

## برآوردهای توانمند در مدل رگرسیون پواسون

سید امیررضا محمودی<sup>۱</sup>، روح‌الله روزگار<sup>۲</sup>

تاریخ دریافت: ۱۴۰۱/۰۷/۲۴

تاریخ پذیرش: ۱۴۰۲/۰۲/۲۲

### چکیده:

بسیاری از روش‌های برآوردیابی رگرسیونی در مواجهه با داده‌های پرت به شدت تحت تأثیر قرار می‌گیرند و خطاهای زیادی در برآوردهای حاصل از آن‌ها رخ می‌دهد. در سال‌های اخیر، برای حل این مشکل برآوردهایی توانمند توسعه یافته‌اند. برآوردگر حداقل واگرایی توان چگالی یک روش برآورد بر مبنای حداقل فاصله بین دو تابع چگالی است که این روش، در مواجهه با موقعیت‌هایی که داده‌ها شامل تعدادی داده پرت هستند برآوردهایی توانمند ارائه می‌دهد. در این پژوهش، روش برآوردگر توانمند حداقل واگرایی توان چگالی را برای برآورد پارامترهای مدل رگرسیون پواسون ارائه می‌کنیم که می‌تواند برآوردهای توانمند با کمترین نقصان در کارایی تولید کند. همچنین عملکرد برآوردهای پیشنهادی را از طریق ارائه مثال واقعی مورد بررسی قرار خواهیم داد.

**واژه‌های کلیدی:** برآوردگر حداقل واگرایی توان چگالی، پارامتر همسان‌ساز، توانمندی، داده پرت، رگرسیون پواسون، مدل خطی تعمیم یافته.

## ۱ مقدمه

توسعه یافته‌اند. در واقع توانمندی<sup>۵</sup> به معنای عدم حساسیت در برابر برخی انحرافات از مدل واقعی است. روش‌های توانمند در کارهای پیرسون، باکس و توکی (۱۹۶۰) و نظریه‌های رسمی‌تر در مورد توانمندی در دهه ۱۹۷۰ توسعه یافتند.

در مدل‌های رگرسیون، هدف روش‌های توانمند شناسایی نقاط پرت، نقاط بانفوذ<sup>۶</sup> و در نهایت توصیف بهترین برازش برای داده‌هاست. یکی از اولین گزینه‌های جایگزین برای روش پرکاربرد حداقل مربعات (LS)، به‌عنوان یک برآوردگر توانمند، توسط ادوورس (۱۸۸۷) پیشنهاد شد که برآوردگر حداقل انحراف مطلق<sup>۷</sup> (LAD) نامیده شد. نوآوری بعدی برآوردگر<sup>۸</sup>  $M$  هوبر<sup>۸</sup> (Huber(۱۹۷۳)Huber(۱۹۸۳)) [۱۲] و [۱۳] بود. سپس به‌منظور محدود کردن تأثیر نقاط بانفوذ بالا، برآوردهای نوع<sup>۹</sup>  $M$  تعمیم یافته به نام برآوردهای مالوز (۱۹۷۵) [۱۴] پیشنهاد شد. در این زمینه روسیو (۱۹۸۴) روش حداقل میانه مربع<sup>۹</sup> (LMS) را پیشنهاد کرد.

آمار علم ریاضی تفسیر و توضیح داده‌ها است و تحلیل‌های رگرسیونی یکی از مهم‌ترین ابزارهای کاربردی در علم آمار است. روش حداقل مربعات<sup>۳</sup> (LS) یکی از محبوب‌ترین برآوردهای رگرسیون است که در آثار گاوس و لژاندر معرفی شد (برای برخی از بحث‌های تاریخی به پلاکت (۱۹۷۲)، استیگلر (۱۹۸۱) و استیگلر (۱۹۸۶) مراجعه کنید). روش LS که مربوط به بهینه‌سازی برازش با به حداقل رساندن مجموع مربعات باقیمانده است، به دلیل سهولت محاسبه آن پذیرفته شده است. اما وجود مشاهدات پرت، هم در متغیرهای وابسته و هم در متغیرهای توضیحی، می‌تواند بر روی برآوردهای LS تأثیر زیادی داشته باشد. در یک قرن گذشته حجم وسیعی از مقالات در مورد داده‌های پرت<sup>۴</sup> و خطرات آن‌ها برای روش‌های آماری کلاسیک ارائه شده است. برای حل این مشکل، تکنیک‌های جدید آماری مانند روش‌های توانمند

<sup>۱</sup>دانش‌آموخته کارشناسی ارشد رشته آمار، گروه ریاضی، دانشگاه یاسوج

<sup>۲</sup> هیئت علمی گروه ریاضی، دانشگاه یاسوج (نویسنده مسئول: roozegar@yu.ac.ir)

<sup>۳</sup>Least Squares

<sup>۴</sup>outliers

<sup>۵</sup>Robustness

<sup>۶</sup>leverage points

<sup>۷</sup>Least Absolute Deviation

<sup>۸</sup>Huber's M-estimator

<sup>۹</sup>Least Median Squared

جدول نیز برای فهم و درک بهتر مفاهیم ارائه شده است.

## ۲ تعاریف، فرضیات و قضایا

مواردی پیش می‌آید که ارتباط بین متغیر پاسخ و متغیر توضیحی خطی نیست و یا متغیرهای پاسخ پیوسته نمی‌باشند و یا ممکن است که توزیع متغیر پاسخ نرمال نباشد. در چنین مواقعی مدل خطی تعمیم‌یافته  $(GLM)$ <sup>۱۵</sup> می‌تواند به عنوان یک ابزار کلی و بسیار مهم راهگشا باشد.  $GLM$  به آزمایشگر اجازه می‌دهد تا متغیرهای پاسخ با هر توزیعی از میان خانواده توزیع‌های نمایی را با هر ترکیب خطی از متغیرهای توضیحی مدل‌سازی کند.

مدل‌های خطی تعمیم‌یافته همان‌طور که از اسم آن‌ها پیداست تعمیمی از مدل‌های خطی می‌باشند. مدل‌های خطی در مواقعی که متغیر پاسخ  $(Y_i)$  پیوسته یا نزدیک به توزیع نرمال باشند، به فرم زیر خواهند بود:

$$E(Y_i) = \mu_i = x_i^T \beta; \quad Y_i \sim N(\mu_i, \sigma^2) \quad (1)$$

مدل‌های خطی به فرم بالا که در آن متغیرهای تصادفی  $Y_i$  مستقل هستند، اساس اکثر تحلیل‌های داده‌های پیوسته هستند. متغیرهای تصادفی  $Y_i$  برای موضوعات مختلف، ممکن است مقادیر مورد انتظار  $\mu_i$  متفاوتی داشته باشد. بردار  $x_i^T$  نشان‌دهنده ردیف  $i$ -ام ماتریس طرح  $X$  است.

پیشرفت‌ها در تئوری آماری و نرم‌افزار رایانه‌ای به ما امکان می‌دهد از روش‌هایی مشابه روش‌های توسعه‌یافته برای مدل‌های خطی در موقعیت‌های کلی‌تر زیر استفاده کنیم:

۱- متغیرهای پاسخ دارای توزیعی غیر از توزیع نرمال باشند و حتی ممکن است به جای پیوسته، گروه‌بندی باشند.

۲- رابطه بین متغیر پاسخ و متغیرهای توضیحی به فرم خطی ساده در ۱ نباشد.

در مواقعی که متغیر پاسخ  $(Y_i)$  جزء خانواده نمایی باشد با مدل‌های غیرخطی سروکار داریم که بین متغیر پاسخ و توضیحی رابطه مستقیم خطی وجود ندارد. بلکه پس از اعمال تابع پیوندی مانند  $g$  روی میانگین متغیر پاسخ، رابطه خطی به صورت زیر به دست می‌آید:

$$g(\mu_i) = x_i^T \beta$$

روش‌های توانمند برآورد پارامترهای مدل خطی تعمیم‌یافته در سال‌های اخیر مورد توجه برخی از پژوهشگران قرار گرفته است. در این مورد کانتونی و رانچتی (۲۰۰۱) روش توانمند برآورد شبه-درست‌نمایی هویر<sup>۱۰</sup>  $(HQ - LE)$  و حسینیان (۲۰۰۹) [۱۱] روش توانمند برآورد ماکسیمم درست‌نمایی وزنی<sup>۱۱</sup>  $(WMLE)$  را برای برآورد پارامترهای مدل خطی تعمیم‌یافته ارائه داده‌اند. دوریو و ایسایا [۸] از این روش در برآورد توانمند مدل رگرسیون خطی استفاده کردند. یکی از حالت‌های خاص مدل‌های خطی تعمیم‌یافته مدل رگرسیون پواسون است. در این زمینه هال و شن (۲۰۱۰) [۱۰]، ابونازل و صابر (۲۰۲۰) [۱]، ابونازل و داوود (۲۰۲۲) [۲]، امین و همکاران (۲۰۲۱) [۳]، چن و همکاران (۲۰۱۸) [۷] و شان تسو (۲۰۰۵) [۱۷] سعی کردند از روش‌های توانمندی برای برآورد پارامترهای مدل رگرسیون پواسون استفاده کنند؛ اما نکته حائز اهمیت این است که توانمندی تنها معیار بهینه در برآورد پارامترها نمی‌باشد بلکه برآوردگری مناسب است که در عین توانمندی کارایی مناسبی نیز داشته باشد. در این مقاله سعی داریم با روش مبتنی بر حداقل و اگرایی توان چگالی، برآوردگرهایی توانمند و درعین حال کارا برای پارامترهای مدل رگرسیون پواسون ارائه کنیم. خانواده فواصل مبتنی بر چگالی که به نام و اگرایی توان چگالی معروف است برای اولین بار توسط باسو و همکاران [۴] در سال ۱۹۹۸ معرفی شد. برای آشنایی بیشتر با این خانواده فواصل مبتنی بر چگالی می‌توان به کارهای باسو [۴]، سیمپسون [۱۵] و بران [۵] مراجعه کرد. این خانواده به پارامتر همسان‌ساز و نامنفی  $\alpha$  وابسته است که این پارامتر تعادل بین کارایی<sup>۱۲</sup> و توانمندی را در این خانواده برقرار می‌کند. لذا اهمیت و مزیت مدلی که در این مقاله معرفی می‌شود نسبت به مدل‌های توانمند اشاره شده در بالا، کارایی مناسب در عین توانمندی است.

در ادامه تعریف جامعی از روش برآوردگر حداقل و اگرایی توان چگالی  $(MDPDE)$ <sup>۱۳</sup> ارائه می‌دهیم، سپس از این روش در برآورد پارامترهای مدل رگرسیون پواسون<sup>۱۴</sup> استفاده می‌کنیم و نشان می‌دهیم که این روش دارای خصوصیات مناسبی از جمله توانمندی و کارایی است. سپس عملکرد  $MDPDE$ ‌های پیشنهادی را در مدل رگرسیون پواسون با اعمال آن بر روی یک مجموعه داده واقعی بررسی خواهیم کرد و نشان خواهیم داد که برآوردهای حاصل از این روش در مقابل مشاهدات پرت و دارای نفوذ، توانمند بوده و کارایی قابل قبولی دارند. چندین نمودار و

<sup>10</sup>Huber Quasi-Likelihood Estimate

<sup>11</sup>Weighted Maximum Likelihood Estimate

<sup>12</sup>Efficiency

<sup>13</sup> Minimum Density Power Divergence Estimator

<sup>14</sup> Poisson Regression

<sup>15</sup>Generalized Linear Model

تابع  $g$ ، تابع پیوند نامیده می‌شود که یک تابع ریاضی ساده است.

## ۱۰۲ مدل‌های خطی تعمیم‌یافته

وحدت بسیاری از روش‌های آماری توسط نلدر و ودربورن (۱۹۷۲) با استفاده از ایده یک مدل خطی تعمیم‌یافته نشان داده شد. این مدل بر اساس مجموعه‌ای از متغیرهای تصادفی مستقل  $Y_1, \dots, Y_N$  تعریف شده که هر کدام از  $Y_i$  ها عضو خانواده توزیع‌های نمایی است. ویژگی‌های مدل به صورت زیر است:

۱- توزیع هر کدام از  $Y_i$  ها به فرم کانونی بوده و تنها به پارامتر  $\theta_i$  بستگی دارد، بنابراین

$$f(y_i; \theta_i) = \exp[y_i b_i(\theta_i) + c_i(\theta_i) + d_i(y_i)].$$

۲- توزیع تمام  $Y_i$  ها یکسان بوده و تابع چگالی احتمال توأم از  $Y_1, \dots, Y_N$  به صورت زیر است

$$f(y_1, \dots, y_N; \theta_1, \dots, \theta_N) = \prod_{i=1}^N \exp[y_i b_i(\theta_i) + c_i(\theta_i) + d_i(y_i)] \\ = \exp \left[ \sum_{i=1}^N y_i b_i(\theta_i) + \sum_{i=1}^N c_i(\theta_i) + \sum_{i=1}^N d_i(y_i) \right] \quad (2)$$

فرض کنید  $E(Y_i) = \mu_i$ ، به طوری که  $\mu_i$  تابعی از  $\theta_i$  است. برای یک مدل خطی تعمیم‌یافته تبدیلی از  $\mu_i$  مانند زیر وجود دارد

$$g(\mu_i) = x_i^T \beta.$$

در این رابطه برای  $i = 1, \dots, N$  داریم:

الف. تابع پیوند  $g$  یک تابع یکنوا و دیفرانسیل پذیر است.

ب. بردار  $x_i$  یک بردار  $1 \times p$  از متغیرهای توضیحی است.

ج.  $\beta$  بردار  $1 \times p$  از پارامترهاست. بردار  $x_i^T$  ردیف  $i$  ام از ماتریس طرح  $X$  است.

د. متغیرهای پاسخ  $Y_1, \dots, Y_N$  توزیع یکسانی از خانواده نمایی دارند.

در مدل‌های خطی تعمیم‌یافته (GLM) با انتخاب چگالی‌های گوناگون از خانواده نمایی به جای  $f$  و تابع پیوندهای گوناگون  $g$ ، مدل‌های رگرسیون متفاوتی به دست می‌آید. به عنوان مثال اگر  $f$  چگالی نرمال و  $g$  تابع پیوند همانی انتخاب شوند، مدل خطی تعمیم‌یافته به مدل رگرسیون خطی نرمال معمولی تنزل می‌یابد و یا اگر  $f$  چگالی پواسون و  $g$  تابع پیوند لگاریتمی  $g(\mu) = \log(\mu)$  انتخاب شوند، حالت رگرسیون پواسون به دست می‌آید که در مدل‌سازی داده‌های شمارش پذیر

استفاده می‌شود. اگر  $f$  چگالی دوجمله‌ای و تابع پیوند لجیت<sup>۱۶</sup>  $g(\mu) = \log(\mu/(1-\mu))$  یا تابع پیوند پروبیت<sup>۱۷</sup>  $g(\mu) = \Phi^{-1}(\mu)$  انتخاب شوند آنگاه به ترتیب به ترتیب مدل‌های رگرسیون لجستیک و پروبیت را تولید می‌کنند به طوری که برای مدل‌سازی متغیرهای پاسخ دو دویی استفاده می‌شوند.

یک حالت بسیار پرکاربرد از مدل‌های خطی تعمیم‌یافته رگرسیون پواسون می‌باشد که آن را به طور مفصل مورد بررسی قرار می‌دهیم. روش معمول در برآورد پارامترهای مدل رگرسیون خطی تعمیم‌یافته روش درست‌نمایی ماکسیم (MLE) و روش حداقل مربعات (LS) می‌باشد؛ اما این روش‌های کلاسیک به وجود داده پرت در مجموعه داده‌ها حساس بوده و برآوردهای ارائه شده توسط این روش‌ها تحت تأثیر داده‌های پرت به شدت از مقدار صحیح خود فاصله می‌گیرند که در اصطلاح می‌گوییم این روش‌ها توانمند نیستند؛ بنابراین ارائه روش‌های توانمند بسیار ضرورت دارد. در این مقاله از روش برآوردگر حداقل واگرایی توان چگالی (MDPDE) در برآورد پارامترهای مدل خطی تعمیم‌یافته به طور عام و مدل رگرسیون پواسون به طور خاص استفاده می‌کنیم.

## ۲۰۲ اندازه واگرایی توان چگالی

به طور کلی در استنباط بر اساس حداقل فاصله، برآورد پارامتر مورد نظر خود را به وسیله مینیم کردن یک اندازه مناسب از فاصله بین داده‌ها و مدل پارامتری فرض شده (پیشنهاد شده) به دست می‌آوریم.

تعریف ۱۰۲. (باسو و همکاران) [۴] و گوش و باسو [۹] اگر  $X_1, X_2, \dots, X_n$  نمونه‌ای تصادفی به حجم  $n$  از تابع چگالی واقعی  $g$  باشد که  $g$  ناشناخته باشد و بخواهیم این تابع چگالی را با تابع چگالی  $f$  برآورد کنیم، آنگاه اندازه واگرایی توان چگالی (DPD)<sup>۱۸</sup> بین دو تابع توزیع  $g$  و  $f$  که با نماد  $d_\alpha(g, f)$  نشان داده می‌شود به صورت زیر تعریف می‌شود.

برای حالت  $\alpha > 0$ :

$$d_\alpha(g, f) = \int \{f^{1+\alpha}(x; \theta) - (\frac{1+\alpha}{\alpha})f^\alpha(x; \theta)g(x) + \frac{1}{\alpha}g^{1+\alpha}(x)\}d(x) \quad (3)$$

و برای حالت  $\alpha = 0$ :

$$d_0(g, f) = \lim_{\alpha \rightarrow 0} d_\alpha(g, f) = \int g(x) \log\left(\frac{g(x)}{f(x)}\right)d(x) \quad (4)$$

<sup>16</sup> Logit link function

<sup>17</sup> Probit link function

<sup>18</sup> Density Power Divergence

چگالی بردار پارامتری  $\theta$  برای یک نمونه مستقل و هم‌توزیع را از رابطه زیر محاسبه کنیم:

$$\frac{1}{n} \sum_{i=1}^n u_{\theta}(X_i) f_{\theta}^{\alpha}(X_i) - \int u_{\theta}(x) f_{\theta}^{1+\alpha}(x) d(x) = 0.$$

تذکر ۴.۲. معادله برآوردیابی که در قضیه ۳.۲ آمده، در حقیقت یک مدل وزنی از معادله حداکثر درستنمایی است، به این صورت که برای تمامی  $\alpha > 0$  این معادله به مشاهدات پرت وزن پایین‌تری نسبت به مدل و به مشاهداتی که به مدل مفروض نزدیک‌تر باشند وزن بالاتری اختصاص می‌دهد. در مقابل در حالتی که  $\alpha = 0$  باشد، این معادله به تمام مشاهدات، حتی مشاهداتی که آن‌ها را به‌عنوان داده پرت می‌شناسیم وزنی برابر یک اختصاص می‌دهد؛ بنابراین با انتخاب  $\alpha$  نزدیک به صفر، می‌توانیم وزن تمامی مشاهدات را نزدیک به یک بگیریم که این کار باعث بهبود کارایی مجانبی برآوردگر در مقایسه با روش حداقل فاصله می‌شود. از طرف دیگر هر چه  $\alpha$  به یک نزدیک‌تر باشد، توانمندی این برآوردگر در مواجهه با داده‌های پرت افزایش پیدا می‌کند. نکته‌های گفته‌شده دقیقاً به برقراری توازن بین کارایی و توانمندی برآوردگر توسط پارامتر همسان‌ساز  $\alpha$  اشاره دارد.

## ۴.۲ برآوردگر حداقل و آگرایی توان چگالی برای مشاهدات مستقل و غیرهم‌توزیع

گاهی با مواردی روبه‌رو می‌شویم که مشاهدات ما اگرچه از هم مستقل هستند ولی توزیع‌های متفاوتی دارند.

فرض کنید که داده‌های مشاهده‌شده ما به صورت  $Y_1, \dots, Y_n$  باشند که از هم مستقل بوده اما برای هر  $i = 1, \dots, n$ ،  $Y_i \sim g_i$  باشد؛ یعنی هر یک از نقاط  $Y_i$ ، متعلق به توابع چگالی جداگانه به صورت  $g_1, \dots, g_n$  است؛ بنابراین برای پیش‌بینی هر  $g_i$  از مدل  $f_i$  و  $i = 1, \dots, n$  متعلق به خانواده توابع چگالی  $F_{i,\theta} = f_i(\cdot; \theta) \mid \theta \in \Theta$  استفاده می‌کنیم. این توابع اگرچه ممکن است توزیع‌های متفاوتی داشته باشند ولی همگی آن‌ها در بردار پارامتری  $\theta$  مشترک هستند. هدف اصلی ما برآورد کردن بردار پارامتری  $\theta$  با استفاده از به حداقل رساندن اختلاف توان چگالی بین داده‌ها و مدل در نظر گرفته‌شده است.

در عمل،  $g$  توزیع داده‌ها و  $f$  توزیع مدل است (که وابسته به پارامتر مجهول است). این اندازه (تابع) تنها به همان پارامتر همسان‌ساز  $\alpha$  بستگی دارد. تابع  $d_{\alpha}(g, f)$  یک اندازه است. بدین معنا که این عبارت همواره غیر منفی است و زمانی صفر می‌شود که  $f \equiv g$  باشد.

فرض کنید که بخواهیم بردار پارامتری  $\theta$  را برآورد کنیم. همچنین فرض کنید

$$\{f_{\theta} : \theta \in \Theta \subseteq R^p\}$$

خانواده پارامتری از توابع و  $G$  تابع توزیع متناظر با تابع چگالی  $g$  باشد و  $g \in G$  که  $G$  کلاس تمام توزیع‌ها با تکیه‌گاه یکسان است. حال اگر برآوردگر مورد نظر یا همان برآوردگر و آگرایی توان چگالی بردار پارامتری  $\theta$  را به وسیله  $T_{\alpha}(G)$  نشان دهیم، آنگاه خواهیم داشت:

$$d_{\alpha}(g, f_{T_{\alpha}(G)}) = \min_{\theta \in \Theta} d_{\alpha}(g, f_{\theta})$$

مفهوم این رابطه این است که اگر  $g$  تابع چگالی صحیح ما باشد، آنگاه از بین فضای پارامتری مربوط به  $\theta$ ، توسط برآوردگر حداقل و آگرایی توان چگالی آن بردار عددی را انتخاب می‌کنیم که فاصله بین تابع چگالی صحیح ( $g$ ) و تابع چگالی برآورد شده توسط برآوردگر حداقل و آگرایی توان چگالی ( $f_{T_{\alpha}(G)}$ ) کمترین فاصله را داشته باشد.

## ۳.۲ برآوردگر حداقل و آگرایی توان چگالی برای مشاهدات مستقل و هم‌توزیع

در قضیه‌های زیر به محاسبه برآورد حداقل و آگرایی توان چگالی، زمانی که از یک نمونه مستقل و هم‌توزیع استفاده کنیم می‌پردازیم.

قضیه ۲.۲. (گوش و باسو (۲۰۱۳) [۹]) خانواده توابع چگالی:  $\{f_{\theta} : \theta \in \Theta\}$  را در نظر بگیریم و همچنین اگر فرض کنیم  $X_1, \dots, X_n$  یک نمونه تصادفی از توزیع  $G$  باشد و  $d_{\alpha}(g, f)$  به صورتی که در قبل توضیح داده‌ایم باشد. در این صورت با استفاده از روش گوش و باسو (۲۰۱۳) [۹] برآوردگر حداقل و آگرایی توان چگالی بردار پارامتری  $\theta$  از مینیمم کردن عبارت زیر حاصل می‌شود:

$$\begin{aligned} H_{\alpha}(\theta) &= \int f_{\theta}^{1+\alpha}(x) d(x) - (1 + \frac{1}{\alpha}) \frac{1}{n} \sum_{i=1}^n f_{\theta}^{\alpha}(X_i) \\ &= \frac{1}{n} \sum_{i=1}^n V_{n,\theta}(X_i) \end{aligned}$$

به‌طوری‌که  $V_{n,\theta}(X) = \int f_{\theta}^{1+\alpha}(x) d(x) - (1 + \frac{1}{\alpha}) f_{\theta}^{\alpha}(X)$

قضیه ۳.۲. (گوش و باسو [۹]) اگر  $u_{\theta}(x) = \frac{\partial}{\partial \theta} \log f_{\theta}(x)$  آنگاه تحت شرایط مشتق‌پذیری مدل، می‌توانیم برآورد حداقل و آگرایی توان

شرایط مشتق پذیری مدل، برآوردگر حداقل و اگرایی توان چگالی پارامتر  $\theta$  را به روش باسو می توان از عبارت زیر محاسبه کرد:

$$\sum_{i=1}^n \{f_i(Y_i; \theta)^\alpha u_i(Y_i; \theta) - \int f_i(y; \theta)^{1+\alpha} u_i(y; \theta) dy\} = 0 \quad (7)$$

$$u_i(y; \theta) = \frac{\partial}{\partial \theta} \log f_i(y; \theta)$$

تذکر ۶.۲. اگر  $\alpha \rightarrow 0$  بنابراین برای به دست آوردن برآورد پارامتر  $\theta$  در حالتی که مشاهدات مستقل و غیرهم توزیع باشند کافی است تابع هدف زیر را مینیم کنیم:

$$\frac{1}{n} \sum_{i=1}^n \{-\ln(f_i(Y_i; \theta))\}.$$

ملاحظه می کنید که عبارت به دست آمده همان برآوردگر ماکسیم درستنمایی است؛ بنابراین نتیجه می گیریم برآوردگر حداقل و اگرایی توان چگالی زمانی که  $\alpha = 0$  باشد معادل با برآوردگر ماکسیم درستنمایی است؛ بنابراین معادله برآوردی  $\gamma$  یک تعمیم ساده از برآوردگر ماکسیم درستنمایی می باشد.

تذکر ۷.۲. به طور کلی برآوردگر حداقل و اگرایی توان چگالی  $T_\alpha(G_1, \dots, G_n)$  برای مشاهدات مستقل ولی غیرهمگن، آن برآوردگری است که در عبارت زیر صدق کند

$$\begin{aligned} & \frac{1}{n} \sum_{i=1}^n d_\alpha(g_i(\cdot), f_i(\cdot; T_\alpha(G_1, \dots, G_n))) \\ &= \min_{\theta \in \Theta} \frac{1}{n} \sum_{i=1}^n d_\alpha(g_i(\cdot), f_i(\cdot; \theta)) \end{aligned} \quad (8)$$

یعنی برآوردگر حداقل و اگرایی توان چگالی آن مقداری از پارامتر  $\theta$  در فضای پارامتری  $\Theta$  است که به ازای آن میانگین تمام فواصل بین  $g_i$  و  $f_i$  ها حداقل شود.

## ۵.۲ برآوردگر حداقل و اگرایی توان چگالی برای مدل های خطی تعمیم یافته

### ۱.۵.۲ تعریف مدل خطی تعمیم یافته:

گویم  $n$  متغیر مستقل  $Y_1, \dots, Y_n$  از مدل خطی تعمیم یافته تبعیت می کند هرگاه تابع چگالی این متغیرها از فرم نمایی تعمیم یافته به صورت زیر پیروی کند

$$f(y_i; \theta_i, \phi) = \exp \left\{ \frac{y_i \theta_i - b(\theta_i)}{a(\phi)} + c(y_i, \phi) \right\} \quad (9)$$

وقتی که پارامتر کانونی  $\theta_i$  (پارامتر مکان) وابسته به متغیرهای مستقل  $X_i$  باشد و  $\phi_i$  نیز به عنوان پارامتر مزاحم باشد. همچنین میانگین

## ۱.۴.۲ روش باسو وقتی مشاهدات مستقل و غیرهم توزیع باشند

در این حالت چگالی مدل  $f_i$  و توزیع واقعی  $g_i$  برای هر نقطه متفاوت است، بنابراین برای برآورد پارامتر مورد نظر ما باید اختلاف بین داده ها و مدل را به طور جداگانه برای هر نقطه محاسبه کرده و سپس سعی کنیم میانگین تمامی این فواصل را مینیم کنیم. به عبارت دیگر اگر فاصله بین چگالی واقعی  $g_i$  و مدل  $f_i$  را با  $d_\alpha(g_i, f_i(y; \theta))$  نشان دهیم داریم:

$$d_\alpha(g_i, f_i(y; \theta)) = \int \{f_i^{1+\alpha}(y; \theta) - (1 + \frac{1}{\alpha}) f_i^\alpha(y; \theta) g_i + \frac{1}{\alpha} g_i^{1+\alpha}\}$$

که عبارت سومی مستقل از پارامتر  $\theta$  بوده و در فرایند مینیم سازی تأثیری ندارد. چون در بیشتر موارد چگالی واقعی  $g_i$  ناشناخته است، در محاسبات خود از برآورد آن استفاده می کنیم. اگر  $d_\alpha(\hat{g}_i, f_i(\cdot; \theta))$  را به عنوان فاصله بین  $i$  امین  $\hat{g}_i$  و چگالی مدل  $f_i$  تعریف کنیم، می توانیم برای به حداقل رساندن تمام فواصل بالا به ازای  $i = 1, \dots, n$  با به حداقل رساندن

$$\frac{1}{n} \sum_{i=1}^n d_\alpha(\hat{g}_i, f_i(\cdot; \theta)), \theta \in \Theta$$

به هدف خود برسیم؛ اما برای برآورد کردن چگالی واقعی داده ها معمولاً از چگالی تجربی استفاده می کنیم. در چگالی تجربی به هر نقطه احتمال  $\frac{1}{n}$  اختصاص داده می شود و چون در این حالت از هر تابع چگالی واقعی  $g_i$ ، تنها یک نقطه  $Y_i$  در دسترس داریم بنابراین بهترین تخمین ممکن چگالی  $g_i$  توزیع تباهیده شده در نقطه  $Y_i$  است و داریم:

$$\begin{aligned} d_\alpha(\hat{g}_i, f_i(\cdot; \theta)) &= \int f_i(y; \theta)^{1+\alpha} dy \\ &\quad - (1 + \frac{1}{\alpha}) f_i(Y_i; \theta)^\alpha + K \end{aligned} \quad (5)$$

که  $K$  یک ثابت و مستقل از پارامتر  $\theta$  است؛ بنابراین برای برآورد کردن پارامتر  $\theta$  از روش حداقل و اگرایی توان چگالی به روش باسو برای مشاهدات مستقل و غیرهم توزیع باید تابع هدف زیر را به حداقل برسانیم.

$$\begin{aligned} H_n(\theta) &= \frac{1}{n} \sum_{i=1}^n \{ \int f_i(y; \theta)^{1+\alpha} dy - (1 + \frac{1}{\alpha}) f_i(Y_i; \theta)^\alpha \} \\ &= \frac{1}{n} \sum_{i=1}^n V_i(Y_i; \theta) \end{aligned} \quad (6)$$

به طوری که  $V_i(Y_i, \theta) = \int f_i^{1+\alpha}(y; \theta) dy - (1 + \frac{1}{\alpha}) f_i(Y_i; \theta)^\alpha$  است.

نتیجه ۵.۲. اگر فرض کنیم  $Y_1, \dots, Y_n$  یک نمونه تصادفی مستقل و غیرهم توزیع باشد به طوری که  $Y_i \sim g_i$ ،  $i = 1, \dots, n$ ، آنگاه تحت

مشتق‌گیری به صورت زیر محاسبه می‌کنیم:

$$\nabla_{\beta} \log(f_i(y_i; (\beta, \phi))) = \frac{(y_i - \mu_i)}{\text{Var}(Y_i)g'(\mu_i)} x_i = K_{1i}(y_i; (\beta, \phi)) x_i, \quad (14)$$

$$\begin{aligned} \nabla_{\phi} \log(f_i(y_i; (\beta, \phi))) &= -\frac{(y_i \theta_i - b(\theta_i))}{a'(\phi)} a'(\phi) + \frac{\partial}{\partial \phi} c(y_i, \phi) \\ &= K_{2i}(y_i; (\beta, \phi)) \end{aligned} \quad (15)$$

به طوری که  $K_{1i}$  و  $K_{2i}$  توابع نشانگر هستند؛ بنابراین با جایگذاری روابط ۱۴ و ۱۵ در رابطه‌ی ۱۳ معادلات برآوردی به صورت زیر می‌شوند:

$$\sum_{i=1}^n x_i \left[ \int K_{1i}(y; (\beta, \phi)) f_i(y; (\beta, \phi))^{1+\alpha} dy - K_{1i}(y_i; (\beta, \phi)) f_i(y_i; (\beta, \phi))^{\alpha} \right] = 0 \quad (16)$$

$$\sum_{i=1}^n \left[ \int K_{2i}(y; (\beta, \phi)) f_i(y; (\beta, \phi))^{1+\alpha} dy - K_{2i}(y_i; (\beta, \phi)) f_i(y_i; (\beta, \phi))^{\alpha} \right] = 0 \quad (17)$$

اگر بخواهیم که پارامتر  $\beta$  را با ثابت در نظر گرفتن  $\phi$  برآورد کنیم، کافی است تا فقط معادله برآوردی ۱۶ در نظر گرفته شود. به علاوه برای حالتی که  $\alpha = 0$  باشد قسمت اول رابطه ۱۶ برابر صفر خواهد بود، یعنی داریم:

$$\begin{aligned} &\int \frac{(y - \mu_i)}{\text{Var}(y)g'(\mu_i)} x_i f_i(y; (\beta, \phi))^{1+\alpha} dy \\ &= \frac{x_i}{\text{Var}(y)g'(\mu_i)} \left[ \int (y - \mu_i) f_i(y; (\beta, \phi))^{1+\alpha} dy \right] \\ &= \frac{x_i}{\text{Var}(y)g'(\mu_i)} \left[ \int y f_i(y; (\beta, \phi)) dy - \mu_i \int f_i(y; (\beta, \phi)) dy \right] \\ &= \frac{x_i}{\text{Var}(y)g'(\mu_i)} (E(Y) - \mu_i) \\ &= \frac{x_i}{\text{Var}(y)g'(\mu_i)} (\mu_i - \mu_i) = 0 \end{aligned} \quad (18)$$

و معادلات برآوردی برای  $\beta$  (با نادیده گرفتن  $\phi$ ) به صورت زیر ساده می‌شود:

$$\sum_{i=1}^n \frac{(Y_i - \mu_i)}{\text{Var}(Y_i)g'(\mu_i)} x_i = 0 \quad (19)$$

برآوردگر حداقل واگرایی توان چگالی زمانی که  $\alpha = 0$  باشد معادل با برآوردگر ماکسیم درست‌نمایی است؛ بنابراین معادله برآوردی ۱۳ یک تعمیم ساده از برآوردگر ماکسیم درست‌نمایی می‌باشد. همچنین اگر چگالی  $f$  به صورت  $\int f(y; (\theta_i, \phi))^{1+\alpha} dy$  باشد که از پارامتر مکانی  $\theta_i$  مستقل است، مانند چگالی توزیع نرمال، آنگاه داریم:

$$\int \frac{(y_i - \mu_i)}{\text{Var}(y_i)g'(\mu_i)} x_i f_i(y_i; (\beta, \phi))^{1+\alpha} dy = 0$$

متغیرهای  $Y_i$  یعنی  $\mu_i$  برابر باشد با  $\eta_i = x_i^T \beta$  به طوری که  $g(\mu_i)$  تابع پیوند و یک تابع یکنوا و مشتق‌پذیر باشد. پس ما مجموعه‌ای از مشاهدات مستقل و غیر هم‌توزیع  $y_1, \dots, y_n$  داریم که برای  $i = 1, \dots, n$  دارای چگالی

$$f_i(\cdot; (\beta, \phi)) = f(y_i; \theta_i, \phi) \quad (10)$$

است. هدف ما برآورد بردار پارامتری  $\theta = (\beta, \phi)$  است؛ بنابراین بر اساس مشاهدات بالا و با استفاده از روش باسو کافی است در رابطه شماره ۶ به جای  $f$  تابع چگالی ۱۰ و به جای بردار  $\theta$  پارامترهای  $(\beta, \phi)$  را قرار داده تا برای مشاهدات مستقل و غیر هم‌توزیع، برآوردگر  $MDPDE$  را به دست آوریم. از این رو برای مشاهدات مستقل و غیر هم‌توزیع، برآوردگر حداقل واگرایی توان چگالی ( $MDPDE$ ) مربوط به مدل خطی تعمیم‌یافته برای پارامترهای  $(\beta, \phi)$  با مینیم سازی عبارت زیر به دست می‌آید:

$$H_n(\beta, \phi) = \frac{1}{n} \sum_{i=1}^n V_i(Y_i; (\beta, \phi)) \quad (11)$$

به طوری که

$$V_i(Y_i; (\beta, \phi)) = \int f_i^{1+\alpha}(y; (\beta, \phi)) dy - (1 + \frac{1}{\alpha}) f_i^{\alpha}(Y_i; (\beta, \phi)).$$

در برآورد حداقل  $DPD$  پیشنهادی، به طور هم‌زمان پارامترهای  $\beta$  و  $\phi$  را فقط با به حداقل رساندن  $H_n(\beta, \phi)$  با توجه به هر دو پارامتر به صورت توانمند برآورد می‌کنیم.

نتیجه ۸.۲. با توجه به نتیجه ۵.۲ تحت شرایط مشتق‌پذیری مدل، با جایگذاری پارامترهای  $(\beta, \phi)$  به جای بردار  $\theta$ ، برآوردگر حداقل واگرایی توان چگالی پارامترهای  $\beta$  و  $\phi$  را به روش باسو می‌توان از حل عبارت‌های زیر به دست آورد:

$$\sum_{i=1}^n \nabla V_i(Y_i; (\beta, \phi)) = 0, \quad (12)$$

یا

$$\begin{aligned} &\sum_{i=1}^n \left[ \int u_i(y; (\beta, \phi)) f_i(y; (\beta, \phi))^{1+\alpha} dy \right. \\ &\quad \left. - u_i(Y_i; (\beta, \phi)) f_i(Y_i; (\beta, \phi))^{\alpha} \right] = 0 \end{aligned} \quad (13)$$

به طوری که  $u_i(y; (\beta, \phi)) = \nabla \log f_i(y; (\beta, \phi))$

لازم است بدانیم که  $\nabla$  مشتق را با توجه به  $(\beta, \phi)$  نشان می‌دهد. مشتقات جزئی  $\nabla_{\beta}$  و  $\nabla_{\phi}$  را با استفاده از قانون زنجیره‌ای برای

لم ۰۹۰۲. اگر فرض کنیم  $Y_1, \dots, Y_n$  یک نمونه تصادفی مستقل و غیر هم توزیع باشد به طوری که  $Y_i \sim g_i$  و  $i = 1, \dots, n$  آنگاه، با توجه به تعاریف بالا، برای این نمونه مستقل و غیرهمگن مقادیر  $\Omega_n$  و  $\Psi_n$  به صورت زیر به دست می آید:

$$\begin{aligned} \Psi_n(\beta, \phi) &= \frac{1}{n} \sum_{i=1}^n M_i^{1+\alpha}(\beta, \phi) \\ &= \frac{1}{n} \begin{pmatrix} X^T \Gamma_{11}^{(\alpha)} X & X^T \Gamma_{12}^{(\alpha)} \mathbf{1} \\ \mathbf{1}^T \Gamma_{12}^{(\alpha)} X & \mathbf{1}^T \Gamma_{22}^{(\alpha)} \mathbf{1} \end{pmatrix}; \end{aligned} \quad (23)$$

$$\begin{aligned} \Omega_n(\beta, \phi) &= \frac{1}{n} \sum_{i=1}^n [M_i^{1+\alpha}(\beta, \phi) - N_i^{1+\alpha}(\beta, \phi)(N_i^{1+\alpha}(\beta, \phi))^T] \\ &= \frac{1}{n} \begin{pmatrix} X^T [\Gamma_{11}^{(\alpha)} - (\Gamma_{11}^{(\alpha)})^T \Gamma_{12}^{(\alpha)}] X & X^T [\Gamma_{12}^{(\alpha)} - \Gamma_{11}^{(\alpha)} \Gamma_{22}^{(\alpha)}] \mathbf{1} \\ \mathbf{1}^T [\Gamma_{12}^{(\alpha)} - \Gamma_{11}^{(\alpha)} \Gamma_{22}^{(\alpha)}] X & \mathbf{1}^T [\Gamma_{22}^{(\alpha)} - (\Gamma_{22}^{(\alpha)})^T \Gamma_{12}^{(\alpha)}] \mathbf{1} \end{pmatrix}. \end{aligned} \quad (24)$$

که در اینجا  $\mathbf{1}$  یک بردار  $n$  بعدی با عناصر  $\mathbf{1}$  و به صورت  $\mathbf{1}^T = [1, \dots, 1]$  است.

اثبات. مقادیر  $\Psi_n$  و  $\Omega_n$  با جایگذاری  $M_i^{1+\alpha}$  ها و  $N_i^{1+\alpha}$  ها با روابط و تعاریف متناظر آن ها و انجام محاسبات جبری ساده به دست می آید.  $\square$

با توجه به مقدمات بالا و با استفاده از مفروضات ۷ گانه که در گوش باسو (۲۰۱۳) [۹] ارائه شده، در زیر به خواص مجانبی برآوردگر حداقل و اگرایی توان چگالی برای مشاهدات مستقل و غیرهمگن می پردازیم.

## ۱۰۶۰۲ خواص مجانبی برآوردگر حداقل و اگرایی توان چگالی برای مشاهدات مستقل و غیرهم توزیع

قضیه ۱۰۰۲. (گوش و باسو [۹]) تحت فرض های ۱ تا ۷ گفته شده، نتایج زیر برقرار است:

- (۱) یک دنباله سازگار  $\hat{\theta}_n = (\hat{\beta}_n, \hat{\phi}_n)$  از ریشه های معادله برآوردگر حداقل و اگرایی توان چگالی (روابط ۱۶ و ۱۷) وجود دارد.
- (۲) توزیع مجانبی  $\Omega_n^{-\frac{1}{2}} \Psi_n [\sqrt{n}((\hat{\beta}_n, \hat{\phi}_n) - (\beta^g, \phi^g))]$  توزیع نرمال  $(p+1)$  بعدی با (بردار) میانگین صفر و ماتریس واریانس-کوارینانس  $I_{p+1}$  می باشد، همان ماتریس همانی  $p+1$  بعدی است. به طوری که  $\Omega_n = \Omega_n(\beta^g, \phi^g)$  و  $\Psi_n = \Psi_n(\beta^g, \phi^g)$  است.

از قضیه فوق چنین نتیجه می گیریم که معکوس ماتریس  $\Psi_n^{-1} \Omega_n \Psi_n^{-1}$  برآوردی از کارایی مجانبی برآوردگرهای حداقل و اگرایی توان چگالی MDPDE ها  $(\hat{\beta}_n, \hat{\phi}_n)$  را ارائه می دهد. اگرچه این، بستگی به اندازه نمونه  $n$  و متغیرهای  $x_i$  داده شده دارد، اما برآورد

و بنابراین معادله برآوردی ۱۶ به صورت زیر ساده می شود:

$$\sum_{i=1}^n \frac{(Y_i - \mu_i)}{\text{Var}(Y_i) g'(\mu_i)} x_i f_i(Y_i; (\beta, \phi))^\alpha = 0. \quad (20)$$

## ۶۰۲ ویژگی های مجانبی برآوردگر حداقل و اگرایی توان چگالی

برآوردگر حداقل و اگرایی توان چگالی دارای برخی ویژگی های مجانبی مانند توزیع مجانبی، کارایی مجانبی و توانمندی مجانبی است که در ادامه به آن ها اشاره می کنیم. در ابتدا توزیع توأم مجانبی برآوردگر حداقل و اگرایی توان چگالی  $(\hat{\beta}, \hat{\phi})$  پارامترهای  $(\beta, \phi)$  که با حل معادلات برآوردی ۱۶ و ۱۷ به دست آمده را به دست خواهیم آورد. فرض می کنیم که توزیع واقعی مولد داده ها نیز به چگالی مدل با پارامترهای  $(\beta^g, \phi^g)$  تعلق دارد. برای  $i = 1, \dots, n$  و  $j, k = 1, 2$  عبارات زیر را تعریف می کنیم:

$$\gamma_{ji} = \gamma_{ji}^{1+\alpha}(\beta, \phi) = \int K_{ji}(y; (\beta, \phi)) f_i(y; (\beta, \phi))^{1+\alpha} dy,$$

$$\begin{aligned} \gamma_{jki} &= \gamma_{jki}^{1+\alpha}(\beta, \phi) = \int K_{ji}(y; (\beta, \phi)) K_{ki}(y; (\beta, \phi)) \\ &\quad f_i(y; (\beta, \phi))^{1+\alpha} dy \end{aligned}$$

به طوری که:

$$N_i^{1+\alpha}(\beta, \phi) = \int u_i(y; (\beta, \phi)) f_i(y; (\beta, \phi))^{1+\alpha} dy = \begin{pmatrix} \gamma_{1i} x_i \\ \gamma_{2i} \end{pmatrix},$$

$$\begin{aligned} M_i^{1+\alpha}(\beta, \phi) &= \int u_i(y; (\beta, \phi)) u_i(y; (\beta, \phi))^T f_i(y; (\beta, \phi))^{1+\alpha} dy \\ &= \begin{pmatrix} \gamma_{11i} x_i x_i^T & \gamma_{12i} x_i \\ \gamma_{21i} x_i^T & \gamma_{22i} \end{pmatrix}. \end{aligned}$$

اکنون برای  $k = 1, 2$  و  $X^T = [x_1, \dots, x_n]$  ماتریس های  $\Gamma_j^{(\alpha)}$  و همچنین مقادیر  $\Psi_n$  و  $\Omega_n$  را به صورت زیر تعریف می کنیم:

$$\Gamma_j^{(\alpha)} = \text{Diag}(\gamma_{ji})_{i=1, \dots, n}, \quad \Gamma_{jk}^{(\alpha)} = \text{Diag}(\gamma_{jki})_{i=1, \dots, n}.$$

$$\Psi_n(\beta, \phi) = \frac{1}{n} \sum_{i=1}^n M_i^{1+\alpha}(\beta, \phi) \quad (21)$$

$$\Omega_n(\beta, \phi) = \frac{1}{n} \sum_{i=1}^n [M_i^{1+\alpha}(\beta, \phi) - N_i^{1+\alpha}(\beta, \phi)(N_i^{1+\alpha}(\beta, \phi))^T] \quad (22)$$

و با تابع چگالی احتمال زیر می‌باشند:

$$f(y_i; \mu_i) = \frac{\mu_i^{y_i} e^{-\mu_i}}{y_i!}, \quad y_i = 0, 1, 2, 3, \dots \quad (25)$$

این تابع چگالی را می‌توان به فرم خانواده توزیع‌های نمایی (و حالت خاص آن یعنی فرم کانونی) به صورت زیر نوشت:

$$f(y_i; \mu_i) = \exp \{y_i \log(\mu_i) - \mu_i - \log(y_i!)\} \quad (26)$$

با نمادگذاری  $\mu_i = e^{(x_i^T \beta)} = e^{\eta_i}$  و  $\eta_i = x_i^T \beta$  فرم کانونی تابع چگالی به صورت زیر خواهد بود:

$$\begin{aligned} f(y_i; \eta_i) &= \exp \{y_i \log(e^{\eta_i}) - e^{\eta_i} - \log(y_i!)\} \\ &= \exp \{y_i \eta_i - e^{\eta_i} - \log(y_i!)\} \end{aligned} \quad (27)$$

ملاحظه می‌کنیم که رگرسیون پواسون در واقع یک مورد خاص از  $GLM$  با پارامتر شکل معلوم  $\phi = 1$  و  $\theta_i = \eta_i = x_i^T \beta$  و  $b(\theta_i) = e^{\theta_i} = e^{\eta_i}$ ،  $c(y_i) = -\log(y_i!)$ ،  $a(\phi) = 1$  است.

فرض کنید  $g$  یک تابع یکنوای صعودی با دامنه اعداد حقیقی مثبت باشد. از آنجایی که در اینجا میانگین  $\mu_i = e^{(x_i^T \beta)} = e^{\eta_i}$  است، تابع پیوند  $g$  را تابع لگاریتم طبیعی "log" انتخاب می‌کنیم. لذا پارامترهای مدل رگرسیونی ما  $\beta$  از طریق رابطه زیر وارد مدل می‌شوند:

$$g(\mu_i) = \log(\mu_i) = x_i^T \beta = \eta_i$$

می‌دانیم بردار متغیرهای مستقل مربوط به  $i$ امین مشاهده  $\beta = (\beta_1, \dots, \beta_p)^T$  بردار ضرایب رگرسیونی هستند. در بخش قبلی نشان دادیم که در حالتی که داده‌ها مستقل و غیرهم‌توزیع هستند و حالتی که مقدار پارامتر  $\phi$  معلوم و ثابت باشد می‌توانیم برآورد حداقل و اگرایی توان چگالی  $\beta$  را به وسیله مینیم کردن عبارت زیر به دست آوریم:

$$\sum_{i=1}^n x_i \left[ \int K_{\eta_i}(y; \beta) f_i(y; \beta)^{1+\alpha} dy - K_{\eta_i}(y_i; \beta) f_i(y_i; \beta) \right] = \quad (28)$$

یعنی هدف ما پیدا کردن آن مقدار از بردار پارامتری  $\beta$  است که به ازای آن فاصله بین چگالی‌های مدل پیشنهادشده و چگالی‌های واقعی برای تمام نقاط حداقل شود. در قضیه زیر نحوه محاسبه برآوردگر حداقل و اگرایی توان چگالی مربوط به مدل رگرسیون خطی تعمیم‌یافته ارائه می‌شود:

**قضیه ۱۰۳.** فرض کنیم یک نمونه تصادفی به صورت  $(x_i, y_i)$  و  $i = 1, \dots, n$  داریم، اگر مدل رگرسیون خطی تعمیم‌یافته پس از اعمال تابع

معقولی از کارایی مجانبی برای مقادیر بزرگ  $n$  نشان می‌دهد. علاوه بر این، کواریانس مجانبی برآوردهای  $\hat{\beta}_n$  و  $\hat{\phi}_n$  به‌طورکلی صفر نیست و بنابراین این برآوردها برای همه مدل‌های خطی تعمیم‌یافته ( $GLM$ )ها مجانباً مستقل نیستند.

### ۳ اجرای روش $MDPDE$ در برآورد ضرایب مدل رگرسیون پواسون برای داده‌های شمارش‌پذیر

در تحقیقات و متون آماری قدیمی، هیچ روش توانمند خاصی برای برآورد پارامترهای رگرسیون پواسون وجود ندارد. با این حال، در این بخش از روش توانمند برآوردگر حداقل و اگرایی توان چگالی برای برآورد ضرایب مدل رگرسیون پواسون استفاده خواهیم کرد؛ بنابراین بر روی رگرسیون پواسون تمرکز می‌کنیم که در آن مقادیر مشاهده‌شده متغیرهای پاسخ مجموعه‌ای از اعداد صحیح غیر منفی هستند. مفیدترین ابزار رگرسیون برای داده‌های شمارش‌پذیر، مدل رگرسیون پواسون است که در آن، با توجه به مقادیر متغیرهای توضیحی، متغیرهای پاسخ به‌طور مستقل از توزیع پواسون پیروی می‌کنند اما این توزیع بسته به مقادیر متناظر متغیر توضیحی ممکن است پارامترهای میانگین متفاوتی داشته باشد.

به‌طور دقیق‌تر، فرض کنید  $(x_1, y_1), \dots, (x_n, y_n)$  مشاهدات نمونه از مدل رگرسیون پواسون باشد؛ یعنی یک مدل خطی تعمیم‌یافته در نظر می‌گیریم که  $Y_i$  ها متغیرهای پاسخ با توزیع پواسون و  $X_i$  ها متغیرهای مستقل توضیحی هستند. همچنین فرض کنید که مقادیر متغیر توضیحی  $x_i$  ثابت است. پس در مدل رگرسیون پواسون، متغیرهای پاسخ شمارش‌پذیر  $Y_i$  مستقل بوده و دارای توزیع پواسون با پارامتر  $\mu_i = e^{(x_i^T \beta)}$  و

$$\mu_i = E(Y_i | x_i) = e^{(x_i^T \beta)}$$

هستند. به‌طوری‌که  $\mu_i > 0$  و میانگین و واریانس متناظر با هر کدام از  $Y_i$  ها یکسان و برابر با مقدار  $\mu_i$  است. پس

$$\mu_i = E(Y_i | x_i) = e^{(x_i^T \beta)}, \quad Var(Y_i | x_i) = e^{(x_i^T \beta)}$$

بنابراین در این مدل خطی تعمیم‌یافته به ازای هر  $i$  و  $i = 1, \dots, n$ ،  $Y_i \sim PO(\mu_i)$ . یعنی  $Y_i$  ها متغیرهای تصادفی مستقل و غیرهم‌توزیع



پیوند لگاریتمی را به صورت

$$g(\mu_i) = \log(\mu_i) = \mathbf{x}_i^T \boldsymbol{\beta}, \quad i = 1, \dots, n$$

مستقل و غیرهم توزیع به صورت  $(x_i, y_i)$  و  $i = 1, \dots, n$  داریم، همچنین مدل رگرسیون خطی تعمیم یافته پس از اعمال تابع پیوند لگاریتمی را به صورت

$$g(\mu_i) = \log(\mu_i) = \mathbf{x}_i^T \boldsymbol{\beta}, \quad i = 1, \dots, n$$

در نظر می گیریم که متغیرهای پاسخ  $(Y_i \sim PO(e^{\mathbf{x}_i^T \boldsymbol{\beta}}))$  دارای توزیع پواسون با پارامتر  $\mu_i = e^{\mathbf{x}_i^T \boldsymbol{\beta}}$  هستند و  $\mathbf{x}_i^T$  بردار متغیرهای مستقل مربوط به  $i$  امین مشاهده و  $\boldsymbol{\beta}$  بردار ضرایب رگرسیونی باشند. آنگاه مقادیر  $\Omega_n, \Psi_n, M_i^{1+\alpha}, N_i^{1+\alpha}$  به صورت زیر به دست می آید:

$$N_i^{1+\alpha}(\boldsymbol{\beta}) = \sum_{y=0}^{\infty} (y - e^{\mathbf{x}_i^T \boldsymbol{\beta}}) x_i f_i(y; \boldsymbol{\beta})^{1+\alpha} = \gamma_{11} x_i \quad (31)$$

$$M_i^{1+\alpha}(\boldsymbol{\beta}) = \sum_{y=0}^{\infty} (y - e^{\mathbf{x}_i^T \boldsymbol{\beta}})^2 (x_i x_i^T) f_i(y; \boldsymbol{\beta})^{1+\alpha} = \gamma_{111} (x_i x_i^T) \quad (32)$$

$$\Psi_n(\boldsymbol{\beta}) = \frac{1}{n} (X^T \Gamma_{11}^{(\alpha)} X) \quad (33)$$

$$\Omega_n(\boldsymbol{\beta}) = \frac{1}{n} (X^T [\Gamma_{11}^{(2\alpha)} - (\Gamma_{11}^{(\alpha)})^2] X) \quad (34)$$

به طوری که  $f_i(y; \boldsymbol{\beta})$  تابع چگالی احتمال توزیع پواسون با میانگین  $\mu_i = e^{\mathbf{x}_i^T \boldsymbol{\beta}}$  است.

اثبات. با توجه به گسسته بودن متغیر تصادفی پواسون می توان در تعاریف و نمادگذاری های بخش قبلی، به جای علامت  $\int$  از علامت  $\sum$  و جمع روی تمام مقادیر متغیر تصادفی پواسون استفاده کرد. سپس می توان با استفاده از فرم تابع چگالی پواسون و تعریف  $u_i(y; \boldsymbol{\beta})$  برحسب  $K_{1i}(y; \boldsymbol{\beta})$  مطابق با رابطه ۱۴ مقدار  $K_{1i}(y; \boldsymbol{\beta})$  و در نهایت مقدار  $\gamma_{1i}$  از رابطه ۴۰ مقادیر  $N_i^{1+\alpha}$  و  $M_i^{1+\alpha}$  را به دست آورد. با جایگذاری  $M_i^{1+\alpha}$  ها و  $N_i^{1+\alpha}$  ها با روابط و تعاریف متناظر آن ها و انجام محاسبات ساده جبری مقادیر  $\Psi_n$  و  $\Omega_n$  به دست می آیند. □

تذکر ۴.۳. نکته قابل توجه این است که شرایط روی  $x_i$  به گونه ای است که مقادیر باقیمانده در نمونه های بزرگ کران دار هستند. همچنین طیفی از باقیمانده های ماتریس مجموع فراهم شده ی  $(X^T X)$ ، دور از نقطه صفر کران دار هستند.

در نظر بگیریم که متغیرهای پاسخ شمارش پذیر  $y_i$  دارای توزیع پواسون با پارامتر  $\mu_i = e^{\mathbf{x}_i^T \boldsymbol{\beta}}$  هستند و  $\mathbf{x}_i^T$  بردار متغیرهای مستقل مربوط به  $i$  امین مشاهده و  $\boldsymbol{\beta}$  بردار ضرایب رگرسیونی باشند. آنگاه با استفاده از نمادگذاری بالا و شکل توزیع پواسون، برآوردگر حداقل و اگرایی توان چگالی مربوط به ضرایب رگرسیونی  $\beta_j$ ،  $j = 1, \dots, p$ ، برای  $\alpha \geq 0$  از حل کردن معادله زیر به دست می آید:

$$\sum_{i=1}^n \left[ \gamma_{1i}(\boldsymbol{\beta}) - (y_i - e^{\mathbf{x}_i^T \boldsymbol{\beta}}) f_i(y; \boldsymbol{\beta})^\alpha \right] x_i = 0, \quad j = 1, \dots, p \quad (29)$$

به طوری که  $f_i(y; \boldsymbol{\beta})$  تابع چگالی احتمال توزیع پواسون با میانگین  $\mu_i = e^{\mathbf{x}_i^T \boldsymbol{\beta}}$  است و

$$\gamma_{1i} = \gamma_{1i}^{1+\alpha}(\boldsymbol{\beta}) = \int K_{1i}(y; \boldsymbol{\beta}) f_i(y; \boldsymbol{\beta})^{1+\alpha} dy$$

اثبات قضیه بالا در پیوست ۱ آمده است.

نتیجه ۲.۳. به طور خاص، برای  $\alpha = 0$ ، معادله برآوردی بالا به معادله برآوردی ماکسیمم درست نمایی  $MLE$  ارائه شده توسط رابطه زیر ساده می شود.

$$\sum_{i=1}^n (y_i - e^{\mathbf{x}_i^T \boldsymbol{\beta}}) x_i = 0 \quad (30)$$

با این حال، برای  $\alpha > 0$ ، هیچ شکل ساده شده ای برای  $\gamma_{1i}$  و  $\gamma_{11i}$  وجود ندارد، بنابراین ما نیاز داریم که این کمیت ها را به صورت عددی محاسبه و سپس معادله برآوردی ۴۴ را برحسب مؤلفه های بردار ضرایب رگرسیونی  $\boldsymbol{\beta}$  به صورت عددی حل کنیم.

## ۱.۳ ویژگی های جانبی برآوردگر $MDPDE$ مربوط به پارامترهای مدل رگرسیون پواسون

ویژگی های جانبی برآوردگر  $MDPDE$  برای پارامترهای  $\boldsymbol{\beta}$  تحت مدل رگرسیون پواسون مستقیماً از قضیه ۱۰.۲ پیروی می کند. برای بررسی خواص جانبی برآوردگرها ابتدا قضیه زیر را بیان می کنیم.

قضیه ۳.۳. فرض کنیم که توزیع واقعی مولد داده ها زیرمجموعه خانواده مدل توزیع ها باشد به طوری که  $g_i(y) = f_i(y; \boldsymbol{\theta})$  و یک نمونه تصادفی

نسبت به کارایی برآوردگر  $MLE$  به دست می‌آید (می‌دانیم که برآوردگر ماکزیمم درست‌نمایی دارای حداکثر میزان کارایی ( $e_n(T_n) = 1$ ) است؛ بنابراین، برآوردی از کارایی نسبی  $MDPDE$ ‌های مختلف از مؤلفه  $i$ ام بردار پارامتری  $\beta = (\beta_1, \dots, \beta_p)$  با توجه به کارایی برآوردگر  $MLE$  آن (برآوردگر  $OLS$ ) به صورت زیر ارائه می‌شود.

$$\widehat{RE}_{i,\alpha} = \frac{\widehat{AV}_i^*}{\widehat{AV}_\alpha^*} \times 100$$

که  $\widehat{AV}^i$  در واقع  $i$ -مین مؤلفه قطری ماتریس  $\widehat{AV}$  است. واضح است که برآورد بالا از کارایی نسبی، به حجم نمونه  $n$  و انتخاب متغیرهای توضیحی داده شده  $x_i$  بستگی دارد؛ اما می‌توان نشان داد که اگر  $x_i$  ها مناسب انتخاب شود آنگاه سازگاری برآوردگر  $\hat{\beta}_n$  نشان‌دهنده این است که اندازه‌گیری بالا برآوردگر سازگاری از کارایی نسبی مجانبی به ما می‌دهد. به عنوان مثال،  $X^T X$  باید محدود باشد.

**تذکر ۶.۳.** برآوردگر حداقل واگرایی توان چگالی به ازای  $\alpha = 0$  همان برآوردگر درست‌نمایی ماکزیمم است که دارای بالاترین میزان کارایی یعنی مقدار ۱ است. با افزایش میزان  $\alpha$  از کارایی برآوردگر حداقل واگرایی توان چگالی کاسته می‌شود و هم‌زمان میزان توانمندی این برآوردگر افزایش می‌یابد. با انجام شبیه‌سازی مشخص می‌شود که از دست دادن کارایی برای  $MDPDE$  با  $\alpha$  مثبت کوچک کاملاً ناچیز است؛ بنابراین میزان کاهش  $ARE$  به ازای مقادیر کوچک  $\alpha$ ، بسیار کم است. حتی برای  $\alpha$  مثبت بزرگ نزدیک به ۰.۵، اگر  $x_i$  ها نسبتاً کوچک باشند، می‌توانیم کارایی بسیار بالایی داشته باشیم.

## ۴ مدل‌سازی داده‌های واقعی به روش

### $MDPDE$ در مدل رگرسیون پواسون

در این بخش، عملکرد  $MDPDE$ ‌های پیشنهادی را در مدل رگرسیون پواسون و با اعمال آن بر روی یک مجموعه داده واقعی بررسی خواهیم کرد و نشان خواهیم داد که برآوردهای حاصل از این روش در مقابل مشاهدات پرت و دارای نفوذ، توانمند بوده و کارایی قابل قبولی دارند.

<sup>19</sup>Asymptotic Variance

<sup>20</sup>Asymptotic Relative Efficiency

## ۲.۳ توزیع مجانبی برآوردگر $MDPDE$ مربوط به پارامترهای مدل رگرسیون پواسون

**قضیه ۵.۳.** تحت تنظیمات مربوط به مدل رگرسیون پواسون که در ابتدای این بخش مطرح شد و همچنین تحت فرض‌های ۱ تا ۷ گوش و باسو (۲۰۱۳) نتایج زیر اتفاق می‌افتد:

(۱) بازه سازگاری به عنوان  $\hat{\beta}_n = \hat{\beta}_n^{(\alpha)}$  از ریشه‌های معادله برآوردی حداقل  $DPD$  در رابطه ۲۹ برای پارامتر همسان‌ساز  $\alpha$  وجود دارد.

$$(X^T [\Gamma_{11}^{(\alpha)}(\beta^g) - (\Gamma_1^{(\alpha)})^2(\beta^g)]X)^{-1} (X^T \Gamma_{11}^{(\alpha)}(\beta^g)X)(\hat{\beta}_n - \beta^g) \quad (2)$$

دارای توزیع مجانبی نرمال  $p$  بعدی با بردار میانگین صفر و ماتریس واریانس-کوواریانس  $I_p$  می‌باشد. واریانس مجانبی برآوردگر  $\beta^g$  را به اختصار با  $AV$  <sup>۱۹</sup> نشان می‌دهیم و به صورت زیر اندازه‌گیری می‌شود

$$AV_\alpha(\beta^g) = (X^T \Gamma_{11}^{(\alpha)}(\beta^g)X)^{-1} (X^T [\Gamma_{11}^{(\alpha)}(\beta^g) - (\Gamma_1^{(\alpha)})^2(\beta^g)]X)(X^T \Gamma_{11}^{(\alpha)}(\beta^g)X)^{-1} \quad (35)$$

کارایی مجانبی برآوردهای مختلف  $MDPDE$  برای  $\beta$ ، یعنی  $\hat{\beta}_n = \hat{\beta}_n^{(\alpha)}$ ، را می‌توان بر اساس واریانس مجانبی فوق اندازه‌گیری کرد. به طوری که می‌توان واریانس مجانبی این برآوردها را به طور مداوم با جایگزینی  $\beta^g$  با  $\hat{\beta}_n$  برآورد کرد، یعنی:

$$\widehat{AV}_\alpha = AV_\alpha(\hat{\beta}_n)$$

نکته قابل توجه دیگر این است که برآوردگر حداقل واگرایی توان چگالی در حالت  $\alpha = 0$  همان برآوردگر ماکزیمم درست‌نمایی است؛ بنابراین اگر در عبارات مربوط به واریانس مجانبی مقدار  $\alpha$  را برابر صفر قرار دهیم، آنگاه واریانس مجانبی برآوردگر  $MLE$  یعنی  $AV$  به دست می‌آید.

## ۳.۳ کارایی نسبی مجانبی برآوردگر $MDPDE$ مربوط به پارامترهای مدل رگرسیون پواسون

کارایی نسبی مجانبی برآوردگر را به اختصار با  $ARE$  <sup>۲۰</sup> نشان می‌دهیم که در اینجا  $ARE$  کارایی مجانبی برآوردگر حداقل واگرایی توان چگالی

## ۱۰۴ مدل سازی داده های صرع به روش MDPDE در مدل رگرسیون پواسون

مثال ۱۰۴. در این مثال یک مجموعه داده شامل ۵۹ بیمار صرعی از تال و ویل (۱۹۹۰) [۱۶] (جدول ۲، بخش ۵) را در نظر می گیریم. داده ها از یک کار آزمایی بالینی انجام شده توسط لپیک و همکاران (۱۹۸۵) به دست آمد. به طوری که در آن کار آزمایی بیماران مبتلا به صرع با داروی ضد صرع «پروگابید» یا با «دارونما (تسکین دهنده)» با انتساب تصادفی تحت درمان قرار گرفتند. در واقع تقریباً نیمی از بیماران (۲۸ بیمار) به صورت تصادفی انتخاب شدند و با استفاده از «دارونما (تسکین دهنده)» تحت درمان قرار گرفتند و نیمی دیگر از بیماران (۳۱ بیمار) با استفاده از داروی ضد صرع «پروگابید» تحت درمان قرار گرفتند.

در این مثال تعداد کل حملات صرع ذکر شده در طول چهار دوره برای هر بیمار را با هم جمع می کنیم و به عنوان متغیر پاسخ  $Y_i$  در نظر می گیریم که با توجه به نحوه پراکندگی مشاهدات حاصل از این متغیر، می توان گفت که متغیر پاسخ  $Y_i$  از توزیع پواسون پیروی می کند؛ بنابراین مجموعه داده های صرع را با مجموعه ای از متغیرهای توضیحی مناسب از طریق مدل رگرسیون پواسون مدل سازی می کنیم (حسینیان ۲۰۰۹ [۱۱]). متغیرهای توضیحی در نظر گرفته شده در این رابطه عبارت اند از: پایه <sup>۲۱</sup> (نرخ تشنج پایه هشت هفته ای قبل از تصادفی سازی در مضرب ۴)، سن <sup>۲۲</sup> (سن بیمار در مضربی از ۱۰ سال) و درمان کمکی <sup>۲۳</sup> (یک شاخص باینری برای گروه کنترل-درمان). توجه کنید که تعامل بین درمان و نرخ تشنج پایه در این مثال مهم است، زیرا بسته به تعداد پایه، این تعامل نرخ تشنج بالاتر یا پایین تری را برای گروه درمان در مقایسه با گروه دارونما نشان می دهد. در واقع، این دارو تنها در صورتی صرع را کاهش می دهد که تعداد پایه با توجه به آستانه بحرانی به اندازه کافی زیاد شود. این داده ها توسط حسینیان (۲۰۰۹) [۱۱] تجزیه و تحلیل شدند که برآوردگر ماکسیمم درستنمایی <sup>۲۴</sup> را با روش های توانمند پیشنهاد شده توسط خود او (برآوردگر ماکسیمم درستنمایی وزنی <sup>۲۵</sup>) در همان مقاله و روش های کانتونی و رانچتی (۲۰۰۱) [۶] مقایسه کرد. با توجه به نتایج مربوط به برآورد پارامترهای مدل رگرسیون پواسون و مقادیر  $p$  آن ها برای مجموعه داده های صرع که توسط حسینیان و کانتونی ارائه شده و در جدول ۶-۴ آمده است می توان گفت که با استفاده از روش های

WMLE (حسینیان) و MLE پارامترهای  $\beta_1$ ،  $\beta_2$  و  $\beta_3$  در مدل ۳۷ می مانند اما چالش و تفاوت در روش های توانمند (مانند حسینیان) و MLE بر روی این است که آیا پارامتر  $\beta_4$  نیز در مدل می ماند یا خیر؟

حسینیان بر این باور است که به دلیل مشاهدات پرت، اثر متقابل بین درمان و نرخ تشنج پایه بر اساس برآوردگر ماکسیمم درستنمایی ناچیز است؛ یعنی چون اندازه  $p$ -مقدار برای  $\beta_4$  (ضریب اثر متقابل  $Trt : Base$ ) بر اساس برآوردگر MLE نسبتاً بزرگ است پس فرض  $H_0$  در آزمون فرض ۳۶ رد نمی شود و  $\beta_4$  در مدل نمی ماند. در حالی که بر اساس برآوردگرهای پیشنهادی توانمند حسینیان (WMLE) اندازه  $p$ -مقدار برای  $\beta_4$  خیلی کوچک است پس فرض  $H_0$  در آزمون فرض ۳۶ رد می شود و لذا ضریب اثر متقابل  $Trt : Base$  یعنی پارامتر  $\beta_4$  در مدل می ماند؛ بنابراین حسینیان این تعامل را معنی دار نشان می دهد و با استفاده از روش پیشنهادی خودشان متغیر متقابل را در مدل نگه می دارد.

پس نتیجه می گیریم چنانچه مدل توانمندی به داده ها برازش داده شود، انتظار داریم که پارامتر  $\beta_4$  معنی دار شود. لذا در این بخش از مقاله، برآوردگرهای حداقل و اگرایی توان چگالی توانمند را برای مجموعه داده های صرع اعمال می کنیم و سعی می کنیم نشان دهیم که آیا برآوردگرهای پیشنهادی ما نیز به اندازه کافی توانمند هستند که با برآوردگر ماکسیمم درستنمایی برای اثر متقابل  $Trt : Base$  متمایز شوند؟ آیا روش MDPDE بهتر از روش MLE عمل می کند؟ آیا مانند روش حسینیان (WMLE) اثر متقابل  $Trt : Base$  را در مدل نگه می دارد؟

برای پیدا کردن پاسخ، سؤال موردعلاقه فوق را می توان به عنوان آزمون برای فرضیه های زیر فرمول بندی کرد:

$$\begin{cases} H_0 : \beta_4 = 0 \\ H_1 : \beta_4 \neq 0 \end{cases} \quad (36)$$

برای داده ها مدل رگرسیون پواسون را در نظر می گیریم به طوری که لگاریتم نرخ تشنج پایه ای ( $Base$ )، لگاریتم سن ( $Age$ ) و شاخص باینری ( $Trt$ ) به عنوان متغیر مستقل و لگاریتم تعداد کل تشنج در هر چهار معاینه بالینی متوالی پس از تصادفی سازی ( $Y_i$ ) به عنوان متغیر

<sup>21</sup>Base<sup>22</sup>Age<sup>23</sup>Trt<sup>24</sup>MLE<sup>25</sup>WMLE

وابسته در نظر گرفته شده است.

می‌کنید با توجه به انحراف استاندارد ضرایب برآورد شده از روش حسینیان و روش  $MDPDE$ ، با  $\alpha = 0.8$  روش  $MDPDE$  روشی کارا تر می‌باشد.

$$\text{متغیرهای مستقل} = \begin{cases} X_1 = Trt \\ X_2 = Base \\ X_3 = Age \\ X_4 = Trt \times Base \end{cases}$$

و

$$Y_i = \text{متغیر وابسته}$$

تابع پیوند  $g$  را تابع لگاریتم طبیعی "log" انتخاب می‌کنیم. لذا پارامترهای مدل رگرسیونی پواسون  $\beta$  از طریق رابطه زیر وارد مدل می‌شوند:

$$g(\mu_i) = \log(\mu_i) = x_i^T \beta = \eta_i$$

بنابراین مدل رگرسیون پواسون برای داده‌های صرع به صورت زیر خواهد بود:

$$\log(\hat{\mu}) = \log(E(\hat{Y})) = x_i^T \hat{\beta} = \hat{\beta}_0 + \hat{\beta}_1 X_1 + \hat{\beta}_2 X_2 + \hat{\beta}_3 X_3 + \hat{\beta}_4 X_4 \quad (37)$$

نتایج مربوط به برآورد پارامترهای مدل رگرسیون پواسون ۳۷، خطاهای استاندارد و مقادیر  $p$  آن‌ها برای مجموعه داده‌های صرع با استفاده از روش برآورد ماکسیمم درستنمایی و روش برآورد ماکسیمم درستنمایی وزنی در جدول ۱ و بر اساس برآوردگر حداقل و اگرایی توان چگالی با  $\alpha$  های متفاوت در جدول ۲ ارائه شده است. در جدول ۲ ملاحظه می‌کنیم بر اساس برآوردگر توانمند حداقل و اگرایی توان چگالی برای  $\alpha = 0.3$ ،  $\alpha = 0.5$  و  $\alpha = 0.8$  اندازه  $p$ -مقدار برای  $\beta_4$  خیلی کوچک است پس فرض  $H_0$  در آزمون فرض ۳۶ رد می‌شود و لذا ضریب اثر متقابل  $Base : Trt$  یعنی پارامتر  $\beta_4$  در مدل می‌ماند؛ بنابراین روش  $MDPDE$  این تعامل را معنی‌دار نشان می‌دهد و استفاده از روش پیشنهادی توانمند ما متغیر متقابل را در مدل نگه می‌دارد.

نتیجه: واضح است که برآوردگرهای  $MDPDE$  مربوط به  $\alpha \geq 0.3$  با برآوردگر ماکسیمم درستنمایی کاملاً متفاوت هستند. با توجه به نتایج به دست آمده ملاحظه می‌گردد روش برآورد حداقل و اگرایی توان چگالی برای  $\alpha \geq 0.3$  یک روش توانمند می‌باشد زیرا برای  $\alpha \geq 0.3$  ضریب  $\beta_4$  معنادار شده است. بنابراین برای برآوردگرهای  $MDPDE$  اثر متقابل تحت مدل رگرسیون پواسون نیز قابل توجه است. در واقع، این برآوردگرها کاملاً شبیه به برآوردگرهای توانمند در نظر گرفته شده در حسینیان (۲۰۰۹) هستند، اما همان‌طور که قبلاً توضیح دادیم، دارای خواص مجانبی برتری هستند زیرا همان‌طور که در جداول ۱ و ۲ ملاحظه

## پیوست

پیوست ۱: به ازای هر نقطه از مشاهدات، چگالی مدل پیشنهادی به صورت  $f_i \equiv PO(\mu_i)$  است و داریم:

$$f_i \sim PO(\mu_i) \Rightarrow f(y_i; \mu_i) = \frac{\mu_i^{y_i} e^{-\mu_i}}{y_i!}, \quad y_i = 0, 1, 2, 3, \dots \quad (38)$$

در بخش ۲ برای  $i = 1, \dots, n$  و  $j, k = 1, 2$  مقدار  $\gamma_{ji}$  را به صورت عبارت زیر تعریف کردیم:

$$\gamma_{ji} = \gamma_{ji}^{1+\alpha}(\beta, \phi) = \int K_{ji}(y; (\beta, \phi)) f_i(y; (\beta, \phi))^{1+\alpha} dy \quad (39)$$

چون پارامتر  $\phi$  معلوم و ثابت است آن را در رابطه کنار می‌گذاریم. پس برای  $j = 1$  مقدار  $\gamma_{1i}$  به صورت عبارت زیر خواهد بود:

$$\gamma_{1i} = \gamma_{1i}^{1+\alpha}(\beta) = \int K_{1i}(y; \beta) f_i(y; \beta)^{1+\alpha} dy \quad (40)$$

اکنون جهت اثبات قضیه از رابطه ۲۸ به صورت زیر استفاده می‌کنیم:

$$\sum_{i=1}^n x_i \left[ \int K_{1i}(y; \beta) f_i(y; \beta)^{1+\alpha} dy - K_{1i}(y_i; \beta) f_i(y_i; \beta)^\alpha \right] =$$

ملاحظه می‌کنیم که قسمت اول عبارت فوق برابر با رابطه ۴۰ است، بنابراین با جایگذاری مقدار  $\gamma_{1i}$  در رابطه فوق داریم:

$$\sum_{i=1}^n x_i [\gamma_{1i}(\beta) - K_{1i}(y_i; \beta) f_i(y_i; \beta)^\alpha] = 0 \quad (41)$$

با توجه به رابطه ۱۴ مقدار  $K_{1i}$  به صورت زیر تعریف می‌شود:

$$K_{1i}(y_i; \beta) = \frac{(y_i - \mu_i)}{Var(Y_i) g'(\mu_i)} \quad (42)$$

از طرفی

$$g(\mu_i) = \log(\mu_i) \Rightarrow g'(\mu_i) = \frac{1}{\mu_i}, \quad Var(Y_i) = \mu_i$$

حال مقادیر میانگین و واریانس را در رابطه ۴۲ جایگذاری می‌کنیم

$$K_{1i}(y_i; \beta) = \frac{(y_i - \mu_i)}{\mu_i \cdot \frac{1}{\mu_i}} = (y_i - \mu_i) = (y_i - e^{(x_i^T \beta)}) \quad (43)$$

	Int.	Age	Base	Trt	Base:Trt
MLE	۱/۸۷	۰/۲۴	۰/۰۸۵	-۰/۲۶	۰/۰۰۸
st.err	۰/۱۳	۰/۰۴	۰/۰۰۴	۰/۰۷۷	۰/۰۰۴
p-value	۲e - ۱۶	۳/۷e - ۹	۲e - ۱۶	۰/۰۰۰۹	۰/۰۸۸
WMLE	۲/۱۳	۰/۰۴۴	۰/۱۲۸	-۰/۴۷	۰/۰۵۴
st.err	۰/۱۹۸	۰/۰۵۷	۰/۰۱۴	۰/۱۶	۰/۰۲۱
p-value	۱/۱e - ۲۷	۴/۴e - ۰۱	۹/۲e - ۲۱	۲/۶e - ۰۳	۱e - ۰۲

جدول ۱: برآورد پارامترهای مدل رگرسیون پواسون برای مجموعه داده‌های صرع از روش ماکسیم درستنمایی (MLE) و روش ماکسیم درستنمایی وزنی (WMLE) با خطاهای استاندارد و مقادیر p آن‌ها.

در نهایت با جایگذاری  $K_{\gamma_i}(y_i; \beta)$  در رابطه ۴۱ قضیه اثبات می‌شود: ریشه‌های معادله ۴۴ همان مقادیر برآوردهایی است که به دنبال به دست آوردن آن‌ها بودیم. بسته به تعداد متغیرهای مستقل به‌کاررفته در مدل رگرسیون (p) با حل کردن این معادله و به دست آوردن ریشه‌های آن‌ها برآورد بردار پارامتری  $\beta$  به دست می‌آید.

$$\sum_{i=1}^n [\gamma_{\gamma_i}(\beta) - (y_i - e^{(x_i^T \beta)}) f_i(y; \beta)^\alpha] x_i = 0 \quad (44)$$

## مراجع

- [1] Abonazel, M. R., Saber, O. M. (2020). A comparative study of robust estimators for Poisson regression model with outliers. *Journal of Statistical Applications and Probability*, **9**, 279-286 .
- [2] Abonazel, M. R., Dawoud, I. (2022). Developing robust ridge estimators for Poisson regression model. *Concurrency and Computation: Practice and Experience*, **34(15)**, e6979 .
- [3] Amin, M., Akram, M. N., Kibria, B. G. (2021). A new adjusted Liu estimator for the Poisson regression model. *Concurrency and computation: Practice and experience*, **33(20)**, e6340 .
- [4] Basu, A., Harris, I. R., Hjort, N. L. and Jones M. C. (1998). Robust and efficient estimation by minimizing a density power divergence. *Biometrika*. **85**, 3, 549-559.
- [5] Beran, R. (1977). Minimum Hellinger Distance Estimates for Parametric Models. *The annals of Statistics*, **5**, 3, 445-463.
- [6] Cantoni, E. and Ronchetti, E. (2001). Robust inference for generalised linear models. *Journal of the American Statistical Association*. **96**, 455, 1022-1030.
- [7] Chen, W., Qian, L., Shi, J., Franklin, M. (2018). Comparing performance between log-binomial and robust Poisson regression models for estimating risk ratios under model misspecification. *BMC medical research methodology*, **18(1)**, 1-12 .
- [8] Durio, A. and Isaia, E. D. (2011). The Minimum Density Power Divergence Approach in Building Robust Regression Models. *INFORMATICA*. **22**, 1, 43-56.

	$\alpha = 0$	$\alpha = 0.1$	$\alpha = 0.3$	$\alpha = 0.5$	$\alpha = 0.7$	$\alpha = 1$
Intercept						
Estimate	۱۸۶۸۰	۱۸۵۷۸	۱۶۳۸۹	۱۷۳۵۳	۱۶۷۷۱	۱۸۱۶۹
SE( $\times 100$ )	۱۳۵۹۲۹	۱۵۲۵۰۹	۱۲۶۸۶۹	۱۳۷۰۸۱	۱۴۹۱۸۵	۱۷۰۰۴۳
p-value	$< 2e - 16$	۰/۰۰۰۰	۰/۰۰۰۰	۰/۰۰۰۰	۰/۰۰۰۰	۰/۰۰۰۰
Trt						
Estimate	-۰/۲۵۵۳	-۰/۲۶۵۵	-۰/۲۲۸۶	-۰/۳۰۸۹	-۰/۲۴۸۱	-۰/۸۸۹۴
SE( $\times 100$ )	۷۶۵۲۵	۸۶۸۱۲	۷۹۱۳۹	۸۴۵۶۶	۹۱۱۱۱	۱۰۱۷۸۷
p-value	۰/۰۰۰۸	۰/۰۰۰۶	۰/۰۰۰۰	۰/۰۰۰۰	۰/۰۰۰۳	۰/۰۰۲۷
Base						
Estimate	۰/۰۸۵۴	۰/۰۵۴۷	۰/۰۸۵۰	۰/۱۵۲۴	۰/۰۸۵۶	۰/۱۵۴۹
SE( $\times 100$ )	۰/۳۶۶۶	۰/۴۱۰۱	۰/۲۷۷۸	۰/۳۰۵۵	۰/۳۳۵۹	۰/۳۹۵۹
p-value	$< 2e - 16$	۰/۰۰۰۰	۰/۰۰۰۰	۰/۰۰۰۰	۰/۰۰۰۰	۰/۰۰۰۰
Age						
Estimate	۰/۲۴۳۵	۰/۲۰۵۶	۰/۲۴۲۲	۰/۱۳۸۶	۰/۲۳۶۴	۰/۱۰۴۴
SE( $\times 100$ )	۴۱۲۹۷	۴۷۲۴۲	۳۹۳۷۴	۴۲۴۱۶	۴۶۱۳۸	۵۲۱۱۹
p-value	$3.72e - 09$	۰/۰۱۷۷	۰/۳۰۴۵	۰/۳۹۷۲	۰/۶۰۱۷	۰/۲۸۷۸
Trt $\times$ Base						
Estimate	۰/۰۰۷۵	-۰/۱۰۷۶	-۰/۰۶۷۹	-۰/۰۶۸۹	-۰/۰۶۸۵	۰/۰۶۴۰
SE( $\times 100$ )	۰/۴۴۰۹	۰/۴۸۹۳	۰/۳۲۳۰	۰/۳۵۳۷	۰/۳۸۸۸	۰/۴۶۰۰
p-value	۰/۰۸۷۵	۰/۰۳۲۳	۰/۰۰۰۰	۰/۰۰۰۰	۰/۰۰۱۳	۰/۰۳۷۳

جدول ۲: برآورد پارامترهای مدل رگرسیون پواسون، خطاهای استاندارد مجانبی و مقادیر  $p$  آن‌ها برای مجموعه داده‌های صرع با استفاده از برآوردگر حداقل واگرایی توان چگالی با  $\alpha$  های متفاوت.

- [9] Ghosh, A. and Basu, A. (2013). Robust estimation for independent non-homogeneous observations using density power divergence with applications to linear regression. *Electronic Journal of Statistics*. **7**, 2420–2456.
- [10] Hall, D. B., Shen, J. (2010). Robust estimation for zero-inflated Poisson regression. *Scandinavian Journal of Statistics*, **37(2)**, 237-252 .
- [11] Hosseinian, S. (2009). Robust inference for generalized linear models: binary and poisson regression. PHD thesis, Ecole Polytechnique Federal de Lausanne.
- [12] Huber, P. J. (1983). Minimax Aspects of Bounded-Influence Regression (With Discussion). *Journal of the American Statistical Association*. **78**, 66-80.
- [13] Huber, P. J. (1973). Robust Regression: Asymptotics, Conjectures and Monte Carlo. *Annals of Statistics*. **1**, 799-821.
- [14] Mallows, C. L. (1975). *on Some Topics in Robustness, Unpublished Memorandum*. Bell Telephone Laboratories, Mary Hill, N. J.
- [15] Simpson, D. G. (1987). Minimum Hellinger Distance Estimation for the Analysis of Count Data, *Journal of the American Statistical Association*, **82**, 802-807.
- [16] Thall, P.F. and Vail S.C. (1990). Some covariance models for longitudinal count data with overdispersion. *Biometrics*. **46**, 3, 657–671 .
- [17] Tsou, T. S. (2006). Robust poisson regression. *Journal of Statistical Planning and Inference*, **136(9)**, 3173-3186 .

## Robust estimations in Poisson regression model

Amirreza Mahmoodi<sup>1</sup> and Roohollah Roozegar<sup>2</sup>

### Abstract:

Many regression estimation techniques are strongly affected by outlier data and many errors occur in their estimation. In the recent years, robust methods have been developed to solve this issue. The minimum density power divergence estimator is an estimation method based on the minimum distance between two density functions, which provides a robust estimate in situations where the data contain a number of outliers. In this research, we present the robust estimation method of minimum density power divergence to estimate the parameters of the Poisson regression model, which can produce robust estimators with the least loss in efficiency. Also, we will investigate the performance of the proposed estimators by providing a real example.

**Keywords:** Generalized linear model, Minimum density power divergence estimator, Outlier data, Poisson Regression, Robustness, Tuning parameter .

---

<sup>1</sup> Master's degree graduate, Collage of science, Yasouj university, Yasouj, Iran.

<sup>2</sup>Department of mathematics, Collage of science, Yasouj university, Yasouj, Iran