

آزمون تعیین خطای مشخص‌سازی مدل خطی عام با داده‌های گم‌شده

فیاض بهاری^{*}، صفر پارسی^{**} و مجتبی گنجعلی^{*}

گروه آمار و علوم کامپیوتر، دانشگاه محقق اردبیلی^{*}

گروه آمار، دانشگاه شهید بهشتی^{**}

تاریخ دریافت: ۱۳۹۶/۱۰/۲۵ تاریخ پذیرش: ۱۳۹۷/۷/۲۳

چکیده: در این مقاله مدل خطی عام را در تحلیل داده‌هایی که در آن‌ها متغیرهای کمکی و متغیر پاسخ گم‌شده‌ی دارند، در نظر می‌گیریم. برای تعیین نیکویی برازش مدل خطی عام در حضور داده‌های گم‌شده، آزمون جدیدی را بر اساس آزمون رمزی می‌سازیم. نشان می‌دهیم که تحت فرض صفر، آماره‌های آزمون در برخی از حالات از توزیع فیشر تبعیت می‌کند و در برخی از حالات به توزیع شبه-فیشر میل می‌کند. علاوه بر این، عملکرد آماره‌های آزمون‌های آزمون را بر اساس چند مسئله شبیه‌سازی مقایسه می‌کنیم. همچنین از این آماره‌ها برای بررسی کفايت مدل خطی عام در تحلیل داده‌های واقعی استفاده می‌کنیم.

واژه‌های کلیدی : مدل خطی عام، داده‌های گم‌شده، آزمون نیکویی برازش، توزیع شبه-فیشر، آزمون رمزی.

رده‌بندی موضوعی (۲۰۱۰): ۶۲J۰۲، ۶۲F۰۳

۱- مقدمه

مدل خطی عام^۱ یکی از روش‌های متداول در تعیین رابطه بین پدیده‌ها است. یک مدل خطی عام بیانگر رابطه بین متغیر پاسخ y و بردار متغیرهای کمکی x با بعد m است. مدل خطی عام از رابطه زیر پیروی می‌کند.

$$y = g^T(\mathbf{x})\boldsymbol{\beta} + \varepsilon, \quad (1)$$

۱- آدرس الکترونیکی مسئول مقاله: parsi@uma.ac.ir

که در آن (\cdot) g یکتابع برداری معلوم با بعد p ، β یک پارامتر برداری با بعد p و ϵ خطای نمونه‌گیری با واریانس ثابت است. همچنین فرض بر این است که $E(\epsilon|\mathbf{x}) = 0$ و $E(\epsilon^2|\mathbf{x}) < \infty$. مدل خطی ساده حالت خاصی از مدل خطی عام است؛ بهطوری‌که وقتی $x = g(\mathbf{x})$ ، مدل خطی ساده نتیجه می‌شود. به همین دلیل مدل خطی عام از مدل خطی ساده، انعطاف‌پذیرتر است و به ما اجازه استنباط در مورد مدل‌های پیچیده‌تر را می‌دهد. برای ملاحظه جزئیات بیشتر در این زمینه به [۱] مراجعه شود.

یک مشکل اساسی در مطالعه مدل‌های خطی، کفایت مدل برآششده است. بر همین اساس [۲] آزمون تعیین خطای مشخص‌سازی مدل رگرسیونی و یا به عبارت دقیق‌تر آزمون تعیین خطای معادله رگرسیونی^۱ (RESET) را معرفی کرد که یک ابزار مناسب برای تشخیص عدم‌کفایت مدل است. در برخی از مطالعات ممکن است، برخی از متغیرهای کمکی کنار گذاشته شوند. این امر باعث می‌شود تا یک اریبی حذف متغیر^۲ (OVB) به وجود آید که باعث می‌شود متغیر پاسخ به درستی پیش‌بینی نشود. آزمون رمزی کمک می‌کند تا اثر متغیرهای حذف شده در مدل را تشخیص دهیم. به همین دلیل، آزمون رمزی، بهویژه در مباحث اقتصادسنجی برای تحلیل داده‌های فضایی^۳، کاربرد فراوانی پیدا کرده است، بهطوری‌که در متون اقتصادسنجی آزمون رمزی به آزمون تعیین خطای مشخص‌سازی مدل معروف است. به عنوان نمونه، اخیراً [۳] از آزمون رمزی برای تشخیص چگونگی تأثیر متغیرهای فضایی بر OVB استفاده کردند. عملکرد خوب آزمون رمزی توسط بسیاری از محققین از جمله [۴] مورد بررسی قرار گرفت. نتایج بررسی آن‌ها نشان می‌دهد که با افزایش عدم‌کفایت مدل، احتمال رد مدل برآششده افزایش می‌یابد. در واقع، کاربرد واقعی آزمون رمزی در تشخیص شکل تابعی مدل خطی برآششده است. این آزمون کفایت مدل برآششده را می‌سنجد. در همین راستا، [۵] آزمون رمزی را به مدل‌های خطی تعمیم‌یافته^۴ بسط داد. نتایج خوب آزمون رمزی برای مدل خطی تعمیم‌یافته با استفاده از شبیه‌سازی در [۵] به خوبی نمایان است.

در این مقاله هدف ما بررسی کفایت مدل‌های خطی عام با استفاده از راهکار رمزی است. در این راستا، مشکل اساسی دیگر مطالعات آماری، یعنی حضور داده‌های گم‌شده^۵ در مطالعات را در نظر می‌گیریم. برآشش مدل خطی عام بدون در نظر گرفتن اثر داده‌های گم‌شده، ممکن است منجر به برآوردهای اریب شود که باعث می‌شود از کفایت مدل خطی عام کاسته شود. با استفاده از

1- Regression Equation Specification Error Test

2- Omission-Variable Bias

3-Spatial Data

4- Generalized Linear Models

5 -Missing Data

روش‌های پیشرفته آماری و ابزار پیشرفته محاسباتی، روش‌هایی برای مواجهه با این مشکل مطرح شد. با دسته‌بندی الگوی داده‌های گم‌شده به سه گروه توسط [۶] کار با داده‌های گم‌شده شکل ساده‌تری به خود گرفت. در این مقاله فرض بر این است که داده‌ها از الگوی قابل‌چشم‌پوشی^۱ پیروی می‌کنند. پس فرض بر این است که یا الگوی گم‌شدنگی داده‌ها، بر مبنای تعریف [۷]، به صورت کاملاً تصادفی^۲ (MCAR) و یا به صورت تصادفی^۳ (MAR) است. همچنین، فرض بر این است که داده‌های گم‌شده می‌توانند هم در متغیرهای کمکی و هم در متغیر پاسخ رخ دهند. در [۸] روش‌های جانه‌ی داده‌های گم‌شده موردمطالعه قرار گرفته است و روش‌های برآورد داده‌ها بحث شده است. اما اخیراً توجه بیشتر محققین بر تصحیح معادلات برآورد است تا بتوان با تصحیح معادلات برآورده، برآوردگرهای نااریب و سازگار را به دست آورد. برای مطالعه بیشتر در این زمینه به [۹] و [۱۰] مراجعه شود.

در مطالعات بدون داده گم‌شده [۱۱] و [۱۲] آزمون نیکوبی برازش مدل خطی عام را به ترتیب با استفاده از روش‌های پارامتری و ناپارامتری انجام دادند. در حالتی که متغیر پاسخ با خطا اندازه‌گیری شده باشد، [۱۳] آزمون نوع امتیاز^۴ را برای بررسی کفايت مدل خطی عام به کار برد. در حالتی که الگوی گم‌شدنگی داده‌ها قابل‌چشم‌پوشی باشد، برخی از محققین راهکارهایی معرفی کردند. از جمله، [۱۴] یک آزمون مناسب دیگر بر اساستابع امتیاز معرفی کرد. به علاوه، [۱۵] روش آزمون مناسبی را بر اساس انتگرال کمترین توان دوم فاصله بین برازش‌های ناپارامتری و پارامتری^۵ ساخت، به طوری که داده‌های گم‌شده با یک الگوی قابل‌چشم‌پوشی در داده‌ها رخ می‌دهند.

هدف ما در این مقاله، تعمیم آزمون رمزی برای مدل خطی عام و بهویژه تعمیم این آزمون برای تشخیص کفايت مدل خطی عام در حضور داده‌های گم‌شده است.

در بخش بعد، آماره‌های آزمون مناسب را بر اساس روش‌های مناسب برآورده، در حالت داده‌های کامل و داده‌های ناکامل معرفی خواهیم کرد. در ادامه ویژگی‌های توزیعی آماره‌های ارائه‌شده را به دست می‌آوریم. در بخش ۳، آماره‌های ارائه‌شده را بر اساس شبیه‌سازی چند مسئله آماری، مقایسه خواهیم کرد. در بخش ۴، بر اساس آماره‌های ارائه‌شده، یک مسئله واقعی را در اقتصاد تحلیل خواهیم کرد.

1- Ignorable Mechanism

2- Missing Completely at Random

3- Missing at Random

4- Score-Type Test

5- Minimum Integrated Square Distance Between the Nonparametric and Parametric Fits

۲-آزمون‌های مشخص‌سازی مدل خطی عام و ویژگی‌های آن‌ها

از آزمون رمزی تنها برای بررسی کفايت مدل خطی ساده و مدل خطی چندگانه استفاده می‌شود. اين آزمون بيشتر در كارهای عملی موردنوجه محققین قرار گرفته است و تنها [۵] به صورت نظری به آن پرداخته است و آن را به مدل‌های خطی تعتمید یافته، بسط داده است.

در اين بخش، ابتدا آزمون رمزی را در حالت داده‌های كامل، برای تشخيص کفايت مدل خطی عام بسط می‌دهيم. سپس در بخش ۲-۲ تحت داده‌های گم‌شده، آماره آزمون جدیدی را ارائه خواهيم داد که از داده‌های گم‌شده نيز در مشخص‌سازی مدل خطی عام استفاده می‌كند. در هر مرحله پaramترهای مدل خطی عام را در حالت داده‌های كامل و حالت داده‌های ناكامل با استفاده از روش كمترین توان‌های دوم خطی، برآورد می‌كنيم و برای مشخص‌سازی مدل خطی عام بر اساس روش برآورد اشاره شده، آماره آزمون مناسب را خواهيم ساخت.

۲-۱- حالت داده‌های كامل

برای داده‌های كامل، (Full) معادله برآورد زير را برای برآورد پaramترهای مدل خطی عام رابطه (۱) در نظر می‌گيريم:

$$\sum_{i=1}^n \Psi_{\beta}(y_i | \mathbf{x}_i) = 0, \quad (1)$$

كه در آن برای، $n = 1, \dots, n$ ، $\Psi_{\beta}(y_i | \mathbf{x}_i) = g(\mathbf{x}_i)(y_i - g^T(\mathbf{x}_i)\beta)$ تابع امتياز حاصل از روش برآورد كمترین توان‌های دوم خطأ است. فرض می‌كنيم \hat{y} مقادير برآوري شده متغير پاسخ از مدل خطی رابطه (۱) برای i -امين مشاهده باشد. مدل خطی عام جديد زير را در نظر می‌گيريم:

$$y = g^T(\mathbf{x})\beta + \gamma_1 \hat{y}^1 + \gamma_2 \hat{y}^2 + \dots + \gamma_q \hat{y}^{q+1} + \eta, \quad (2)$$

كه در آن $\gamma_1, \gamma_2, \dots, \gamma_q$ پaramترهای جديد مدل خطی عام هستند و η خطای جديد مدل خطی عام است که از توزيع $(0, \sigma^2)$ پيروی می‌کند. آزمون رمزی فرضيات زير را برای بررسی کفايت مدل خطی عام در نظر می‌گيرد:

$$H_0: \gamma_1 = \gamma_2 = \dots = \gamma_q = 0 \quad vs \quad H_1: \exists i \in \{1, \dots, q+1\} \quad \gamma_i \neq 0.$$

فرض صفر بيان می‌کند که مدل برآوري شده مناسب است اما فرض مقابل بيان می‌کند که مدل برآوري شده کفايت و مشخص‌سازی لازم برای بيان رابطه بين متغير پاسخ و کمکی را ندارد. در واقع آزمون رمزی ميزان تأثير $(g^T(\mathbf{x})\beta)^k$ ها را بر متغير پاسخ را با استفاده از مقادير برآورده شده آن يعني $\hat{y}^1, \hat{y}^2, \dots, \hat{y}^{q+1}$ ها بيان می‌کند و توابع چندجمله‌ای از آن را به فرض مقابل برای بررسی

کفايت مدل اضافه می‌کند. در آزمون رمزی مدل کفايت لازم را ندارد اگر و تنها اگر فرض صفر بودن هر یک از y_i ‌ها رد شود. در این حالت، مدل رگرسیونی تحت رابطه (۱)، مدل نامقید^۱ و مدل رگرسیونی تحت رابطه (۳)، مدل مقید^۲ نامیده می‌شود. بر اساس تابع آزمون رمزی در حالت مدل خطی ساده، توابع زیر را برای ساخت آماره آزمون رمزی برای مدل خطی عام تعریف می‌کنیم. مجموع توان‌های دوم خطا برای مدل نامقید در رابطه (۱) در حالت داده‌های کامل بهصورت زیر تعریف می‌شود:

$$SSE_{U,Full} = \sum_{i=1}^n (y_i - \hat{y}_{Ui})^2,$$

که در آن \hat{y}_i مقادیر برازش شده از مدل نامقید هستند. مجموع توان‌های دوم خطا برای مدل مقید رابطه (۳) در حالت داده‌های کامل بهصورت زیر تعریف می‌شود:

$$SSE_{R,Full} = \sum_{i=1}^n (y_i - \hat{y}_{Ri})^2,$$

که در آن \hat{y}_{Ri} مقادیر برازش شده از مدل مقید هستند. بنابراین، آماره آزمون رمزی در حالت داده‌های کامل بهصورت زیر تعریف می‌شود:

$$F_{Full} = \frac{(SSE_{U,Full} - SSE_{R,Full}) / q}{SSE_{R,Full} / (n - p - q)}. \quad (4)$$

وقتی داده گم شده در مجموعه داده‌ها وجود نداشته باشد، از این آماره آزمون برای بررسی کفايت مدل خطی عام استفاده می‌کنیم که ویژگی‌های توزیعی آن در قسمت پایانی این بخش موردنبحث قرار می‌گیرد.

۲-۲- حالت داده‌های گم شده

بر اساس دسته‌بندی [۶]، گوییم الگوی گم‌شده‌گی داده‌ها MCAR است، اگر و تنها اگر گم‌شده‌گی داده‌ها نه به مشاهدات و نه به داده‌های گم‌شده وابسته باشند. همچنین گوییم الگوی گم‌شده‌گی داده‌ها MAR است، اگر و تنها اگر گم‌شده‌گی داده‌ها تنها به مشاهدات وابسته باشد. این الگوها که گم‌شده‌گی داده‌ها در آن‌ها به داده‌های گم‌شده وابسته نیست، الگوهای قابل‌چشم‌پوشی نامیده می‌شوند.

1- Unrestricted Model

2- Restricted Model

در این بخش حالتی را در نظر می‌گیریم که داده‌های گم شده در متغیر پاسخ و یا در متغیر کمکی رخ می‌دهند. حتی فرض بر این است که داده‌های گم شده می‌توانند در متغیر کمکی و متغیر پاسخ به صورت همزمان رخ دهند. تنها کافی است که یکی از متغیرها به صورت کامل مشاهده شده باشد تا بتوان توابع مجهول از جمله احتمال گم شدگی داده‌ها را برآورد کرد. در این حالت، ساده‌ترین روش برای استنباط در مورد داده‌ها، کنار گذاشتن داده‌هایی است که به صورت ناقص مشاهده شده‌اند و استنباط‌ها با داده‌هایی انجام می‌شود که به صورت کامل مشاهده شده‌اند. این روش، روش حالت کامل^۱ (CC) نامیده می‌شود. بنابراین در این حالت، پارامترهای مدل خطی عam از رابطه زیر به دست می‌آید:

$$\sum_{i=1}^n \delta_i \Psi_{\beta}(y_i | \mathbf{x}_i) = 0, \quad (5)$$

که در آن، δ_i یکتابع نشانگر است و در صورتی که i -امین داده به صورت کامل مشاهده شده باشد، برابر یک و در غیر این صورت برابر صفر است. در این حالت تابع آزمون رمزی به صورت زیر خواهد بود:

$$F_{CC} = \frac{(SSE_{U,CC} - SSE_{R,CC}) / q}{SSE_{R,CC} / (\sum_{i=1}^n \delta_i - p - q)}, \quad (6)$$

که در آن، $SSE_{U,CC}$ و $SSE_{R,CC}$ به ترتیب، مجموع توان‌های دوم خطای مدل‌های مقید و نامفید بر اساس روش برآورد حالت کامل هستند. در رابطه (6)، بر اساس مدل نامقید، داریم:

$$SSE_{U,CC} = \sum_{i=1}^n \delta_i (y_i - \hat{y}_{Ui})^2, \quad (7)$$

و بر اساس مدل مقید، داریم:

$$SSE_{R,CC} = \sum_{i=1}^n \delta_i (y_i - \hat{y}_{Ri})^2. \quad (8)$$

وقتی الگوی گم شدگی داده‌ها MAR است، ممکن است، روش حالت کامل برآوردهای اریب را نتیجه دهد. بنابراین، از یک روش دیگر برای برآورد پارامترهای مدل خطی عam استفاده می‌کنیم. در این روش از وزن‌های معکوس احتمال^۲ (IPW) استفاده می‌شود که اولین بار توسط [۱۶] معرفی شد. این روش برآوردهای نااریب را نتیجه می‌دهد. عملکرد خوب روش IPW در مقایسه

1- Complete Case

2 -Inverse Probability Weights

با روش CC توسط بسیاری از محققین از جمله [۹] و [۱۷] مورد بررسی قرار گرفته است. در روش IPW پارامترهای مدل خطی عام از حل معادلات برآورده زیر به دست می‌آید:

$$\sum_{i=1}^n \frac{\delta_i}{\hat{\pi}_i} \Psi_\beta(y_i | \mathbf{x}_i) = 0, \quad (9)$$

که در آن، π_i احتمال مشاهده i -امین عضو نمونه است. در مطالعات واقعی، مقدار π_i نامعلوم است و می‌توان آن را به صورت ناپارامتری زیر برآورد کرد:

$$\hat{\pi}(v_i) = \frac{\sum_{j=1}^n \delta_j K_h(v_j - v_i)}{\sum_{j=1}^n K_h(v_j - v_i)}, \quad (10)$$

که در آن، v_i i -امین جزء متغیرهای کاملاً مشاهده شده است و K_h یکتابع هسته^۱ با پارامتر هموارسازی^۲ h است. برای مشاهده جزئیات بیشتر در مورد روش وزن معکوس احتمال، رجوع شود به [۱۶] و برای مشاهده جزئیات بیشتر در مورد وزن‌های مناسب به [۱۰] مراجعه شود.

در روش وزن معکوس احتمال، آماره آزمون رمزی به صورت زیر خواهد بود:

$$F_{IPW} = \frac{(SSE_{U,IPW} - SSE_{R,IPW}) / q}{SSE_{R,IPW} / (\sum_{i=1}^n \delta_i - p - q)}, \quad (11)$$

که در آن، $SSE_{U,IPW}$ و $SSE_{R,IPW}$ به ترتیب مجموع توان‌های دوم خطای مقید و نامقید برای مدل برآشش شده بر اساس روش IPW هستند. در رابطه (۱۱)، بر اساس مدل نامقید، داریم:

$$SSE_{U,IPW} = \sum_{i=1}^n \frac{\delta_i}{\hat{\pi}_i} (y_i - \hat{y}_{Ui})^2, \quad (12)$$

و بر اساس مدل مقید، داریم:

$$SSE_{R,IPW} = \sum_{i=1}^n \frac{\delta_i}{\hat{\pi}_i} (y_i - \hat{y}_{Ri})^2. \quad (13)$$

1- Kernel Function

2 -Smoothing Parameter

۳-۲- خواص توزیعی آماره‌های آزمون

در این بخش، برخی از خواص آماره‌های آزمون ارائه شده در بخش ۲ را موردنبررسی قرار می‌دهیم. برای رسیدن به این هدف، نیاز داریم تا تعریف زیر را انجام دهیم.

تعریف ۱: اگر $(y_1, y_2, \dots, y_n) \sim N(\mu, \sigma^2)$ باشد، فرض کنید:

$$F = \frac{\mathbf{y}^T A \mathbf{y} / df_1}{\mathbf{y}^T B \mathbf{y} / df_2}, \quad (14)$$

آنگاه، می‌گوییم F دارای توزیع شبه-فیشر $QF(df_1, df_2, A, B)$ است. به طوری که A و B ماتریس‌های $n \times n$ و df_2 درجات آزادی توزیع شبه-فیشر هستند که به ترتیب رتبه ماتریس‌های A و B هستند.

این توزیع دارای فرم بسته نیست و تنها تحت شرایطی که در تذکر زیر بیان شده است، به توزیع فیشر تبدیل می‌شود.

تذکر ۱: اگر A و B ماتریس‌های متقارن و خودتوان باشند و $AB = 0$. آنگاه، F از توزیع فیشر $F(df_1, df_2)$ پیروی می‌کند. به عبارت دیگر، توزیع فیشر حالت خاصی از توزیع شبه-فیشر است. حال، می‌توانیم خواص توزیعی آماره‌ها را به دست آوریم. این ویژگی‌ها در قضیه زیر داده شده است.

قضیه ۱: تحت فرض صفر داریم:

$$\text{الف)} F_{Full} \sim F(q, n-p-q)$$

$$\text{ب)} F_{CC} \sim F(q, \sum_{i=1}^n \delta_i - p - q)$$

همچنین، به ازای حجم نمونه‌های بزرگ داریم:

$$\text{ج)} F_{IPW} \xrightarrow{D} QF(q, \sum_{i=1}^n \delta_i - p - q, A, B)$$

که در آن اگر $(g(X), Z)$ و W یک ماتریس قطری تعریف شود که درایه‌های قطر اصلی آن برابر با $\frac{\delta_i}{\pi_i}$ است و X ماتریس مشاهدات متغیرهای کمکی باشد. آنگاه، A ، B و Z را به صورت زیر تعریف می‌کنیم.

$$A = W [G(G^T W G)^{-1} G^T - g(X)(g^T(X) W g(X))^{-1} g^T(X)] W,$$

$$B = (W - WG(G^T WG)^{-1} G^T W),$$

$$Z = \begin{bmatrix} \hat{y}_{U,1} & \hat{y}_{U,1} & \cdots & \hat{y}_{U,1}^{q+1} \\ \hat{y}_{U,2} & \hat{y}_{U,2} & \cdots & \hat{y}_{U,2}^{q+1} \\ \vdots & \vdots & \vdots & \vdots \\ \hat{y}_{U,n} & \hat{y}_{U,n} & \cdots & \hat{y}_{U,n}^{q+1} \end{bmatrix}.$$

برهان: برای اثبات قسمت (الف) قضیه ۱، می‌توانیم $SSE_{R,Full}$ را به صورت زیر بنویسیم:

$$\begin{aligned} SSE_{R,Full} &= \sum_{i=1}^n (y_i - \hat{y}_{Ri})^2 = (\mathbf{y} - \hat{\mathbf{y}}_R)^T (\mathbf{y} - \hat{\mathbf{y}}_R) \\ &= (\mathbf{y} - G(G^T G)^{-1} G^T \mathbf{y})^T (\mathbf{y} - G(G^T G)^{-1} G^T \mathbf{y}) \\ &= \mathbf{y}^T (I - H)^T (I - H) \mathbf{y}, \end{aligned}$$

که در آن، I یک ماتریس همانی $n \times n$ و $H = G(G^T G)^{-1} G^T$. به راحتی می‌توان ثابت کرد که H و درنتیجه $I - H$ ماتریس‌های متقارن خودتوان هستند. بنابراین می‌توان نوشت:

$$SSE_{R,Full} = \mathbf{y}^T (I - H) \mathbf{y}. \quad (15)$$

پس، خواهیم داشت:

$$\frac{SSE_{R,Full}}{\sigma^2} \sim \chi^2(n-p-q). \quad (16)$$

که در آن، درجه آزادی از رتبه ماتریس $I - H$ حاصل شده است. چون $I - H$ یک ماتریس متقارن خودتوان است، پس رتبه آن برابر با اثر آن خواهد بود. پس،

$$\begin{aligned} df &= \text{trace}(I - H) = \text{trace}(I) - \text{trace}(G(G^T G)^{-1} G^T) \\ &= n - \text{trace}((G^T G)^{-1} G^T G) = n - \text{trace}(I_{(p+q)(p+q)}) = n - p - q, \end{aligned}$$

که در آن، $I_{(p+q)(p+q)}$ یک ماتریس همانی $(p+q) \times (p+q)$ است. از طرف دیگر، به صورت مشابه با عبارت بالا، می‌توانیم $SSE_{U,Full} - SSE_{R,Full}$ را به صورت زیر بازنویسی کنیم:

$$\begin{aligned} SSE_{U,Full} - SSE_{R,Full} &= \mathbf{y}^T (G(G^T G)^{-1} G^T - g(X)(g^T(X)g(X))^{-1} g^T(X)) \mathbf{y} \\ &:= \mathbf{y}^T H^* \mathbf{y}. \end{aligned} \quad (17)$$

با توجه به رابطه $G(G^T G)^{-1} g(X) = g(X)$ و فرمول معکوس ماتریس افزایش شده، به راحتی می‌توان نتیجه گرفت که H^* یک ماتریس متقارن خودتوان است. بنابراین، می‌توان نوشت:

$$\frac{SSE_{U,Full} - SSE_{R,Full}}{\sigma^2} \sim \chi^2(q). \quad (18)$$

درجه آزادی از اثر ماتریس خودتوان H^* به دست می‌آید که برابر است با:

$$\begin{aligned} df &= \text{trace}(G(G^T G)^{-1} G^T - g(X)(g^T(X)g(X))^{-1} g^T(X)) \\ &= p + q - p = q. \end{aligned} \quad (19)$$

حال، با استفاده از رابطه‌های (16) و (18)، قسمت (الف) قضیه ۱ حاصل می‌شود.

خواص توزیعی آماره آزمون روش حالت کامل از این حقیقت که ما از داده‌های ناقص چشم‌پوشی می‌کنیم و از داده‌های کامل برای استنباط در مورد مدل استفاده می‌کنیم، حاصل می‌شود. در این حالت، ما از $\sum_{i=1}^n \delta_i$ تعداد داده در استنباط‌ها استفاده می‌کنیم. بنابراین بهصورت مشابه با روش داده‌های کامل، آماره آزمون F_{CC} نیز از توزیع فیشر با درجات آزادی کاهش یافته پیروی می‌کند ($F(q, \sum_{i=1}^n \delta_i - p - q)$).

درروش وزن معکوس احتمال، می‌توان پارامترهای مدل خطی عام را با استفاده از معادلات برآورد رابطه (۹) بهصورت زیر استخراج کرد.

$$\hat{\beta} = (X^T \hat{W} X)^{-1} X^T \hat{W} \hat{y} \quad (20)$$

که در آن، \hat{W} یک ماتریس قطری است و درایه i -ام قطر اصلی آن برابر است با $\frac{\delta_i}{\hat{\pi}_i}$. از طرف دیگر، می‌توان نوشت:

$$\begin{aligned} SSE_{U,IPW} &= \sum_{i=1}^n \frac{\delta_i}{\pi_i} (y_i - \hat{y}_i)^2 = (\mathbf{y} - \hat{\mathbf{y}})^T \hat{W} (\mathbf{y} - \hat{\mathbf{y}}) \\ &= (\mathbf{y} - g(X)(g^T(X)\hat{W}g(X))^{-1}g^T(X)\hat{W}\mathbf{y})^T \hat{W} \\ &\quad \times (\mathbf{y} - g(X)(g^T(X)\hat{W}g(X))^{-1}g^T(X)\hat{W}\mathbf{y}) \\ &= \mathbf{y}^T (I - g(X)(g^T(X)\hat{W}g(X))^{-1}g^T(X)\hat{W})^T \hat{W} \\ &\quad \times (I - g(X)(g^T(X)\hat{W}g(X))^{-1}g^T(X)\hat{W})\mathbf{y} \\ &= \mathbf{y}^T (\hat{W} - \hat{W}g(X)(g^T(X)\hat{W}g(X))^{-1}g^T(X)\hat{W})\mathbf{y}. \end{aligned}$$

با توجه به این که درایه‌های قطر اصلی ماتریس \hat{W} شامل $(\hat{\pi}_i)_{i=1}^n$ است. می‌توان ثابت کرد که به ازای حجم نمونه بزرگ و پارامتر هموارسازی کوچک، $E(\hat{\pi}(\cdot)) = \pi(\cdot) + o_p(1)$ و $Var(\hat{\pi}(\cdot)) = o_p(1)$ که در آن، $(1 - \hat{\pi}_i)^{-1}$ نماد اوی کوچک در احتمال است. بنابراین با استفاده از نابرابری چبیشف نتیجه می‌شود که $\hat{\pi}_i = \pi(\cdot) + o_p(1)$. پس درایه i -ام قطر اصلی ماتریس \hat{W} معادل خواهد بود با $\frac{\delta_i}{\pi_i} + o_p(1)$. حال با توجه به پیوستگیتابع $SSE_{U,IPW}$ در \hat{W} می‌توان نتیجه گرفت:

$$SSE_{U,IPW} = \mathbf{y}^T (W - Wg(X)(g^T(X)Wg(X))^{-1}g^TW)\mathbf{y} + o_p(1). \quad (21)$$

که در آن، W یک ماتریس قطری است و درایه i -ام قطر اصلی آن برابر است با $\frac{\delta_i}{\pi_i}$. بهصورت مشابه می‌توان نتیجه گرفت:

$$SSE_{R,IPW} = \mathbf{y}^T (W - WG(G^T W G)^{-1}G^T W)\mathbf{y} + o_p(1). \quad (22)$$

بنابراین، با به کار بردن چند عملیات ریاضی ساده، خواهیم داشت:

$$\begin{aligned} F_{IPW} &= \frac{(SSE_{U,IPW} - SSE_{R,IPW})/q}{SSE_{R,IPW}/(\sum_{i=1}^n \delta_i - p - q)} \\ &= \frac{(\mathbf{y}^T (W [G(G^T W G)^{-1}G^T - g(X)(g^T(X)Wg(X))^{-1}g^T(X)W]\mathbf{y})/q + o_p(1))}{(\mathbf{y}^T (W - WG(G^T W G)^{-1}G^T W)\mathbf{y})/(\sum_{i=1}^n \delta_i - p - q)} \end{aligned} \quad (23)$$

در نهایت می‌توان آماره آزمون روش IPW را بهصورت زیر نوشت:

$$\begin{aligned} F_{IPW} &= \frac{(SSE_{U,IPW} - SSE_{R,IPW})/q}{SSE_{R,IPW}/(\sum_{i=1}^n \delta_i - p - q)} \\ &= \frac{(\mathbf{y}^T (W [G(G^T W G)^{-1}G^T - g(X)(g^T(X)Wg(X))^{-1}g^T(X)W]\mathbf{y})/q + o_p(1))}{(\mathbf{y}^T (W - WG(G^T W G)^{-1}G^T W)\mathbf{y})/(\sum_{i=1}^n \delta_i - p - q)} \end{aligned}$$

حال، با استفاده از تعریف ۱ و قضیه مینکووسکی^۱ قسمت (ج) قضیه ۱ نتیجه می‌شود. همچنین، درجات آزادی به صورت مشابه با اثبات قسمت (ب) قضیه ۱ نتیجه می‌شود. ■

در قضیه ۱، آماره آزمون‌ها در روش داده‌های کامل و روش حالت کامل از توزیع دقیق فیشر پیروی می‌کنند. همچنین، در روش وزن معکوس احتمال، نیاز به برآورد مقادیر نامعلوم (π) داریم که باعث می‌شود تا آماره آزمون این روش به توزیع شبه-فیشر همگرا شود.

تذکر ۲: در مسئله شبیه‌سازی و مطالعه داده‌های واقعی برای محاسبه p -value نیاز داریم که مقادیر چندک‌های توزیع شبه-فیشر را به دست آوریم. برای این منظور چندک‌های p -ام توزیع شبه-فیشر را از الگوریتم زیر با استفاده از شبیه‌سازی تقریب می‌زنیم:

گام ۱.تابع آزمون F_{IPW} را N بار تولید کنید.

گام ۲. در این گام F_{IPW} ها را از گام ۱ مرتب کنید و مقدار $\lfloor pN + 1 \rfloor$ -ام آن را ذخیره کنید (نماد $\lfloor \cdot \rfloor$ بیانگر جزء صحیح است).

گام ۳. گام‌های ۱ و ۲ را t بار تکرار کنید.

گام ۴. برای تقریب چندک p -ام، از مقادیر ذخیره شده F_{IPW} ها در گام ۲، میانگین بگیرید.

F_{IPW} با توجه به رابطه (۱۱) تولید می‌شود. همچنین t تعداد تکرارهای الگوریتم مونت‌کارلو را نشان می‌دهد. بنابراین هر چه مقدار t بزرگ‌تر باشد، انتظار داریم مقادیر برآورد شده از توزیع شبه-فیشر به مقدار واقعی نزدیک‌تر باشند. مطالعات اولیه ما نشان می‌دهد که انتخاب مقادیر بزرگ‌تر از 50° به برآوردهای مناسب منجر می‌شود. در این مقاله مقدار $t = 1000$ اختیار شده است.

۳-شبیه‌سازی چند مسئله

در این بخش، عملکرد تابع آزمون‌های معرفی شده را بحث خواهیم کرد. مسئله شبیه‌سازی را به دو مرحله تقسیم می‌کنیم. در مرحله اول، مدل خطی عام با دو متغیر کمکی را در نظر می‌گیریم و در مرحله دوم، مدل خطی عام با سه متغیر کمکی را در نظر می‌گیریم. برای مشاهده اثر حجم نمونه در مطالعات، در هر مرحله از شبیه‌سازی از حجم نمونه‌های 50° و 100° استفاده می‌کنیم. همچنین، برای مشاهده اثر الگوی گم‌شدنگی بر تحلیل‌ها، از الگوهای مختلف استفاده می‌کنیم.

در آزمون رمزی فرض مقابله باعث می‌شود تا مدل خطی عام تحت این فرض به مقادیر برآورد شده متغیر پاسخ از فرض صفر وابسته باشد. این امر باعث می‌شود تا نتوان از فرض مقابله برای

تولید داده‌ها استفاده کرد. برای حل این مشکل همانند آزمون‌های ارائه شده به روش تابع امتیاز عمل می‌کنیم که بر صحت مسئله تأثیرگذار نیست. داده‌ها را از مدل خطی عام زیر تولید می‌کنیم:

$$y = g^T(\mathbf{x})\beta + ch(\mathbf{x}) + \varepsilon, \quad (24)$$

و مدل خطی عام رابطه (۱) را بر داده‌ها برازش می‌دهیم. در هر مرحله برای مقادیر مختلف c ، توان تجربی (EP) رد فرض صفر را حساب می‌کنیم که با افزایش مقدار c از فرض صفر دورتر می‌شویم. وقتی $c = 0$ ، مدل خطی عام رابطه (۲۴) با مدل خطی عام رابطه (۱) معادل است. همچنانی، دو نوع متفاوت از مدل خطی عام مقید زیر را در نظر می‌گیریم تا اثر قیدهای مختلف را نیز مشاهده کنیم.

$$\begin{aligned} \text{RESET ۱: } y &= g^T(\mathbf{x})\beta + \gamma_1 \hat{y}^\top + \eta, \\ \text{RESET ۲: } y &= g^T(\mathbf{x})\beta + \gamma_1 \hat{y}^\top + \gamma_2 \hat{y}^\top + \eta. \end{aligned}$$

در هر مرحله، توان تجربی رد فرض صفر با استفاده از 2000 تکرار الگوریتم مونت‌کارلو^۱ برآورد شده است.

۳-۱- مرحله اول: مدل خطی عام با دو متغیر کمکی

در رابطه (۲۴)، فرض کنید،

$$\begin{aligned} h(\mathbf{x}) &= \sqrt{1 + \sin(2\pi x_1) + \frac{(1+x_2)}{4}}, \\ g(\mathbf{x}) &= (1 + \sin(2\pi x_1), \frac{(1+x_2)}{4})^T, \end{aligned}$$

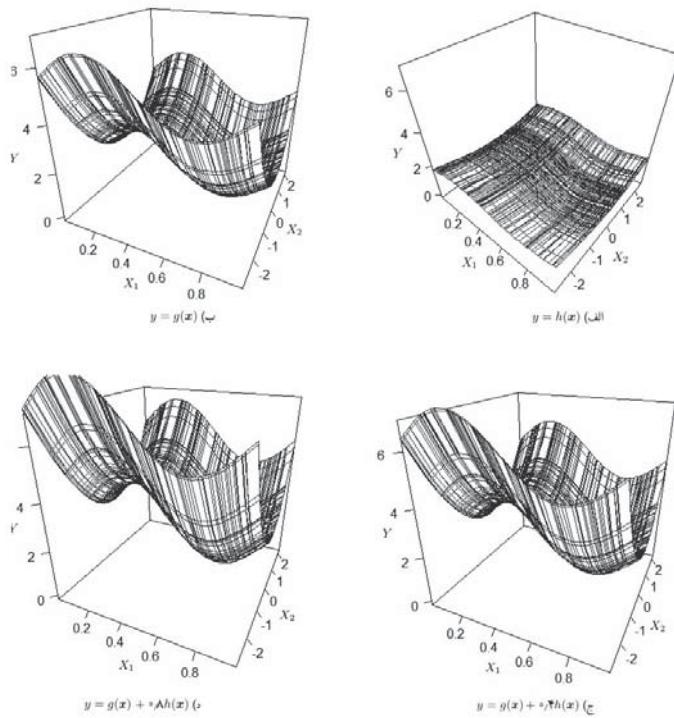
که در آن، x_1 از توزیع یکنواخت $(0, 1) U$ تولید می‌شود، x_2 از توزیع نرمال $(0, 1) N$ تولید می‌شود، ε یک متغیر تصادفی از توزیع نرمال $(0, 1) N$ است و پارامترهای مدل خطی عام برابر با بردار $(1, 2)$ در نظر گرفته شده است.

الگوهای گمشدگی زیر را برای تولید داده‌های گمشده در متغیر پاسخ در نظر می‌گیریم:

$$\begin{aligned} \text{حالت اول: } \pi_1(\mathbf{x}_i) &= 1 / (1 + e^{-\left(\frac{\left((1+\sin(2\pi x_{1i})) + \frac{(1+x_{2i})}{4}\right)}{\Delta}\right)}) \\ \text{حالت دوم: } \pi_2(\mathbf{x}_i) &= 0 / 73 \end{aligned}$$

¹-Monte Carlo

با استفاده از هر دو الگوی گمشده، تقریباً ۲۷ داده گمشده در متغیر پاسخ رخ می‌دهد. در حالی که در اولینتابع گمشده از الگوی گمشده MAR پیروی می‌کند و تابع بعدی از الگوی MCAR پیروی می‌کند.



شکل (۱): نمودارهای مختلف مربوط به اجزای مدل‌های خطی عام تحت فرض صفر و فرض مقابله. نمودار (الف) جزء $h(\mathbf{x})$ از فرض مقابله را نشان می‌دهد که در هر مرحله از شبیه‌سازی به مدل خطی عام تحت فرض صفر (نمودار (ب)) با ضریب c اضافه می‌شود تا فرض مقابله شود. نمودارهای (ج) و (د) نیز به ترتیب مدل خطی عام را تحت فرض مقابله از مقادیر $c = 0 / 4 / 8$ نشان می‌دهند.

در شکل (۱) نمودارهای مختلف رسم شده است تا دید بهتری از شکل مدل خطی عام تحت فرض صفر در مقایسه با مدل خطی عام تحت فرض مقابله داشته باشیم. در این شکل، نمودار (ب) مدل خطی عام را تحت فرض صفر نشان می‌دهد که با اضافه شدن ضریبی از تابع $h(\mathbf{x})$ ، مدل‌های مفروض تحت رابطه (۲۴) به دست می‌آید. دو نمونه از نمودارهای مفروض تحت رابطه (۲۴) در شکل (۱) در قسمت (ج) و (د) داده شده است.

جدول (۱): مرحله اول: توان تجربی رد فرض صفر بر اساس قید RESET1 به ازای حجم نمونه ۵۰ و ۱۰۰ (Full: حالت دادههای کامل؛ CC: حالت کامل؛ IPW: وزن معکوس احتمال).

<i>n</i>								الگوی گمشدگی	
۱۰۰			۵۰			C			
IPW	CC	Full	IPW	CC	Full				
۰/۰۴۹۵	۰/۵۱۰	۰/۰۵۳۰	۰/۰۵۲۵	۰/۰۵۰۰	۰/۰۴۳۵	۰/۰۰			
۰/۰۶۸۵	۰/۰۶۳۰	۰/۰۷۲۵	۰/۰۶۱۵	۰/۰۵۸۵	۰/۰۶۰۰	۰/۱۰			
۰/۱۱۳۵	۰/۱۱۱۵	۰/۱۳۶۵	۰/۰۸۷۰	۰/۰۸۸۰	۰/۱۰۱۵	۰/۲۰			
۰/۲۰۳۰	۰/۱۹۱۰	۰/۲۸۵۰	۰/۱۲۹۰	۰/۱۴۹۵	۰/۱۵۲۰	۰/۳۰			
۰/۳۲۱۵	۰/۳۰۲۵	۰/۴۲۴۵	۰/۱۸۳۰	۰/۱۷۷۵	۰/۲۲۴۵	۰/۴۰			
۰/۴۵۹۵	۰/۴۳۸۵	۰/۵۷۸۵	۰/۲۴۵۰	۰/۲۳۴۵	۰/۳۲۴۰	۰/۵۰			
۰/۶۱۲۰	۰/۵۸۷۰	۰/۷۳۸۵	۰/۳۳۳۵	۰/۳۱۰۰	۰/۴۳۴۵	۰/۶۰	$\pi_1: MAR$		
۰/۷۴۶۵	۰/۷۲۵۰	۰/۸۵۸۵	۰/۴۲۳۵	۰/۴۱۲۵	۰/۵۴۹۰	۰/۷۰			
۰/۸۴۵۰	۰/۸۲۵۵	۰/۹۳۰۰	۰/۵۱۹۵	۰/۵۰۵۵	۰/۶۶۲۵	۰/۸۰			
۰/۹۱۰۰	۰/۹۰۰۰	۰/۹۶۸۵	۰/۶۰۲۵	۰/۵۸۹۵	۰/۷۶۳۰	۰/۹۰			
۰/۹۵۶۰	۰/۹۴۸۵	۰/۹۸۸۰	۰/۶۹۸۵	۰/۶۸۶۸	۰/۸۳۹۰	۱/۰۰			
۰/۹۷۷۵	۰/۹۷۵۵	۰/۹۹۴۵	۰/۷۷۷۵	۰/۷۶۵۵	۰/۸۹۵۰	۱/۱۰			
۰/۹۸۵۵	۰/۹۸۴۵	۰/۹۹۹۰	۰/۸۴۴۰	۰/۸۳۵۰	۰/۹۳۰۰	۱/۲۰			
۰/۰۵۹۵	۰/۰۵۸۵	۰/۰۵۳۰	۰/۰۵۶۰	۰/۰۵۳۵	۰/۰۴۳۵	۰/۰۰			
۰/۰۶۰۰	۰/۰۶۵۰	۰/۰۷۲۵	۰/۰۶۳۵	۰/۰۶۰۰	۰/۰۶۵۵	۰/۱۰			
۰/۱۱۷۰	۰/۱۱۲۰	۰/۱۳۶۵	۰/۰۸۶۵	۰/۰۸۶۵	۰/۱۰۱۵	۰/۲۰			
۰/۲۰۵۵	۰/۱۹۸۰	۰/۲۵۸۰	۰/۱۲۲۵	۰/۱۲۱۰	۰/۱۵۲۰	۰/۳۰			
۰/۳۱۲۵	۰/۳۰۲۵	۰/۴۱۴۵	۰/۱۸۱۵	۰/۱۷۴۰	۰/۲۲۴۵	۰/۴۰			
۰/۴۵۹۵	۰/۴۴۶۰	۰/۵۷۸۵	۰/۲۵۲۰	۰/۲۴۷۰	۰/۳۲۴۰	۰/۵۰			
۰/۶۰۰۰	۰/۵۸۸۰	۰/۷۳۸۵	۰/۳۳۹۰	۰/۳۳۳۵	۰/۴۳۴۵	۰/۶۰			
۰/۷۳۰۵	۰/۷۲۷۰	۰/۸۵۸۵	۰/۴۲۳۰	۰/۴۱۹۵	۰/۴۴۹۰	۰/۷۰	$\pi_2: MCAR$		
۰/۸۳۴۰	۰/۸۲۷۰	۰/۹۳۰۰	۰/۵۲۲۰	۰/۵۱۱۰	۰/۶۶۲۵	۰/۸۰			
۰/۹۰۴۵	۰/۹۰۰۰	۰/۹۶۸۵	۰/۶۱۱۵	۰/۶۰۰۰	۰/۷۶۳۰	۰/۹۰			
۰/۹۴۵۰	۰/۹۴۶۰	۰/۹۸۸۰	۰/۶۹۹۰	۰/۶۹۷۰	۰/۸۳۹۰	۱/۰۰			
۰/۹۶۹۰	۰/۹۶۹۵	۰/۹۹۴۵	۰/۷۸۰۵	۰/۷۷۷۵	۰/۸۹۵۰	۱/۱۰			
۰/۹۸۳۵	۰/۹۸۳۵	۰/۹۹۹۰	۰/۸۳۸۵	۰/۸۳۵۵	۰/۹۳۰۰	۱/۲۰			

جدول (۲): مرحله اول: توان تجربی رد فرض صفر بر اساس قید RESET^۲ به ازای حجم نمونه ۵۰ و ۱۰۰ (Full: حالت داده‌های کامل؛ CC: حالت کامل؛ IPW: وزن معکوس احتمال).

<i>n</i>								الگوی گمشدگی	
۱۰۰			۵۰			C			
IPW	CC	Full	IPW	CC	Full				
۰/۰۴۵۰	۰/۰۴۶۵	۰/۰۵۲۵	۰/۰۴۹۰	۰/۰۵۲۵	۰/۰۵۰۰	۰/۰۰	$\pi_1: MAR$		
۰/۰۶۰۵	۰/۰۶۱۰	۰/۰۷۰۵	۰/۰۵۸۵	۰/۰۶۳۵	۰/۰۶۳۰	۰/۱۰			
۰/۱۰۴۰	۰/۱۰۳۰	۰/۱۲۴۰	۰/۰۸۰۵	۰/۰۷۸۵	۰/۰۸۵۰	۰/۲۰			
۰/۱۷۷۵	۰/۱۷۴۵	۰/۲۳۹۰	۰/۱۱۳۵	۰/۱۰۶۰	۰/۱۳۴۵	۰/۳۰			
۰/۲۹۱۵	۰/۲۷۱۰	۰/۳۷۷۰	۰/۱۶۲۰	۰/۱۵۲۰	۰/۱۹۶۵	۰/۴۰			
۰/۴۱۶۵	۰/۴۰۰۰	۰/۵۳۵۵	۰/۲۱۳۰	۰/۲۰۵۰	۰/۲۸۵۰	۰/۵۰			
۰/۵۵۲۰	۰/۵۳۷۰	۰/۶۸۸۵	۰/۲۸۶۵	۰/۲۷۵۰	۰/۳۷۸۰	۰/۶۰			
۰/۶۹۷۰	۰/۶۷۵۵	۰/۸۲۹۵	۰/۳۶۷۵	۰/۳۵۴۵	۰/۵۰۳۰	۰/۷۰			
۰/۸۱۴۰	۰/۸۰۱۵	۰/۹۰۹۰	۰/۴۵۴۵	۰/۴۵۳۵	۰/۶۰۲۵	۰/۸۰			
۰/۸۸۶۰	۰/۸۷۷۰	۰/۹۵۲۵	۰/۵۴۸۵	۰/۵۴۰۰	۰/۷۰۴۵	۰/۹۰			
۰/۹۳۶۰	۰/۹۳۵۵	۰/۹۸۶۰	۰/۶۲۵۵	۰/۶۲۱۰	۰/۷۹۲۵	۱/۰۰			
۰/۹۶۷۵	۰/۹۶۴۵	۰/۹۹۵۰	۰/۷۰۹۰	۰/۷۱۰۰	۰/۸۶۶۰	۱/۱۰			
۰/۹۸۲۵	۰/۹۸۴۵	۰/۹۹۸۰	۰/۷۸۵۵	۰/۷۹۴۵	۰/۹۱۴۵	۱/۲۰			
۰/۰۵۳۰	۰/۰۵۱۵	۰/۰۵۲۵	۰/۰۵۲۰	۰/۰۵۶۰	۰/۰۵۰۰	۰/۰۰	$\pi_2: MAR$		
۰/۰۶۴۵	۰/۰۶۲۵	۰/۰۷۰۵	۰/۰۵۸۰	۰/۰۶۸۰	۰/۰۶۳۰	۰/۱۰			
۰/۱۰۰۵	۰/۰۹۵۵	۰/۱۲۴۰	۰/۰۷۷۰	۰/۰۷۷۵	۰/۰۸۵۰	۰/۲۰			
۰/۱۶۸۰	۰/۱۶۶۵	۰/۲۳۹۰	۰/۱۰۷۵	۰/۱۰۸۰	۰/۱۳۲۵	۰/۳۰			
۰/۲۷۵۵	۰/۲۶۹۵	۰/۳۷۷۰	۰/۱۵۹۵	۰/۱۵۰۵	۰/۱۹۶۵	۰/۴۰			
۰/۴۱۴۷	۰/۴۰۶۵	۰/۵۳۵۵	۰/۲۱۵۰	۰/۲۰۹۰	۰/۲۸۵۰	۰/۵۰			
۰/۵۴۶۰	۰/۵۴۲۰	۰/۶۸۸۵	۰/۲۸۰۰	۰/۲۷۷۵	۰/۳۷۸۰	۰/۶۰			
۰/۶۷۸۵	۰/۶۷۹۵	۰/۸۲۹۸	۰/۳۷۰۵	۰/۳۶۸۰	۰/۵۰۳۰	۰/۷۰			
۰/۸۰۱۰	۰/۸۰۳۰	۰/۹۰۹۰	۰/۴۵۴۰	۰/۴۵۱۵	۰/۶۰۲۵	۰/۸۰			
۰/۹۲۵۵	۰/۹۲۵۰	۰/۹۸۶۰	۰/۵۵۰۵	۰/۵۴۳۰	۰/۷۰۴۵	۰/۹۰			
۰/۹۲۵۵	۰/۹۲۵۰	۰/۹۸۶۰	۰/۶۴۰۵	۰/۶۳۲۰	۰/۷۹۲۵	۱/۰۰			
۰/۹۶۱۰	۰/۹۵۹۵	۰/۹۹۵۰	۰/۷۱۱۵	۰/۷۱۷۵	۰/۸۶۶۰	۱/۱۰			
۰/۹۷۸۵	۰/۹۸۱۵	۰/۹۹۸۰	۰/۷۸۳۰	۰/۷۸۸۰	۰/۹۴۵۰	۱/۲۰			

نمودار (ج) بیانگر مدل خطی عام تحت فرض مقابله با ضریب ثابت $c = 0 / ۴$ و نمودار (د) بیانگر مدل خطی عام تحت فرض مقابله با ضریب ثابت $c = ۰ / ۸$ است. تابع $h(\mathbf{x})$ یک تابع مثبت است، بنابراین با افزایش مقدار c ، مدل‌های جدید اندکی به سمت بالا انتقال می‌یابند. همچنین شکل تقریباً مسطح تابع $h(\mathbf{x})$ باعث می‌شود تا نمودارهای تحت فرض مقابله در مقایسه با نمودار تحت فرض صفر از لحاظ ظاهری تفاوت چندانی نداشته باشند. این ویژگی‌های تابع $h(\mathbf{x})$ باعث می‌شود تا با افزایش مقدار c ، توان آزمون بهصورت آهسته افزایش یابد. درصورتی که تابع $h(\mathbf{x})$ را طوری انتخاب می‌کردیم که شکل نمودارها تحت فرض مقابله تغییرات بیشتری می‌داشت، با افزایش مقدار c احتمال رد فرض صفر از حالت قبلی خیلی بیشتر می‌شد. به همین دلیل $h(\mathbf{x})$ را تقریباً مسطح اختیار کردیم تا عملکرد آماره‌های پیشنهادشده در بدترین حالات نیز مطالعه شود. نتایج مرحله اول با توجه به آماره‌های RESET_1 و RESET_2 به ترتیب در جدول‌های (۱) و (۲) داده شده است.

۳-۲-۳- مرحله دوم: مدل خطی عام با یک متغیر کمکی

برای مدل خطی عام رابطه (۲۴)، فرض کنید، $g(\mathbf{x}) = (x_1, \frac{(1+x_2)}{4}, x_2)^T$ و $U(x_1 + x_2, h(\mathbf{x})) = N(0, 1)$. که در آن، x_1 از توزیع نرمال $N(0, 1)$ و x_2 از توزیع یکنواخت $U(0, 1)$ و x_2 از توزیع نرمال $N(0, 1)$ تولید می‌شوند. ϵ خطای نمونه‌گیری تصادفی از توزیع نرمال $N(0, 1)$ و پارامترهای مدل خطی عام برابر با بردار $(1, 2, 3)$ است.

الگوهای گم‌شده‌گی زیر را برای تولید داده‌های گم‌شده در متغیر پاسخ y و متغیر کمکی x_1 در نظر می‌گیریم.

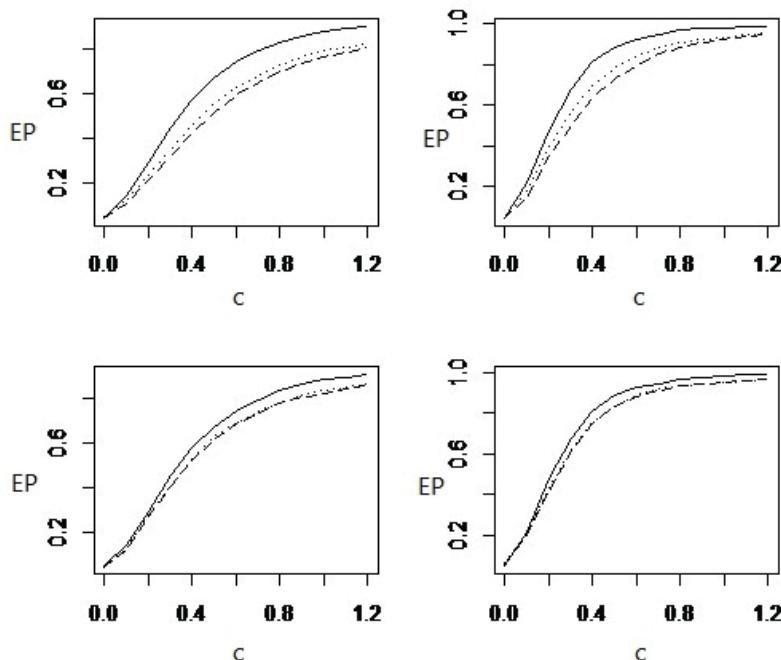
$$\text{حالت سوم: } \pi_r(\mathbf{x}_i) = 1 / (1 + e^{(-\alpha / \Delta x_{ri}^T)}) ,$$

$$\text{حالت چهارم: } \pi_r(\mathbf{x}_i) := \begin{cases} \pi_{r1}(\mathbf{x}_i) = 1 / (1 + e^{(-\alpha / (\Delta x_{1i}^T + x_{1i}^T + x_{2i}^T)))}) \\ \pi_{r2}(\mathbf{x}_i) = 1 / (1 + e^{(-\alpha / (\Delta x_{2i}^T + x_{1i}^T + x_{2i}^T)))}) \end{cases}$$

با استفاده از الگوهای فوق، در هر دو حالت، بهطور متوسط \bar{x}_1 داده گم‌شده در متغیرها ایجاد می‌شود. در حالت سوم، متغیر پاسخ y و متغیر کمکی x_1 یا بهصورت همزمان گم‌شده هستند و یا بهصورت همزمان مشاهده شده‌اند. اما در حالت چهارم، π_{r1} احتمال آن است که متغیر پاسخ y گم‌شده باشد. از طرف دیگر، π_{r2} احتمال آن است که متغیر کمکی x_1 گم‌شده باشد، بهشرط آن که متغیر پاسخ y مشاهده شده باشد. همچنین با استفاده از الگوی گم‌شده‌گی π_{r2} ، π_{r1} داده گم‌شده در متغیر پاسخ y خواهیم داشت و با استفاده از الگوی گم‌شده‌گی π_{r1}

، $13/5\%$ داده گم شده در متغیر کمکی π_1 خواهیم داشت. بنابراین در حالت چهارم نیز به طور متوسط 29% داده گم شده در داده ها خواهیم داشت.

نتایج مرحله دوم در جدول های (۳) و (۴) داده شده است. همچنین، نمودار توان تجربی رد فرض صفر به ازای قید RESET1 در شکل (۲) داده شده است. در شکل (۲)، نمودارهای بالایی، توان تجربی رد فرض صفر را به ازای الگوی گم شدگی π_4 نشان می دهند. همچنین نمودارهای پایینی، توان تجربی رد فرض صفر را به ازای الگوی گم شدگی π_5 نشان می دهند. به علاوه، نمودارهای سمت راست، بر اساس نمونه ۵۰ تایی و نمودارهای سمت راست، بر اساس نمونه ۱۰۰ هستند.



شکل (۲): نمودار توان تجربی رد فرض صفر برای مقادیر مختلف c تحت مرحله دوم بر اساس قید RESET1: نمودارهای بالایی بر اساس الگوی گم شدگی π_4 و نمودارهای پایینی بر اساس الگوی گم شدگی π_5 هستند. نمودارهای سمت چپ بر اساس نمونه ۵۰ تایی و نمودارهای سمت راست بر اساس نمونه ۱۰۰ تایی هستند. همچنین، نمودارهای خط ممتد، نمودارهای خط تیره و نمودارهای نقطه ای به ترتیب توان تجربی آماره آزمون های روش داده های کامل، روش حالت کامل و روش وزن معکوس احتمال را نشان می دهند.

جدول (۳): مرحله دوم: توان تجربی رد فرض صفر بر اساس قید ۱ RESET به ازای حجم نمونه ۵۰ و ۱۰۰ (Full) : حالت دادههای کامل؛ CC: حالت کامل؛ IPW: وزن معکوس احتمال).

<i>n</i>							
۱۰۰			۵۰			الگوی گمشدگی	
IPW	CC	Full	IPW	CC	Full	C	
۰/۰۴۸۵	۰/۰۴۸۵	۰/۰۴۵۵	۰/۰۵۴۰	۰/۰۴۷۰	۰/۰۴۵۵	۰/۰۰	
۰/۱۷۰۰	۰/۱۴۵۰	۰/۲۱۳۵	۰/۱۲۶۵	۰/۱۱۰۵	۰/۱۴۸۰	۰/۱۰	
۰/۴۰۱۰	۰/۳۵۰۵	۰/۴۷۶۵	۰/۲۳۵۰	۰/۲۱۳۵	۰/۲۹۵۵	۰/۲۰	
۰/۵۶۸۵	۰/۵۰۱۰	۰/۶۷۶۰	۰/۳۵۳۰	۰/۳۲۳۰	۰/۴۵۵۰	۰/۳۰	
۰/۶۹۸۰	۰/۶۳۲۰	۰/۸۱۰۰	۰/۴۶۱۰	۰/۴۲۱۰	۰/۵۷۶۵	۰/۴۰	
۰/۷۸۳۰	۰/۷۲۹۰	۰/۸۸۳۵	۰/۵۵۷۵	۰/۵۱۷۰	۰/۶۷۰۰	۰/۵۰	$\pi_1: MAR$
۰/۸۴۳۵	۰/۷۹۷۵	۰/۹۲۴۰	۰/۶۳۰۵	۰/۵۹۲۵	۰/۷۴۲۰	۰/۶۰	
۰/۸۸۱۵	۰/۸۵۱۵	۰/۹۴۵۵	۰/۶۸۲۵	۰/۶۵۳۰	۰/۷۹۳۵	۰/۷۰	
۰/۹۰۹۰	۰/۸۸۴۰	۰/۹۶۶۰	۰/۷۳۰۰	۰/۵۹۹۰	۰/۸۳۱۰	۰/۸۰	
۰/۹۲۵۰	۰/۹۰۸۵	۰/۹۷۳۰	۰/۷۶۵۰	۰/۷۳۴۵	۰/۸۶۲۰	۰/۹۰	
۰/۹۳۳۵	۰/۹۲۳۰	۰/۹۷۹۵	۰/۷۹۲۵	۰/۷۶۶۰	۰/۸۸۲۰	۱/۰۰	
۰/۹۴۷۵	۰/۹۳۶۵	۰/۹۸۵۵	۰/۸۱۲۰	۰/۷۹۱۰	۰/۸۹۴۰	۱/۱۰	
۰/۹۵۴۰	۰/۹۴۴۵	۰/۹۸۷۵	۰/۸۲۹۵	۰/۸۰۹۵	۰/۹۰۴۵	۱/۲۰	
۰/۰۶۴۵	۰/۰۵۷۵	۰/۰۴۵۵	۰/۰۵۰۰	۰/۰۴۶۰	۰/۰۵۰۰	۰/۰۰	
۰/۲۱۴۵	۰/۲۰۰۰	۰/۲۱۳۵	۰/۱۲۹۰	۰/۱۲۶۵	۰/۱۴۸۰	۰/۱۰	
۰/۴۳۱۵	۰/۴۱۹۰	۰/۴۷۶۵	۰/۲۸۳۵	۰/۲۷۴۵	۰/۲۹۵۵	۰/۲۰	
۰/۶۱۸۵	۰/۶۱۳۰	۰/۶۷۶۰	۰/۴۰۲۷	۰/۴۰۸۰	۰/۴۵۵۰	۰/۳۰	
۰/۷۵۷۰	۰/۷۴۸۵	۰/۸۱۰۰	۰/۵۲۹۵	۰/۵۲۱۵	۰/۵۷۶۵	۰/۴۰	
۰/۸۲۹۵	۰/۸۳۰۰	۰/۸۸۳۵	۰/۶۲۶۰	۰/۶۱۷۵	۰/۶۷۰۰	۰/۵۰	
۰/۸۸۶۰	۰/۸۷۹۵	۰/۹۲۴۰	۰/۶۹۳۰	۰/۶۸۲۵	۰/۷۴۲۰	۰/۶۰	$\pi_2: MAR$
۰/۹۱۴۵	۰/۹۱۱۵	۰/۹۴۵۵	۰/۷۳۹۰	۰/۷۳۳۰	۰/۷۹۳۵	۰/۷۰	
۰/۹۳۲۰	۰/۹۳۳۵	۰/۹۶۶۰	۰/۷۸۰۰	۰/۷۷۴۵	۰/۸۳۱۰	۰/۸۰	
۰/۹۴۳۵	۰/۹۴۲۵	۰/۹۷۳۰	۰/۸۱۳۵	۰/۸۰۷۵	۰/۸۶۲۰	۰/۹۰	
۰/۹۵۰۵	۰/۹۵۳۰	۰/۹۷۹۵	۰/۸۳۳۵	۰/۸۲۲۵	۰/۸۸۲۰	۱/۰۰	
۰/۹۵۵۰	۰/۹۶۱۰	۰/۹۸۵۵	۰/۸۴۹۵	۰/۸۴۵۰	۰/۸۹۴۰	۱/۱۰	
۰/۹۶۳۰	۰/۹۶۵۰	۰/۹۸۷۵	۰/۸۵۹۵	۰/۸۵۷۰	۰/۹۰۴۵	۱/۲۰	

جدول (۴): مرحله دوم؛ توان تجربی رد فرض صفر بر اساس قید RESET^۲ به ازای حجم نمونه ۵۰ و ۱۰۰ (Full)؛ حالت داده‌های کامل؛ CC: حالت کامل؛ IPW: وزن معکوس احتمال).

<i>n</i>							
۱۰۰			۵۰			الگوی گمشده‌گی	
IPW	CC	Full	IPW	CC	Full	C	
۰/۰۴۸۵	۰/۰۴۸۵	۰/۰۴۵۵	۰/۰۵۰۰	۰/۰۴۹۰	۰/۰۵۴۰	۰/۰۰	
۰/۱۷۴۰	۰/۱۵۵۰	۰/۲۰۷۰	۰/۱۲۶۰	۰/۱۱۲۵	۰/۱۴۲۵	۰/۱۰	
۰/۳۸۶۵	۰/۳۳۶۵	۰/۴۵۳۵	۰/۲۲۵۰	۰/۲۰۵۵	۰/۲۷۸۰	۰/۲۰	
۰/۵۲۷۰	۰/۴۷۸۵	۰/۶۳۲۰	۰/۳۳۸۰	۰/۳۰۹۰	۰/۴۲۷۰	۰/۳۰	
۰/۶۶۴۵	۰/۵۹۹۰	۰/۷۷۰۰	۰/۴۳۶۰	۰/۴۰۵۵	۰/۵۵۱۵	۰/۴۰	
۰/۷۵۱۰	۰/۶۹۷۰	۰/۸۵۲۵	۰/۵۲۹۰	۰/۴۹۴۵	۰/۶۴۴۵	۰/۵۰	$\pi_1: MAR$
۰/۸۱۳۵	۰/۷۶۷۰	۰/۹۰۸۰	۰/۶۰۱۵	۰/۵۶۸۵	۰/۷۱۳۵	۰/۶۰	
۰/۸۵۹۵	۰/۸۲۱۵	۰/۹۳۴۰	۰/۶۶۲۵	۰/۶۳۱۵	۰/۷۶۹۵	۰/۷۰	
۰/۸۹۶۵	۰/۸۶۲۰	۰/۹۵۳۰	۰/۷۰۶۰	۰/۶۷۶۰	۰/۸۰۸۰	۰/۸۰	
۰/۹۱۹۰	۰/۸۸۵۵	۰/۹۶۵۵	۰/۷۴۰۰	۰/۷۱۳۵	۰/۸۳۶۵	۰/۹۰	
۰/۹۲۹۰	۰/۹۱۱۰	۰/۹۷۳۰	۰/۷۷۱۰	۰/۷۳۸۰	۰/۸۶۱۵	۱/۰۰	
۰/۹۳۸۵	۰/۹۲۷۵	۰/۹۷۹۰	۰/۷۶۹۵	۰/۷۶۹۵	۰/۸۸۳۵	۱/۱۰	
۰/۹۴۵۰	۰/۹۳۵۵	۰/۹۸۶۵	۰/۸۱۵۰	۰/۷۹۵۵	۰/۸۹۱۵	۱/۲۰	
۰/۰۴۹۵	۰/۰۴۸۰	۰/۰۴۵۵	۰/۰۵۰۰	۰/۰۵۵۵	۰/۰۵۴۰	۰/۰۰	
۰/۱۹۵۰	۰/۱۸۸۰	۰/۲۰۷۰	۰/۱۳۲۵	۰/۱۳۴۰	۰/۱۴۲۵	۰/۱۰	
۰/۳۹۸۰	۰/۳۹۹۰	۰/۴۵۳۵	۰/۲۶۸۰	۰/۲۶۳۰	۰/۲۷۸۰	۰/۲۰	
۰/۵۷۹۰	۰/۵۸۴	۰/۶۳۲۰	۰/۳۸۱۵	۰/۳۷۴۵	۰/۴۲۷۰	۰/۳۰	
۰/۷۱۲۰	۰/۷۰۷۵	۰/۷۷۰۰	۰/۴۹۲۵	۰/۴۸۳۰	۰/۵۵۱۵	۰/۴۰	
۰/۸۰۷۵	۰/۸۰۸۰	۰/۸۵۲۵	۰/۵۸۸۰	۰/۵۷۹۵	۰/۶۴۴۵	۰/۵۰	
۰/۸۵۹۰	۰/۸۶۰۰	۰/۹۰۸۰	۰/۶۵۱۵	۰/۶۴۸۵	۰/۷۱۳۵	۰/۶۰	$\pi_2: MAR$
۰/۸۹۷۵	۰/۸۹۵۵	۰/۹۳۴۰	۰/۷۰۳۵	۰/۷۰۰۰	۰/۷۶۹۵	۰/۷۰	
۰/۹۱۶۵	۰/۹۱۹۰	۰/۹۵۳۰	۰/۷۰۳۳	۰/۷۴۴۰	۰/۸۰۸۰	۰/۸۰	
۰/۹۳۱۰	۰/۹۳۶۰	۰/۹۶۵۵	۰/۷۷۹۵	۰/۷۷۷۰	۰/۸۳۶۵	۰/۹۰	
۰/۹۴۰۰	۰/۹۴۵۵	۰/۹۷۳۰	۰/۸۰۶۵	۰/۸۰۵۰	۰/۸۶۱۵	۱/۰۰	
۰/۹۵۴۵	۰/۹۵۲۰	۰/۹۷۹۰	۰/۸۳۱۰	۰/۸۲۶۰	۰/۸۸۳۵	۱/۱۰	
۰/۹۵۵۰	۰/۹۵۷۵	۰/۹۸۶۵	۰/۸۴۷۰	۰/۸۴۵۰	۰/۸۹۱۵	۱/۲۰	

عملکرد بسیار خوب روش IPW در مقایسه با روش CC از شکل (۲) بهخوبی نمایان است. به طوری که به ازای الگوی اول این عملکرد نمود بیشتری دارد. وقتی الگوی گم‌شده‌ی π است، توان تجربی رد فرض صفر روش CC به توان تجربی رد فرض صفر روش IPW نزدیک‌تر می‌شود. این نتایج را می‌توان از جدول (۴) نیز تحت قید RESET۲ به دست آورد. با مقایسه نتایج جدول (۳) و جدول (۴)، می‌توان نتیجه گرفت که مطالعه تحت قید RESET۱ از مطالعه تحت قید RESET۲ پرتوان‌تر است. این نتیجه‌گیری می‌تواند از انتخابتابع (x) h نشأت بگیرد. زیرا ما RESET۲ را طوری انتخاب کرده‌ایم که تابعی از درایه‌های تابع برداری (x) g است. انتخاب دیگری از (x) h ، می‌توانست نتایج دیگری را به دست دهد.

۴-داده‌های واقعی

در این بخش، از آزمون‌های مشخصسازی مدل پیشنهادشده، برای بررسی کفایت مدل برآشش شده بر داده‌های واقعی استفاده می‌شود. به همین منظور، یک مجموعه داده واقعی در نظر گرفته می‌شود که برخی از اطلاعات آن گم‌شده است. داده‌های مربوط به وضع کفیت هوای شهر نیویورک در سال ۱۹۷۳ به ازای ۱۵۳ روز مختلف در نظر گرفته شد. این داده‌ها در بسته محاسباتی "speff2trial" با نام داده "airquality" در نرم‌افزار "R" گنجانده شده است. جزئیات این داده‌ها در [۱۸] داده‌شده است. ما متغیر مربوط به سطح گاز اوزون (Y) بر حسب تعداد ذرات در میلیارد (ppb) را به عنوان متغیر پاسخ در نظر می‌گیریم که نزدیک به ۲۴ درصد از اطلاعات آن گم‌شده است. همچنین سرعت باد (X) بر حسب مایل بر ساعت (mph) را به عنوان متغیر کمکی در نظر می‌گیریم که به صورت کامل مشاهده شده است.

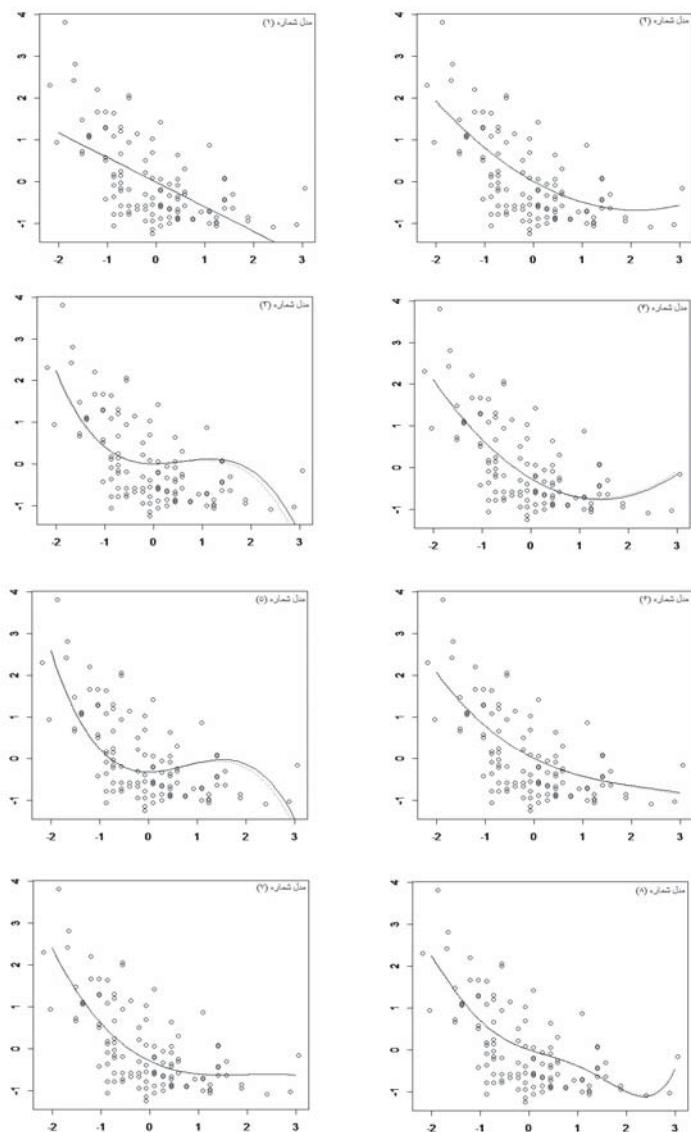
برای سهولت محاسبات، داده‌ها بر اساس داده‌های مشاهده شده، استاندارد شده‌اند. مدل‌های مختلف برای بحث در مورد رابطه بین دو متغیر برآشش داده شده است و صحت آن‌ها با استفاده از آزمون مشخصسازی مدل RESET۲ بررسی شده است. نتایج این بررسی در جدول (۵) درج شده است. همچنین، شکل (۳) برخی از مدل‌های برآشش شده بر داده‌ها را نشان می‌دهد. از جدول (۵) می‌توان نتیجه گرفت که برآشش مدل خطی ساده برای این داده‌ها مناسب نیست. این نتیجه‌گیری از شکل (۳) نیز قابل استنتاج است. علاوه بر مدل شماره ۱، مشخصسازی مدل‌های شماره ۳ و ۵ نیز در سطح ۵٪ رد می‌شود. این مدل‌ها کفایت لازم برای بررسی میزان ذرات گاز اوزون در مقابل سرعت وزش باد را ندارند. از بین مدل‌هایی که مشخصسازی آن‌ها با استفاده از آزمون مشخصسازی RESET۲ در سطح ۵٪ رد نمی‌شوند. مدل‌های ۲ و ۸ از بالاترین سطح معنی‌داری برخوردار هستند و با توجه به شکل (۳) بهخوبی بر داده‌ها برآشش شده‌اند. همچنین با توجه به این که مدل شماره ۲ در مقایسه با مدل شماره ۸ از سطح معنی‌داری بالاتر و فرمول ساده‌تری برخوردار است، به عنوان مدل خطی عام مناسب بر این داده‌ها انتخاب می‌شود.

جدول (۵): عملکرد مدل‌های مختلف بر میزان گاز اوزون در مقابل سرعت باد. برآوردهای یک از پارامترها با $\hat{\beta}_1, \hat{\beta}_2, \hat{\beta}_3$ و F -value RESET 2 مقادیر آماره آزمون با P -value داده شده است. همچنین، برای هر مدل، ردیف بالا بیانگر نتایج روش IPW و ردیف پایین بیانگر نتایج روش CC است.

p -value	F -value	$\hat{\beta}_1$	$\hat{\beta}_2$	$\hat{\beta}_3$	$\hat{\beta}$	مدل	
۰/۰۰۰۰	۱۵/۱۴۶۶	–	–	–۰/۵۹۲۸	–۰/۰۱۶۱	$y = \beta_1 + \beta_2 x$	۱
۰/۰۰۰۰	۱۵/۹۳۳۸	–	–	–۰/۵۸۷۶	–۰/۰۲۴۴		
۰/۴۵۱۶	۰/۸۰۰۵	–	–	۰/۱۵۵۵	–۰/۶۵۴۴	$y = \beta_1 x + \beta_2 x^2$	۲
۰/۴۶۰۶	۰/۷۳۲۱	–	–	۰/۱۵۳۳	–۰/۶۴۹۱		
۰/۰۰۰۴	۱۱/۳۳۲۹	–	–	۰/۱۴۹۷	۰/۲۶۰۱	$y = \beta_1 x + \beta_2 x^2$	۳
۰/۰۰۰۰	۱۰/۸۴۵۰	–	–	–۰/۱۵۳۴	–۰/۲۳۹۷		
۰/۰۶۲۹	۲/۸۳۶۴	–	۰/۲۴۴۱	–۰/۶۹۶۸	–۰/۲۶۸۲	$y = \beta_1 + \beta_2 x + \beta_3 x^2$	۴
۰/۰۶۶۹	۲/۶۲۴۱	–	۰/۲۴۷۱	–۰/۶۸۴۳	–۰/۲۶۶۱		
۰/۰۰۰۴	۸/۲۸۹۲	–	–۰/۱۷۱۳	۰/۳۸۸۵	–۰/۳۲۷۱	$y = \beta_1 + \beta_2 x^2 + \beta_3 x^3$	۵
۰/۰۰۰۰	۸/۷۱۰۴	–	–۰/۱۷۴۲	۰/۳۷۲۵	–۰/۳۲۶۸		
۰/۱۳۵۹	۲/۰۳۲۲	–	–۰/۰۲۵۰	۰/۱۷۷۷	–۰/۵۸۲۷	$y = \beta_1 + \beta_2 x^2 + \beta_3 x^3$	۶
۰/۱۸۱۷	۱/۶۶۷۵	–	–۰/۰۲۴۵	۰/۱۷۲۲	–۰/۵۸۳۴		
۰/۱۷۹۲	۱/۷۴۶۲	–۰/۰۵۰۰	۰/۲۹۸۸	–۰/۵۵۸۵	–۰/۳۰۰۰	$y = \beta_1 + \beta_2 x + \beta_3 x^2 + \beta_4 x^3$	۷
۰/۲۱۵۰	۱/۴۹۸۱	۰/۰۴۹۴	۰/۲۹۵۴	–۰/۵۵۵۸	–۰/۲۹۵۳		
۰/۲۴۷۵	۱/۴۱۴۳	۰/۰۱۶۳	–۰/۱۷۱۶	۰/۱۵۵۱	–۰/۳۸۹۲	$y = \beta_1 x + \beta_2 x^2 + \beta_3 x^3 + \beta_4 x^4$	۸
۰/۲۶۰۶	۱/۳۰۴۶	۰/۰۱۴۹	–۰/۱۵۷۸	۰/۱۵۴۵	–۰/۴۰۶۴		

۵-بحث و نتیجه‌گیری

در مبحث شبیه‌سازی برای برآورد مقادیر مجھول ازتابع هسته نرمال استاندارد استفاده کردیم. به طوری که پارامتر هموارسازی آن را با استفاده از روش اعتبارسنجی^۱ متناظر برآورد کردیم. همچنین، برای به دست آوردن توان تجربی و سطح معناداری آزمون‌ها به ترتیب به چندک‌ها وتابع توزیع شبه-فیشر نیاز داشتیم که به صورت صریح قابل محاسبه نبودند. به همین دلیل، از روش شبیه‌سازی برای برآورد این مقادیر استفاده کردہایم. از ۱۰۰۰ تکرار الگوریتم مونت کارلو با حجم نمونه ۵۰۰ برای برآورد مقادیر موردنظر استفاده کردہایم.



شکل (۳): نمودار مدل‌های برآش شده: نمودار با خط ممتد بیانگر روش CC و نمودار نقطه‌چین بیانگر روش IPW است.

وقتی داده گمشده در متغیرها وجود دارد، از روش‌هایی استفاده کرده‌ایم که مشاهدات ناقص را کنار می‌گذارد که باعث کاهش درجه آزادی توزیع آماره آزمون‌ها می‌شود. اگرچه، روش‌هایی وجود دارند که از مشاهدات ناقص در استنباط مدل استفاده می‌کنند. کار بعدی ما می‌تواند، استفاده از مدل‌های برآورد و ساخت تابع آزمون‌هایی باشد که مانع از کاهش درجه آزادی تابع آزمون‌ها می‌شود.

از روش‌های ناپارامتری برای برآورد مقدار مجھول (π) استفاده کردیم. هرچند، روش‌های دیگری از جمله روش برآورد رگرسیون لوژستیک وجود دارند که ممکن است در برخی از حالات عملکرد بهتری نسبت به روش برآورد ناپارامتری داشته باشند. از طرفی، چون برآورد ناپارامتری در این حالت همواره عملکرد قابل قبولی دارد، با استفاده از این روش، مقادیر نامعلوم برآورد شده است.

در مبحث شبیه‌سازی مشاهده کردیم که استفاده از روش‌های نوین می‌تواند در استنباط‌های آماری با داده‌های ناقص مفید باشد. در کل آزمون مشخص‌سازی رمزی با استفاده از روش برآورد IPW در مقایسه با روش برآورد CC عملکرد قابل قبول‌تری دارد. هر چند به ازای الگوی گمشدگی MCAR، عملکرد آزمون مشخص‌سازی رمزی با استفاده از روش برآورد CC بهبود می‌باید اما همچنان با به کارگیری روش برآورد IPW به ازای هر دو الگوی گمشدگی نتایج بهتری نسبت به روش CC حاصل می‌شود. همچنین، با توجه به این که تشخیص الگوی گمشدگی داده‌ها کار بسیار پیچیده‌ای است، استفاده از روش IPW توصیه می‌شود. بنابراین آزمون مشخص‌سازی رمزی با استفاده از روش برآورد وزن معکوس احتمال می‌تواند یک گزینه مناسب در تعیین صحت مدل باشد.

منابع

- [1] Madsen, H. and Thyregod, P. 2010. *Introduction to general and generalized linear models*. CRC Press.
- [2] Ramsey, G. B. (1969). Test for specification error in classical linear least square regression analysis. *Journal of the Royal Statistical Society*, **31**, 350-71.
- [3] Griffith, D. A. and Chun, Y. (2016). Evaluating eigenvector spatial filter corrections for omitted georeference variables. *Econometrics*, **21**, 1-12.
- [4] Shukur, G. and Mantalos, P. (2004). Size and power of the RESET test as applied to systems of equations. A Bootstrap Approach, *Journal of Modern Applied Statistical Methods*, **3**, 370-385.
- [5] Sapra, S. (2005). A regression error specification test (RESET) for generalized linear model. *Economics Bulletin*, **3**, 1-6.
- [6] Rubin, D. B. (1976). Inference and missing data. *Biometrika*, **63**, 581-592.

- [7] Little, R. J. A. and Rubin, D. B. (2002). *Statistical analysis with missing data. Second Edition*, Wiley-Interscience, New York.
- [8] Basilevsky, A., Sabourin, D., Hum, D. and Anderson, A. (1985). Missing data estimators in the general linear model: an evaluation of simulated data as an experimental design. *Communications in Statistics-Simulation and Computation*, **14**(2), 371-394.
- [9] Little, R. J. A. (1992). Regression with missing X's: A review. *Journal of the American Statistical Association*, **87**, 1227-1237.
- [10] Wang, S. and Wang, C.Y. (2001). A note on kernel assisted estimators in missing covariate regression. *Statistics and Probability letters*, **55**, 439-449.
- [11] Hardle, W. and Mammen, E. (1993). Comparing nonparametric versus parametric regression fits. *Annals of Statistics*, **21**, 1921-1947.
- [12] Hardle, W., Mammen, E. and Muller, M. (1998). Testing parametric versus semiparametric modeling in generalized linear models. *Journal of the American Statistical Association*, **93**(444), 1461-1474.
- [13] Zhu, L.X. and Cui, H.J. (2005). Testing lack-of-fit for general linear errors in variables models. *Statistica Sinica*, **15**, 1049-1068.
- [14] Guo, X. and Xu, W. (2012). Goodness-of-fit tests for general linear models with covariates missed at random. *Journal of Statistical Planning and Inference*, **142**, 2047-2058.
- [15] Li, X. (2012). Lack-of-fit testing of a regression model with response missing at random. *Journal of Statistical Planning and Inference*, **142**(1), 155-170.
- [16] Zhao, L. P. and Lipsitz, S. (1992). Design and analysis of two-stage studies. *Statistics in Medicine*, **11**, 769-782.
- [17] Carpenter, J. R. and Kenward, M. G. (2006). A comparison of multiple imputation and doubly robust estimation for analyses with missing data. *Journal of the Royal statistical Society*, **169**, 571-584.
- [18] Chambers, J. M., Cleveland, W. S., Kleiner, B. and Tukey, P. A. (1983). *Graphical methods for data analysis*. Belmont, CA: Wadsworth.

General Linear Model Specification Error Test with Missing Data

Fayyaz Bahari*, Safar Parsi*, and Mojtaba Ganjali**

*Department of Statistics and Computer Sciences, University of Mohaghegh
Ardabili, Ardabil, Iran

**Department of Statistics, Shahid Beheshti University, Tehran, Iran

Abstract

In this paper, we consider a general linear model where missing data may occur in response and covariate variables. We propose a new test based on Ramsey's test to identify goodness of fit for general linear model with missing data. We show that under the null hypothesis, our test functions for complete case analysis follow a Fisher distribution and the other test function used for analysis with available data converges in distribution to Quasi-Fisher distribution. Furthermore, we compare proposed test functions by using some simulation studies. Also, we apply our methods in analyzing a real data set.

Keywords: General linear model, Missing data, Goodness of fit, Ramsey's test, Quasi-Fisher distribution.

Mathematics Subject Classification (2010): 62J02, 62F03.