

التقدير المتبين للتباين التقاربي في نموذج الإنحدار البواسوني لبيانات سلالس زمانية

أ.د. البيومى عوض طاقية	أ.د. محمد توفيق البلقينى
أستاذ الإحصاء التطبيقي	أستاذ الرياضيات والإحصاء الإكتوارى
كلية التجارة - جامعة المنصورة	كلية التجارة - جامعة المنصورة

الباحث / أحمد ابوسليمان العدل الطنطاوى
معيد بقسم الإحصاء التطبيقي
كلية التجارة - جامعة المنصورة

التقدير المتبين للبيان التقاري في نموذج الانحدار البواسوني لبيانات سلاسل زمنية

الملخص:

يسهدف هذا البحث تقدير التباين التقاري في نموذج الانحدار البواسوني لتحليل بيانات سلسلة زمنية وذلك في ظل وجود مشكلات التقدير مثل الارتباط الذاتي وعدم ثبات تباين حدود الخطأ heteroskedasticity، حيث يتم التعبير عن الارتباط الذاتي النموذج أحد أنواع نماذج المعلمة المشتقة parameter-driven models، حيث يتم التعبير عن الارتباط الذاتي بين المشاهدات من خلال إدراج العملية الكامنة latent process في دالة الربط للنموذج، ويتم تقدير متغير معاملات الانحدار β من خلال تعظيم دالة الإمكان الزائفة maximizing the pseudo-likelihood والتي تتجاهل وجود العملية الكامنة. ويكون المقدر الناتج هو مقدر نموذج خططي معتمم، وقد تم عرض الإتساق والتقارب الطبيعي لهذا المقدر في دراسة Davis et al (2000). ومن أجل إجراء الاستدلالات الإحصائية بشكل صحيح حول معاملات الانحدار، فإن ذلك يتطلب إيجاد تقدير متنسق للبيان التقاري لـ β ، وحيث أن طرق التقدير المتبينة تمكنا من الحصول على تقدير متنسق للبيان التقاري في ظل وجود مشكلات التقدير مثل الارتباط الذاتي و عدم ثبات تباين حدود الخطأ فإن هذا البحث سوف يقوم بالمقارنة بين طريقتين من طرق التقدير المتبينة للبيان التقاري وهما؛ طريقة أساس كرنسال kernel-based التي تم اقتراحها في دراسة Wu (2012) ومقدر OPG أو خوارزمية BHHH التي نقترح استخدامها في هذا البحث. وبالتطبيق العملي على مجموعتين من البيانات؛ الأعداد الشهرية لحالات شلل الأطفال في الولايات المتحدة الأمريكية في الفترة من 1970 إلى 1983 والأعداد الشهرية لحالات استقبال الحمى الروماتيزمية في مستشفي أطفال المنصورة خلال الفترة من 2010 إلى 2021، وقد أوضحت النتائج أن مقدر OPG أو خوارزمية BHHH هي الأفضل في تقدير التباين التقاري لـ β .

ROBUST ESTIMATION OF ASYMPTOTIC VARIANCE IN A POISSON REGRESSION MODEL FOR TIME SERIES DATA.

Abstract:

This paper aims to estimate asymptotic variance for Poisson regression model for time series of counts in the presence of the estimation problems, such as; autocorrelation and heteroskedasticity. This model represents a parameter-driven model since the autocorrelation among the observations is introduced by incorporating a latent process in the link function of the model. The regression coefficient vector β is estimated by maximizing the pseudo-likelihood that ignores the existence of the latent process. The resulting estimator is a generalized linear model estimator, and its consistency and asymptotic normality have been established by Davis et al (2000). To perform valid statistical inferences about the regression coefficients, it is required to develop a consistent estimation procedure for the asymptotic covariance

matrix of $\hat{\beta}$. Since the robust estimation enables us to obtain a consistent estimation for the asymptotic variance in the presence of the estimation problems, such as; autocorrelation and heteroskedasticity. This study will compare between two robust estimation methods for the asymptotic variance; kernel-based method which is suggested by Wu (2012) and OPG estimator or BHHH algorithm which is proposed in this paper. The methods are applied to two data sets; the monthly polio data in the U.S.A from 1970 to 1983 and monthly numbers of rheumatic fever in Mansoura University Children Hospital from 2010 to 2021. The result revealed that OPG estimator or BHHH algorithm is a better estimator for the asymptotic variance of $\hat{\beta}$.

١- المقدمة:

إن تحليل السلاسل الزمنية التي تتكون من قيم معدودة (أي قيم صحيحة غير سالبة) هي محل اهتمام العديد من الباحثين، وذلك لأن لها العديد من التطبيقات في عالم الواقع. يهتم هذا البحث بتقدير التباين التقاربي (أو مصفوفة التغاير التقاربي Asymptotic Covariance Matrix) في فئة النماذج الخطية المعممة لمعلمة مشتقة Parameter-driven Generalized linear model لتحليل بيانات سلاسل زمنية معدودة والتي تعتبر أداة هامة في نمذجة السلاسل الزمنية التي لا تتبع التوزيع الطبيعي. إن تحديد نموذج لبيانات سلاسل زمنية معدودة يتطلب الأخذ في الإعتبار الإرتباط الذاتي بين المشاهدات ، ولقد قام Cox (1981) بتقسيم نماذج السلاسل الزمنية إلى فئتين من النماذج، وذلك بناءً على كيفية إدخال الإرتباط الذاتي بين البيانات إلى النموذج وهم:

- نماذج المشاهدة المشتقة .Observation-driven models

وفي هذا النوع من النماذج يتم إدخال الإرتباط الذاتي بين البيانات إلى النموذج من خلال جعل المشاهدات الحالية معتمدة بشكل واضح وصريح على مشاهدات الماضي مثل ARIMA و AR و GARCH.

- نماذج المعلمة المشتقة .Parameter-driven models

وفي هذا النوع من النماذج يتم تقديم الإرتباط الذاتي بين البيانات من خلال عملية كامنة latent process تضاف إلى المتباين الخطي. ولذلك، يمكننا القول أن النماذج الخطية المعممة لبيانات سلاسل زمنية معدودة -والتي هي محل اهتمامنا في هذا البحث- تُعد نوع من أنواع نماذج المعلمة المشتقة Parameter-driven models. بحيث يتم إدخال العملية الكامنة latent process إلى النموذج الخطي المعمم من خلال إضافتها إلى دالة الرابط.

وفي هذا البحث سوف يتم تقدير التباين التقاربي في نموذج إحدار لبيانات سلاسل زمنية معدودة، وذلك في ظل نموذج خطى معمم لمعلمة مشتقة بحيث يتم التعبير عن الإرتباط الذاتي بين بيانات السلسلة الزمنية المعدودة من خلال عملية كامنة latent process تضاف إلى المتباين الخطي.

وبفرض أن التوزيع الشرطي لمتغير الإستجابة Y_t بعلمومية العملية الكامنة α_t يتبع توزيع بواسون-أي أن $Y_t | \alpha_t \sim Po(\lambda_t)$.

(1-1) المشكلة:

في هذه الدراسة حاول الحصول على مقدّر متّسق لمصفوفة التغاير التقاربي لـ $\hat{\beta}$ estimator for the asymptotic covariance matrix في نموذج الإنحدار البواسوني لتحليل بيانات سلسلة زمنية معروفة. وحيث أن مصفوفة التغاير التقاربي يمكن التعبير عنها بحدود دوال التغاير الذاتي (ACVFs) للعملية الكامنة α_t ، فقد قام (Davis and Wu (2009) بتقديم طريقة مبتكرة لتقدير مصفوفة التغاير التقاربي في ظل نموذج إنحدار ذو حدin سالب لتحليل سلسلة زمنية معروفة، وذلك من خلال تحديد نموذج للعملية الكامنة α_t وتقدير معلماتها وتغييراتها الذاتية (ACVFs) والحصول على مقدّر متّسق لمصفوفة التغاير التقاربي من خلال التعويض بمقدّرات التغايرات الذاتية للعملية الكامنة α_t ولكن إتساق هذا المقدّر كان مشكوك فيه، وذلك لعدم إمكانية إثباته. وهذا ما تم تداركه في دراسة (Wu (2012) حيث تم تقدير مصفوفة التغاير التقاربي لـ $\hat{\beta}$ بدون تخصيص نموذج للعملية الكامنة α_t ، ولكن تم التعامل معها بشكل لامعليمي. وذلك من خلال استخدام الطرق اللامعليمية لتقدير التباين، وقد استخدم طرفيتين هما؛ طريقة أساس كرنال-Kernel based التي قدمها (Newey and West (1987) Subsampling وطريقة المعاينة الفرعية التي قدمها (Carlstein (1986)، وبذلك حصل على مقدّرين لمصفوفة التغاير التقاربي لـ $\hat{\beta}$ بالإعتماد على هاتين الطرفيتين. وقد أثبتت الإتساق لكلا المقدّرين في ظل نموذج إنحدار ذو حدin سالب لتحليل بيانات سلسلة زمنية معروفة. وكان الدافع وراء هذا البحث هو أن دراسة Wu (2012) قد أوضحت أنه يمكننا الحصول على مقدّر متّسق لمصفوفة التغاير التقاربي لـ $\hat{\beta}$ بإستخدام طريقة أساس كرنال Kernel-based عند استخدام نموذج خطى معمم لمعلمة مشتقة والتي يكون فيها التوزيع الشرطي $Y_t | \alpha_t$ هو توزيع بواسون بدلاً من توزيع ذو الحدين السالب.

وفي هذه الدراسة حاول الإجابة على السؤال: هل مقدّر أساس كرنال Kernel-based يقدم أفضل تقدير متّسق لمصفوفة التغاير التقاربي لـ $\hat{\beta}$ في نموذج الإنحدار البواسوني لبيانات سلسلة زمنية؟ وذلك من خلال مقارنته بمقدّر آخر نقترح استخدامه في هذه الدراسة وهو (مقدّر حاصل الضرب الخارجي لمتجهات التفاضلات الجزئية من الدرجة الأولى) outer product of gradients والتي قدمها Berdente, Hall, (OPG) و الذي يسمى أيضاً خوارزمية BHHHHall and Hausman (1974) وهي طريقة رقمية تستخدم في البحث التجاري.

(1-2) الأهمية:

إن أهمية هذه الدراسة تتبع من ضرورة إيجاد مقدّر متّسق لمصفوفة التغاير التقاربي لـ $\hat{\beta}$ ، وذلك بهدف إجراء الإستدلالات الإحصائية الممكنة بالنسبة لـ β من إنشاء فترات ثقة وإختبارات فروض، حيث تتجه الأفكار المستقبلية في هذا الصدد نحو الإستدلال الإحصائى، وكخطوة أولية في هذا الإتجاه حاول تقديم مقدّر متّسق لمصفوفة التغاير التقاربي لـ $\hat{\beta}$ التي حصلنا عليها من خلال تعظيم

دالة الإمكان اللوغاريتمي الزائفه وذلك في ظل نموذج خطى معمم لمعلمة مشتقة- Parameter-driven Generalized linear model

(1-3) أهداف البحث:

يهدف هذا البحث إلى استخدام طريقة أساس كرنال Kernel-based OPG ومقدر عليه خوارزمية BHHH لتقدير التباين التقاربي لـ $\hat{\beta}$ وذلك في ظل استخدام نموذج الإنحدار البواسوني لبيانات سلاسل زمنية معدودة، وسوف تتم المقارنة بين التقديرات الناتجة بالتطبيق على مجموعتين من البيانات، هما الأعداد الشهرية للإصابة بشلل الأطفال في الولايات المتحدة الأمريكية خلال الفترة من ١٩٧٠ إلى ١٩٨٣ والأعداد الشهرية لحالات الحمى الروماتيزمية التي يتم استقبالها بمستشفى أطفال المنصورة خلال الفترة من ١ يناير ٢٠١٠ إلى ٣١ ديسمبر ٢٠٢١.

٢ - النموذج الخطى المعمم لمعلمة مشتقة لبيانات سلسلة زمنية معدودة

يتم تحديد النموذج الخطى المعمم لمعلمة مشتقة Parameter-driven Generalized linear model من خلال:

المكون العشوائى : random component

وفيه يتم تحديد التوزيع الشرطي لمتغيرات الإستجابة Y_t بمعلمة العملية الكامنة α_t ، أي تحديد $p(Y_t|\alpha_t)$ ، وذلك بفرض أن المشاهدات Y_n, \dots, Y_1 تكون مستقلة بمعلمة α_t .

المكون المنتظم : systematic component

وفيه يتم تحديد دالة الربط (f) التي يتحدد من خلالها شكل العلاقة بين μ_t المتوسط الشرطي لـ Y_t والمتنبأ الخطى مضافاً إليه العملية الكامنة α_t ، وبالتالي فإن دالة الربط تأخذ الشكل التالي $f(\mu_t) = X_t^T \beta + \alpha_t$ ، حيث تقوم العملية الكامنة α_t بإدخال الإرتباط الذاتي في النموذج وذلك بفرض أنها تخرج بشكل مستقل من المشاهدات.

وفي هذا البحث سوف نفترض نموذج خطى معمم لمعلمة مشتقة وهو نموذج الإنحدار البواسوني لتحليل بيانات سلاسل زمنية معدودة.

(1-2) نموذج الإنحدار البواسوني لبيانات سلسلة زمنية

بفرض أن $\{Y_t: t = 1, 2, \dots, n\}$ ترمز لبيانات سلسلة زمنية معروفة، وأن X_t هو متجه المتغيرات القسيرة والتي يفترض أن تكون غير عشوائية ومكونها الأول هو الواحد الصحيح، وفي بعض الحالات، قد يعتمد X_t على حجم العينة n ، ولذلك سوف يتم كتابتها بدليل سفلي مزدوج كالتالي X_{nt} . وافتراضنا أن المتغيرات العشوائية Y_1, \dots, Y_n تكون مستقلة بمعلومية العملية الكامنة α_t ، وأن التوزيع الشرطي للمشاهدة Y_t بمعلومية العملية الكامنة α_t هو توزيع بواسون؛ أي أن:

$$Y_t | \alpha_t \sim po(\lambda_t) \quad (1)$$

وأن دالة الربط هي:

$$\log \lambda_t = X_{nt}^T \beta + \alpha_t \quad (2)$$

حيث أن $\beta = (\beta_1, \dots, \beta_k)^T$ هو متجه معلمات الإنحدار، وأن α_t هي عملية خطية ساكنة. فبدلاً من التعامل مع العملية الكامنة α_t أنتاء التقاضل، فإنه من الأنساب استخدام ϵ_t ، حيث أن $\epsilon_t = e^{\alpha_t}$ ، وهي سلسلة زمنية ساكنة وغير سالبة بمتوسط واحد؛ أي أن $E(\epsilon_t) = 1$. ومن ثم يمكن صياغة المتوسط الشرطي لـ Y_t بمعلومية α_t على النحو التالي:

$$E(Y_t | \alpha_t) = \lambda_t = \exp(X_{nt}^T \beta + \alpha_t) = \exp(X_{nt}^T \beta) \epsilon_t \quad (3)$$

وبالتالي، فإن متوسط Y_t هو:

$$\mu_t = E(Y_t) = E[E(Y_t | \alpha_t)] = E[\exp(X_{nt}^T \beta) \epsilon_t] = \exp(X_{nt}^T \beta) \quad (4)$$

وتباين Y_t هو:

$$\begin{aligned} var(Y_t) &= E[var(Y_t | \alpha_t)] + var[E(Y_t | \alpha_t)] \\ &= E[\exp(X_{nt}^T \beta) \epsilon_t] + var[\exp(X_{nt}^T \beta) \epsilon_t] \\ &= \exp(X_{nt}^T \beta) + \exp(2X_{nt}^T \beta) var(\epsilon_t) \\ &= \exp(X_{nt}^T \beta) [1 + \exp(X_{nt}^T \beta) \gamma_\epsilon(0)] \\ &= \mu_t [1 + \mu_t \gamma_\epsilon(0)] \end{aligned} \quad (5)$$

ودالة التغير الذاتي لـ Y_t هي:

$$\begin{aligned}
\text{cov}(Y_{t+h}, Y_t) &= \text{cov}[E(Y_{t+h}|\alpha_{t+h}), E(Y_t|\alpha_t)] + 0 \\
&= \text{cov}\left(e^{(X_{nt+h}^T\beta)}\epsilon_{t+h}, e^{(X_{nt}^T\beta)}\epsilon_t\right) \\
&= E\left[\left(e^{(X_{nt+h}^T\beta)}\epsilon_{t+h} - e^{(X_{nt+h}^T\beta)}\right)\left(e^{(X_{nt}^T\beta)}\epsilon_t - e^{(X_{nt}^T\beta)}\right)\right] \\
&= e^{(X_{nt+h}^T+X_{nt}^T)\beta} E(\epsilon_{t+h}\epsilon_t) - e^{(X_{nt+h}^T+X_{nt}^T)\beta} E(\epsilon_{t+h}) \\
&\quad - e^{(X_{nt+h}^T+X_{nt}^T)\beta} E(\epsilon_t) + e^{(X_{nt+h}^T+X_{nt}^T)\beta}
\end{aligned}$$

وحيث أن:

$$E(\epsilon_{t+h}) = E(\epsilon_t) = 1$$

فإن:

$$\begin{aligned}
\text{cov}(Y_{t+h}, Y_t) &= e^{(X_{nt+h}^T+X_{nt}^T)\beta}(\gamma_\epsilon(h) - 1) \\
&= e^{X_{nt+h}^T\beta}e^{X_{nt}^T\beta}(\gamma_\epsilon(h) - 1) \\
&= \mu_{t+h}\mu_t(\gamma_\epsilon(h) - 1)
\end{aligned} \tag{6}$$

عند $h \neq 0$

وبفرض أن متجه معلمات الإنحدار الحقيقي هو β_0 ، فإنه يمكن الحصول على مقدار النموذج الخطى المعمم $\hat{\beta}_n$ من خلال تعظيم دالة الإمكان اللوغاريتمي الزائف pseudo log-likelihood كالتالى:

$$\begin{aligned}
\ell(\beta) &= \log \left\{ \prod_{t=1}^n e^{-\lambda_t} \frac{\lambda_t^{Y_t}}{Y_t!} \right\} \\
&= \sum_{t=1}^n \log e^{-\lambda_t} + \sum_{t=1}^n \log \lambda_t^{Y_t} - \log \left[\prod_{t=1}^n Y_t! \right]
\end{aligned}$$

$$= - \sum_{t=1}^n \lambda_t + \sum_{t=1}^n Y_t \log \lambda_t - \log \left[\prod_{t=1}^n Y_t! \right]$$

وحيث أن $\lambda_t = e^{(X_{nt}^T \beta + \alpha_t)}$ ، وبإهمال وجود العمليات الكامنة، فإن $\lambda_t = e^{(X_{nt}^T \beta + \alpha_t)}$ وبالتالي نحصل على دالة الإمكان الزائفة التالية:

$$\ell(\beta) = - \sum_{t=1}^n e^{(X_{nt}^T \beta)} + \sum_{t=1}^n Y_t X_{nt}^T \beta - \log \left[\prod_{t=1}^n Y_t! \right] \quad (7)$$

وفي ظل شروط الاتساق والتقارب الطبيعي الوارد ذكرها في دراسة Davis et al (2000) يكون التوزيع التقارب Asymptotic distribution لـ $\hat{\beta}_n$ عندما $n \rightarrow \infty$ ، كالتالي:

$$M_n^{-1} (\hat{\beta}_n - \beta_0) \xrightarrow{d} N(0, [\Omega_1(\beta_0)]^{-1} [\Omega_1(\beta_0) + \Omega_{11}(\beta_0)] [\Omega_1(\beta_0)]^{-1})$$

حيث يكون:

$$\Omega_1(\beta_0) = \lim_{n \rightarrow \infty} M_n^T \left(\sum_{t=1}^n X_{nt} X_{nt}^T e^{X_{nt}^T \beta_0} \right) M_n \quad (8)$$

$$\Omega_{11}(\beta_0) = \sum_{k=-\infty}^{\infty} W_k \gamma_{\epsilon}(k) \quad (9)$$

وذلك عندما تكون (k) دالة التغير الذاتي لـ ϵ_t عند فجوة زمنية k .
وحيث أن

$$W_k = \lim_{n \rightarrow \infty} M_n^T \left(\sum_{t=1}^n X_{nt} X_{n,t+k}^T e^{(X_{nt}^T + X_{n,t+k}^T) \beta_0} \right) M_n \quad (10)$$

وذلك بفرض أن $M_n = n^{-\frac{1}{2}} I_P$ حيث أن I_P هي مصفوفة الوحدة $P \times P$ والتي تجعل النهايات السابقة موجودة، بحيث تكون مصفوفة التغير التقارب لـ $\hat{\beta}_n$ لها الصيغة التالية:

$$[\Omega_1(\beta_0)]^{-1} [\Omega_1(\beta_0) + \Omega_{11}(\beta_0)] [\Omega_1(\beta_0)]^{-1}$$

٣ - تدبر مصفوفة التغير التقاري لـ $\hat{\beta}$

(١-٣) مشاكل التدبر:

(١-١-٣) عدم ثبات التباين: **Heteroskedasticity**

في حالة أن يكون تباين حد الخطأ ثابت عند المشاهدات المختلفة للمتغير التفسيري فإن هذا يسمى ثبات التباين homoskedasticity بمعنى أن تباين التوزيع الإحتمالي لحد الخطأ (وهو نفسه التباين الشرطي لـ Y_i بمعلومية X_i) يظل ثابت بغض النظر عن القيم التي يأخذها المتغير التفسيري (X) ، ونجد أن عدم ثبات تباين حد الخطأ عند المشاهدات المختلفة للمتغير التفسيري يسمى عدم ثبات التباين heteroskedasticity. وهناك عدة أسباب يمكن أن تؤدي إلى عدم ثبات تباين حد الخطأ ومنها ما يلي:

- ١- طبيعة الظاهرة محل الدراسة، فقد يزيد تباين أو تشتت الأخطاء كلما زادت قيم المتغير التفسيري فعلى سبيل المثال؛ يزيد تباين الإنفاق عند قيم الدخل المرتفعة ويقل تباين الإنفاق عند قيم الدخل المنخفض حيث أن أصحاب الدخول المرتفعة يكون لديهم نطاق أكبر للإختيار بشأن التصرف في دخولهم وبالتالي من المتوقع أن يزيد التباين في الإنفاق كلما زاد الدخل، وقد يحدث العكس بأن يقل تباين أو تشتت الأخطاء كلما زادت قيم المتغير التفسيري مثل الظواهر التي تعتمد على التعلم من الخطأ فنجد أنه كلما زاد تعلم الأشخاص كلما قل خطأهم السلوكي.
- ٢- يمكن أن يظهر عدم ثبات التباين كنتيجة لوجود القيم المتطرفة outliers في مشاهدات العينة . ونجد أن إستبعاد أو تعديل هذه المشاهدات خاصة إذا كان حجم العينة صغير فإن ذلك قد يؤدي إلى تغيير النتائج.
- ٣- عدم تحديد نموذج الإنحدار بشكل صحيح قد يكون سبب في عدم ثبات تباين حد الخطأ، ففي كثير من الأحيان يظهر عدم ثبات التباين بسبب عدم وجود بعض المتغيرات الهامة في النموذج، وتختفي هذه المشكلة بمجرد إدخال هذه المتغيرات الهامة إلى النموذج.
- ٤- الإنماء في توزيع واحد أو أكثر من المتغيرات التفسيرية في النموذج قد يتسبب في عدم ثبات تباين حد الخطأ.
- ٥- هناك مصادر أخرى لعدم ثبات تباين حد الخطأ مثل إستخدام صيغة خاطئة للدالة التي تمثل النموذج أو إستخدام تحويلات غير صحيحة للبيانات.

وللكشف عن عدم ثبات التباين يمكن إستخدام عدد من الاختبارات الإحصائية؛ وأحد هذه الاختبارات هو اختبار Breusch-Pagan

(٣-١-٢) مشكلة الارتباط الذاتي Autocorrelation

في الحالة التي يكون فيها الارتباط بين حدود الخطأ المتتالية في نموذج الإنحدار مساوي للصفر ، فإن هذا يعني أن حدود الخطأ مستقلة، أما في حالة أن تكون حدود الخطأ في نموذج الإنحدار مرتبطة فإن هذا يطلق عليه مشكلة الإرتباط الذاتي ، ونجد أن مشكلة الإرتباط الذاتي عادة ما تظهر في بيانات السلسل الزمنية حيث يتم جمع البيانات بشكل مرتب خلال الزمن وبالتالي فإن المشاهدات المتتالية عادة ما تكون مرتبطة خاصة إذا كانت الفترات الزمنية بين المشاهدات المتتالية قصيرة ، ونجد أن هناك عدة أسباب لوجود الإرتباط الذاتي بين حدود الخطأ في نموذج الإنحدار ومنها ما يلي:

١- أن يكون هناك ترتيب ما في وحدات المعاينة التي يتم دراستها قد يؤدي إلى وجود الإرتباط الذاتي سواء كانت المشاهدات مرتبة خلال الزمن مثل بيانات السلسل الزمنية أو أن تكون المشاهدات مرتبة في فضاء مثل البيانات المقطعة cross-section data

٢- إستبعاد بعض المتغيرات الهامة من النموذج قد يكون هو مصدر الإرتباط الذاتي حيث أن ذلك يؤدي إلى وجود نمط ما في قيم الباقي الناتجة من توفيق نموذج الإنحدار، وعند إدخال هذه المتغيرات الهامة إلى النموذج يختفي نمط الإرتباط الذي تم مشاهدته بين الباقي، إلا أن هناك أسباب يمكن أن تؤدي إلى حذف أو إهمال بعض المتغيرات الهامة في النموذج ومنها أن يكون المتغير وصفي أو أن مشاهدات متغير ما غير متاحة.

٣- التحديد الخاطئ لصيغة الدالة في نموذج الإنحدار، فعلى سبيل المثال عندما يتم افتراض أن هناك علاقة خطية بين المتغير التابع والمتغيرات التفسيرية ، في حين أن هناك حدود أسيّة أو لوغاريمية في النموذج فإن هذا قد يؤدي إلى ظهور الإرتباط الذاتي بين حدود الخطأ.

٤- إجراء تحويلات على البيانات قد يتسبب في وجود إرتباط ذاتي بين حدود الخطأ.

وللكشف عن وجود الإرتباط الذاتي بين حدود الخطأ في نموذج الإنحدار يمكن استخدام عدد من الاختبارات وأحد هذه الاختبارات هو اختبار Durbin-Watson .

ونجد أن مشكلتي الإرتباط الذاتي بين حدود الخطأ وعدم ثبات تباين حد الخطأ تؤثر على تباينات معاملات الإنحدار التي نرغب في أن تكون أصغر ما يمكن لكيتحقق أقصى درجة من الدقة، فعلى سبيل المثال عند تقدير معاملات الإنحدار بإستخدام طريقة المربيعات الصغرى (OLS) في ظل وجود ارتباط ذاتي بين حدود الخطأ أو عدم ثبات تباين حد الخطأ heteroskedasticity فإن مقدر OLS لن يكون له أقل تباين من بين كل المقدرات غير المتحيز، وهذا بدوره يؤثر على دقة الإستدلالات الإحصائية الخاصة بمعاملات الإنحدار. مع ملاحظة أن مشكلتي الإرتباط الذاتي بين حدود الخطأ وعدم ثبات تباين حد الخطأ لن تؤثر على خصائص الإتساق وعدم التحيز لمقدرات معاملات الإنحدار. وفي حالة تجاهل وجود مشكلات التقدير، فإن هذا يتطلب استخدام طرق التقدير المتينة robust estimation لتقدير التباينات القارببة لمقدرات معاملات الإنحدار. ولذلك، في

هذا البحث سوف يتم استخدام طريقتين من طرق التقدير المتينة للتباين التقاري وهم؛ ؛ طريقة أساس كرنايل kernel-based ومقدر OPG أو خوارزمية BHHH.

(٣-٢) تقدير التباين التقاري لـ $\hat{\beta}$ باستخدام طريقة أساس كرنايل Kernel-based

يمكن تقدير مصفوفة التغير التقاري في حالة البيانات المرتبطة ذاتياً بإستخدام الطرق الامعمليه لتقدير التباين ومن بين هذه الطرق طريقة أساس كرنايل kernel Based التي اقترحها Newey and West (1987) ونجد أن التقدير المتسق لمصفوفة التغير التقاري هو أمر هام لبناء فترات الثقة وإجراء اختبارات الفروض التقاريية وذلك لأن تحقيق الاتساق يجعلنا نقوم بإجراء الاستدلالات الإحصائية بالقرب من القيمة الحقيقية للمعلمة. ويتم استخدام دوال كرنايل لتمهيد دالة التغير الذاتي للعينة وذلك بحيث تقل قيمة الأوزان التي تستخدم لترجيح التغيرات الذاتية للعينة كلما زادت الفجوة الزمنية.

بالنسبة لنموذج انحدار بواسون لبيانات سلسلة زمنية الذي تمت مناقشته في القسم الثاني من هذا البحث، سوف نجد أنه بأخذ تقاضل دالة الإمكان اللوغاريتمي الزائفة - the pseudo log-likelihood function بالنسبة لـ β ، فأنتا ستحصل على $\hat{\beta}$ من خلال حل معادلة التقدير المعممهة التالية:

$$M_n^T \sum_{t=1}^n x_t (y_t - e^{x_t^T \beta}) = 0 \quad (11)$$

حيث أن

$$U_t(\beta) = M_n^T x_t (y_t - e^{x_t^T \beta})$$

قدمت دراسة (2012) Wu مقدر متسق لـ $\Omega_1^{-1} (\Omega_1 + \Omega_2)^{-1}$ والتي تمثل مصفوفة التغير التقاري لـ $\hat{\beta}$ بإستخدام طريقة أساس كرنايل Kernel-based حيث أن المقدر المتسق لـ Ω_1 نحصل عليه بالتعويض المباشر في الصيغة التالية:

$$\hat{\Gamma}_1 = M_n^T \left[\sum_{t=1}^n x_t x_t^T e^{x_t^T \hat{\beta}} \right] M_n \quad (12)$$

وأن المقدر المتسق لـ $\Omega_1 + \Omega_2$ هو:

$$\begin{aligned}
\hat{\Gamma}_n &= \sum_{h=-n+1}^{n-1} \sum_{t=\max(1-h,1)}^{\min(n-h,n)} E[U_t(\hat{\beta}) U_t^T(\hat{\beta})] \\
&= \sum_{t=1}^n E[U_t(\hat{\beta}) U_t^T(\hat{\beta})] + \sum_{h=1}^{n-1} \sum_{t=1}^{n-h} E[U_t(\hat{\beta}) U_{t+h}^T(\hat{\beta})] \\
&\quad + \sum_{h=-n+1}^{-1} \sum_{t=1-h}^n E[U_t(\hat{\beta}) U_{t+h}^T(\hat{\beta})] \\
&= \sum_0 + \sum_{h=1}^{n-1} \left(\sum_h + \sum_h^T \right)
\end{aligned}$$

حيث أن:

$$\sum_h = \sum_{t=1}^{n-h} E[U_t(\hat{\beta}) U_{t+h}^T(\hat{\beta})]$$

وباستخدام أوزان كرناں سوف نحصل على المقدار التالي:

$$\hat{\Gamma}_n = \sum_0 + \sum_{h=1}^{k-1} w(h/k) \left(\sum_h + \sum_h^T \right) \quad (13)$$

حيث أن $w(\cdot)$ هي دالة كرناں و k هي (عرض الحزمة) bandwidth وهذا المقدار قائم على فكرة بتر أو تقليل وزن الحدود غير المرغوب فيها، وبالتالي فإن $\hat{\Gamma}_n \hat{\Gamma}_1^{-1} \hat{\Gamma}_1$ هو مقدر متспект لـ $\Omega_1^{-1}(\Omega_1 + \Omega_2)\Omega_1^{-1}$ والتي تمثل مصفوفة التغير التقاريبي لـ $\hat{\beta}$.

(٣-٣) تقييم التباين التقاريبي لـ $\hat{\beta}$ باستخدام طريقة OPG أو خوارزمية BHHH

مصفوفة التغير التقاريبي لمقدار الإمكان الأعظم $\hat{\beta}$ هي مصفوفة في المعلمات β المجهولة (أى أنها دالة في المعلمات β المجهولة) ويمكن حسابها من خلال معکوس مصفوفة المعلومات كالتالي:

$$\text{Var}(\hat{\beta}) = [I(\beta)]^{-1} \quad (14)$$

وحيث أن مصفوفة المعلومات هي سالبة القيمة المتوقعة لمصفوفة هيسين Hessian (وهي مصفوفة التفاضلات الجزئية من الدرجة الثانية لدالة الإمكان اللوغاريتمي بالنسبة لـ β) ، أى أن

$$\begin{aligned} I(\beta) &= -E(H(\beta)) \\ &= -E\left(\frac{\partial^2 \ln L(\beta)}{\partial \beta \partial \beta^T}\right) \end{aligned} \quad (15)$$

وبالتالي فإن مصفوفة التغير التقاربي لمقدار الإمكان الأعظم $\hat{\beta}$ ستكون:

$$\begin{aligned} \text{Var}(\hat{\beta}) &= [I(\beta)]^{-1} \\ &= [-E(H(\beta))]^{-1} \\ &= -\left[E\left(\frac{\partial^2 \ln L(\beta)}{\partial \beta \partial \beta^T}\right)\right]^{-1} \end{aligned} \quad (16)$$

وبما أن متجه المعلمات الحقيقية β مجهولة، فإنه يمكننا استبدال β بـ $\hat{\beta}$ وذلك لتقدير مصفوفة التغير التقاربي لمقدار الإمكان الأعظم، إلا أن هذا المقدر نادراً ما يمكن الحصول عليه وذلك لأن القيمة المتوقعة الدقيقة للتفاضلات الجزئية من الدرجة الثانية لدالة الإمكان اللوغاريتمي ستكون غير معروفة، وهناك بديل آخر لتقدير مصفوفة التغير التقاربي لمقدار الإمكان الأعظم $\hat{\beta}$ عن طريق حساب سالب مصفوفة التفاضلات الجزئية من الدرجة الثانية لدالة الإمكان اللوغاريتمي بدون استخدام التوقع كالتالي:

$$\hat{I}(\hat{\beta}) = \left(-\frac{\partial^2 \ln L(\beta)}{\partial \beta \partial \beta^T}\right) \quad (17)$$

ولكن عيب هذا المقدر هو أن التفاضلات الجزئية من الدرجة الثانية في بعض الحالات يكون من المعقد اشتغالها وبرمجتها على الكمبيوتر. وهناك بديل آخر لتقدير مصفوفة التغير التقاربي لـ $\hat{\beta}$ وذلك من خلال استخدام خوارزمية BHHH او ما يطلق عليه outer product of gradients (OPG) estimator (مقدر حاصل الضرب الخارجي لمتجهات التفاضلات الجزئية من الدرجة الأولى) والتي قدمها Berdent, Hall, Hall and Hausman (1974) والقائمة على أنه عند تحديد النموذج بشكل دقيق وعندما تكون القيمة المتوقعة للتفاضلات الجزئية من الدرجة الأولى مساوية للصفر (أى عند القيمة العظمى لدالة الإمكان) فإن سالب القيمة المتوقعة لمصفوفة هيسين Hessian سيكون مساوي لتباين التفاضلات الجزئية من الدرجة الأولى var(g_i(β)) والذي يسمى (the variance of gradients) في المجتمع حيث أن:

$$g_i(\beta) = \frac{\partial \ln L(\beta)}{\partial \beta}$$

والتي تعني أن (β) هو متجه متوجه $k \times 1$ للتقاضلات الجزئية من الدرجة الأولى لدالة الإمكان اللوغاريتمي. وبالنسبة للعينة، نجد أنه عند تحديد النموذج بشكل دقيق، فإن تباين التقاضلات الجزئية من الدرجة الأولى $(g_i(\hat{\beta}))$ سوف يكون تقريب جيد لـ $-E(H(\beta))$ - كلما زادت حجم العينة؛ أي أن $(H(\beta)) \rightarrow -E(H(\beta))$ كلما $n \rightarrow \infty$ وذلك عند الحد الأقصى لدالة الإمكان (أي عندما يكون توقع التقاضلات الجزئية من الدرجة الأولى مساوياً للففر)

وبعبارة أخرى، فإن سالب القيمة المتوقعة لمصفوفة التقاضلات الجزئية من الدرجة الثانية يمكن تقديرها من خلال مصفوفة التغير للتقاضلات الجزئية من الدرجة الأولى عندما تكون n كبيرة بما يكفي، وبالتالي فإن:

$$\begin{aligned} \widehat{\text{Var}}(\hat{\beta}) &= [\hat{I}(\hat{\beta})]^{-1} \\ &= [-E(H(\hat{\beta}))]^{-1} \\ &= [\text{var}(g_i(\hat{\beta}))]^{-1} \\ &= \left[\frac{1}{n} \sum_{i=1}^n g_i(\hat{\beta}) g_i(\hat{\beta})^T \right]^{-1} \end{aligned} \tag{18}$$

وهذا ما يسمى outer product of gradients (OPG) estimator (مقدر حاصل الضرب الخارجي لمتجهات التقاضلات الجزئية من الدرجة الأولى) أو خوارزمية BHHC.

وهذه الطريقة تستخدم في البحث التجاري والقائمة على إجراء مجموعة من التكرارات للحصول على تباين التقاضلات الجزئية من الدرجة الأولى عند الحد الأقصى لدالة الإمكان، والتي سبق استخدامها في العديد من الدراسات من بينها دراسة Berliana, et al (2019) ودراسة Aini (2020) ودراسة Wenur and Suharsono (2020).

ونجد أنه عند تحديد النموذج بشكل دقيق فإن توزيع المعاينة للفرق ما بين المقدر والقيمة الحقيقية للمعلمات سوف يكون توزيع طبيعي بشكل تقاربٍ بمتوسط صفر، وتغييرٍ يساوي معكوس سالب القيمة المتوقعة لمصفوفة هيسين Hessian

$$\sqrt{n}(\hat{\beta} - \beta) \xrightarrow{d} N\left(0, [-E(H(\beta))]^{-1}\right)$$

لما $n \rightarrow \infty$ حيث أن β هو متجه المعلمات الحقيقية و $\hat{\beta}$ هو مقدر الإمكان الأعظم و $[-E(H(\beta))]^{-1}$ هي سالب القيمة المتوقعة لمصفوفة هيسين Hessian في المجتمع. ولكن إذا كان النموذج غير محدد بشكل دقيق misspecified، فإن التغير التقاربي لـ $\hat{\beta}$ يكون أكثر تعقيداً، فنجد أنه بالنسبة لأي نموذج تكون فيه القيمة المتوقعة للتقاضلات الجزئية من الدرجة الأولى لدالة الإمكان اللوغاريتمي في المجتمع مساوية للصفر فإن:

$$\sqrt{n}(\hat{\beta} - \beta) \xrightarrow{d} N\left(0, [-E(H(\beta))]^{-1} \text{var}(g_i(\beta)) [-E(H(\beta))]^{-1}\right)$$

حيث أن $(g_i(\beta))$ هو تباين التقاضلات الجزئية من الدرجة الأولى لدالة الإمكان اللوغاريتمي بالنسبة لـ β في المجتمع.

وعندما يكون النموذج محدد دقيق، فإن $\text{var}(g_i(\beta)) = -E(H(\beta))$ وبالتالي فإن $[-E(H(\beta))]^{-1} \text{var}(g_i(\beta)) [-E(H(\beta))]^{-1} = [-E(H(\beta))]^{-1}$ وهذا ما يجعلنا نحصل على نفس التغير التقاربي في حالة أن يكون النموذج محدد بشكل دقيق. إلا أنه إذا كان النموذج غير محدد بشكل دقيق أو أن هناك مخالفات لفروض النموذج مثل وجود إرتباط ذاتي أو عدم ثبات تباين حدود الخطأ سوف تكون صيغة التغير التقاربي هي:

$[-E(H(\beta))]^{-1} \text{var}(g_i(\beta)) [-E(H(\beta))]^{-1}$ ونجد أن هذه المصفوفة سوف تكون صالحة سواء كان النموذج محدد بشكل دقيق أم لا. وهذه الصيغة تسمى مصفوفة التغير المتينة Robust covariance matrix، وفي بعض الأحيان تسمى أيضاً مقدار "sandwich" للتغير، حيث أن معكوس سالب القيمة المتوقعة لمصفوفة هيسين Hessian تظهر على كلا الجانبين.

وبالنسبة لنموذج الإنحدار ال بواسوني الذي هو محل دراستنا، سيكون سالب متوسط مصفوفة هيسين في العينة كالتالي:

$$-\frac{1}{n}H(\hat{\beta}) = -\frac{1}{n} \left. \frac{\partial^2 \ln L(\beta)}{\partial \beta \partial \beta^T} \right|_{\hat{\beta}} = -\frac{1}{n} \sum_{t=1}^n x_t x_t^T e^{x_t^T \hat{\beta}} \quad (19)$$

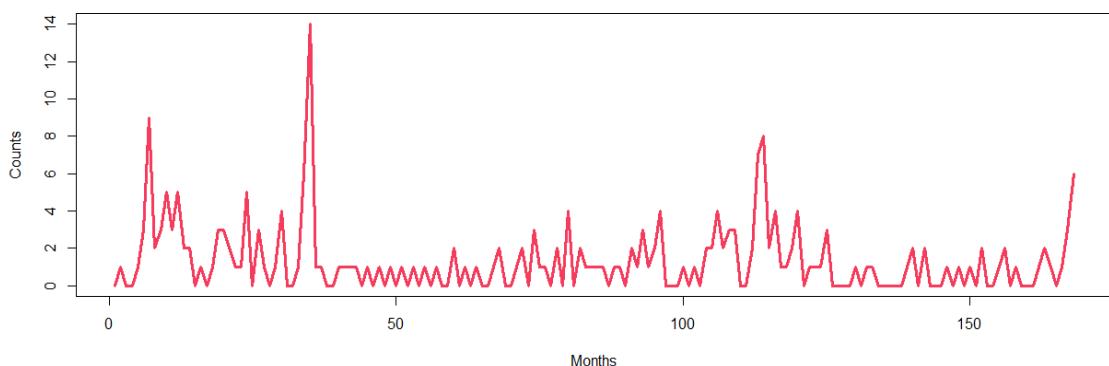
ويكون تباين التقاضلات الجزئية من الدرجة الأولى لدالة الإمكان اللوغاريتمي هي:

$$\begin{aligned} \text{var} (g_i(\hat{\beta})) &= \text{var} \left(\frac{\partial \ln L (\beta)}{\partial \beta} \Big|_{\hat{\beta}} \right) \\ &= \text{var} \left(\sum_{t=1}^n x_t (y_t - e^{x_t^T \hat{\beta}}) \right) \end{aligned} \quad (20)$$

4 - الدراسة التطبيقية

(٤-١) التطبيق على الأعداد الشهرية للإصابة بشلل الأطفال:

تمثل هذه البيانات الأعداد الشهرية للإصابة بشلل الأطفال في الولايات المتحدة الأمريكية خلال السنوات من ١٩٧٠ إلى ١٩٨٣ كما هو مسجل في مركز مكافحة الأمراض بالولايات المتحدة الأمريكية وبذلك يكون لدينا سلسلة زمنية تتكون من ١٦٨ مشاهدة، والتي سبق دراستها أيضاً في العديد من الدراسات، منها؛ (Davis et al (1999) و Davis et al (2000) و Wu (2007) و Safari et al (2017)). وتعتبر هذه البيانات مثال نموذجي عند دراسة النماذج الخطية المعممة لمعلمة مشتقة. ونجد أن أول من يستخدم هذه البيانات هي دراسة Zeger (1988) والذي افترض نموذج معلمات مشتقة parameter-driven model بحيث يكون التوزيع الشرطي للمشاهدات بمعلومية العملية الكامنة latent process هو توزيع بواسون، واستخدام نظرية معادلات التقدير من أجل تقييم معلمات النموذج.



الشكل (4-1) يمثل الأعداد الشهرية للإصابة بشلل الأطفال في الولايات المتحدة من ١٩٧٠ إلى ١٩٨٣

الشكل (4-1) يوضح أن هناك بعض التغيرات الموسمية في البيانات وأن هناك إمكانية لوجود اتجاه خطى متناقض خلال الزمن. ونجد أن الكشف عن وجود إتجاه خطى متناقض هو من الأهداف

الرئيسية لدراسة هذه البيانات، وعلى الرغم من أن القيمة المشاهدة في نوفمبر ١٩٧٢ وهي القيمة ٤٤ تعتبر قيمة متطرفة outlier، إلا أنه لم يتم إستبعادها أو تعديلها عند تحليل هذه البيانات وذلك لأن لها تأثير طفيف على النتائج وذلك وفقاً لدراسة Chan and Ledolter (1995) حيث تم تعديل هذه القيمة المتطرفة ووجد أن هناك تغير طفيف في النتائج.

ونجد أنه في (2000) Davis et al تم دراسة هذه البيانات في إطار نموذج المعلمة المشتقة parameter-driven model وقد تم استخدام طريقة الإمكان الزائف pseudo-likelihood method لتقدير معلمات النموذج. وذلك بفرض أن التوزيع الشرطي للمشاهدات بمعلومية العملية الكامنة latent process هو توزيع بواسون كالتالي:

$$Y_t | \alpha_t \stackrel{\text{indep}}{\sim} \text{po}(\lambda_t)$$

وهذا هو نفس النموذج الذي سنقوم بتطبيقه والذي سبق توضيحه في القسم الثاني من هذا البحث. وسوف نقوم بإستخدام نفس متغيرات الإنحدار التي تم استخدامها في الدراستين السابقتين وهذه المتغيرات هي حد التقاطع والإتجاه الخطوي وحدود متسلسلة فوريير Fourier السنوية والنصف سنوية للتعبير عن النمط الموسمي وبالتالي:

$$x_t = (1, t'/1000, \cos(2\pi t'/12), \sin(2\pi t'/12), \cos(2\pi t'/6), \sin(2\pi t'/6))^T$$

حيث أن $t' = t - 73$ والمستخدمة في تحديد موقع حد التقاطع عند شهر يناير ١٩٧٦ . وهذا يعني أننا سوف نصل لنفس النتائج التي توصلت إليها دراسة Davis et al (2000) فيما يتعلق بالنموذج وتقدير الإنحدار إلا أننا في هذه الدراسة سنقوم بإستخدام طريقة أساس كرنال kernel ومقدار OPG أو خوارزمية BHHH والتي سبق توضيحيها في في القسم الثالث من هذا البحث وذلك لتقدير التباينات التقاربية لـ β .

سوف نقوم بتوفيق النموذج الخطوي المعمم بواسوني المعياري The standard Poisson GLM والذي سبق توضيحيه في في القسم الثاني من هذا البحث لبيانات الأعداد الشهرية للإصابة بشلل الأطفال في الولايات المتحدة باستخدام الدالة "glm.po" في البرنامج الإحصائي R وتم عرض النتائج في الجدول (4-1).

الجدول (4-1): تقديرات المعلمات لبيانات شلل الأطفال بالإعتماد على توفيق نموذج خطى معمم بواسوني معياري.

GLM	Estimate	Std. Error	z value	Pr(> z)
Intercept	0.20694	0.07508	2.75	0.005849 **
Trend	-4.79866	1.40289	-3.421	0.000625 ***
$\cos(2\pi t'/12)$	-0.14873	0.09722	-1.53	0.126037
$\sin(2\pi t'/12)$	-0.53188	0.10904	-4.878	1.07e-06 ***

$\cos(2\pi t'/6)$	0.1691	0.09881	1.711	0.087013 .
$\sin(2\pi t'/6)$	-0.43214	0.1008	-4.287	1.81e-05 ***

تظهر تقديرات β في العمود (٢) من الجدول (٤-١) وتنظر الأخطاء المعيارية لـ $\hat{\beta}$ في العمود (٣) من من الجدول (٤-١) مع ملاحظة أن الأخطاء المعيارية لـ $\hat{\beta}$ المحسوبة في الجدول السابق تتجاهل إمكانية وجود العملية الكامنة latent process وبالتالي فإنه لا يمكن الاعتماد عليها في الإستدلالات الإحصائية الخاصة بمعاملات الإنحدار لأنها قد تؤدي إلى إستنتاجات خاطئة.

سوف يتم استخدام اختبار Breusch-Pagan للكشف عن عدم ثبات تباين حدود الخطأ سوف. ونجد أن إحصاءة الإختبار و P-value لهذا الإختبار هي:

Breusch-Pagan test

BP	Df	p-value
8.2776	3	0.04061

حيث أن P-value أقل من 0.05، فإن القرار هو رفض الفرض العدلي بأن تباينات الأخطاء متساوية. وهذا يعني أن هناك دليل كافي على عدم ثبات تباين حدود الخطأ في نموذج الإنحدار عند مستوى معنوية 0.05.

سوف يتم استخدام اختبار Durbin-Watson للكشف عن وجود إرتباط ذاتي بين حدود الخطأ في النموذج. ونجد أن إحصاءة الإختبار و P-value لهذا الإختبار هي:

Durbin-Watson test

DW	p-value
1.5008	0.0003086

حيث أن P-value قيمة صغيرة جدا، فإن القرار هو رفض الفرض العدلي بأن الإرتباط الذاتي بين حدود الخطأ مساوي للصفر. وهذا يعني أن هناك دليل كافي على وجود إرتباط ذاتي بين حدود الخطأ في نموذج الإنحدار.

وبناءً على النتائج السابقة، فإنه لا يمكننا الاعتماد على الأخطاء المعيارية لـ $\hat{\beta}$ الناتجة عن توفيق نموذج خططي معتمد بواسوني معياري في ظل تجاهل وجود الإرتباط الذاتي وعدم ثبات تباين حدود الخطأ. وللحصول على مقدرات متينة robust estimators للتباينات التقاريرية لـ $\hat{\beta}$ والتي تسمح لنا

بالحصول على تقديرات متسقة يمكن استخدامها في الاستدلالات الإحصائية الخاصة بمعاملات الإنحدار، سوف يتم استخدام طريقة أساس كرنال kernel-based والتي تم توضيحها في في القسم الثالث من هذا البحث، وذلك بالإعتماد على ثلات دوال كرنال مختلفة وهم؛ Bartlett kernel و Quadratic Spectral kernel و Parzen kernel . كما أننا سنقوم بتقدير التباينات التقاريبية لـ $\hat{\beta}$ بإستخدام مقدر OPG أو خوارزمية BHHH والتي سبق توضيحها في القسم الثالث من هذا البحث وتم عرض النتائج في الجدول (2-4) كما يلي:

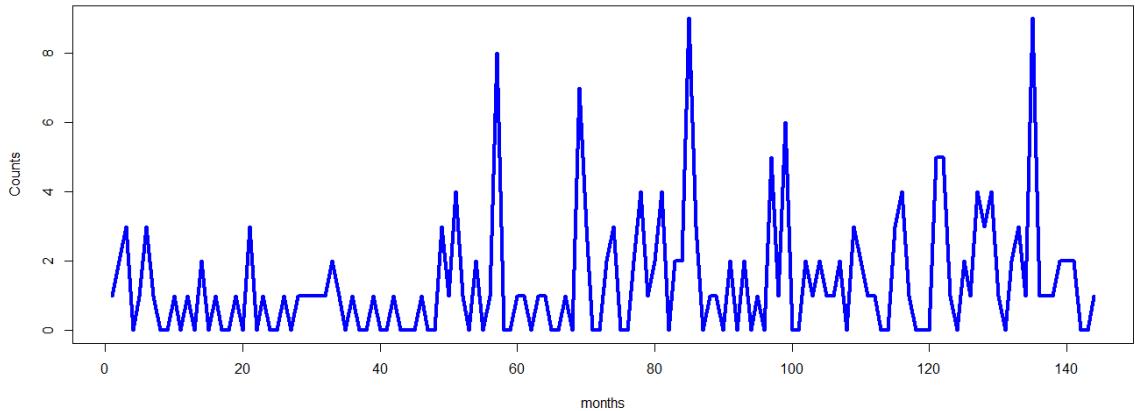
الجدول (2-4): تقديرات التباينات التقاريبية لـ $\hat{\beta}$.

	original	Bartlett	Parzen	Quadratic Spectral	OPG
Intercept	0.0090	0.0139	0.0143	0.0145	0.0042
Trend	4.6735	8.2279	8.2636	8.3158	1.0058
$\cos(2\pi t^{\circ}/12)$	0.0173	0.0199	0.0205	0.0202	0.0060
$\sin(2\pi t^{\circ}/12)$	0.0235	0.0433	0.0435	0.0447	0.0079
$\cos(2\pi t^{\circ}/6)$	0.0180	0.0209	0.0212	0.0213	0.0058
$\sin(2\pi t^{\circ}/6)$	0.0206	0.0218	0.0221	0.0222	0.0064

ومن خلال الجدول السابق نجد أنه لا يوجد اختلافات جوهريه بين تقديرات أساس كرنال للتباينات التقاريبية لـ $\hat{\beta}$ بإستخدام ثلات دوال كرنال مختلفة، والتي تظهر في الأعمدة 2 و 3 و 4. في حين أن تقديرات OPG للتباينات التقاريبية لـ $\hat{\beta}$ والتي تظهر في العمود 5 كانت أقل بفارق كبير عن التباينات التقاريبية التي حصلنا عليها بإستخدام طريقة أساس كرنال، ولذلك فإننا نوصي بإستخدام مقدر OPG لتقدير التباينات التقاريبية لـ $\hat{\beta}$ في ظل إستخدام نموذج خطى معمم بواسونى لتحليل بيانات سلاسل زمنية وذلك في ظل تجاهل مشكلات التقدير مثل وجود إرتباط ذاتي بين حدود الخطأ أو عدم ثبات تباين حدود الخطأ، حيث أن مقدر OPG يحقق أقل قيم للتباينات التقاريبية.

(4-2) التطبيق على الأعداد الشهرية لحالات الحمى الروماتيزمية:

تمثل هذه البيانات الأعداد الشهرية لحالات الحمى الروماتيزمية التي يتم استقبالها بمستشفى أطفال المنصورة خلال الفترة من ١ يناير ٢٠١٠ إلى ٣١ ديسمبر ٢٠٢١ .



الشكل (4-2) يمثل الأعداد الشهرية لاستقبال حالات الحمى الروماتيزمية في مستشفى أطفال المنصورة خلال الفترة من ١ يناير ٢٠١٠ إلى ٣١ ديسمبر ٢٠٢١ .

الشكل (4-2) يوضح أن هناك بعض التغيرات الموسمية في البيانات وأن هناك إمكانية لوجود اتجاه خطى متناقص خلال الزمن. وسوف يتم دراسة هذه البيانات من خلال نموذج المعلمة المشتقة parameter-driven model وبفرض أن التوزيع الشرطى للمشاهدات بمعلومية العملية الكامنة هو توزيع بواسون كالتالى:

$$Y_t \mid \alpha_t \stackrel{\text{indep}}{\sim} \text{po}(\lambda_t)$$

والذى سبق توضيحه فى القسم الثانى من هذا البحث ، وقد تم استخدام طريقة الإمكان الزائف pseudo-likelihood method لتقدير معلمات النموذج. وقد أوضح التحليل المبدئي لهذه البيانات إلى الحاجة بأن يكون النموذج متضمن إتجاه خطى متناقص محتمل خلال الزمن وحدود متسلسلة فورير Fourier للتعبير عن النمط الموسمى في البيانات، ومن خلال اختبار معنوية معاملات الإنحدار وجد أن حد الإتجاه الخطى لم يكن معنوى ، ولذلك تم استبعاده من النموذج ،

وبالتالى فإن استقبال حالات الحمى الروماتيزمية في مستشفى أطفال المنصورة ليس له اتجاه متناقص معنوى خلال الفترة من ١ يناير ٢٠١٠ إلى ٣١ ديسمبر ٢٠٢١ ، في حين أن حدود متسلسلة فورير Fourier الربع سنوية والنصف سنوية للتعبير عن النمط الموسمى كان لها معاملات معنوية ، وبالتالي فإن متغيرات الإنحدار هي:

$$x_t = (1, \cos(2\pi t/6), \sin(2\pi t/6), \cos(2\pi t/3), \sin(2\pi t/3))^T$$

وتم توفيق النموذج الخطى المعمم البواسوني المعياري The standard Poisson GLM والذي سبق توضيحه في القسم الثانى من هذا البحث لبيانات الأعداد الشهرية لاستقبال حالات الحمى

الروماتيزمية في مستشفى الأطفال بالمنصورة باستخدام الدالة "glm.po" في البرنامج الإحصائي R وتم عرض النتائج في الجدول (4-3).

الجدول (4-3): تقييرات المعلمات لبيانات الحمى الروماتيزمية بالإعتماد على توفيق نموذج خطى معنوم بواسونى معياري.

GLM	Estimate	Std. Error	z value	Pr(> z)
Intercept	0.16167	0.08412	1.922	0.05461 .
$\cos(2\pi t/6)$	-0.34302	0.1035	-3.314	0.00092 ***
$\sin(2\pi t/6)$	0.66176	0.12664	5.225	1.74e-07 ***
$\cos(2\pi t/3)$	0.32825	0.10411	3.153	0.00162 **
$\sin(2\pi t/3)$	0.24431	0.11478	2.128	0.03330 *

تظهر تقديرات β في العمود (٢) من الجدول (4-4) وتظهر الأخطاء المعيارية $L\hat{\beta}$ في العمود (٣) من من الجدول (4-3) مع ملاحظة أن الأخطاء المعيارية $L\hat{\beta}$ المحسوبة في الجدول السابق تتغافل إمكانية وجود العملية الكامنة latent process وبالتالي فإنه لا يمكن الإعتماد عليها في الإستدلالات الإحصائية الخاصة بمعاملات الإنحدار لأنها قد تؤدي إلى إستنتاجات خاطئة.

سوف يتم استخدام اختبار Breusch-Pagan للكشف عن عدم ثبات تباين حدود الخطأ Heteroskedasticity ونجد أن إحصاء الإختبار و P-value لهذا الإختبار هما:

Breusch-Pagan test

BP	Df	p-value
10.499	4	0.03281

حيث أن P-value أقل من 0.05، فإن القرار هو رفض الفرض العدمي بأن تباينات الأخطاء متساوية. وهذا يعني أن هناك دليل كافى على عدم ثبات تباين حدود الخطأ في نموذج الإنحدار عند مستوى معنوية 0.05.

وسوف يتم استخدام اختبار Durbin-Watson للكشف عن وجود إرتباط ذاتي بين حدود الخطأ في النموذج. ونجد أن إحصاء الإختبار و P-value لهذه الإختبار كالتالى:

Durbin-Watson test

DW	p-value
1.9775	0.446

حيث أن P-value أكبر من ٠٠٥، فإن القرار هو عدم رفض الفرض العدلي بأن الإرتباط الذاتي بين حدود الخطأ مساوي للصفر. وهذا يعني أنه لا يوجد دليل كافي على وجود إرتباط ذاتي بين حدود الخطأ في نموذج الإنحدار.

وبناءً على النتائج السابقة، فإنه لا يمكننا الاعتماد على الأخطاء المعيارية $L\hat{\beta}$ الناتجة عن توفيق نموذج خطّي معتمد بواسوني معياري بسبب وجود إحدى مشكلات التقدير وهي عدم ثبات تباين حدود الخطأ. وللحصول على مقدرات متينة robust estimators للبيانات التقاريرية $L\hat{\beta}$ والتي تسمح لنا بالحصول على تقديرات متسبة يمكن استخدامها في الإستدلالات الإحصائية الخاصة بمعاملات الإنحدار، سوف يتم استخدام طريقة أساس كرنال kernel-based والتي تم توضيحها في القسم الثالث من هذا البحث، وذلك بالإعتماد على ثلاثة دوال كرنال مختلفة وهم؛ Bartlett، Quadratic Spectral kernel و Parzen kernel. كما أنشأ سنتقم بتقدير البيانات التقاريرية $L\hat{\beta}$ باستخدام مقدر OPG أو خوارزمية BHHH والتي سبق توضيحها في القسم الثالث من هذا البحث وتم عرض النتائج في الجدول (4-4) كما يلي:

الجدول (4-4): تقديرات البيانات التقاريرية $L\hat{\beta}$.

	original	Bartlett	Parzen	Quadratic Spectral	OPG
Intercept	0.0092	0.0099	0.0104	0.0099	0.0058
$\cos(2\pi t/6)$	0.0174	0.0206	0.0184	0.0183	0.0085
$\sin(2\pi t/6)$	0.0213	0.0151	0.0148	0.0147	0.0149
$\cos(2\pi t/3)$	0.0168	0.0184	0.0197	0.0192	0.0095
$\sin(2\pi t/3)$	0.0208	0.0157	0.0155	0.0154	0.0099

ومن خلال الجدول السابق نجد أنه لا يوجد اختلافات جوهريّة بين تقديرات أساس كرنال للبيانات التقاريرية $L\hat{\beta}$ باستخدام ثلاثة دوال كرنال مختلفة، والتي تظهر في الأعمدة 2 و 3 و 4. في حين أن تقديرات OPG للبيانات التقاريرية $L\hat{\beta}$ والتي تظهر في العمود 5 كانت أقل بفارق كبير عن البيانات التقاريرية التي حصلنا عليها باستخدام طريقة أساس كرنال بإستثناء تقدير التباين التقاريري $L\hat{\beta}^3$ حيث كان التقدير باستخدام مقدر OPG له قيمة قريبة إلى حد كبير من القيم التي حصلنا عليها باستخدام طريقة أساس كرنال ولذلك فإننا نوصي باستخدام مقدر OPG لتقدير البيانات التقاريرية

$L\hat{\beta}$ في ظل استخدام نموذج خطى معمم بواسونى لتحليل بيانات سلاسل زمنية عندما يتم تجاهل وجود إحدى مشكلات التقدير مثل وجود إرتباط ذاتي بين حدود الخطأ او عدم ثبات تباين حدود الخطأ، حيث أن مقدر OPG يحقق أقل قيم للبيانات التقاريبية.

٥ – النتائج والتوصيات (٥-١) النتائج:

قامت هذه الدراسة بالمقارنة بين طريقتين من الطرق المتينة لتقدير التباين التقاربى $L\hat{\beta}$ وهما طريقة أساس كرنال Kernel-based التي تم اقتراها في دراسة (Wu, 2012) أو مقدر OPG أو خوارزمية BHHH التي نقترح استخدامها في هذه الدراسة وذلك في ظل نموذج الإنحدار البواسونى لتحليل بيانات سلسلة زمنية، ومن خلال التطبيق العملى على مجموعتين من البيانات توصلت الدراسة إلى النتائج التالية:

- عند استخدام طريقة أساس كرنال Kernel-based لتقدير التباين التقاربى $L\hat{\beta}$ بالإعتماد على ثلاثة دوال كرنال مختلفة وهم؛ Bartlett kernel و Parzen kernel و Quadratic Spectral kernel، قد توصلت الدراسة إلى أن استخدام أيًا من الدوال الثلاثة سوف يعطي نتائج متقاربة إلى حد كبير عند تقدير التباين التقاربى $L\hat{\beta}$.
- بمقارنة مقدر OPG أو خوارزمية BHHH التي تم اقتراها في هذه الدراسة مع طريقة أساس كرنال Kernel-based التي تم اقتراها في دراسة (Wu, 2012)، قد تبين أن مقدر OPG أو خوارزمية BHHH هي الأفضل في تقدير التباين التقاربى $L\hat{\beta}$ ، حيث اتضح من خلال التطبيق العملى على مجموعتين من البيانات أن تقديرات التباين التقاربى $L\hat{\beta}$ باستخدام مقدر OPG كانت أقل بفارق كبير عن تقديرات التباين التقاربى $L\hat{\beta}$ التي حصلنا عليها باستخدام طريقة أساس كرنال Kernel-based.

٥-٢) التوصيات:

في هذه الدراسة تم استخدام طريقتين من طرق التقدير المتينة وهما طريقة أساس كرنال- Kernel-based ومقدر OPG أو خوارزمية BHHH لتقدير التباين التقاربى في نموذج الإنحدار البواسونى لبيانات سلسلة زمنية وذلك في ظل وجود مخالفات لفرضيات النموذج مثل الإرتباط الذاتي بين حدود الخطأ وعدم ثبات تباين حدود الخطأ مع التطبيق على مجموعتين من البيانات. ويوصى الباحث استخدام مقدر OPG أو خوارزمية BHHH لتقدير التباين التقاربى $L\hat{\beta}$ عند استخدام هذا النوع من النماذج حيث أن هذه الطريقة تحقق أقل قيم لتقدير التباين التقاربى.

المراجع:

1. Aini, Q. "Bivariate zero inflated generalized Poisson regression model in the number of pregnant maternal mortality and the number of postpartum maternal mortality in the Central Java Province in 2017." *In Journal of Physics: Conference Series* (Vol. 1511, No. 1, p. 012055). IOP Publishing, 2020.
2. Berliana, S, Purhad, Sutikno, and S Rahayu. "Multivariate generalized Poisson regression model with exposure and correlation as a function of covariates: Parameter estimation and hypothesis testing." *In AIP Conference Proceedings* (Vol. 2192, No. 1, p. 090001). AIP Publishing LLC, 2019, December.
3. Berndt, E.R., B.H. Hall, R.E. Hal, and Hausman. "Estimation and inference in nonlinear structural models." *In Annals of Economic and Social Measurement, Volume 3, number 4*, 1974: 653–665.
4. Carlstein , E. "The use of subseries values for estimating the variance of a general statistic from a stationary sequence." *Annals of Statistics* 14, 1986: 1171–1179.
5. Chan , K.S., and J. Ledolte. "Monte Carlo EM estimation for time series models involving counts." *Journal of the American Statistical Association*, 90(429), 1995: 242–252.

6. Cox , D.R. "Statistical analysis of time series: some recent developments." *Scandinavian Journal of Statistics* 8, 1981: 93–115.
7. Davis, R.A. , W.T.M. Dunsmuir, and Y. Wang,. "On autocorrelation in a Poisson regression model." *Biometrika* 87, 2000: 491–505.
8. Davis, R.A., and R. Wu. "A negative binomial model for time series of counts." *Biometrika* 96, 2009: 735–749.
9. Davis, R.A., W.T.M. Dunsmuir, and Y. Wang. "Modeling time series of count data, , 1999, pp." *in: S. Ghosh (Ed.), Asymptotics, Nonparametrics and Time Seriesc, MarcelDekker, New York*, 1999: 63–114.
10. Newey, W.K., and K.D. West. "A simple, positive semi-definite, heteroskedasticity and autocorrelation consistent covariance matrix." *Econometrica* 55, 1987: 703–708.
11. Safari, A., R.M. Altman, and B Leroux. "Parameter–driven models for time series of count data.." *arXiv preprint arXiv:1711.02753.*, 2017.
12. Wenur, G.H., and A. Suharsono. "Three–parameter bivariate gamma regression model for analyzing under–five mortality rate and maternal mortality rate." *In Journal of Physics: Conference Series (Vol. 1538, No. 1, p. 012054). IOP Publishing*, 2020.
13. Wu, R. "Estimation for Some Linear and Nonlinear Time Series Models." *ProQuest*, 2007.

14. Wu, R. "On variance estimation in a negative binomial time series regression model ." *Journal of Multivariate Analysis*, 112, 2012: 145–155.
15. Zeger , S.L. "A regression model for time series of counts." *Biometrika* 75, 1988: 621–629.