

تعیین حجم نمونه در مطالعات فاقد تخصیص تصادفی بقا با داده‌های بدون سانسور و دارای سانسور

دکتر سقراط فقیه زاده^۱، مهدی رهگذر

چکیده مقاله

مقدمه. در پژوهشهایی که از روشهای آنالیز بقا بهره گرفته می‌شود، تعیین حجم نمونه کافی برای دستیابی به توان آماری مناسب دارای اهمیت است. در روشهای پارامتری و ناپارامتری آمار کلاسیک تخصیص تصادفی نمونه‌ها از شرایط اساسی محسوب می‌شود. تحقق چنین شرطی در بسیاری از پژوهشهای کارآزمایی بالینی و بهداشتی امکان پذیر نیست از آنجاکه مطالعات مشاهده‌ای بقا نمی‌تواند افراد را بطور تصادفی به بیمارها منتسب کرد لذا می‌توان از رگرسیون خطی شامل متغیر مستقل با اثر ثابت در تحلیل استفاده نمود، نوشتار فوق حاصل تعیین حجم نمونه در اینگونه مطالعات آنالیز بقا با داده‌های فاقد سانسور و دارای سانسور می‌باشد.

روشها. در مطالعات فاقد تخصیص تصادفی بقا، می‌توان از رگرسیون خطی که شامل متغیر دارای اثر ثابت است، استفاده نمود. چنین رگرسیونی در واقع امید ریاضی متغیر وابسته به شرط متغیر مستقل را بیان می‌کند. با در نظر گرفتن متغیر دو جمله‌ای برای تعیین عضویت فرد در یکی از دو گروه مورد مقایسه و منظور کردن توزیع نمایی برای تابع مخاطره در رگرسیون بقا، تابع درستنمایی تشکیل گردید. با توجه باینکه توزیع مجانبی برآورد گریپارامتر در تابع درستنمایی نرمال می‌باشد؛ فرمول واریانس برآوردگر ضریب رگرسیون بدست آمد. سپس بایان واریانس ضریب رگرسیون متغیر دارای اثر ثابت بر حسب ضریب تعیین رگرسیون، فرمولهایی برای تعیین حجم نمونه هم در داده‌های فاقد سانسور و هم دارای سانسور بقا فراهم شده است.

نتایج. برای مقایسه تابع مخاطره مربوط به دو گروه که فاقد سانسور در داده‌ها میباشند، برآوردی از ضریب تعیین رگرسیون بقا، نسبت مخاطره و نسبت عضویت در گروه و واریانس‌های آنها از تابع درستنمایی بدست آمد. در صورتیکه داده‌ها دارای سانسور باشند علاوه بر عناصر فوق برآوردی از احتمال سانسور باید مدنظر قرار گیرد. بایافتن واریانس برآوردگر ماکزیمم درستنمایی و با توجه به توزیع مجانبی نرمال آن و به کمک ضریب تعیین رگرسیون فرمولهایی برای تعیین حجم نمونه بدست آمده است. حجم نمونه تعیین شده توان لازم جهت آزمونی که برای اثر سایر متغیرهای مستقل تطبیق یافته است را در بر دارد.

بحث. کاربرد مدل رگرسیونی در مطالعات فاقد تخصیص تصادفی بقا موجب شده است که فرمولهای مناسبی برای برآورد حجم نمونه، هم در مطالعات فاقد سانسور و هم در مطالعات دارای سانسور فراهم شود که در سطح اشتباه α دسترسی به توان آماری لازم نیز ممکن می‌گردد.

در مدل‌های نیمه پارامتری متناسب کاکس که واریانس پارامتر به حالت ساده‌تری تبدیل نمی‌شود باید از یک مدل شبیه سازی استفاده شود، وقتی ضریب تعیین رگرسیون نسبتاً بزرگ باشد توانی که بر اساس آزمون لگ - رتبه‌ای تطبیق نشده محاسبه می‌شود، توان رایش از مقدار واقعی برآورد می‌کند ولی وقتی ضریب تعیین نزدیک به صفر باشد تفاوت در توان‌ها کمتر می‌شود. با افزایش ضریب تعیین رگرسیون، تفاوت بین توانهای حاصل از آزمون لگ - رتبه‌ای و ضریب تعیین تطبیق شده باروش مورد نظر افزایش می‌یابد.

● واژه‌های کلیدی: آنالیز بقا، تعیین حجم نمونه، عدم تخصیص تصادفی، داده‌های فاقد سانسور، داده‌های دارای سانسور.

مقدمه

در مطالعات آماری و تحلیل‌های بقا با توجه به اهداف مورد بررسی لازم است که نمونه‌ای را با حجم لازم انتخاب نمایم تا بر اساس آن بتوان در سطح اشتباه معین و توان مناسب استنباطهایی را در مورد پارامترهای مورد نظر به عمل آوریم. تخصیص تصادفی افراد به بیمارها، لازمه بسیاری از روش‌ها و تحلیل‌های آماری از جمله در آنالیز بقا است. اما مطالعاتی نیز وجود دارند که تخصیص تصادفی امکان پذیر نمی‌باشد. فرض کنید در یک مرکز آموزشی بخواهیم زمان تا وقوع سرطان ریه را، در دو گروه سیگاری و غیر سیگاری‌ها مقایسه کنیم، در اینجا امکان تخصیص تصادفی افراد به دو گروه فوق امکان پذیر نیست یا در مقایسه روند آخرین باروری زنان شهری با زنان روستایی، تخصیص زنان به دو گروه شهری و روستایی به صورت تصادفی صورت نمی‌پذیرد. در این مثال ممکن است زمان تا وقوع سرطان ریه به عوامل دیگری غیر از کشیدن سیگار نیز بستگی داشته باشد. بنابراین در رگرسیون بقا رابطه متغیر مورد نظر Z که تخصیص به گروهها را تعیین می‌کند دارای اثر ثابت است، با متغیرهای کمکی W (Covariates) و متغیر تصادفی زمان بقا، T نه تنها در مطالعه بلکه در برآورد حجم نمونه نیز باید مدنظر قرار گیرد.

جهت برآورد حجم نمونه برای مطالعات تصادفی در آنالیز بقا روشهایی پیشنهاد شده است از جمله توسط فریدمن (Freedman) (۱۹۸۲) (۱)، شوئن فلد (Schoenfeld) (۱۹۸۳) (۲)، لاجین و فولکس (Lachin and Foulkes) (۱۹۸۶) (۳)، لاگاتوس و لن (Lagatos and Lan) (۱۹۹۲) (۴). برای مطالعات فاقد تخصیص تصادفی آنالیز بقا، فرمولی برای برآورد

می‌باشد. آزمونی با سطح اشتباه α به ازای مقادیر زیر، فرض H_0 رارذ می‌کند:

$$|\hat{\beta}_1| > Z_{1-\alpha/2} \sqrt{\text{var}(\hat{\beta}_1)}$$

که در آن $Z_{1-\alpha}$ چندک $\%100(1-\alpha)$ توزیع نرمال استاندارد است. برای داشتن توان $1-\gamma$ تحت فرض

$$Pr \left\{ |\beta_1| > Z_{1-\alpha/2} \sqrt{\text{var}(\hat{\beta}_1)} \right\} = 1-\gamma, H_a: \beta_1 \neq 0$$

یعنی:

واریانس مجانبی $\hat{\beta}_1$ می‌شود:

$$\text{var}(\hat{\beta}_1) = \left[\frac{\beta_1}{Z_{1-\alpha/2} + Z_{1-\gamma}} \right]^2 \quad (1)$$

که در آن $Z_{1-\gamma}$ چندک $\%100(1-\gamma)$ توزیع نرمال استاندارد می‌باشد. توجه شود که $\text{var}(\hat{\beta}_1)$ بستگی به تعداد افراد در مطالعه یعنی n دارد ولی این وابستگی در معادله (۱) محو شده است. هم برای داده‌های دارای سانسور و هم در داده‌های فاقد سانسور نشان داده می‌شود که $\text{var}(\hat{\beta}_1)$ می‌تواند به صورت تابعی از ضریب تعیین رگرسیون خطی Z بر حسب W $R^2_{z^*/w^*}$ بیان شود. با مساوی قرار دادن واریانس حاصل از رگرسیون با معادله (۱) فرمولی برای n ، یعنی حجم نمونه مورد لزوم برای آزمونی در سطح اشتباه α با توان $1-\gamma$ نتیجه خواهد شد.

داده‌های فاقد سانسور

در داده‌های فاقد سانسور $E(X_i) = \frac{1}{\lambda_i}$ است پس از یافتن $\text{var}(\hat{\beta}_1)$ به صورت زیر:

$$\text{var}(\hat{\beta}_1) = \left\{ \left[1 - R_{z^*/w^*} \right] n P_1 (1 - P_1) \right\}^{-1}$$

باتوجه به توزیع مجانبی نرمال $\hat{\beta}_1$ تعداد نمونه لازم برای انجام آزمونی در سطح اشتباه α با توان $1-\gamma$ خواهد شد:

$$n = \left[\frac{Z_{1-\alpha/2} + Z_{1-\gamma}}{\beta_1} \right]^2 \frac{1}{P_1 (1 - P_1) \left\{ 1 - R_{z^*/w^*} \right\}} \quad (2)$$

که در آن P_1 نسبت افراد در گروه ۱ می‌باشد. با تغییر از حالت آزمون فرض به سمت برآورد فاصله‌ای، حجم نمونه لازم برای برآورد β_1 توسط یک فاصله اطمینان با عرض $2d$ می‌شود:

$$\text{var}(\hat{\beta}_1) = \left[\frac{\beta_1}{Z_{1-\alpha/2} + Z_{1-\gamma}} \right]^2 \quad (3)$$

که در آن d مقدار ثابتی است که از پیش معین می‌شود.

داده‌های دارای سانسور

در داده‌های دارای سانسور $E(X_i) = \frac{1}{\lambda_i} (1 - \pi_i)$ می‌باشد، بنابراین، واریانس خواهد شد:

$$\text{var}(\hat{\beta}_1) = \left\{ (1 - \pi) \left[1 - R_{z^*/w^*} \right] n P_1 (1 - P_1) \right\}^{-1}$$

حجم نمونه توسط برناردو و همکاران (M.V.patricia Bernardo) (۲۰۰۰) ارائه شده (۵) و در آن فرض شده است که توزیع زمان تا وقوع حادثه یک توزیع نمایی است. آنها به تبعیت از روش رگرسیونی که توسط لیزیتس و پارزن (Lipsitz and parzen) (۱۹۹۵) (۶) برای مطالعات غیر مشاهده‌ای ارائه شده از رگرسیون نمایی جهت مدل سازی مخاطره Z نسبت به W استفاده نموده‌اند. معمولاً در مقایسه‌های دارای تخصیص تصادفی بقاء توان آزمون بر اساس فرمول آزمون لگ-رتبه‌ای (Log-rank) محاسبه می‌شود. برناردو و همکاران (۲۰۰۰) (۵) نشان داده‌اند که توان بدست آمده بر اساس فرمول آزمون لگ-رتبه‌ای، بیش از مقدار واقعی آن برآورد می‌شود. وایت مر (Whittemore) (۱۹۸۱) (۷) مساله مشابه‌ای را برای توزیع دوجمله‌ای وسیگنورینی (Signorini) (۱۹۹۱) (۸) برای داده‌های شمارشی مورد مطالعه قرار داده‌اند. در این نوشتار با استفاده از روش برناردو و همکاران (۲۰۰۰) (۵) و لایپزیتس و پارزن (۱۹۹۵) (۶) فرمول‌های تعیین حجم نمونه در مطالعات آنالیز بقاء با داده‌های فاقد سانسور و دارای سانسور و کاربردی از آنها ارائه می‌شود.

روش‌ها

لیزیتس و پارزن (۱۹۹۵) محاسبه حجم نمونه را در مطالعات غیر تصادفی مورد بحث قرار داده‌اند که در مقایسه دو تیمار وقتی افراد به صورت تصادفی به دو تیمار تخصیص داده نمی‌شوند، می‌توان از رگرسیون چندگانه متغیر وابسته به شرط متغیر کمکی استفاده نمود (۶). برناردو و همکاران (۲۰۰۰) این روش را به آنالیز رگرسیون بقاء، تعمیم داده فرمولهایی را اثبات نموده‌اند (۵).

زمینه موضوع در آنالیز بقاء

فرض کنید $i=1, \dots, n, T_i$ یک متغیر تصادفی نامنفی باشد که برای n فرد مورد نظر، زمان را از لحظه ورود در مطالعه تا وقوع حادثه مورد نظر بیان می‌نماید و C_i متغیر تصادفی مبین سانسور شدن باشد که توزیع آن دلخواه است و X_i به صورت $\min(C_i, T_i)$ در نظر گرفته شود. متغیر مورد نظر یعنی Z_i ، یک متغیر کمکی دوجمله‌ای است که عضویت در گروه را در یک مطالعه غیر تصادفی مشخص می‌کند. اگر فرد i در گروه ۱ باشد مقدار آن به صورت $Z_i=1$ و اگر فرد i در گروه ۲ قرار گیرد، $Z_i=0$ است. سایر متغیرهای کمکی بانام W_i برای هر فرد i به صورت بردار منظور و در پایه (base-line) قرار می‌گیرند.

فرض می‌کنیم که T_i به صورت شرطی مستقل از C_i به شرط Z_i و W_i باشد. هدف اصلی مقایسه تابع مخاطره مربوط دو گروه است، در رگرسیون نمایی، تابع مخاطره فرد i ام به صورت زیر است:

$$\exp(\hat{\beta} + \beta_1 Z_i + \beta_1' W_i)$$

بنابراین توان آزمونی به صورت $H_0: \beta_1 = 0$ بستگی به واریانس $\hat{\beta}_1$ خواهد داشت. با استفاده از نظریه درست‌نمایی استاندارد و برای مقادیر به اندازه کافی بزرگ n ، $\hat{\beta}_1$ دارای توزیع تقریباً نرمال با میانگین β_1 و واریانس $\text{var}(\hat{\beta}_1)$

در صورتیکه نسبت مردان در جامعه دارندگان سرطان گلوبولهای سفید $P_1 = 0/65$ باشد با توجه به اینکه $Z_{1-\gamma} = 1/03$ و $Z_{1-\alpha/2} = 1/96$ است با استفاده از فرمول (۲) حجم نمونه برابر ۹۹ نفر خواهد شد.

ب) داده‌های دارای سانسور

پژوهشگری می‌خواهد تابع مخاطره دریافت کنندگان کلیه را در یک مرکز تحقیقاتی کلیه در میان دو گروه شهری و روستایی مقایسه نماید. اگر توزیع بقا نمایی باشد و احتمال سانسور بر اساس تجربه‌های قبلی $\pi = 0/3$ و مقدار ضریب تعیین $R^2_{z/w} = 0/05$ و $\beta_1 = 0/92$ باشد، حجم نمونه لازم جهت کسب توان ۹۰ درصد در سطح اشتباه $\alpha = 0/05$ چقدر است؟ در صورتی که نسبت شهری‌ها به روستائیان در دریافت کنندگان کلیه در مراکز برابر $p_1 = 0/75$ باشد. با توجه به این که $Z_{1-\gamma} = 1/28$ و $Z_{1-\alpha/2} = 1/96$ است با استفاده از فرمول (۴) حجم نمونه برابر ۱۸۸ نفر خواهد شد. در داده‌های موجود با منظور کردن نسبت مخاطره $\beta_1 = 0/22$ در رگرسیون مخاطره متناسب یا نمایی، توانها محاسبه شدند، جدول ۱ توان حاصل از روش آزمون تطبیق نشده (Unadjusted test) دو نمونه‌ای لگ - رتبه‌ای و روش آزمون والد (Wald) در رگرسیون تطبیق شده رابه ازای نسبت مخاطره فوق نشان می‌دهد. ضرایب تعیین با انجام $R^2_{z/w}$ رگرسیون هرمتغیر بر حسب سایر متغیرهای موجود بدست آمده است و P_1 عبارت از نسبت تعلق افراد به گروه اول می‌باشد.

لذا حجم نمونه n برای آزمون در سطح اشتباه α باتوان $\gamma - 1$ در این حالت می‌شود:

$$(4) \quad n = \left[\frac{Z_{1-\alpha/2} + Z_{1-\gamma}}{\beta_1} \right]^2 \frac{1}{p_1(1-p_1) [1 - R^2_{z/w*}]} (1-\pi)$$

که π عبارت است از احتمال اینکه یک فرد به طور تصادفی ضمن نادیده انگاشتن متغیرهای کمکی دچار سانسور شود.

یافته‌ها

حال با استفاده از داده‌های مطالعاتی قبلی بقا (۹). کاربرد فرمولهای تعیین حجم نمونه مذکور ارائه می‌شود.

الف) داده‌های فاقد سانسور

محقق می‌خواهد تابع مخاطره تسکین استروئید- ایندیوسد (Steroid-induced) را که در اثر استفاده از داروی مرکاپتوپورین - ۶ (Mercaptoporine) پدیده می‌آید در بین زنان و مردانی که دچار سرطان گلوبولهای سفید هستند مقایسه نماید. در صورتیکه بداند سانسور داده‌ها اتفاق نخواهد افتاد و توزیع داده‌ها نمایی است و مطالعات قبلی مقدار ضریب تعیین را $R^2_{z/w} = 0/45$ و $\beta_1 = 0/85$ نشان داده باشد. حجم نمونه لازم جهت کسب توان ۸۵ درصد در سطح اشتباه $\alpha = 0/05$ چقدر است؟

جدول ۱: محاسبه توان بر اساس آزمون دو نمونه‌ای تطبیق نشده لگ - رتبه‌ای و روش تطبیق شده برای آزمون دو طرفه با خطای ۰/۰۵

نوع داده	متغیر مورد نظر	مقدار	توان	توان
فاقد سانسور	سن	۰/۱۹	۰/۴۴	۸۱/۳۲
	لگاریتم تعداد گلوبولهای سفید	۰/۶۴	۰/۳۵	۷۲/۸۹
دارای سانسور	وضعیت انجام عمل	۰/۲۰	۰/۲۹	۶۰/۰۸
	مرحله بیماری	۰/۱۸۵	۰/۷۸	۷۲/۲۰
	داشتن علائم سیستمیک	۰/۲۲	۰/۴۹	۷۲/۵۲

تصادفی، در تحلیل رگرسیون خطی، متغیر مستقل نقش عدم تخصیص تصادفی را ایفاء می‌نماید. این مطلب به آنالیز بقا نیز تعمیم داده می‌شود. به طوری که اگر بخواهیم تابع مخاطره دو گروه را که امکان تخصیص تصادفی برای آنها وجود ندارد با هم مقایسه نمائیم کافی است یک متغیر Z راطوری در نظر بگیریم که مقادیر آن مبین گروهها باشد و سایر متغیرهای تبیینی (مستقل) رابه صورت بردار W در مدل رگرسیون منظور می‌نمائیم. استفاده از مدل رگرسیونی در مطالعات غیر تصادفی آنالیز بقا موجب می‌شود که فرمولهای مناسبی برای برآورد حجم نمونه هم برای مطالعات فاقد سانسور و هم دارای سانسور فراهم شود. در این صورت در سطح اشتباه α پیدا کردن حجم نمونه برای رسیدن به توان آماری لازم نیز ممکن می‌گردد. اگر β_1 ضریب متغیر Z در مدل رگرسیون بقا باشد. با توجه به ارتباط موجود بین

بحث

هر چند روشهای پارامتری و ناپارامتری در آمار کلاسیک انتخاب تصادفی نمونه‌ها در بسیاری از مدل‌های آماری از شرایط اساسی محسوب می‌شود. لیکن در بسیاری از پژوهشهای پزشکی و بهداشتی امکان تخصیص تصادفی نمونه‌ها فراهم نیست و همواره این سوال مطرح بوده است که در تحلیل چنین داده‌هایی باید از چه روشهایی استفاده نمود. بانقش اساسی که آنالیز رگرسیون خطی ایفاء می‌نماید اکنون به این نیاز پاسخ مناسبی داده شده است. از آنجا که در تحلیل مدل رگرسیون خطی چند گانه با متغیر مستقل دارای اثر ثابت، متغیر پاسخ (وابسته) و باقیمانده‌ها دارای توزیع تصادفی نرمال بوده و امید ریاضی متغیر وابسته به شرط متغیر مستقل به صورت رگرسیون خطی بیان می‌شود، بنابراین برای تحلیل داده‌های فاقد تخصیص

طبق نظریه درستنمایی، که ازحل معادلات امتیاز (score equations) بدست می‌آید. برآوردگری سازگار و مجانباً نرمال برای β وجود خواهد داشت که دارای ماتریس کوواریانس $E\{I(\beta)\}^{-1}$ می‌باشد.

داده‌های فاقد سانسور

در داده‌های بدون سانسور $E(X_i) = \frac{1}{\lambda_i}$ است. پس از بدست آوردن ماتریس مربوط به $E\{I(\beta)\}$ واریانس مجانبی بستگی به عنصر $(2,2)$ ، در معکوس ماتریس مذکور دارد. لذا با کمک قانون ماتریسهای مجانبی، و طبق روابط ماتریسها، می‌توان $var(\hat{\beta}_1)^{-1}$ را به صورت زیر نوشت (10):

$$Z^* \left\{ I - W^* \left(W^{*'} W^* \right)^{-1} W^{*'} \right\} Z^* = Z^* \left[1 - \frac{1}{n} J \right] Z^* - Z^* \left\{ W^* \left(W^{*'} W^* \right)^{-1} W^{*'} - \frac{1}{n} J \right\} Z^*$$

که در آن Z^* برداری $1 \times n$ است که عنصر نام آن Z_i^* می‌باشد و W^* یک ماتریس $n \times p$ است که سطر نام آن $W_i^{*'}$ است. و J ماتریس $n \times n$ است که تمام عناصر آن 1 هستند. با توجه به رابطه اساسی موجود در نظریه رگرسیون است وقتی که رگرسیون Z^* بر حسب W^* بیان شود [11] یعنی:

$$SS_{\text{رگرسیون}} - SS_{\text{کل}} = SS_{\text{خطا}}$$

نتیجه می‌شود که: (5)

$$Z^* \left\{ I - W^* \left(W^{*'} W^* \right)^{-1} W^{*'} \right\} Z^* = \left(1 - R_{z^* | w^*}^2 \right) \sum_{i=1}^N (Z_i - \bar{Z})^2$$

که در آن $R_{z^* | w^*}^2$ ضریب تعیین حاصل از رگرسیون Z^* به شرط W^* است. چون Z_i^* یک متغیر تصادفی دوجمله‌ای است، معادله (5) ساده شده به صورت زیر درمی‌آید:

(6)

$$\hat{var}(Z_i^*) = Z_i^* \left\{ I - W^* \left(W^{*'} W^* \right)^{-1} W^{*'} \right\} z^* = \left(1 - R_{z^* | w^*}^2 \right) n p_1 (1 - p_1)$$

بامساوی قراردادن معادلات (1) و (6) و حل آن برای n ، تعداد افراد لازم برای انجام آزمونی در سطح اشتباه α با توان $1-\gamma$ به صورت رابطه (2) درمی‌آید.

بافرض اینکه $(Z_i^*, W_i^{*'})$ مشاهدات مستقل باتوزیع یکسان باشند. $R_{z^* | w^*}^2$ در احتمال به مربع ضریب همبستگی چندگانه $\rho_{z^* | w^*}^2$ همگراست (کریستنسن (Christensen)، 1973، (12)). بنابراین، در مطالعات آینده نگر که در آن دارای ماتریس طرح (Design matrix) نیستیم در واقع $\rho_{z^* | w^*}^2$ را برآورد می‌کنیم و نه مقدار نمونه‌ای آن $R_{z^* | w^*}^2$ را.

داده‌های دارای سانسور

فرض کنید که افراد بعد از T_a سال وارد مطالعه می‌شوند، و تعقیب (Follow up) آنها T_c سال دیگر پس از پایان حضورشان ادامه می‌یابد. فرض کنید $f(c)$ متغیر تصادفی سانسور شدن C دارای یک چگالی دلخواه $f(c)$ می‌باشد از آنجا که T از یک توزیع نمایی پیروی می‌کند. لذا:

(7)

$$\pi_i = Pr(T_i > C_i) = \int_0^\infty pr(T_i > C_i | C_i = c_i) f(c_i) dc_i = \int_0^\infty exp(-\lambda_i c_i) f(c_i) dc_i$$

ضریب تعیین $R_{z^* | w^*}^2$ و واریانس پارامتر $\hat{\beta}_1$ ، فرمول‌هایی برای برآورد حجم نمونه به اثبات می‌رسد. فرمول آزمون لگ-رتبه‌ای برای مقایسه تابع مخاطره بین گروهها، زمانی مورد استفاده قرار می‌گیرد که تخصیص افراده گروهها به صورت تصادفی باشد. در صورت فقدان تخصیص تصادفی ممکن است که تابع مخاطره در بین گروهها یکسان نباشد لذا روش این مقاله مناسب است. در مدل‌های رگرسیون مخاطره‌های نیمه پارامتری متناسب کاکس که واریانس $var(\hat{\beta}_1)$ به حالت ساده‌تری تبدیل نمی‌شود باید از یک مدل شبیه سازی استفاده شود.

جدول 1 نشان می‌دهد که وقتی $R_{z^* | w^*}^2$ برای تعیین فرمول حجم نمونه مناسب نسبتاً بزرگ می‌باشد توانی که بر اساس آزمون لگ-رتبه‌ای تطبیق نشده محاسبه می‌شود، توان را بیش از مقدار واقعی برآورد می‌کند ولی وقتی $R_{z^* | w^*}^2$ نزدیک به صفر باشد مثل متغیرهای سن و لگاریتم تعداد گلبولهای سفید، تفاوت در توان کمتر می‌شود. به طور مثال در مقایسه متغیر مرحله بیماری، توان بر اساس لگ-رتبه‌ای برابر 80/90 درصد است ولی توان واقعی 72/20 درصد می‌باشد. بر اساس جدول 1، وقتی مقدار $R_{z^* | w^*}^2$ افزایش می‌یابد تفاوت بین توانهای حاصل از محاسبات لگ-رتبه‌ای و $R_{z^* | w^*}^2$ تطبیق شده نیز افزایش می‌یابد.

ضمیمه

اکنون اثبات فرمولها که بیشتر بر اساس مطالب برنارد و همکارانش (2000) (5) و ویلیزیتس و پارزن (6) استوار است به اختصار بیان می‌شود:

مدل رگرسیون نمایی

اگر تمام متغیرهای کمکی به صورت تصحیح شده بامیانگین در نظر گرفته شوند، بعضی از فرمولهای بعدی ساده‌تر می‌شوند. بنابراین مدل رگرسیون نمایی را به صورت زیر بازنویسی می‌کنیم.

$$\lambda_i = exp \left[\beta_0^* + \beta_1 Z_i^* + \beta_2 W_i^{*'} \right]$$

$$\beta_0^* = \beta_0 + \beta_1 \bar{Z} + \beta_2 \bar{W}, Z_i^* = Z_i - \bar{Z}, W_i^{*'} = W_i - \bar{W}$$

$$\beta = (\beta_0^*, \beta_1, \beta_2), \text{ که در آن:}$$

درستنمایی برای β بصورت:

$$L(\beta) = \prod_{i=1}^N \left\{ \lambda_i exp(-\lambda_i x_i) \right\}^{\delta_i} exp(-\lambda_i x_i)^{1-\delta_i}$$

است که در آن، اگر $T_i \leq C_i$ باشد $\delta_i = 1$ است و در غیر این صورت $\delta_i = 0$ می‌باشد. نخست ماتریس اطلاع مشاهده شده (β) لادیربط را از تابع درستنمایی بدست می‌آوریم.

که در آن: $\lambda_i = \exp(\beta_0^* + \beta_1 Z_i^* + \beta_2 W_i^*)$

یادآوری می‌شود که در اینجا:

$$X_i = \min(T_i, C_i)$$

$$E(X_i) = E \left\{ T_i I(T_i < C_i) + C_i I(T_i \geq C_i) \right\}$$

$$= \int_0^\infty \int_0^{C_i} t_i \lambda_i \exp(-\lambda_i t_i) dt_i f(c_i) dc_i + \int_0^\infty C_i \exp(-\lambda_i c_i) f(c_i) dc_i$$

$$= \frac{1}{\lambda_i} (1 - \pi_i)$$

که در آن I(A) یک تابع مشخصه

(Indicator function) است که اگر A

درست باشد مقدار ۱ و در غیر این صورت

مقدار ۰ را اختیار می‌کند. بنابراین مقدار منتظره

ماتریس اطلاع مشاهده شده نظیر I(β)

حاصل از تابع درستنمایی است منتها x_i از تمام عناصر ماتریس حذف و تمام

عناصر در مقدار (1 - π_i) ضرب می‌شوند.

برآورد احتمال شرطی سانسور شدن π_i بشرط آنکه متغیرهای کمکی

افراد مشخص باشد از طریق داده‌ها مشکل است. لذا مقدار π_i توسط π

برآورد می‌شود. می‌توان π را به صورت نسبت افرادی که در یک مجموعه

از داده‌های معین سانسور شده‌اند بر آورد نمود.

بعد از جایگزینی π_i توسط π، ماتریس اطلاع منتظره بدست خواهد آمد.

که وقتی π = ۰ باشد ماتریس حاصل به ماتریس حالت داده‌های فاقد

سانسور تبدیل میشود.

بطور مشابه بامساوی قراردادن معادلات، حجم نمونه n برای آزمونی

در سطح اشتباه α می‌توان ۱ - γ به صورت رابطه (۴) در خواهد آمد.

توجه نمایید که با انتقال ۱ - π به سمت چپ معادله (۴) فرمولی برای تعداد

شکست‌ها بدست (Failures) خواهد آمد.

برعکس، با معلوم بودن n، می‌توانیم توان یک مقایسه را برای آزمونهای

در سطح α به صورت زیر بدست آوریم:

$$1 - \gamma = \Phi \left[\left\{ \beta_1^2 n p_1 (1 - p_1) \left[1 - R_{z^*}^2 \right] \right\}^{1/2} - Z_{1-\alpha/2} \right]$$

که در آن Φ تابع توزیع نرمال استاندارد می‌باشد.

در مدل نیمه پارامتری متناسب کاکس مطالعه شبیه سازی که توسط برناردو

و همکاران (۲۰۰۰) (۵) انجام شده نشان داده است که این برآورد

بطور متناسبی عمل می‌کند. بایان مدل رگرسیون کاکس توسط فرایندهای

شمارشی که توسط اندرسن و همکاران (۱۹۸۲) (۱۳) ارائه شده می‌توان به

دست‌آوردهای جدیدی رسید.

مراجع

- 1- Freedman , L.S. Tables of the number of patients required in clinical trials using the log -rank test. *Statist. Med.* 1982, 1, 121-129.
- 2- Schoenfeld ,D.A. Sample -size formula for the proportional -hazards regression model . *Biometrics* . 1983 ,39, 499-503.
- 3- Lachin , J.M. and Foulkes ,M.A. Evaluation of sample size and power for analyses of survival with allowance for nonuniform patient entry , losses to follow -up , noncompliance and stratification . *Biometrics.* 1986, 42, 507-519.
- 4- Lakatos , E. and Lan ,K.K.G. A comparison of sample size methods for the logrank statistic. *Statist. Med.* 1992, 11, 179-191.
- 5- Bernardo patricia M.V., Lipsitz Stuart R ., Harrington David P. and Catalano paul J.. Sample size calculations for failure time random variables in non-randomized studies. *The statistician* , 49 , 2000, part 1, 31-40.
- 6- Lipsitz, S.R and parzen, M. Sample size calculations for non-randomized studies *Statistician* 1995, 44, 81-90
- 7- Whittemore , A.S. Sample size for logistic regression with small response probability . *J. Am Statist. Ass.* 1981. 76, 27-32.
- 8- Signorini, D.F. Sample size for poisson regression. *Biometrika.* 1991, 78, 446-450.
- 9- Kleinbaum .D.G.,. *Survival analysis , A self -learning text.* Springer-Verlag New York, Inc 1989.
- 10- Snedecor ,G.W. and Cochran, W.G. *Statistical Methods.* Ames : Iowa State University press 1980.
- 11- Myers , R.H. and Milton , J.S. *A 1-1rst coures in the theory of Linear Models.* Boston , 1999, PW, S-kent.
- 12- Christensen, R. *Plan Answers to complex Questions.* New York : Springer .1987.
- 13- Andersen ,P.K. and Gill ,R.D. Cox's regression model for counting processes: a large sample study . *Anal. of Statist.* 1982, 10, 1100-1120.