

مقایسه مدل‌های آماری حاشیه‌ای و آمیخته در تحلیل داده‌های پزشکی

میرسعید یکانی نژاد^۱، مهدی یاسری^{*}، کرامت نوری جلیانی^۲، آرش اکابری^۳

^۱دانشجوی دوره دکتری تخصصی آمار زیستی، گروه اپیدمیولوژی و آمار زیستی، دانشکده بهداشت، دانشگاه علوم پزشکی تهران، تهران، ایران

^۲دانشیار آمار زیستی، گروه اپیدمیولوژی و آمار زیستی، دانشکده بهداشت، دانشگاه علوم پزشکی تهران، تهران، ایران

^۳کارشناس ارشد آمار زیستی، دانشگاه علوم پزشکی خراسان شمالی، بجنورد، ایران

*نوبنده مسئول: تهران، دانشگاه علوم پزشکی تهران، دانشکده بهداشت، گروه اپیدمیولوژی و آمار زیستی

پست الکترونیک: m.yaseri@yahoo.com

چکیده

زمینه و هدف: امروزه داده‌های زیادی وجود دارند که در آنها فرض استقلال داده‌ها که پیش فرض اصلی بسیاری از مدل‌های آماری است برقرار نیست. داده‌های حاصل از نمونه گیری خوش‌ای، مطالعات طولی با اندازه گیری‌های مکرر و یا داده‌های زوجی مانند داده‌های دو چشم و همچنین مطالعات همسان شده نمونه‌هایی از این داده‌ها هستند

مواد و روش کار: دو مدل آماری با در نظر گرفتن همبستگی بین مشاهدات، مدل‌های آمیخته و مدل‌های حاشیه‌ای هستند که در این مقاله مورد مقایسه قرار گرفته‌اند. این مدل‌ها از نظر روشی که همبستگی بین داده‌ها را در نظر می‌گیرند و تفسیر ضرایب رگرسیونی با یکدیگر تفاوت دارند.

یافته‌ها: در مدل‌های غیر خطی ضرایب رگرسیونی مدل حاشیه‌ای تغییرات در سطح جامعه را نشان می‌دهد در حالیکه در مدل‌های آمیخته این ضرایب تغییرات را در یک فرد یا خوش‌خصوص نشان می‌دهند. در مدل‌های خطی تفسیر ضرایب رگرسیونی در هر دو مدل یکسان است.

نتیجه گیری: به عنوان یک نتیجه گیری کلی در مدل‌های غیر خطی که تفسیر نتایج متفاوت است بر اساس کاربرد مورد نیاز بهتر است از یکی از این دو مدل استفاده شود. در واقع برای سیاستگذاران بهداشتی که دید جامعه نگر دارند استفاده از مدل حاشیه‌ای توصیه می‌شود در حالیکه برای پژوهشکان معالج که بیشتر به تغییرات فردی در یک بیمار علا قمند هستند استفاده از مدل آمیخته مناسب‌تر است.

واژه‌های کلیدی: مدل حاشیه‌ای، مدل آمیخته، مدل خطی، مدل غیر خطی

مقدمه

برقرار نمی‌باشد لذا استفاده از این مدل‌ها گرچه ممکن است به اریبی برآوردهای نیانجامد و یا مقدار این اریبی قابل اغماس باشد با این وجود خطای معیار برآوردهای ضرایب به شدت تحت تاثیر پیش فرض استقلال داده‌ها است [۱-۳]. به عبارت دیگر در صورتیکه داده‌ها از هم مستقل نباشند خطای معیار و در نتیجه فاصله اطمینان و نتیجه آزمون فرضها برای صفر بودن ضرایب رگرسیونی غیر قابل اعتماد خواهد بود. لذا در آنالیز این داده‌ها استفاده از روش‌هایی که بتواند این وابستگی را در نظر بگیرد ضروری است. روش‌های مختلفی برای حل این مساله ابداع شده

در بسیاری از داده‌های پزشکی فرض استقلال داده‌ها در برقرار نمی‌باشد برای مثال داده‌هایی که به روش نمونه گیری خوش‌ای جمع آوری می‌شوند و یا مطالعاتی که بصورت طولی انجام می‌شوند و در آن اندازه گیری‌های مکرر وجود دارد، و یا داده‌هایی که به طور همزمان از یک یا چند عضو بدن جمع آوری می‌شود و همچنین هنگامیکه در یک مطالعه همسان سازی انجام می‌شود فرض استقلال داده‌ها را نمی‌توان پذیرفت زیرا داده‌های یک خوش، یک فرد در طول زمان یا نمونه‌های همسان شده به هم وابسته هستند. پیش فرض مورد نیاز در برآش مدل‌های خطی تعمیم یافته فرض استقلال داده‌هاست

(۳)

$$E(y_i | b_i) = X_i \beta + z_i b_i$$

که b یک بردار از اثرات تصادفی است که از خوش‌هایی به خوش‌های دیگر در تغییر است. معرفی اثرات تصادفی منجر به ایجاد ساختار کوواریانس اثرات تصادفی می‌شود.

(۴)

$$\sum i = Z_i G Z_i' + \delta^2 I_{ni}$$

در دو مدل مذکور تفسیر ضرایب β یکسان است و در هر دوی آنها ضریب β نشان دهنده‌ی آن است که متغیرهای کمکی به چه میزان، میانگین متغیر پاسخ را در جامعه مورد مطالعه تغییر می‌دهند. [۲,۳] این تفسیر از β در معادله (۱) کاملاً آشکار است و مدل‌های حاشیه‌ای مستقیماً به مدل (۱) اشاره دارند از این رو می‌توان تفسیر β را به تغییرات در میانگین جامعه تعمیم داد. جالب است که در مورد مدل‌های آمیخته‌ی خطی نیز می‌توان تفسیر حاشیه‌ای از میانگین متغیر پاسخ داشت زیرا:

$$E(y_i) = E\{E(y_i | b_i)\}$$

(۵)

$$\begin{aligned} &= E(X_i \beta + z_i b_i) \\ &= X_i \beta + z_i E(b_i) \\ &= X_i \beta \end{aligned}$$

پارامتر β در معادلات (۱) و (۳) تفسیر یکسانی دارد. زیرا معادله (۳) یک مدل آمیخته خطی است. (به عبارتی سمت راست (۳) یکتابع خطی از b است).

به بیان ساده‌تر در مدل اثرات آمیخته خطی، ضرایب β تفسیر حاشیه‌ای دارد زیرا میانگین تغییرات خطی متغیر پاسخ بر اساس متغیرهای کمکی در هر سطح برابر تغییرات میانگین متغیر پاسخ در جامعه بر اساس متغیرهای کمکی است.

بخش دوم: مدل‌های تعمیم یافته‌ی خطی

در این بخش به مقایسه‌ی مدل‌های حاشیه‌ای و مدل‌های تعمیم یافته آمیخته می‌پردازیم همانطور که می‌دانیم یکی از مولفه‌های مدل‌های تعمیم یافته، تابع ربط^۱ است.

است که مهمترین آنها مدل‌های آمیخته^۱ و مدل‌های حاشیه‌ای^۲ هستند. گرچه از ابداع این مدل‌ها مدت زمان زیادی می‌گذرد اما هنوز اتفاق نظر در مورد برتری یکی از این مدل‌ها بر دیگری وجود ندارد. [۶-۴, ۱] [برخی از آمار شناسان برای هر یک از این دو مدل هویت مستقل قائل هستند و برتری هریک از این مدل‌ها را بر اساس کاربرد آنها تعریف می‌کنند. [۴, ۵, ۷]. در این مقاله به بررسی تفاوت‌های مدل‌های آمیخته و مدل‌های حاشیه‌ای می‌پردازیم. این مقاله شامل دو بخش اصلی است که در این دو بخش تفاوت‌های میان مدل‌های آمیخته و مدل‌های حاشیه‌ای در دو کلاس بزرگ مدل‌های خطی^۳ و مدل‌های خطی تعمیم^۴ یافته مورد بررسی قرار می‌گیرد. در هر یک از این دو بخش ابتدا تفاوت در نحوه در نظر گرفتن همبستگی در این دو مدل بررسی می‌شود و سپس تفسیر ضرایب رگرسیونی در آنها توضیح داده می‌شود و در پایان با یک مثال عددی و یک مثال واقعی حاصل از طرح سلامت و بیماری در سال ۱۳۹۰ اختلاف در تفسیر ضرایب در این دو مدل نشان داده شده و تفاوت در کاربرد آنها بیان می‌شود.

بخش اول: مدل‌های خطی

در مدل‌های کلاسیک آماری میانگین متغیر پاسخ به صورت تابعی خطی از متغیرهای مستقل بیان می‌شود و به منظور در نظر گرفتن همبستگی مشاهدات از دو روش عمده استفاده می‌شود در مدل‌های حاشیه‌ای یک الگوی همبستگی تعریف می‌شود که به صورت یک ماتریس همبستگی است

(۱)

$$E(y_i) = X_i \beta$$

(۲)

$$\sum i = cor(y_i)$$

روش دوم معرفی اثرات تصادفی در مدل برای میانگین متغیر پاسخ است.

1 - Mixed model

2 - Marginal model

3 - Linear model

4 - Generalized linear models

اکنون مدل‌های تعمیم یافته‌ی آمیخته‌ی خطی را برای میانگین شرطی متغیر پاسخ، به شرط برداری از اثرات تصادفی b_i در نظر می‌گیریم.

(۹)

$$g[E(y_i | b_i)] = X_i \beta^* + Z_i b_i$$

در اینجا پارامترهای ثابت را با β^* نمایش می‌دهیم تا از نظیر آنها در مدل‌های حاشیه‌ای متمایز باشند. در اینجا پارامترهای رگرسیونی تفسیر شرطی برای یک خوش‌یا یک فرد دارند. یعنی β^* بر حسب یک واحد تغییر در متغیر کمکی، زمانی که b_i ثابت در نظر گرفته می‌شود بیان می‌شود (۸). معمول ترین روش برای ثابت در نظر گرفتن اثر تصادفی آن است که میانگین شرطی متغیر پاسخ را در نظر بگیریم بنابراین بر خلاف β در مدل‌های حاشیه‌ای، β^* بر اساس تغییر در میانگین متغیر پاسخ در هر خوش‌یا هر فرد تفسیر می‌شود و پارامترهای رگرسیونی β^* در مورد تغییرات متغیر پاسخ در جامعه اطلاعی را نمی‌دهند. در صورتی که بخواهیم میانگین حاشیه‌ای متغیر پاسخ را بدست آوریم باید از توزیع اثرات تصادفی b_i میانگین بگیریم. که این مستلزم میانگین گرفتن از یک تابع غیر خطی از اثرات تصادفی، β_i است.

$$\begin{aligned} \mu_i &= E(y_i) \\ &= E\{E(y_i | b_i)\} \\ &= E\{h(X_i \beta^* + Z_i b_i)\} \end{aligned}$$

برای میانگین گرفتن از یک تابع غیر خطی از اثرات تصادفی، میانگین وزنی بر اساس توزیع اثرات تصادفی می‌گیریم.

$$\mu = E(y_i) = E\{h(X_i \beta^* + Z_i b_i)\} = \int_{-\infty}^{\infty} h(X_i \beta^* + Z_i b_i) f(b_i) db_i$$

در معادله بالا، انتگرال گیری معادل میانگین گرفتن می‌باشد و مقادیر تابع چگالی احتمال $f(b_i)$ وزنهای مورد استفاده هستند همانطور که از انتگرال فوق بر می‌آید

(μ_i) g که میانگین متغیر پاسخ را به تابعی خطی از متغیرهای کمکی مرتبط می‌سازد. در بحثی که در مقایسه‌ی دو مدل، در بخش اول انجام گرفت به عنوان یک حالت خاص از مدل‌های تعمیم یافته، تابع ربط یک تابع همانی بود. (μ_i) g که در این حالت تفسیر پارامترهای رگرسیونی β در دو مدل آمیخته و مدل حاشیه‌ای یکسان است. در اینجا حالتی را مورد بررسی قرار خواهیم داد که تابع ربط غیر خطی است. مدل حاشیه‌ای تعمیم یافته‌ی خطی در این حالت بصورت زیر بیان می‌شود.

(۶)

$$g(\mu_i) = g\{E(y_i)\} = X_i \beta$$

که در آن (.) g یک تابع ربط غیر خطی مناسب با متغیر پاسخ است. در مدل‌های حاشیه‌ای تفسیر پارامترهای رگرسیونی β به صورت تغییر در میانگین متغیر پاسخ در جامعه مورد مطالعه بر اساس تغییرات متغیرهای کمکی است. برای مثال، زمانی که پاسخ بصورت بردار y_i دو وضعیتی است و تابع ربط لجیت برای آنها استفاده می‌شود تفسیر پارامترهای رگرسیونی β به صورت میزان تغییر در لگاریتم نسبت شناس در جامعه است

(۷)

$$\log it(\mu_i) = X_i \beta$$

برای هر تابع ربط مفروض، (.) g ، میانگین جامعه را می‌توان بر اساس معکوس تابع ربط بیان کرد.

(۸)

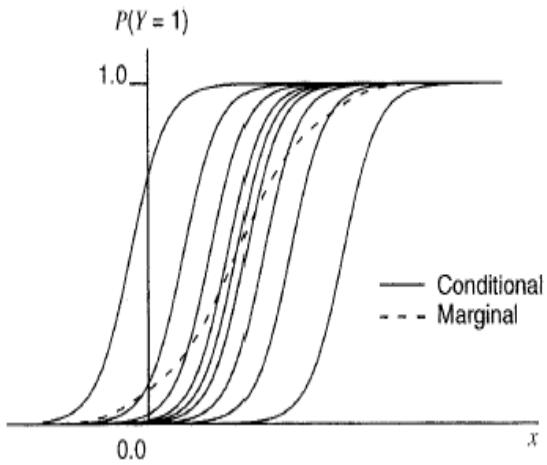
$$h\{g(\mu_i)\} = \mu_i = E(y_i) = h(X_i \beta)$$

به عنوان مثال، زمانی که y_i ها دو وضعیتی هستند و تابع ربط لجیت است مدلی که برای μ_i در نظر گرفته می‌شود به صورت زیر است:

که در اینجا (.) h تابع معکوس لجیت است. پارامترهای رگرسیونی β ، در هر دو فرم (۶) و (۸) نشان دهنده‌ی تغییر در میانگین متغیر پاسخ در جامعه به ازای تغییرات در متغیرهای کمکی هستند.

شکل ۱ علت کوچکتر بودن ضرایب در مدل‌های حاشیه‌ای نسبت به مدل با عرض از مبدأ تصادفی به نمایش درآمده است

برای یک متغیر کمکی با نام X نمودارهای مختص فردی^۱ $P(Y_{ij} = 1 | b_i)$ را برای افراد گوناگون وقتی تغییرپذیری قابل ملاحظه‌ای وجود دارد نمایش داده است. این تغییر پذیری به علت وجود یک تاثیر تصادفی با σ بزرگ است.



در هر مقدار ثابت از x ، تغییر پذیری زیادی، در میانگین‌های شرطی وجود دارد (i) $E(Y_{ij} | b_i)$ میانگین این میانگین‌های شرطی (با تاثیر تصادفی) همان میانگین حاصل از مدل حاشیه‌ای است یعنی $E(Y_{ij})$ این میانگین گیری برای مقادیر مختلف x موجب ایجاد یک منحنی کلی برای مدل حاشیه‌ای می‌شود. این منحنی شبیه کمتری نسبت به تمامی منحنی‌های مدل‌های با تاثیر تصادفی دارد. در حقیقت این منحنی دقیقاً از توزیع لجستیک تبعیت نمی‌کند. چنین خاصیتی برای بسیاری از توابع، بطف نزن و وجود دارد.

البته لازم به ذکر است که علاوه بر تابع ربط همانی در تابع ربط لگاریتم نیز هر دو ضریب یک تفسیر دارند. مدل با تأثیرات تصادفی، عرض از میدا را در نظر بگیرید.

$$\begin{aligned} \ln[E(y_i | b_i)] &= X_i \beta^* + b_i \\ \mu_i = E(y_i) &= E[E(y_i | b_i)] = E[e^{X_i \beta^* + b_i}] = e^{X_i \beta^*} \times E(e^{b_i}) \\ \Rightarrow \ln[E(y_i)] &= X_i \beta^* + \ln E(e^{b_i}) \end{aligned}$$

$$E(y_i) \neq h(X_i\beta) \quad (11)$$

برای مثال در مدل رگرسیون لجستیک با عرض از مبدا تصادفی داریم:

$$, b_i \approx N(0, \delta_b^2)$$

$$\log \text{it} \{E(y_i | b_i)\} = X_i \beta^* + b_i$$

میانگین حاشیه ای از متغیر پاسخ برابر است با:

$$\mu_i = E(y_i)$$

$$= E\{E(y_i | b_i)\}$$

$$= E \left\{ \frac{e^{(X_i \beta^* + b_i)}}{1 + e^{(X_i \beta^* + b_i)}} \right\}$$

$$= \int_{-\infty}^{\infty} \frac{e^{(X_i \beta^* + b_i)}}{1 + e^{(X_i \beta^* + b_i)}} \frac{1}{\sqrt{2\pi} \delta_b^2} e^{\frac{-1}{2} \frac{b_i^2}{\delta_b^2}} db_i$$

این انتگرال به راحتی قابل محاسبه نیست و واضح است که از فرم رگرسیون لجستیک نمی باشد.

(۱۲)

$$\frac{e^{(X_i\beta^* + b_i)}}{1 + e^{(X_i\beta^* + b_i)}}$$

را بایطه حاصله را می توان بصورت تقریبی بفرم زیر بیان کرد.

$$\log itE(y_i) \approx (1 + k\sigma_b^2)^{-\frac{1}{2}X_i\beta^*}$$

که در آن $k = \frac{16\sqrt{3}}{15\pi}$ طرز رسیدن به این فرمول خیلی مهم نیست. آنچه که آهمیت دارد این است که چگونه ضریب در مدل با عرض از مبدأ تصادفی بیشتر از مدل های حاشیه‌ای مم، گردید.

$$\beta = \frac{\beta^*}{\sqrt{1 + 0.346\sigma_b^2}} \quad k^2 = 0.346$$

بنابراین هر گاه $Var(b_i) = \sigma_b^2 > 0$ پارامترهای مدل حاشیه ای رگرسیون لجستیک β مقادیر کوچکتر از β^* پارامترهای مدل رگرسیونی لجستیک با تاثیر تصادفی σ_b^2 می‌گردد. و این تفاوت با افزایش σ_b^2 افزایش می‌یابد. در

اگر تفاضل ریسک را به عنوان یک مدل خطی از ریسک بیمار شدن در نظر بگیریم (در اینجا تفاضل ریسک بیماری پس از درمان و قبل از درمان، به عنوان شاخصی از اثر بخشی درمان بکار می‌رود). این اختلاف ریسک‌ها در ستون چهارم جدول (۱) نشان داده شده است و مقادیر آن از -0.09 تا -0.17 متغیر است.

این مقادیر اثرات فردی درمان می‌باشند. حال به دو طریق می‌توان یک شاخص از اثر بخشی دارو ارائه داد در روش اول از اثرات فردی دارو برای هر سه فرد میانگین می‌گیریم.

$$\frac{-0.13 - 0.17 - 0.09}{3} = -0.13$$

در روش دیگر میانگین ریسک بیمار شدن را قبل از درمان (-0.5) با پس از درمان (-0.37) مقایسه می‌کنیم. این روش در واقع مقایسه ریسک بیمار شدن در جامعه است.

$$(-0.37 - 0.50) / 13 = -0.13$$

بنابراین تفاضل میانگین‌های ریسک بیماری قبل از درمان و پس از درمان در جامعه برابر میانگین اختلاف ریسک‌ها در افراد است. بطور خلاصه «تفاضل میانگین‌ها» برابر «پمیانگین‌تفضال» است. این مثال ساده‌ی عددی موباید آن است که تفسیر ضرایب رگرسیونی در مدل‌های خطی آمیخته و مدل‌های حاشیه‌ای یکسان است.

حال، یک تابع غیر خطی از ریسک بیمار شدن را در نظر می‌گیریم. لگاریتم نسبت شانس را به عنوان یک تابع غیر خطی، که ریسک بیمار شدن را پس از درمان و قبل از درمان مقایسه می‌کند در نظر می‌گیریم. لگاریتم نسبت شانس برای افراد A,B,C در ستون پنجم جدول (۱) نمایش داده شده است.

و از آنجایی که e^{b_i} یک عدد ثابت است (اگر $b_i \sim N(0, \sigma_b^2)$ آنگاه $\ln[E(e^{b_i})] = \sigma_b^2$). بنابراین برای دوتابع ربط همانی و لگاریتم ضرایب رگرسیونی یکسان هستند.

اما بطور کلی حتی با انتگرال گیری روی کلیه مقادیر b_i نیز بصورت مستقیم ضرایب مدل حاشیه‌ای قابل حصول نیست.

بحث

حال با بیان یک مثال عددی از داده‌های فرضی و یک مثال کاربردی از داده‌های طرح سلامت و بیماری به بررسی بیشتر مدل‌های حاشیه‌ای و آمیخته و مقایسه بین آنها می‌پردازیم.

مثال عددی

برای روش ترشدن مطلب به بیان یک مثال ساده می‌پردازیم تا تفاوت‌های اساسی مدل‌های آمیخته و حاشیه‌ای را مشخص کنیم. یک مجموعه از داده‌های فرضی را در جدول (۱) در تظر بگیرید. این مجموعه از داده‌ها نشان دهنده‌ی ریسک واقعی بیمار شدن سه فرد در شروع مطالعه و پس از درمان با یک داروی جدید به منظور کاهش دادن خطر بیماری می‌باشد. این سه فرد از نظر

ریسک بیمار شدن در ابتدای مطالعه کاملاً متفاوت هستند. که این تفاوت را می‌توان به صورت اثرات تصادفی b بیان کرد. یعنی سه فرد A, B, C دارای ریسک‌های شدید، متوسط، ضعیف از بیمار شدن هستند اگر فرض کنیم که همه جامعه نیز به نسبت مساوی دارای ریسک‌های فوق می‌باشند. آنگاه سطر آخر جدول (۱) میانگین‌های ریسک جامعه را قبل از درمان، پس از درمان و اختلاف ریسک را نشان می‌دهند.

جدول ۱: داده‌های فرضی از ریسک بیمار شدن، قبل و پس از درمان، برای سه فرد با ریسک متفاوت برای بیمار شدن

شخص	قبل از درمان	پس از درمان	تفاضل	لگاریتم نسبت شانس
A	۰/۸۰	۰/۶۷	-۰/۱۳	-۰/۶۸
B	۰/۵۰	۰/۳۳	-۰/۱۷	-۰/۷۱
C	۰/۲۰	۰/۱۱	-۰/۹۰	-۰/۷۰
میانگین جامعه	۰/۵۰	۰/۳۷	-۰/۱۳	

دهنده‌ی تغییر در شیوع بیماری در جامعه مورد مطالعه است زمانیکه تمام افراد جامعه تحت درمان باشند. یعنی با مصرف دارو در جامعه شانس بیمار شدن در جامعه 40% کاهش می‌یابد. ($e^{-0.532} \approx 0.4$) این مقدار برآورده برای محققان و سیاست‌گذاران بهداشت حائز اهمیت است. زیرا نشان دهنده‌ی اثر کلی درمان در سطح جامعه است.

مثال کاربردی

در این بخش به مقایسه مدل‌های آماری رگرسیون لجستیک معمولی، حاشیه‌ای و آمیخته در تعیین عوامل موثر بر تغذیه با شیر مادر خواهیم پرداخت. داده‌های مورد استفاده در این مثال مربوط به مطالعه‌ی بررسی سلامت و بیماری است. طرح سلامت و بیماری در سال ۱۳۷۸ در سطح کشور جمهوری اسلامی ایران اجرا شده که در آن ۱۳۴۷۵ خانوار بر اساس یک نمونه گیری چند مرحله‌ای خوش‌ائی و به نسبت یک هزار جمعیت کل خانوارهای

کشور و بطور تصادفی انتخاب گردیده‌اند

از مجموع ۱۳۴۷۵ خانوار طرح سلامت ۱۷۵۶ خانوار کودک زیر دو سال دارند، که در این ۱۷۵۶ خانوار مجموعاً ۲۰۱۰ کودک کمتر از ۲ سال وجود دارند. که نمونه مورد مطالعه را تشکیل می‌دهند. جهت تعیین عوامل موثر بر تغذیه با شیر مادر در کودکان کمتر از دو سال، بر اساس اطلاعات پرسشنامه کودکان به دو گروه استفاده کننده از شیر مادر ($Y=1$) و کودکان که با شیر مادر تغذیه نمی‌شوند ($Y=0$) تقسیم شدند.

نتایج حاصل از سه مدل مورد بررسی در جدول ۲ ارائه شده است با نگاهی به این جدول در می‌یابیم که خطای معیار ضرائب متغیرها در مدل آمیخته و حاشیه‌ای نسبت به مدل معمولی که در آن همبستگی درون خوش‌ائی در نظر گرفته شده بیشتر برآورده شده است مقایسه P مقدارهای این مدل‌ها نشان داد که در مدل معمولی P مقدار کمتری نسبت به دو مدل آمیخته و حاشیه‌ای دارد. با مقایسه مدل حاشیه‌ای و آمیخته در می‌یابیم که با وجود اینکه در هر دو مدل خطای معیار ضرایب افزایش یافته، اما میزان افزایش خطای معیار در مدل حاشیه‌ای به اندازه مدل آمیخته نیست. از آنجایی که مدل‌های آمیخته و حاشیه‌ای روش‌های کاملاً متفاوتی برای در نظر گرفتن

برای مثال لگاریتم نسبت شانس برای فرد A برابر است با:

$$\log\left\{\frac{e^{0.532}}{e^{0.532}-1}\right\} = -0.68$$

مقادیر نسبت شانس برای افراد مورد مطالعه خیلی شبیه هستند. و از -0.68 تا -0.71 در حال تغییرند. که این مقادیر اثرات فردی دارو بر ریسک بیماری می‌باشند. بار دیگر به دو روش می‌توانیم یک شاخص کلی از اثر بخشی دارو ارائه بدهیم. در روش اول از اثرات فردی، که همان مقادیر لگاریتم نسبت شانس برای تک تک افراد هستند میانگین می‌گیریم:

$$\frac{-0.68 - 0.71 - 0.70}{3} = -0.697$$

این مقدار نشان دهنده‌ی آن است که درمان، خطر بیمار شدن را به نصف کاهش می‌دهد. (زیرا $e^{-0.697} \approx 0.5$) در روشی دیگر به عنوان شاخصی از اثر بخشی درمان لگاریتم نسبت شانس قبل از درمان، $\log(0.5) = -0.693$ مقایسه می‌کنیم که در نتیجه این مقایسه مقدار -0.693 برای تفاضل لگاریتم نسبت شانس برای هر فرد حاصل می‌شود که از -0.697 کوچکتر است. بنابراین در یکتابع غیر خطی از ریسک بیمار شدن « مقایسه غیر خطی از میانگین‌ها » برابر با « میانگین مقایسه‌های غیر خطی » نیست.

حال این سوال پیش می‌آید که کدام یک از دو مقدار بدست آمده برای اثر بخشی دارو واقعیت را نشان می‌دهند؟ جواب این سوال این است که هر دوی این مقادیر، مقادیری واقعی هستند اما به سوالهای متفاوتی پاسخ می‌دهند.

برآورد -0.697 یک معیار از تغییرات مورد انتظار در ریسک بیماری برای فردی است که با دارو درمان شده است. یعنی خطر بیماری برای فردی که دارو را استفاده می‌کنند به میزان 50% درصد کاهش $e^{-0.532} \approx 0.5$ می‌یابد.

این برآورد برای پزشک معالج بیمار ارزش ویژه‌ای دارد زیرا او علاقه مند به دانستن اثر متوسط درمان بر روی هر فرد است. از طرف دیگر، مقدار برآورد -0.697 نشان

بنابراین تفسیر ضرایب رگرسیونی در مدل آمیخته وابسته به اثرات تصادفی است.

همبستگی مشاهدات دارند خطای معیار حاصل از این مدلها متفاوت است.

همانطور که در جدول ۲ مشاهده می‌شود متغیرهای

جدول ۲: مقایسه نتایج سه مدل رگرسیونی در بررسی عوامل موثر بر تعذیه با شیر مادر

رگرسیون لجستیک						ردی	متغیر		
آمیخته		حاشیه‌ای		معمولی					
P	(خطای معیار) ضریب	P	(خطای معیار) ضریب	P	(خطای معیار) ضریب				
<0.001	-0.104 (0.021)	<0.001	-0.098 (0.014)	<0.001	-0.106 (0.012)		سن کودک(ماه)		
پایه		پایه		پایه		مرد	جنس کودک		
0.027	-0.447 (0.181)	0.005	-0.385 (0.174)	0.002	-0.428 (0.149)	زن			
پایه		پایه		پایه		25 و کمتر	سن اولین		
0.059	-0.575 (0.348)	0.021	-0.523 (0.276)	0.040	-0.606 (0.235)	بالاتر از 25			
پایه		پایه		پایه		24 و کمتر	فاصله دو تولد آخر		
0.004	0.587 (0.247)	<0.001	0.505 (0.173)	<0.001	0.575 (0.148)	24 از	بیش از		

به عنوان مثال . در مدل حاشیه‌ای با هر ماه افزایش سن کودک لگاریتم شانس تعذیه با شیر مادر در جامعه به میزان ۰.۰۹۸ کاهش می‌یابد در حالیکه براساس مدل آمیخته با هر ماه افزایش سن کودک لگاریتم شانس تعذیه با شیر مادر در یک خوش بطور متوسط ۰.۱۰۴ کاهش می‌یابد.

نتیجه گیری

زمانیکه تابع ربط به فرم همانی و یک تابع خطی باشد تفسیر پارامتر های رگرسیونی در مدل های آمیخته همانند مدلهای حاشیه ای است. در حالیکه وقتی تابع ربط مورد استفاده به شکل غیر خطی است تفسیر پارامترهای رگرسیونی در دو مدل کاملاً متفاوت است. تفسیر نتایج رگرسیونی در آن است که مدل های برآوردهای حاصل از مدل آمیخته برای پزشکان معالج ارزش ویژه ای دارد زیرا آنها علاقه مند به دانستن اثر متوسط درمان بر روی هر فرد هستند. از طرف دیگر، تفسیر نتایج برآوردهای حاصل از مدل حاشیه‌ای تغییر در پارامتر مورد بررسی در جامعه مورد مطالعه است این مقدار برآورد برای محققان و سیاست گذاران بهداشت حائز اهمیت است. گرچه باید دقت کرد که در برخی از توابع ربط مانند همانی این دو ضریب مفهوم یکسانی می‌یابند و هر دو کاربرد را دارند.

جنس کودک، سن اولین حاملگی، و فاصله تولد در مدل حاشیه‌ای در مقایسه با مدل آمیخته اثر معنی دارتری بر روی تعذیه با شیر مادر دارند که این به دلیل است که خطای معیار در مدل آمیخته بیشتر است.

همانطور که دیدیم تفسیر ضرایب رگرسیونی در مدلهای حاشیه‌ای و مدلهای آمیخته کاملاً متفاوت می‌باشد و این دو مدل به دو جامعه هدف متفاوت اشاره دارند در مدلهای حاشیه ای ضرایب رگرسیونی مقدار تغییرات در میانگین جامعه یا مقدار تبدیل یافته میانگین جامعه را به ازای تغییر در متغیر مستقل نشان می‌دهند. و یک مشخصه منحصر بفرد مدلهای حاشیه‌ای در آن است که مدلهای رگرسیونی برای میانگین متغیر پاسخ و الگوی همبستگی مشاهدات به صورت مجزا تعبیین می‌شوند. تفکیک مدل رگرسیونی برای میانگین متغیر پاسخ و مدل همبستگی داده ها از یکدیگر موجب می‌شود که تفسیر ضرایب رگرسیونی در مدل حاشیه ای مستقل از الگوی در نظر گرفته شده برای وابستگی مشاهدات باشد و همانطور که از لفظ حاشیه ای بر می‌آید ضرایب رگرسیونی وابسته به هیچ اثری جز متغیرهای کمکی نیستند.

در مقایسه با مدلهای حاشیه ای اساس مدلهای آمیخته، تغییر پذیری ذاتی در خوش‌هاست و همبستگی بین مشاهدات از این واقعیت ناشی می‌شود که ضرایب رگرسیونی برای مجموعه‌ای از مشاهدات یکسان است.

References

1. Lee Y, Nelder J, Conditional and Marginal Models: Another View, *Statist Sci*, 2004;27(2):20.
2. Fitzmaurice GM, Laird N, Ware J, Applied longitudinal analysis, New Jersey: wiley & sons; 2004.
3. Agresti A, Categorical Data Analysis Hoboken, New Jersey :wiley & sons; 2003.
4. Carriere I, Bouyer J, Choosing marginal or random-effects models for longitudinal binary responses: application to self-reported disability among older persons, *BMC Med Res Methodol*, 2002; Dec 5;2:15.
5. Hadgu A, Koch G, Westrom L,Analysis of ectopic pregnancy data using marginal and conditional models, *Stat Med* , 1997 ;Nov 15;16(21):2403-17.
6. Ten Have TR, Ratcliffe SJ, Reboussin BA, Miller ME, Deviations from the population-averaged versus cluster-specific relationship for clustered binary data, *Stat Methods Med Res*, 2004 Feb;13(1):3-16.
7. Lindsey JK, Lambert P, On the appropriateness of marginal models for repeated measurements in clinical trials, *Stat Med*, 1998 Feb 28;17(4):447-69.
8. Larsen K, Petersen JH, Budtz-Jorgensen E ,Endahl L, Interpreting parameters in the logistic regression model with random effects, *Biometrics* , 2000 Sep;56(3):909-14.

Archive of SID

Comparison of marginal and mixed models in medical data analysis

yekaninejad MS¹, Yaseri M^{1*}, Nourijelyani K², Akaberi A³

¹ PH.D student of Biostatistics, Department of Epidemiology and Biostatistics, School of Public Health, Tehran University of Medical Sciences, Tehran, Iran

² Associated professor of Biostatistics, Department of Epidemiology and Biostatistics, School of Public Health, Tehran University of Medical Sciences, Tehran, Iran

³ M.Sc of Biostatistic,North Khorasan University of Medical Sciences, Bojnurd, Iran

***Corresponding Author:**

Department of Epidemiology
and Biostatistics, School of
Public Health, Tehran
University of Medical Sciences,
Tehran, Iran
Email: m.yaseri@yahoo.com

Abstract

Background & Objectives: In medical researchers, there are lots of correlated data which cannot be analyzed using the usual classical statistical methods because the assumption of independency between observations is not met. Data from cluster sampling, longitudinal studies, observations on paired organs and matched studies are examples of such data.

Materials & Methods: Two statistical methods that can be used to correctly handle these kinds of data are marginal and mixed models. These models are different in considering correlation between subjects and Interpretation of the regression coefficients. These models were compared in this paper.

Results: The regression coefficients in marginal models with non-identity link functions show the change in population whereas in mixed models they represent changes within a subject or a cluster.

Conclusion: In result, in nonlinear models, application of these two kinds of models depends on the areas of their usage. While the marginal models are more attractive to the Health policy makers who are considering the potential effects of a variable on the population as a whole, the mixed model will be of most interest to a physician in a physician/patients context.

Key words: Marginal model, Mixed model, Linear model, Non linear model
