{\partial^2 f(x)}{(\partial x_1)^2} & \frac{\partial^2 f(x)}{\partial x_1 \partial x_2} & \cdots & \frac{\partial^2 f(x)}{\partial x_1 \partial x_n} \\ \frac{\partial^2 f(x)}{\partial x_2 \partial x_1} & \frac{\partial^2 f(x)}{(\partial x_2)^2} & \cdots & \frac{\partial^2 f(x)}{\partial x_2 \partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 f(x)}{\partial x_n \partial x_1} & \frac{\partial^2 f(x)}{\partial x_n \partial x_2} & \cdots & \frac{\partial^2 f(x)}{(\partial x_n)^2} \end{bmatrix} \quad 3$$

5- انموذج المخاطرة النسبية لـ Cox (أبو دحروج ، 2016) Cox Proportional Hazards s Model

5-1: تحديد شكل دالة المخاطرة الاساسية

عام 1972 اقترح العالم David Cox انموذج المخاطرة النسبية لـ Cox شبه المعلمي وهو من اكثر النماذج استعمالاً , إذ انه لا توجد فرضيات تنص على انه من الضروري توفر شكل لدالة المخاطرة الاساسية في النماذج شبه المعلمية للمخاطرة النسبية إذ تقدر العلاقة بين المتغيرات التوضيحية و دالة المخاطرة النسبية بدون اي افتراضات عن شكل دالة المخاطرة الاساسية. , لذا تم استعماله في تحليل بيانات البقاء كونها تتعامل مع الوقت عن طريق تقدير جزء من معالمه وذلك باستعمال طريقة الامكان الاعظم الجزئية , إذ يتكون من دالتين دالة لا معلمية لها شكل غير محدد لدالة المخاطرة الاساسية وتعتمد على أوقات البقاء ودالة معلمية لدراسة تأثير المتغيرات التوضيحية في انموذج المخاطرة النسبية وهي لا تعتمد على أوقات البقاء , لذلك هو انموذج شبه معلمي , وتكون صيغة انموذج المخاطرة النسبية Cox حسب الصيغة الآتية

$$h(t; x) = \exp(\beta x) h_0(t) \quad t > 0 \quad 4$$

$$h(t; x) = \exp(\beta_1 x_{1i} + \beta_2 x_{2i} + \beta_3 x_{3i}) h_0(t) \quad t > 0 \quad 5$$

$h_0(t)$: الدالة الاساسية للمخاطرة المفردة وتكون موجبة عندما يكون متجه المتغيرات التوضيحية جميع قيمه صفراً

$\exp(\beta x)$: وهي تأثير المتغيرات التوضيحية الذي يكون بشكل مضاعف على دالة المخاطرة وهي المخاطرة النسبية المستقلة عن الزمن t وغير السالبة.

βx : مجموعة المتغيرات التوضيحية ولا تحتوي الحد الثابت لأنه موجود مع دالة المخاطرة الأساسية $h_0(t)$

و يستعمل أسلوب Cox لنمذجة الوقت الى حدث معين لقيم المتغيرات التوضيحية والتي تكون ثابتة مع الزمن او تعتمد على الوقت اذ تحتوي البيانات على حالات مراقبة وحالات غير مراقبة ولهذا متغير الحالة يكون متغيراً ثنائياً و يستعمل ايضا واحد او اكثر من المتغيرات التوضيحية للتنبؤ بالحدث , وايضا لا يعتمد على قيم اوقات الحدث وإنما يعتمد على ترتيب اوقات حدوث الحدث.

5-2 : مقدرات الإمكان الأعظم الجزئية لمعطيات نموذج المخاطرة النسبية لcox

في عام 1975 اقترح Cox استعمال دالة الامكان الجزئية وذلك بعد ان توصل الى الاستدلال في تقدير معلمات (β) اذ يتم مستقل في دالة المخاطرة الأساسية بالاعتماد على ترتيب الاحداث التي تقابل الوفاة او الشفاء لكي نحصل على مقدرات الامكان الاعظم الجزئية و لكي تحقق نفس الخواص التقريبية لمقدرات الامكان الاعظم الكاملة ونحصل على تقدير المعلمات تكون الصيغة:

$$L_p(\beta) = \frac{h_j(t_{(i)})}{\sum_{l \in R(t_{(i)})} h_l(t_{(i)})} \quad 6$$

$$L_p(\beta) = \frac{h_0(t)(\beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3)}{\sum_{l \in R(t_{(i)})} h_0(t) \exp(\beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3)} \quad 7$$

نطبق المضروب للاحتتمالات الشرطية بعد ان تختصر الدالة $h_0(t)$ في البسط وفي المقام فتكون الدالة كما يأتي:

$$L_p(\beta) = \prod_{i=1}^n \left[\frac{\exp(\beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3)}{\sum_{l \in R(t_{(i)})} \exp(\beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3)} \right]^{\delta_i} \quad 8$$

إذ إن

n : عدد المفردات التي في العينة

δ_i : متغير الحالة يعطى القيمة واحد عند وقت البقاء المشاهد الذي حصل فيه الحدث t_i وتكون البيانات فيه غير المراقبة ويعطى القيمة صفر عند وقت البقاء المراقب t_i

$R(t_{(i)})$: وهم الذين لازالوا على قيد الحياة غير المراقبين في وقت يسبق وقت الوفاة او هي مجموعة الخطر عند الوقت t_i .

و باعادة الكتابة للصيغة وبالاعتماد على حالات الشفاء او الوفاة:

$$L_p(\beta) = \prod_{i=1}^n \frac{\exp(\beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3)}{\sum_{l \in R(t_{(i)})} \exp(\beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3)} \quad 9$$

r : وهو عدد مفردات الشفاء او الوفاة.

نلاحظ ان دالة لا تعتمد على دالة المخاطرة الأساسية ولا تعتمد على وقت الحدث في حين تعتمد على ترتيب حدوث الحدث المشاهد ترتيب تصاعدي و تعتمد على احتمالات شرطية لوقت البقاء وهي دالة للمعطيات . وبعد ان نأخذ اللوغاريتم للمعطيات غير المعروفة $(\beta_1, \beta_2, \beta_3)$ نشق الدالة ونساوي المشتقة للصفر كما يأتي:

$$\ln L_p(\beta) = \sum_{i=1}^r \left((\beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3) - \ln \sum_i \exp(\beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3) \right) \quad 10$$

$$\ln L_p(\beta) = \sum_{i=1}^r \left(\beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 - \ln \sum_i \exp(\beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3) \right) \quad 11$$

$$\frac{\partial \ln L_p(\beta)}{\partial \beta_1} = \sum_{i=1}^r \left(x_{i1} - \left(\sum_i \exp(\beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3) X_{i1} \right) \left(\frac{1}{\sum_{l \in R(t_{(i)})} \exp(\beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3)} \right) \right) \quad 12$$

$$= \sum_{i=1}^r \left(x_{i1} - \left(\sum_{l \in R(t_{(i)})} \exp(\beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3) X_{i1} \right) \left(\frac{1}{\sum_{l \in R(t_{(i)})} \exp(\beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3)} \right) \right) = 0 \quad 13$$

$$\frac{\partial \ln L_p(\beta)}{\partial \beta_2} = \sum_{i=1}^r \left(x_{i2} - \left(\sum_{l \in R(t_{(i)})} \exp(\beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3) X_{i2} \right) \left(\frac{1}{\sum_{l \in R(t_{(i)})} \exp(\beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3)} \right) \right) \quad 14$$

$$= \sum_{i=1}^r \left(x_{i2} - \frac{1}{\sum_{l \in R(t_{(i)})} \exp(\beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3)} \sum_{l \in R(t_{(i)})} \exp(\beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3) X_{i2} \right) = 0 \quad 15$$

$$\frac{\partial \ln L_p(\beta)}{\partial \beta_3} = \sum_{i=1}^r \left(x_{i3} - \left(\sum_{l \in R(t_{(i)})} \exp(\beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3) X_{i3} \right) \left(\frac{1}{\sum_{l \in R(t_{(i)})} \exp(\beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3)} \right) \right) \quad 16$$

$$= \sum_{i=1}^r \left(x_{i3} - \left(\sum_{l \in R(t_{(i)})} \exp(\beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3) X_{i3} \right) \left(\frac{1}{\sum_{l \in R(t_{(i)})} \exp(\beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3)} \right) \right) = 0 \quad 17$$

5-3 تبين مقدرات الإمكان الأعظم الجزئية

نحصل على تبين مقدرات الإمكان الأعظم الجزئية عن طريق اخذ المشتقة الثانية للوغاريتم دالة الامكان الاعظم الجزئية بالنسبة للمعلومات غير المعروفة وتعويضها في الصيغة 24 اذ إن قطرها الرئيس يمثل تبين معلومات انموذج المخاطرة اي التباين والتباين المشترك ثم حساب المعكوس لمصفوفة المعلومات

رابعاً : مصفوفة معلومات أنموذج المخاطرة النسبية لCOX
ان مصفوفة المعلومات المستعملة عند أنموذج المخاطرة النسبية جزئية لاحتوائها لوغاريتم دالة الامكان الاعظم الجزئية , وبأخذ المشتقة الثانية للوغاريتم الدالة الجزئية لمعلومات الأنموذج غير المعروفة كما يأتي :

$$\frac{\partial^2 \ln L_p(\beta)}{(\partial \beta_1)^2} = \sum_{i=1}^r \left(- \frac{\left(\sum_{l \in R(t_{(j)})} \exp(\beta X_{(i)}) X_{i1} \right)^2 + \sum_{l \in R(t_{(j)})} \exp(\beta X_{(i)}) \sum_{l \in R(t_{(j)})} \exp(\beta X_{(i)}) x_{i1}^2}{\left(\sum_{l \in R(t_{(j)})} \exp(\beta X_{(i)}) \right)^2} \right) \quad 18$$

$$\frac{\partial^2 \ln L_p(\beta)}{(\partial \beta_2)^2} = \sum_{i=1}^r \left(- \frac{\left(\sum_{l \in R(t_{(j)})} \exp(\beta X_{(i)}) X_{i2} \right)^2 + \sum_{l \in R(t_{(j)})} \exp(\beta X_{(i)}) \sum_{l \in R(t_{(j)})} \exp(\beta X_{(i)}) x_{i2}^2}{\left(\sum_{l \in R(t_{(j)})} \exp(\beta X_{(i)}) \right)^2} \right) \quad 19$$

$$\frac{\partial^2 \ln L_p(\beta)}{(\partial \beta_3)^2} = \sum_{i=1}^r \left(- \frac{\left(\sum_{l \in R(t_{(j)})} \exp(\beta X_{(i)}) X_{i3} \right)^2 + \sum_{l \in R(t_{(j)})} \exp(\beta X_{(i)}) \sum_{l \in R(t_{(j)})} \exp(\beta X_{(i)}) x_{i3}^2}{\left(\sum_{l \in R(t_{(j)})} \exp(\beta X_{(i)}) \right)^2} \right) \quad 20$$

$$\frac{\partial^2 \ln L_p(\beta)}{\partial \beta_1 \partial \beta_2} = \frac{\partial^2 \ln L_p(\beta)}{\partial \beta_2 \partial \beta_1} = \sum_{i=1}^r \left(- \frac{\sum_{l \in R(t_{(j)})} \exp(\beta X_{(i)}) x_{i1} x_{i2} \sum_{l \in R(t_{(j)})} \exp(\beta X_{(i)}) + \left(\sum_{l \in R(t_{(j)})} \exp(\beta X_{(i)}) X_{i1} \right) \left(\sum_{l \in R(t_{(j)})} \exp(\beta X_{(i)}) X_{i2} \right)}{\left(\sum_{l \in R(t_{(j)})} \exp(\beta X_{(i)}) \right)^2} \right) \quad 21$$

$$\frac{\partial^2 \ln L_p(\beta)}{\partial \beta_1 \partial \beta_3} = \frac{\partial^2 \ln L_p(\beta)}{\partial \beta_3 \partial \beta_1} = \sum_{i=1}^r \left(- \frac{\sum_{l \in R(t_{(j)})} \exp(\beta X_{(i)}) \sum_{l \in R(t_{(j)})} \exp(\beta X_{(i)}) x_{i1} x_{i3} + \left(\sum_{l \in R(t_{(j)})} \exp(\beta X_{(i)}) X_{i1} \right) \left(\sum_{l \in R(t_{(j)})} \exp(\beta X_{(i)}) X_{i3} \right)}{\left(\sum_{l \in R(t_{(j)})} \exp(\beta X_{(i)}) \right)^2} \right) \quad 22$$

$$\frac{\partial^2 \ln L_p(\beta)}{\partial \beta_2 \partial \beta_3} = \frac{\partial^2 \ln L_p(\beta)}{\partial \beta_3 \partial \beta_2} = \sum_{i=1}^r \left(- \frac{\left(\sum_{l \in R(t_{(j)})} \exp(\beta X_{(i)}) X_{i2} \right) \left(\sum_{l \in R(t_{(j)})} \exp(\beta X_{(i)}) X_{i3} \right) + \sum_{l \in R(t_{(j)})} \exp(\beta X_{(i)}) \sum_{l \in R(t_{(j)})} \exp(\beta X_{(i)}) x_{i2} x_{i3}}{\left(\sum_{l \in R(t_{(j)})} \exp(\beta X_{(i)}) \right)^2} \right) \quad 23$$

$$I(\beta) = - \begin{bmatrix} \frac{\partial^2 \ln L_p(\beta)}{(\partial \beta_1)^2} & \frac{\partial^2 \ln L_p(\beta)}{\partial \beta_1 \partial \beta_2} & \frac{\partial^2 \ln L_p(\beta)}{\partial \beta_1 \partial \beta_3} \\ \frac{\partial^2 \ln L_p(\beta)}{\partial \beta_2 \partial \beta_1} & \frac{\partial^2 \ln L_p(\beta)}{(\partial \beta_2)^2} & \frac{\partial^2 \ln L_p(\beta)}{\partial \beta_2 \partial \beta_3} \\ \frac{\partial^2 \ln L_p(\beta)}{\partial \beta_3 \partial \beta_1} & \frac{\partial^2 \ln L_p(\beta)}{\partial \beta_3 \partial \beta_2} & \frac{\partial^2 \ln L_p(\beta)}{(\partial \beta_3)^2} \end{bmatrix} \quad 24$$

الجانب العملي:

4- بيانات الدراسة :

قامت الباحثة بزيارات متعددة الى مدينة الامام الحسين الطبية لغرض جمع البيانات اللازمة لتحقيق اهداف البحث اذ تم اختيار مدينة الامام الحسين الطبية من بين المشافي المختصة بفيروس كورونا في محافظة كربلاء المقدسة بهدف الحصول على بيانات دقيقة ويومية عن الحالات المصابة في 3 اشهر للمرضى بفيروس كورونا عن قيم (3) عاملاً من عوامل المخاطرة الخطرة على المصابين حسب رأي عدد من الاطباء المختصين بأمراض الجهاز التنفسي وهي نتائج الفحوصات التي تم اجراءها للمرضى المصابين والراقين في المراكز التخصصية والمشافي الاتية والتي يجب ان تكون محفوظة في الملفات للمرضى والبالغ عددهم (126) مريضاً وهم عينة عشوائية من عدد المرضى الكلي في مدينة الامام الحسين (ع) الطبية , مدينة الزائرين/الحجر الصحي , مشفى الهندية العام , فندق بلازة/الحجر الصحي , عيادة خاصة خلال شهر 3 و4 و5 لعام 2020 موزعين على المشافي الاتية :

(1) 92 مريضاً راقدين في مدينة الامام الحسين (ع) الطبية

- (2) 23 مريضاً راقدين في مدينة الزائرين/الحجر الصحي
 (3) 8 مرضى راقدين في مشفى الهندية العام
 (4) مريضين راقدان في فندق بلازة/الحجر الصحي
 (5) مريض واحد في عيادة خاصة د/ حيدر سلوم

كما في الملحق الجدول (1) يمثل طبيعة البيانات التي تم جمعت عن مرضى كورونا
 اذ يمثل :
 البقاء :مدة الاصابة بفيروس كورونا
 الحالة: الحالة حسب المريض خروجه متحسن أو وفاته(1). حصول الوفاة(0) خروجه متحسن
 x_1 متغير العمر.

x_2 : متغير ضغط الدم (0) لا يعاني من ضغط الدم (1) يعاني من ضغط الدم
 x_5 : متغير السكري(0) لا يعاني من السكري (1) يعاني من السكري

5- طريقة المربعات الصغرى المعلمية:

تم ايجاد قيم المعلمات الاولية بطريقة المربعات الصغرى الاعتيادية في برنامج excel وكانت كما يأتي :

$$0.124532\hat{\beta}_1 =$$

$$0.717243\hat{\beta}_2 =$$

$$0.379098\hat{\beta}_3 =$$

6- طريقة نيوتن رافسن في انموذج cox :

تم تطبيق طريقة نيوتن رافسن لإيجاد المعالم الغير معروفة لمشتقات دوال المخاطرة في انموذج cox بعد
 اشتقاقها في المعدلات وايجاد قيم المشتقات ومن مصفوفة المعلومات نحصل على مصفوفة التباين والتباين المشترك
 للمعلمات المقدرة كالآتي :

$$V(\hat{\beta}) = \begin{bmatrix} 0.000821191 & -0.049705826 & -0.02619793 \\ -0.049705826 & 10.06795189 & -5.232323466 \\ -0.02619793 & -5.232323466 & 8.437390174 \end{bmatrix}$$

وبتطبيق طريقة نيوتن رافسن كالآتي :

$$\hat{\beta}_{s+1} = \begin{bmatrix} \hat{\beta}_1 \\ \hat{\beta}_2 \\ \hat{\beta}_3 \end{bmatrix} - \begin{bmatrix} \frac{\partial^2 \ln L_p(\beta)}{(\partial \beta_1)^2} & \frac{\partial^2 \ln L_p(\beta)}{\partial \beta_1 \partial \beta_2} & \frac{\partial^2 \ln L_p(\beta)}{\partial \beta_1 \partial \beta_3} \\ \frac{\partial^2 \ln L_p(\beta)}{\partial \beta_2 \partial \beta_1} & \frac{\partial^2 \ln L_p(\beta)}{(\partial \beta_2)^2} & \frac{\partial^2 \ln L_p(\beta)}{\partial \beta_2 \partial \beta_3} \\ \frac{\partial^2 \ln L_p(\beta)}{\partial \beta_3 \partial \beta_1} & \frac{\partial^2 \ln L_p(\beta)}{\partial \beta_3 \partial \beta_2} & \frac{\partial^2 \ln L_p(\beta)}{(\partial \beta_3)^2} \end{bmatrix}^{-1} \begin{bmatrix} \frac{\partial \ln L_p(\beta)}{\partial \beta_1} \\ \frac{\partial \ln L_p(\beta)}{\partial \beta_2} \\ \frac{\partial \ln L_p(\beta)}{\partial \beta_3} \end{bmatrix} \quad 25$$

$$\hat{\beta}_{s+1} = \begin{bmatrix} 0.124532 \\ 0.717243 \\ 0.379098 \end{bmatrix} - \begin{bmatrix} 0.000821191 & -0.049705826 & -0.02619793 \\ -0.049705826 & 10.06795189 & -5.232323466 \\ -0.02619793 & -5.232323466 & 8.437390174 \end{bmatrix}^{-1} \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix}$$

$$\hat{\beta}_{s+1} = \begin{bmatrix} 0.124532 \\ 0.717243 \\ 0.379098 \end{bmatrix} = \begin{bmatrix} \beta_1 \\ \beta_2 \\ \beta_3 \end{bmatrix}$$

وهي قيم المعلمات المقدرة النهائية والتي منها تم إيجاد قيمة y المقدرة ومن ثم إيجاد قيمة متوسط الخطأ التربيعي كالآتي:

$$\sum_{i=1}^n (Y - \hat{Y})^2 = 4166.382$$

$$d. f (m. s. e.) = 122$$

$$m. s. e. = 4166.382/122 = 34.1507$$

6- الاستنتاجات :

ظهرت نتائج استعمال طريقة نيوتن رافسن لإيجاد المعالم الغير معروفة لمشتقات دوال المخاطرة تقاربت نتائج التقدير باستعمال طريقة نيوتن رافسن لإيجاد المعالم الغير معروفة لمشتقات دوال المخاطرة في انموذج COX شبه المعلمي, بشكل يكاد ان يكون متطابقا

7- التوصيات:

- 1- بعض الاشخاص قد يعانون من عدة عوامل مخاطرة وليس عامل واحد فقط فقد يكون شخص مصاباً بارتفاع ضغط الدم والسمنة والسكر فضلاً عن اذا كان لديه تاريخ مرضي للإصابة بأمراض الرئتين في سن مبكرة وهنا تبرز أهمية الجهود الوقائية والكشف عن أهم عوامل المخاطرة ومعرفة الاسباب الرئيسة للإصابة بهذا المرض, لذلك نوصي باعتماد أكثر من انموذج للمخاطرة والدمج بينها واختيار الافضل
- 2- اعتماد مبدأ التحليل العاملي كأساس للتحليل الاحصائي قبل البدء باستعمال انموذجات التوزيع ودوال المخاطرة لتقليل عدد العوامل الداخلة في التحليل وهو ما يركز الانتباه الى العوامل الحقيقية التي تؤثر في مدة البقاء.
- 3- الاعتماد على انموذجات لا معلمية وشبه معلمية ومحاولة زيادة عدد المعلمات الداخلة في الانموذجات المستهدفة في التحليل لكون المعلمة تحتزن الكثير من المعلومات عن البيانات قيد الدراسة

المصادر:

- 1- Abu Dahrouj, Samir Faraj Rashid, 2016, A comparison of survival models to study the determinants of child mortality in Palestine. Master Thesis, Department of Statistics, Faculty of Economics and Administrative Sciences, Al-Azhar University - Gaza.
- 2- Almansa ,Josué& other. 2013. A factor mixture model for multivariate survival data: an application to the analysis of lifetime mental disorders
- 3- Camblor ,Pablo Martínez & others. 2019. An instrumental variable procedure for estimating Cox models with non-proportional hazards in the presence of unmeasured confounding
- 4- Efron, Bradley. 1976. The Efficiency of Cox's Likelihood Function for Censored Data. Journal of the American Statistical Association
- 5- Hao, Meiling& other. 2018. Semiparametric Inference for the Functional Cox Model
- 6- Toman, Blaza. 1991. Bayes Optimal Designs for Two- and Three-Level Factorial Experiments
- 7- Waagepetersen, Rasmus Waagepetersen& other . 2015. Analysis of multispecies point patterns by using multivariate log-Gaussian Cox processes

الجدول (1) يمثل طبيعة البيانات التي تم جمعت عن مرضى كورونا

ت	البقاء	الحالة	x_1	x_2	x_3
1	20	0	23	0	0
2	19	1	65	1	0
3	18	0	20	0	0
4	25	1	68	0	0
5	26	0	37	0	0
6	27	0	70	1	1
7	14	1	70	1	1
8	17	0	70	0	0
9	29	0	60	1	1
10	28	0	31	0	0
11	18	0	58	0	0
12	15	0	63	0	0
13	22	0	28	0	0
14	37	1	35	0	1
15	23	0	52	0	0
16	20	0	40	0	0
17	41	0	62	1	0
18	24	0	37	0	0
19	32	0	46	0	0
20	20	0	46	0	0
21	21	0	43	0	0
22	22	0	48	0	0
23	30	0	79	1	0
24	22	0	59	1	0
25	30	0	85	0	0
26	27	1	40	0	0

27	25	1	70	1	0
28	31	0	63	1	1
29	25	0	51	1	1
30	41	0	60	1	1
31	18	0	72	1	1
32	25	0	70	0	1
33	37	0	65	0	0
34	27	0	35	0	1
35	26	0	70	0	1
36	20	0	37	0	0
37	28	0	52	0	0
38	37	0	30	0	0
39	24	0	77	0	0
40	22	0	75	0	0
41	22	0	60	0	0
42	25	0	80	0	0
43	20	0	30	0	0
44	26	0	39	0	0
45	30	0	65	1	0
46	25	0	49	0	0
47	22	0	57	0	0
48	26	0	34	0	1
49	21	0	52	0	0
50	20	0	20	0	0
51	25	0	30	0	0
52	28	0	39	0	0
53	30	0	50	1	0
54	29	0	39	1	0
55	32	0	68	1	0

56	30	0	62	0	0
57	38	0	95	1	1
58	33	0	52	0	0
59	31	0	47	0	0
60	19	0	25	0	0
61	23	0	39	0	0
62	19	0	37	0	0
63	26	0	54	0	0
64	28	0	52	0	0
65	23	0	22	0	0
66	42	0	52	0	0
67	30	0	49	0	0
68	27	0	24	0	0
69	30	0	62	0	0
70	21	0	35	0	0
71	30	0	55	0	0
72	27	0	70	0	0
73	24	0	25	0	0
74	14	0	5	0	0
75	33	0	52	0	0
76	21	0	55	0	0
77	40	0	60	0	0
78	25	0	60	0	0
79	22	0	32	0	0
80	15	0	12	0	0
81	26	0	37	0	0
82	38	0	32	0	0
83	16	0	12	0	0
84	19	0	18	0	0

85	15	0	10	0	0
86	14	0	7	0	0
87	31	0	66	0	0
88	25	0	69	0	1
89	19	0	35	0	0
90	29	1	53	0	0
91	28	0	25	0	0
92	31	0	34	0	0
93	13	0	4	0	0
94	26	0	27	0	0
95	15	0	9	0	0
96	26	0	75	1	1
97	20	0	35	0	0
98	17	0	53	0	0
99	18	0	25	0	0
100	24	0	34	0	0
101	17	0	29	0	0
102	23	0	27	0	0
103	19	0	26	0	0
104	20	0	23	0	0
105	22	0	23	0	0
106	27	0	35	0	0
107	23	0	23	0	0
108	19	0	35	0	0
109	29	0	23	0	0
110	20	0	30	0	0
111	23	0	29	0	0
112	14	0	27	0	0
113	24	0	26	0	0

114	24	0	23	0	0
115	30	0	23	0	0
116	29	0	35	0	0
117	23	0	23	0	0
118	15	0	26	0	0
119	16	0	26	0	0
120	23	0	27	0	0
121	24	0	66	0	0
122	33	0	69	0	0
123	26	0	35	0	0
124	20	0	35	0	0
125	22	0	25	0	0
126	32	0	34	0	0

جدول رقم 3 ايجاد قيمة المشقة B_1 لأنموذج cox شبه المعلمي

id	$b_1 x_1$	$b_2 x_2$	$b_3 x_3$	$\exp(\beta X_{(i)})$	$x_{11}^2 \beta X_{(i)}$	$\exp(\beta X_{(i)}) X_{11}$	$\left(\sum_{i \in R(t_{(j)})} \exp(\beta X_{(i)}) X_{11} \right)^2$	$\left(\sum_{i \in R(t_{(j)})} \exp(\beta X_{(i)}) \right)^2$
1	2.864226	0	0	17.53548	9276.26835	403.3160153	162663.8082	307.493
2	8.094552	0.717243	0	6712.959	28362253	436342.3545	1.90395E+11	45063823
3	2.490631	0	0	12.06889	4827.55797	241.3778983	58263.2898	145.6582
4	8.468147	0	0	4760.686	22013411.2	323726.6349	1.04799E+11	22664129
5	4.607668	0	0	100.2501	137242.409	3709.25431	13758567.54	10050.09
6	8.71721	0.717243	0.379098	18279.79	89570983.9	1279585.484	1.63734E+12	3.34E+08
7	8.71721	0.717243	0.379098	18279.79	89570983.9	1279585.484	1.63734E+12	3.34E+08
8	8.71721	0	0	6107.117	29924875.4	427498.22	1.82755E+11	37296883
9	7.471894	0.717243	0.379098	5261.838	18942618.5	315710.3082	99672998706	27686944
10	3.860479	0	0	47.48808	45636.0473	1472.130559	2167168.382	2255.118
11	7.222831	0	0	1370.363	4609902.65	79481.08018	6317242107	1877896
12	7.845489	0	0	2554.187	10137567.1	160913.7638	25893239370	6523870
13	3.486884	0	0	32.68395	25624.2151	915.1505386	837500.5082	1068.24
14	4.358605	0	0.379098	114.1717	139860.346	3996.009885	15968095	13035.18
15	6.475642	0	0	649.1357	1755263.02	33755.05804	1139403943	421377.2
16	4.981263	0	0	145.6582	233053.159	5826.32898	33946109.39	21216.32
17	7.720958	0.717243	0	4620.233	17760176.1	286454.4529	82056153583	21346554
18	4.607668	0	0	100.2501	137242.409	3709.25431	13758567.54	10050.09

19	5.728452	0	0	307.493	650655.233	14144.67898	200071943.4	94551.96
20	5.728452	0	0	307.493	650655.233	14144.67898	200071943.4	94551.96
21	5.354858	0	0	211.6339	391310.993	9100.255657	82814653.03	44788.89
22	5.977516	0	0	394.4591	908833.839	18934.03831	358497806.8	155598
23	9.837994	0.717243	0	38377.91	239516508	3031854.528	9.19214E+12	1.47E+09
24	7.347363	0.717243	0	3179.902	11069239.5	187614.2294	35199099082	10111778
25	10.58518	0	0	39544.57	285709546	3361288.78	1.12983E+13	1.56E+09
26	4.981263	0	0	145.6582	233053.159	5826.32898	33946109.39	21216.32
27	8.71721	0.717243	0	12512.12	61309386.5	875848.3791	7.6711E+11	1.57E+08
28	7.845489	0.717243	0.379098	7645.179	30343714	481646.2543	2.31983E+11	58448756
29	6.35111	0.717243	0.379098	1715.486	4461978.63	87489.77714	7654461103	2942892
30	7.471894	0.717243	0.379098	5261.838	18942618.5	315710.3082	99672998706	27686944
31	8.966273	0.717243	0.379098	23449.74	121563448	1688381.216	2.85063E+12	5.5E+08
32	8.71721	0	0.379098	8922.296	43719252.2	624560.7458	3.90076E+11	79607372
33	8.094552	0	0	3276.57	13843506.5	212977.0224	45359212057	10735908
34	4.358605	0	0.379098	114.1717	139860.346	3996.009885	15968095	13035.18
35	8.71721	0	0.379098	8922.296	43719252.2	624560.7458	3.90076E+11	79607372
36	4.607668	0	0	100.2501	137242.409	3709.25431	13758567.54	10050.09
37	6.475642	0	0	649.1357	1755263.02	33755.05804	1139403943	421377.2
38	3.735947	0	0	41.92772	37734.9491	1257.831636	1582140.425	1757.934
39	9.588931	0	0	14602.25	86576763.8	1124373.556	1.26422E+12	2.13E+08
40	9.339868	0	0	11382.91	64028845.9	853717.9455	7.28834E+11	1.3E+08
41	7.471894	0	0	1757.934	6328561.7	105476.0283	11125192549	3090331
42	9.962526	0	0	21216.32	135784438	1697305.469	2.88085E+12	4.5E+08
43	3.735947	0	0	41.92772	37734.9491	1257.831636	1582140.425	1757.934
44	4.856731	0	0	128.6032	195605.405	5015.523199	25155472.96	16538.77
45	8.094552	0.717243	0	6712.959	28362253	436342.3545	1.90395E+11	45063823
46	6.102047	0	0	446.7714	1072698.19	21891.79988	479250902.1	199604.7
47	7.0983	0	0	1209.908	3930991.49	68964.76291	4756138524	1463878
48	4.234074	0	0.379098	100.8034	116528.718	3427.315234	11746489.71	10161.32
49	6.475642	0	0	649.1357	1755263.02	33755.05804	1139403943	421377.2
50	2.490631	0	0	12.06889	4827.55797	241.3778983	58263.2898	145.6582
51	3.735947	0	0	41.92772	37734.9491	1257.831636	1582140.425	1757.934
52	4.856731	0	0	128.6032	195605.405	5015.523199	25155472.96	16538.77
53	6.226579	0.717243	0	1036.725	2591811.39	51836.22771	2686994503	1074798
54	4.856731	0.717243	0	263.4792	400751.79	10275.68691	105589741.5	69421.26
55	8.468147	0.717243	0	9753.582	45100563.2	663243.5767	4.39892E+11	95132362
56	7.720958	0	0	2255.118	8668673.53	139817.315	19548881574	5085557
57	11.8305	0.717243	0.379098	411202.4	3711101715	39064228.58	1.52601E+15	1.69E+11
58	6.475642	0	0	649.1357	1755263.02	33755.05804	1139403943	421377.2
59	5.852984	0	0	348.2721	769332.988	16368.78698	267937187.1	121293.4

60	3.113289	0	0	22.49492	14059.3227	562.3729086	316263.2883	506.0213
61	4.856731	0	0	128.6032	195605.405	5015.523199	25155472.96	16538.77
62	4.607668	0	0	100.2501	137242.409	3709.25431	13758567.54	10050.09
63	6.724705	0	0	832.7263	2428229.81	44967.21862	2022050751	693433
64	6.475642	0	0	649.1357	1755263.02	33755.05804	1139403943	421377.2
65	2.739695	0	0	15.48226	7493.41212	340.6096416	116014.928	239.7003
66	6.475642	0	0	649.1357	1755263.02	33755.05804	1139403943	421377.2
67	6.102047	0	0	446.7714	1072698.19	21891.79988	479250902.1	199604.7
68	2.988758	0	0	19.861	11439.9333	476.6638855	227208.4598	394.4591
69	7.720958	0	0	2255.118	8668673.53	139817.315	19548881574	5085557
70	4.358605	0	0	78.14805	95731.359	2735.181685	7481218.849	6107.117
71	6.849237	0	0	943.1606	2853060.76	51873.83195	2690894441	889551.9
72	8.71721	0	0	6107.117	29924875.4	427498.22	1.82755E+11	37296883
73	3.113289	0	0	22.49492	14059.3227	562.3729086	316263.2883	506.0213
74	0.622658	0	0	1.863875	46.596885	9.319377001	86.85078769	3.474032
75	6.475642	0	0	649.1357	1755263.02	33755.05804	1139403943	421377.2
76	6.849237	0	0	943.1606	2853060.76	51873.83195	2690894441	889551.9
77	7.471894	0	0	1757.934	6328561.7	105476.0283	11125192549	3090331
78	7.471894	0	0	1757.934	6328561.7	105476.0283	11125192549	3090331
79	3.98501	0	0	53.78585	55076.707	1721.147093	2962347.317	2892.917
80	1.494379	0	0	4.456568	641.745742	53.47881181	2859.983313	19.861
81	4.607668	0	0	100.2501	137242.409	3709.25431	13758567.54	10050.09
82	3.98501	0	0	53.78585	55076.707	1721.147093	2962347.317	2892.917
83	1.494379	0	0	4.456568	641.745742	53.47881181	2859.983313	19.861
84	2.241568	0	0	9.408075	3048.21619	169.3453439	28677.84551	88.51187
85	1.245316	0	0	3.474032	347.403151	34.74031508	1206.889492	12.06889
86	0.871721	0	0	2.391022	117.160093	16.73715612	280.1323949	5.716988
87	8.219084	0	0	3711.101	16165555.8	244932.6634	59992009607	13772270
88	8.592679	0	0.379098	7877.588	37505197	543553.5799	2.9545E+11	62056394
89	4.358605	0	0	78.14805	95731.359	2735.181685	7481218.849	6107.117
90	6.600173	0	0	735.2227	2065240.48	38966.8016	1518411627	540552.4
91	3.113289	0	0	22.49492	14059.3227	562.3729086	316263.2883	506.0213
92	4.234074	0	0	68.99772	79761.368	2345.922589	5503352.793	4760.686
93	0.498126	0	0	1.645635	26.3301591	6.582539783	43.32982999	2.708114
94	3.362352	0	0	28.857	21036.7507	779.1389166	607057.4514	832.7263
95	1.120784	0	0	3.067258	248.447938	27.60532644	762.0540477	9.408075
96	9.339868	0.717243	0.379098	34071.26	191650814	2555344.186	6.52978E+12	1.16E+09
97	4.358605	0	0	78.14805	95731.359	2735.181685	7481218.849	6107.117
98	6.600173	0	0	735.2227	2065240.48	38966.8016	1518411627	540552.4
99	3.113289	0	0	22.49492	14059.3227	562.3729086	316263.2883	506.0213
100	4.234074	0	0	68.99772	79761.368	2345.922589	5503352.793	4760.686

101	3.611416	0	0	37.01842	31132.4916	1073.534193	1152475.663	1370.363
102	3.362352	0	0	28.857	21036.7507	779.1389166	607057.4514	832.7263
103	3.237821	0	0	25.47814	17223.2241	662.431698	438815.7545	649.1357
104	2.864226	0	0	17.53548	9276.26835	403.3160153	162663.8082	307.493
105	2.864226	0	0	17.53548	9276.26835	403.3160153	162663.8082	307.493
106	4.358605	0	0	78.14805	95731.359	2735.181685	7481218.849	6107.117
107	2.864226	0	0	17.53548	9276.26835	403.3160153	162663.8082	307.493
108	4.358605	0	0	78.14805	95731.359	2735.181685	7481218.849	6107.117
109	2.864226	0	0	17.53548	9276.26835	403.3160153	162663.8082	307.493
110	3.735947	0	0	41.92772	37734.9491	1257.831636	1582140.425	1757.934
111	3.611416	0	0	37.01842	31132.4916	1073.534193	1152475.663	1370.363
112	3.362352	0	0	28.857	21036.7507	779.1389166	607057.4514	832.7263
113	3.237821	0	0	25.47814	17223.2241	662.431698	438815.7545	649.1357
114	2.864226	0	0	17.53548	9276.26835	403.3160153	162663.8082	307.493
115	2.864226	0	0	17.53548	9276.26835	403.3160153	162663.8082	307.493
116	4.358605	0	0	78.14805	95731.359	2735.181685	7481218.849	6107.117
117	2.864226	0	0	17.53548	9276.26835	403.3160153	162663.8082	307.493
118	3.237821	0	0	25.47814	17223.2241	662.431698	438815.7545	649.1357
119	3.237821	0	0	25.47814	17223.2241	662.431698	438815.7545	649.1357
120	3.362352	0	0	28.857	21036.7507	779.1389166	607057.4514	832.7263
121	8.219084	0	0	3711.101	16165555.8	244932.6634	59992009607	13772270
122	8.592679	0	0	5392.037	25671490	372050.5802	1.38422E+11	29074067
123	4.358605	0	0	78.14805	95731.359	2735.181685	7481218.849	6107.117
124	4.358605	0	0	78.14805	95731.359	2735.181685	7481218.849	6107.117
125	3.113289	0	0	22.49492	14059.3227	562.3729086	316263.2883	506.0213
126	4.234074	0	0	68.99772	79761.368	2345.922589	5503352.793	4760.686
المجموع				783315.5	5650310123		1.56816E+15	
					B_{11}	9769.067463		

جدول رقم 4 ايجاد قيمة المشتقة للـ B_2 و B_3 لانموذج COX شبه المعلمي

id	$x_{i2}^2 \beta X_{(i)}$	$\left(\sum_{i \in R(t_{(j)})} \exp(\beta X_{(i)}) X_{i2} \right)^2$	$\left(\sum_{i \in R(t_{(j)})} \exp(\beta X_{(i)}) \right)^2$	$x_{i1}^2 \beta X_{(i)}$	$\exp(\beta X_{(i)}) X_{i1}$	$\left(\sum_{i \in R(t_{(j)})} \exp(\beta X_{(i)}) X_{i1} \right)^2$	$\left(\sum_{i \in R(t_{(j)})} \exp(\beta X_{(i)}) \right)^2$
1	0	0	307.493	0	0	0	307.493
2	6712.959	45063823	45063823	0	0	0	45063823
3	0	0	145.6582	0	0	0	145.6582
4	0	0	22664129	0	0	0	22664129
5	0	0	10050.09	0	0	0	10050.09
6	18279.79	3.34E+08	3.34E+08	18279.79	18279.79	3.34E+08	3.34E+08
7	18279.79	3.34E+08	3.34E+08	18279.79	18279.79	3.34E+08	3.34E+08

8	0	0	37296883	0	0	0	37296883
9	5261.838	27686944	27686944	5261.838	5261.838	27686944	27686944
10	0	0	2255.118	0	0	0	2255.118
11	0	0	1877896	0	0	0	1877896
12	0	0	6523870	0	0	0	6523870
13	0	0	1068.24	0	0	0	1068.24
14	0	0	13035.18	114.1717	114.1717	13035.18	13035.18
15	0	0	421377.2	0	0	0	421377.2
16	0	0	21216.32	0	0	0	21216.32
17	4620.233	21346554	21346554	0	0	0	21346554
18	0	0	10050.09	0	0	0	10050.09
19	0	0	94551.96	0	0	0	94551.96
20	0	0	94551.96	0	0	0	94551.96
21	0	0	44788.89	0	0	0	44788.89
22	0	0	155598	0	0	0	155598
23	38377.91	1.47E+09	1.47E+09	0	0	0	1.47E+09
24	3179.902	10111778	10111778	0	0	0	10111778
25	0	0	1.56E+09	0	0	0	1.56E+09
26	0	0	21216.32	0	0	0	21216.32
27	12512.12	1.57E+08	1.57E+08	0	0	0	1.57E+08
28	7645.179	58448756	58448756	7645.179	7645.179	58448756	58448756
29	1715.486	2942892	2942892	1715.486	1715.486	2942892	2942892
30	5261.838	27686944	27686944	5261.838	5261.838	27686944	27686944
31	23449.74	5.5E+08	5.5E+08	23449.74	23449.74	5.5E+08	5.5E+08
32	0	0	79607372	8922.296	8922.296	79607372	79607372
33	0	0	10735908	0	0	0	10735908
34	0	0	13035.18	114.1717	114.1717	13035.18	13035.18
35	0	0	79607372	8922.296	8922.296	79607372	79607372
36	0	0	10050.09	0	0	0	10050.09
37	0	0	421377.2	0	0	0	421377.2
38	0	0	1757.934	0	0	0	1757.934
39	0	0	2.13E+08	0	0	0	2.13E+08
40	0	0	1.3E+08	0	0	0	1.3E+08
41	0	0	3090331	0	0	0	3090331
42	0	0	4.5E+08	0	0	0	4.5E+08
43	0	0	1757.934	0	0	0	1757.934
44	0	0	16538.77	0	0	0	16538.77
45	6712.959	45063823	45063823	0	0	0	45063823
46	0	0	199604.7	0	0	0	199604.7

47	0	0	1463878	0	0	0	1463878
48	0	0	10161.32	100.8034	100.8034	10161.32	10161.32
49	0	0	421377.2	0	0	0	421377.2
50	0	0	145.6582	0	0	0	145.6582
51	0	0	1757.934	0	0	0	1757.934
52	0	0	16538.77	0	0	0	16538.77
53	1036.725	1074798	1074798	0	0	0	1074798
54	263.4792	69421.26	69421.26	0	0	0	69421.26
55	9753.582	95132362	95132362	0	0	0	95132362
56	0	0	5085557	0	0	0	5085557
57	411202.4	1.69E+11	1.69E+11	411202.4	411202.4	1.69E+11	1.69E+11
58	0	0	421377.2	0	0	0	421377.2
59	0	0	121293.4	0	0	0	121293.4
60	0	0	506.0213	0	0	0	506.0213
61	0	0	16538.77	0	0	0	16538.77
62	0	0	10050.09	0	0	0	10050.09
63	0	0	693433	0	0	0	693433
64	0	0	421377.2	0	0	0	421377.2
65	0	0	239.7003	0	0	0	239.7003
66	0	0	421377.2	0	0	0	421377.2
67	0	0	199604.7	0	0	0	199604.7
68	0	0	394.4591	0	0	0	394.4591
69	0	0	5085557	0	0	0	5085557
70	0	0	6107.117	0	0	0	6107.117
71	0	0	889551.9	0	0	0	889551.9
72	0	0	37296883	0	0	0	37296883
73	0	0	506.0213	0	0	0	506.0213
74	0	0	3.474032	0	0	0	3.474032
75	0	0	421377.2	0	0	0	421377.2
76	0	0	889551.9	0	0	0	889551.9
77	0	0	3090331	0	0	0	3090331
78	0	0	3090331	0	0	0	3090331
79	0	0	2892.917	0	0	0	2892.917
80	0	0	19.861	0	0	0	19.861
81	0	0	10050.09	0	0	0	10050.09
82	0	0	2892.917	0	0	0	2892.917
83	0	0	19.861	0	0	0	19.861
84	0	0	88.51187	0	0	0	88.51187
85	0	0	12.06889	0	0	0	12.06889
86	0	0	5.716988	0	0	0	5.716988
87	0	0	13772270	0	0	0	13772270

88	0	0	62056394	7877.58 8	7877.588	62056394	62056394
89	0	0	6107.117	0	0	0	6107.117
90	0	0	540552.4	0	0	0	540552.4
91	0	0	506.0213	0	0	0	506.0213
92	0	0	4760.686	0	0	0	4760.686
93	0	0	2.708114	0	0	0	2.708114
94	0	0	832.7263	0	0	0	832.7263
95	0	0	9.408075	0	0	0	9.408075
96	34071.26	1.16E+09	1.16E+09	34071.2 6	34071.26	1.16E+09	1.16E+09
97	0	0	6107.117	0	0	0	6107.117
98	0	0	540552.4	0	0	0	540552.4
99	0	0	506.0213	0	0	0	506.0213
100	0	0	4760.686	0	0	0	4760.686
101	0	0	1370.363	0	0	0	1370.363
102	0	0	832.7263	0	0	0	832.7263
103	0	0	649.1357	0	0	0	649.1357
104	0	0	307.493	0	0	0	307.493
105	0	0	307.493	0	0	0	307.493
106	0	0	6107.117	0	0	0	6107.117
107	0	0	307.493	0	0	0	307.493
108	0	0	6107.117	0	0	0	6107.117
109	0	0	307.493	0	0	0	307.493
110	0	0	1757.934	0	0	0	1757.934
111	0	0	1370.363	0	0	0	1370.363
112	0	0	832.7263	0	0	0	832.7263
113	0	0	649.1357	0	0	0	649.1357
114	0	0	307.493	0	0	0	307.493
115	0	0	307.493	0	0	0	307.493

11 6	0	0	6107.117	0	0	0	6107.117
11 7	0	0	307.493	0	0	0	307.493
11 8	0	0	649.1357	0	0	0	649.1357
11 9	0	0	649.1357	0	0	0	649.1357
12 0	0	0	832.7263	0	0	0	832.7263
12 1	0	0	13772270	0	0	0	13772270
12 2	0	0	29074067	0	0	0	29074067
12 3	0	0	6107.117	0	0	0	6107.117
12 4	0	0	6107.117	0	0	0	6107.117
12 5	0	0	506.0213	0	0	0	506.0213
12 6	0	0	4760.686	0	0	0	4760.686
الم جم وع	608337.2	1.73E+11		551218. 7		1.72E+11	
	B_{12}			B_{13}	0.983701		

id	b_1x_1	b_2x_2	b_3x_3	$\exp(\beta X_{(i)})$ $x_{11}x_{12}\exp(\beta X_{(i)})$	$\exp(\beta X_{(i)})X_{11}$ $\exp(\beta X_{(i)})X_{12}$	$\sum_{i \in R(t_{(i)})} \exp(\beta X_{(i)})X_{11}$ $\sum_{i \in R(t_{(i)})} \exp(\beta X_{(i)})X_{12}$	$\left(\sum_{i \in R(t_{(i)})} \exp(\beta X_{(i)})\right)^2$	$\exp(\beta X_{(i)})X_{12}$
1	2.864226	0	0	0	403.316	0	307.493	0
2	8.094552	0.717243	0	436342.4	436342.4	2.93E+09	45063823	6712.959
3	2.490631	0	0	0	241.3779	0	145.6582	0
4	8.468147	0	0	0	323726.6	0	22664129	0
5	4.607668	0	0	0	3709.254	0	10050.09	0
6	8.71721	0.717243	0.379098	1279585	1279585	2.34E+10	3.34E+08	18279.79
7	8.71721	0.717243	0.379098	1279585	1279585	2.34E+10	3.34E+08	18279.79
8	8.71721	0	0	0	427498.2	0	37296883	0
9	7.471894	0.717243	0.379098	315710.3	315710.3	1.66E+09	27686944	5261.838
10	3.860479	0	0	0	1472.131	0	2255.118	0
11	7.222831	0	0	0	79481.08	0	1877896	0

12	7.845489	0	0	0	160913.8	0	6523870	0
13	3.486884	0	0	0	915.1505	0	1068.24	0
14	4.358605	0	0.379098	0	3996.01	0	13035.18	0
15	6.475642	0	0	0	33755.06	0	421377.2	0
16	4.981263	0	0	0	5826.329	0	21216.32	0
17	7.720958	0.717243	0	286454.5	286454.5	1.32E+09	21346554	4620.233
18	4.607668	0	0	0	3709.254	0	10050.09	0
19	5.728452	0	0	0	14144.68	0	94551.96	0
20	5.728452	0	0	0	14144.68	0	94551.96	0
21	5.354858	0	0	0	9100.256	0	44788.89	0
22	5.977516	0	0	0	18934.04	0	155598	0
23	9.837994	0.717243	0	3031855	3031855	1.16E+11	1.47E+09	38377.91
24	7.347363	0.717243	0	187614.2	187614.2	5.97E+08	10111778	3179.902
25	10.58518	0	0	0	3361289	0	1.56E+09	0
26	4.981263	0	0	0	5826.329	0	21216.32	0
27	8.71721	0.717243	0	875848.4	875848.4	1.1E+10	1.57E+08	12512.12
28	7.845489	0.717243	0.379098	481646.3	481646.3	3.68E+09	58448756	7645.179
29	6.35111	0.717243	0.379098	87489.78	87489.78	1.5E+08	2942892	1715.486
30	7.471894	0.717243	0.379098	315710.3	315710.3	1.66E+09	27686944	5261.838
31	8.966273	0.717243	0.379098	1688381	1688381	3.96E+10	5.5E+08	23449.74
32	8.71721	0	0.379098	0	624560.7	0	79607372	0
33	8.094552	0	0	0	212977	0	10735908	0
34	4.358605	0	0.379098	0	3996.01	0	13035.18	0
35	8.71721	0	0.379098	0	624560.7	0	79607372	0
36	4.607668	0	0	0	3709.254	0	10050.09	0
37	6.475642	0	0	0	33755.06	0	421377.2	0
38	3.735947	0	0	0	1257.832	0	1757.934	0
39	9.588931	0	0	0	1124374	0	2.13E+08	0
40	9.339868	0	0	0	853717.9	0	1.3E+08	0
41	7.471894	0	0	0	105476	0	3090331	0
42	9.962526	0	0	0	1697305	0	4.5E+08	0
43	3.735947	0	0	0	1257.832	0	1757.934	0
44	4.856731	0	0	0	5015.523	0	16538.77	0
45	8.094552	0.717243	0	436342.4	436342.4	2.93E+09	45063823	6712.959
46	6.102047	0	0	0	21891.8	0	199604.7	0
47	7.0983	0	0	0	68964.76	0	1463878	0
48	4.234074	0	0.379098	0	3427.315	0	10161.32	0
49	6.475642	0	0	0	33755.06	0	421377.2	0
50	2.490631	0	0	0	241.3779	0	145.6582	0
51	3.735947	0	0	0	1257.832	0	1757.934	0
52	4.856731	0	0	0	5015.523	0	16538.77	0

53	6.226579	0.717243	0	51836.23	51836.23	53739890	1074798	1036.725
54	4.856731	0.717243	0	10275.69	10275.69	2707429	69421.26	263.4792
55	8.468147	0.717243	0	663243.6	663243.6	6.47E+09	95132362	9753.582
56	7.720958	0	0	0	139817.3	0	5085557	0
57	11.8305	0.717243	0.379098	39064229	39064229	1.61E+13	1.69E+11	411202.4
58	6.475642	0	0	0	33755.06	0	421377.2	0
59	5.852984	0	0	0	16368.79	0	121293.4	0
60	3.113289	0	0	0	562.3729	0	506.0213	0
61	4.856731	0	0	0	5015.523	0	16538.77	0
62	4.607668	0	0	0	3709.254	0	10050.09	0
63	6.724705	0	0	0	44967.22	0	693433	0
64	6.475642	0	0	0	33755.06	0	421377.2	0
65	2.739695	0	0	0	340.6096	0	239.7003	0
66	6.475642	0	0	0	33755.06	0	421377.2	0
67	6.102047	0	0	0	21891.8	0	199604.7	0
68	2.988758	0	0	0	476.6639	0	394.4591	0
69	7.720958	0	0	0	139817.3	0	5085557	0
70	4.358605	0	0	0	2735.182	0	6107.117	0
71	6.849237	0	0	0	51873.83	0	889551.9	0
72	8.71721	0	0	0	427498.2	0	37296883	0
73	3.113289	0	0	0	562.3729	0	506.0213	0
74	0.622658	0	0	0	9.319377	0	3.474032	0
75	6.475642	0	0	0	33755.06	0	421377.2	0
76	6.849237	0	0	0	51873.83	0	889551.9	0
77	7.471894	0	0	0	105476	0	3090331	0
78	7.471894	0	0	0	105476	0	3090331	0
79	3.98501	0	0	0	1721.147	0	2892.917	0
80	1.494379	0	0	0	53.47881	0	19.861	0
81	4.607668	0	0	0	3709.254	0	10050.09	0
82	3.98501	0	0	0	1721.147	0	2892.917	0
83	1.494379	0	0	0	53.47881	0	19.861	0
84	2.241568	0	0	0	169.3453	0	88.51187	0
85	1.245316	0	0	0	34.74032	0	12.06889	0
86	0.871721	0	0	0	16.73716	0	5.716988	0
87	8.219084	0	0	0	244932.7	0	13772270	0
88	8.592679	0	0.379098	0	543553.6	0	62056394	0
89	4.358605	0	0	0	2735.182	0	6107.117	0
90	6.600173	0	0	0	38966.8	0	540552.4	0
91	3.113289	0	0	0	562.3729	0	506.0213	0
92	4.234074	0	0	0	2345.923	0	4760.686	0
93	0.498126	0	0	0	6.58254	0	2.708114	0

94	3.362352	0	0	0	779.1389	0	832.7263	0
95	1.120784	0	0	0	27.60533	0	9.408075	0
96	9.339868	0.717243	0.379098	2555344	2555344	8.71E+10	1.16E+09	34071.26
97	4.358605	0	0	0	2735.182	0	6107.117	0
98	6.600173	0	0	0	38966.8	0	540552.4	0
99	3.113289	0	0	0	562.3729	0	506.0213	0
100	4.234074	0	0	0	2345.923	0	4760.686	0
101	3.611416	0	0	0	1073.534	0	1370.363	0
102	3.362352	0	0	0	779.1389	0	832.7263	0
103	3.237821	0	0	0	662.4317	0	649.1357	0
104	2.864226	0	0	0	403.316	0	307.493	0
105	2.864226	0	0	0	403.316	0	307.493	0
106	4.358605	0	0	0	2735.182	0	6107.117	0
107	2.864226	0	0	0	403.316	0	307.493	0
108	4.358605	0	0	0	2735.182	0	6107.117	0
109	2.864226	0	0	0	403.316	0	307.493	0
110	3.735947	0	0	0	1257.832	0	1757.934	0
111	3.611416	0	0	0	1073.534	0	1370.363	0
112	3.362352	0	0	0	779.1389	0	832.7263	0
113	3.237821	0	0	0	662.4317	0	649.1357	0
114	2.864226	0	0	0	403.316	0	307.493	0
115	2.864226	0	0	0	403.316	0	307.493	0
116	4.358605	0	0	0	2735.182	0	6107.117	0
117	2.864226	0	0	0	403.316	0	307.493	0
118	3.237821	0	0	0	662.4317	0	649.1357	0
119	3.237821	0	0	0	662.4317	0	649.1357	0
120	3.362352	0	0	0	779.1389	0	832.7263	0
121	8.219084	0	0	0	244932.7	0	13772270	0
122	8.592679	0	0	0	372050.6	0	29074067	0
123	4.358605	0	0	0	2735.182	0	6107.117	0
124	4.358605	0	0	0	2735.182	0	6107.117	0
125	3.113289	0	0	0	562.3729	0	506.0213	0
126	4.234074	0	0	0	2345.923	0	4760.686	0
المجموع				53047493		1.64E+13		
				$B_{11}B_{12}$	94.42638			

جدول رقم 6 ايجاد قيمة المشتقة للـ $B_{11}B_{12}$ لانودج COX شبه المعلمي

جدول رقم 7 ايجاد قيمة المشتقة للـ $B_{11}B_{13}$ لانودج COX شبه المعلمي

id	b_1x_1	b_2x_2	b_3x_3	$\frac{\exp(\beta X_{(i)})}{x_{11}x_{13}\exp(\beta X_{(i)})}$	$\frac{\exp(\beta X_{(i)})x_{11}}{\exp(\beta X_{(i)})x_{13}}$	$\sum_{i \in R(t_{(j)})} \frac{\exp(\beta X_{(i)})x_{11}}{\exp(\beta X_{(i)})x_{13}}$	$\left(\sum_{i \in R(t_{(j)})} \exp(\beta X_{(i)})\right)^2$	$\exp(\beta X_{(i)})x_{13}$
1	2.864226	0	0	0	403.316	0	307.493	0
2	8.094552	0.717243	0	0	436342.4	0	45063823	0
3	2.490631	0	0	0	241.3779	0	145.6582	0
4	8.468147	0	0	0	323726.6	0	22664129	0
5	4.607668	0	0	0	3709.254	0	10050.09	0
6	8.71721	0.717243	0.379098	1279585	1279585	2.34E+10	3.34E+08	18279.79
7	8.71721	0.717243	0.379098	1279585	1279585	2.34E+10	3.34E+08	18279.79
8	8.71721	0	0	0	427498.2	0	37296883	0
9	7.471894	0.717243	0.379098	315710.3	315710.3	1.66E+09	27686944	5261.838
10	3.860479	0	0	0	1472.131	0	2255.118	0
11	7.222831	0	0	0	79481.08	0	1877896	0
12	7.845489	0	0	0	160913.8	0	6523870	0
13	3.486884	0	0	0	915.1505	0	1068.24	0
14	4.358605	0	0.379098	3996.01	3996.01	456231.3	13035.18	114.1717
15	6.475642	0	0	0	33755.06	0	421377.2	0
16	4.981263	0	0	0	5826.329	0	21216.32	0
17	7.720958	0.717243	0	0	286454.5	0	21346554	0
18	4.607668	0	0	0	3709.254	0	10050.09	0
19	5.728452	0	0	0	14144.68	0	94551.96	0
20	5.728452	0	0	0	14144.68	0	94551.96	0
21	5.354858	0	0	0	9100.256	0	44788.89	0
22	5.977516	0	0	0	18934.04	0	155598	0
23	9.837994	0.717243	0	0	3031855	0	1.47E+09	0
24	7.347363	0.717243	0	0	187614.2	0	10111778	0
25	10.58518	0	0	0	3361289	0	1.56E+09	0
26	4.981263	0	0	0	5826.329	0	21216.32	0
27	8.71721	0.717243	0	0	875848.4	0	1.57E+08	0
28	7.845489	0.717243	0.379098	481646.3	481646.3	3.68E+09	58448756	7645.179
29	6.35111	0.717243	0.379098	87489.78	87489.78	1.5E+08	2942892	1715.486
30	7.471894	0.717243	0.379098	315710.3	315710.3	1.66E+09	27686944	5261.838
31	8.966273	0.717243	0.379098	1688381	1688381	3.96E+10	5.5E+08	23449.74
32	8.71721	0	0.379098	624560.7	624560.7	5.57E+09	79607372	8922.296
33	8.094552	0	0	0	212977	0	10735908	0
34	4.358605	0	0.379098	3996.01	3996.01	456231.3	13035.18	114.1717
35	8.71721	0	0.379098	624560.7	624560.7	5.57E+09	79607372	8922.296

36	4.607668	0	0	0	3709.254	0	10050.09	0
37	6.475642	0	0	0	33755.06	0	421377.2	0
38	3.735947	0	0	0	1257.832	0	1757.934	0
39	9.588931	0	0	0	1124374	0	2.13E+08	0
40	9.339868	0	0	0	853717.9	0	1.3E+08	0
41	7.471894	0	0	0	105476	0	3090331	0
42	9.962526	0	0	0	1697305	0	4.5E+08	0
43	3.735947	0	0	0	1257.832	0	1757.934	0
44	4.856731	0	0	0	5015.523	0	16538.77	0
45	8.094552	0.717243	0	0	436342.4	0	45063823	0
46	6.102047	0	0	0	21891.8	0	199604.7	0
47	7.0983	0	0	0	68964.76	0	1463878	0
48	4.234074	0	0.379098	3427.315	3427.315	345485	10161.32	100.8034
49	6.475642	0	0	0	33755.06	0	421377.2	0
50	2.490631	0	0	0	241.3779	0	145.6582	0
51	3.735947	0	0	0	1257.832	0	1757.934	0
52	4.856731	0	0	0	5015.523	0	16538.77	0
53	6.226579	0.717243	0	0	51836.23	0	1074798	0
54	4.856731	0.717243	0	0	10275.69	0	69421.26	0
55	8.468147	0.717243	0	0	663243.6	0	95132362	0
56	7.720958	0	0	0	139817.3	0	5085557	0
57	11.8305	0.717243	0.379098	39064229	39064229	1.61E+13	1.69E+11	411202.4
58	6.475642	0	0	0	33755.06	0	421377.2	0
59	5.852984	0	0	0	16368.79	0	121293.4	0
60	3.113289	0	0	0	562.3729	0	506.0213	0
61	4.856731	0	0	0	5015.523	0	16538.77	0
62	4.607668	0	0	0	3709.254	0	10050.09	0
63	6.724705	0	0	0	44967.22	0	693433	0
64	6.475642	0	0	0	33755.06	0	421377.2	0
65	2.739695	0	0	0	340.6096	0	239.7003	0
66	6.475642	0	0	0	33755.06	0	421377.2	0
67	6.102047	0	0	0	21891.8	0	199604.7	0
68	2.988758	0	0	0	476.6639	0	394.4591	0
69	7.720958	0	0	0	139817.3	0	5085557	0
70	4.358605	0	0	0	2735.182	0	6107.117	0
71	6.849237	0	0	0	51873.83	0	889551.9	0
72	8.71721	0	0	0	427498.2	0	37296883	0
73	3.113289	0	0	0	562.3729	0	506.0213	0
74	0.622658	0	0	0	9.319377	0	3.474032	0
75	6.475642	0	0	0	33755.06	0	421377.2	0
76	6.849237	0	0	0	51873.83	0	889551.9	0

77	7.471894	0	0	0	105476	0	3090331	0
78	7.471894	0	0	0	105476	0	3090331	0
79	3.98501	0	0	0	1721.147	0	2892.917	0
80	1.494379	0	0	0	53.47881	0	19.861	0
81	4.607668	0	0	0	3709.254	0	10050.09	0
82	3.98501	0	0	0	1721.147	0	2892.917	0
83	1.494379	0	0	0	53.47881	0	19.861	0
84	2.241568	0	0	0	169.3453	0	88.51187	0
85	1.245316	0	0	0	34.74032	0	12.06889	0
86	0.871721	0	0	0	16.73716	0	5.716988	0
87	8.219084	0	0	0	244932.7	0	13772270	0
88	8.592679	0	0.379098	543553.6	543553.6	4.28E+09	62056394	7877.588
89	4.358605	0	0	0	2735.182	0	6107.117	0
90	6.600173	0	0	0	38966.8	0	540552.4	0
91	3.113289	0	0	0	562.3729	0	506.0213	0
92	4.234074	0	0	0	2345.923	0	4760.686	0
93	0.498126	0	0	0	6.58254	0	2.708114	0
94	3.362352	0	0	0	779.1389	0	832.7263	0
95	1.120784	0	0	0	27.60533	0	9.408075	0
96	9.339868	0.717243	0.379098	2555344	2555344	8.71E+10	1.16E+09	34071.26
97	4.358605	0	0	0	2735.182	0	6107.117	0
98	6.600173	0	0	0	38966.8	0	540552.4	0
99	3.113289	0	0	0	562.3729	0	506.0213	0
100	4.234074	0	0	0	2345.923	0	4760.686	0
101	3.611416	0	0	0	1073.534	0	1370.363	0
102	3.362352	0	0	0	779.1389	0	832.7263	0
103	3.237821	0	0	0	662.4317	0	649.1357	0
104	2.864226	0	0	0	403.316	0	307.493	0
105	2.864226	0	0	0	403.316	0	307.493	0
106	4.358605	0	0	0	2735.182	0	6107.117	0
107	2.864226	0	0	0	403.316	0	307.493	0
108	4.358605	0	0	0	2735.182	0	6107.117	0
109	2.864226	0	0	0	403.316	0	307.493	0

110	3.735947	0	0	0	1257.832	0	1757.934	0
111	3.611416	0	0	0	1073.534	0	1370.363	0
112	3.362352	0	0	0	779.1389	0	832.7263	0
113	3.237821	0	0	0	662.4317	0	649.1357	0
114	2.864226	0	0	0	403.316	0	307.493	0
115	2.864226	0	0	0	403.316	0	307.493	0
116	4.358605	0	0	0	2735.182	0	6107.117	0
117	2.864226	0	0	0	403.316	0	307.493	0
118	3.237821	0	0	0	662.4317	0	649.1357	0
119	3.237821	0	0	0	662.4317	0	649.1357	0
120	3.362352	0	0	0	779.1389	0	832.7263	0
121	8.219084	0	0	0	244932.7	0	13772270	0
122	8.592679	0	0	0	372050.6	0	29074067	0
123	4.358605	0	0	0	2735.182	0	6107.117	0
124	4.358605	0	0	0	2735.182	0	6107.117	0
125	3.113289	0	0	0	562.3729	0	506.0213	0
126	4.234074	0	0	0	2345.923	0	4760.686	0
المجموع				48871776		1.63E+13		
				$B_{11}B_{13}$	88.88989			

جدول رقم 8 ايجاد قيمة المشتقة للـ $B_{12}B_{13}$ لانودج COX شبه المعلمي

id	b_1x_1	b_2x_2	b_3x_3	$\frac{\exp(\beta X_{(i)})}{x_{i2}x_{i3}\exp(\beta X_{(i)})}$	$\frac{\exp(\beta X_{(i)})x_{i2}}{\exp(\beta X_{(i)})x_{i3}}$	$\sum_{i \in R(t_{(j)})} \exp(\beta X_{(i)})x_{i2}$ $\sum_{i \in R(t_{(j)})} \exp(\beta X_{(i)})x_{i3}$	$\left(\sum_{i \in R(t_{(j)})} \exp(\beta X_{(i)})\right)^2$	$\exp(\beta X_{(i)})x_{i3}$
1	2.864226	0	0	0	0	0	307.493	0
2	8.094552	0.717243	0	0	6712.959	0	45063823	0

3	2.490631	0	0	0	0	0	145.6582	0
4	8.468147	0	0	0	0	0	22664129	0
5	4.607668	0	0	0	0	0	10050.09	0
6	8.71721	0.717243	0.379098	18279.79	18279.79	3.34E+08	3.34E+08	18279.79
7	8.71721	0.717243	0.379098	18279.79	18279.79	3.34E+08	3.34E+08	18279.79
8	8.71721	0	0	0	0	0	37296883	0
9	7.471894	0.717243	0.379098	5261.838	5261.838	27686944	27686944	5261.838
10	3.860479	0	0	0	0	0	2255.118	0
11	7.222831	0	0	0	0	0	1877896	0
12	7.845489	0	0	0	0	0	6523870	0
13	3.486884	0	0	0	0	0	1068.24	0
14	4.358605	0	0.379098	0	0	0	13035.18	114.1717
15	6.475642	0	0	0	0	0	421377.2	0
16	4.981263	0	0	0	0	0	21216.32	0
17	7.720958	0.717243	0	0	4620.233	0	21346554	0
18	4.607668	0	0	0	0	0	10050.09	0
19	5.728452	0	0	0	0	0	94551.96	0
20	5.728452	0	0	0	0	0	94551.96	0
21	5.354858	0	0	0	0	0	44788.89	0
22	5.977516	0	0	0	0	0	155598	0
23	9.837994	0.717243	0	0	38377.91	0	1.47E+09	0
24	7.347363	0.717243	0	0	3179.902	0	10111778	0
25	10.58518	0	0	0	0	0	1.56E+09	0
26	4.981263	0	0	0	0	0	21216.32	0
27	8.71721	0.717243	0	0	12512.12	0	1.57E+08	0
28	7.845489	0.717243	0.379098	7645.179	7645.179	58448756	58448756	7645.179
29	6.35111	0.717243	0.379098	1715.486	1715.486	2942892	2942892	1715.486
30	7.471894	0.717243	0.379098	5261.838	5261.838	27686944	27686944	5261.838
31	8.966273	0.717243	0.379098	23449.74	23449.74	5.5E+08	5.5E+08	23449.74
32	8.71721	0	0.379098	0	0	0	79607372	8922.296
33	8.094552	0	0	0	0	0	10735908	0
34	4.358605	0	0.379098	0	0	0	13035.18	114.1717
35	8.71721	0	0.379098	0	0	0	79607372	8922.296
36	4.607668	0	0	0	0	0	10050.09	0
37	6.475642	0	0	0	0	0	421377.2	0
38	3.735947	0	0	0	0	0	1757.934	0
39	9.588931	0	0	0	0	0	2.13E+08	0
40	9.339868	0	0	0	0	0	1.3E+08	0
41	7.471894	0	0	0	0	0	3090331	0
42	9.962526	0	0	0	0	0	4.5E+08	0
43	3.735947	0	0	0	0	0	1757.934	0

44	4.856731	0	0	0	0	0	16538.77	0
45	8.094552	0.717243	0	0	6712.959	0	45063823	0
46	6.102047	0	0	0	0	0	199604.7	0
47	7.0983	0	0	0	0	0	1463878	0
48	4.234074	0	0.379098	0	0	0	10161.32	100.8034
49	6.475642	0	0	0	0	0	421377.2	0
50	2.490631	0	0	0	0	0	145.6582	0
51	3.735947	0	0	0	0	0	1757.934	0
52	4.856731	0	0	0	0	0	16538.77	0
53	6.226579	0.717243	0	0	1036.725	0	1074798	0
54	4.856731	0.717243	0	0	263.4792	0	69421.26	0
55	8.468147	0.717243	0	0	9753.582	0	95132362	0
56	7.720958	0	0	0	0	0	5085557	0
57	11.8305	0.717243	0.379098	411202.4	411202.4	1.69E+11	1.69E+11	411202.4
58	6.475642	0	0	0	0	0	421377.2	0
59	5.852984	0	0	0	0	0	121293.4	0
60	3.113289	0	0	0	0	0	506.0213	0
61	4.856731	0	0	0	0	0	16538.77	0
62	4.607668	0	0	0	0	0	10050.09	0
63	6.724705	0	0	0	0	0	693433	0
64	6.475642	0	0	0	0	0	421377.2	0
65	2.739695	0	0	0	0	0	239.7003	0
66	6.475642	0	0	0	0	0	421377.2	0
67	6.102047	0	0	0	0	0	199604.7	0
68	2.988758	0	0	0	0	0	394.4591	0
69	7.720958	0	0	0	0	0	5085557	0
70	4.358605	0	0	0	0	0	6107.117	0
71	6.849237	0	0	0	0	0	889551.9	0
72	8.71721	0	0	0	0	0	37296883	0
73	3.113289	0	0	0	0	0	506.0213	0
74	0.622658	0	0	0	0	0	3.474032	0
75	6.475642	0	0	0	0	0	421377.2	0
76	6.849237	0	0	0	0	0	889551.9	0
77	7.471894	0	0	0	0	0	3090331	0
78	7.471894	0	0	0	0	0	3090331	0
79	3.98501	0	0	0	0	0	2892.917	0
80	1.494379	0	0	0	0	0	19.861	0
81	4.607668	0	0	0	0	0	10050.09	0
82	3.98501	0	0	0	0	0	2892.917	0
83	1.494379	0	0	0	0	0	19.861	0
84	2.241568	0	0	0	0	0	88.51187	0

85	1.245316	0	0	0	0	0	12.06889	0
86	0.871721	0	0	0	0	0	5.716988	0
87	8.219084	0	0	0	0	0	13772270	0
88	8.592679	0	0.379098	0	0	0	62056394	7877.588
89	4.358605	0	0	0	0	0	6107.117	0
90	6.600173	0	0	0	0	0	540552.4	0
91	3.113289	0	0	0	0	0	506.0213	0
92	4.234074	0	0	0	0	0	4760.686	0
93	0.498126	0	0	0	0	0	2.708114	0
94	3.362352	0	0	0	0	0	832.7263	0
95	1.120784	0	0	0	0	0	9.408075	0
96	9.339868	0.717243	0.379098	34071.26	34071.26	1.16E+09	1.16E+09	34071.26
97	4.358605	0	0	0	0	0	6107.117	0
98	6.600173	0	0	0	0	0	540552.4	0
99	3.113289	0	0	0	0	0	506.0213	0
100	4.234074	0	0	0	0	0	4760.686	0
101	3.611416	0	0	0	0	0	1370.363	0
102	3.362352	0	0	0	0	0	832.7263	0
103	3.237821	0	0	0	0	0	649.1357	0
104	2.864226	0	0	0	0	0	307.493	0
105	2.864226	0	0	0	0	0	307.493	0
106	4.358605	0	0	0	0	0	6107.117	0
107	2.864226	0	0	0	0	0	307.493	0
108	4.358605	0	0	0	0	0	6107.117	0
109	2.864226	0	0	0	0	0	307.493	0
110	3.735947	0	0	0	0	0	1757.934	0
111	3.611416	0	0	0	0	0	1370.363	0
112	3.362352	0	0	0	0	0	832.7263	0
113	3.237821	0	0	0	0	0	649.1357	0
114	2.864226	0	0	0	0	0	307.493	0
115	2.864226	0	0	0	0	0	307.493	0
116	4.358605	0	0	0	0	0	6107.117	0
117	2.864226	0	0	0	0	0	307.493	0
118	3.237821	0	0	0	0	0	649.1357	0
119	3.237821	0	0	0	0	0	649.1357	0
120	3.362352	0	0	0	0	0	832.7263	0
121	8.219084	0	0	0	0	0	13772270	0
122	8.592679	0	0	0	0	0	29074067	0
123	4.358605	0	0	0	0	0	6107.117	0
124	4.358605	0	0	0	0	0	6107.117	0
125	3.113289	0	0	0	0	0	506.0213	0

126	4.234074	0	0	0	0	0	4760.686	0
المجموع				525167.3		1.72E+11		
				$B_{12}B_{13}$	0.950083			