

Subject:

Year. Month. Date. ()

$$y = XB + \epsilon \rightarrow E(y|X) = XB + \epsilon \quad P = XB$$

$$y|X \sim \text{ber}(p) \rightarrow p^{y_i}(1-p)^{n-y_i}$$

$$y|X \sim N(XB, \sigma^2 I)$$

$$y \sim \text{bin}(n, p) \rightarrow \ln \binom{n}{y} + y \ln p + (n-y) \ln(1-p)$$

حسب رسم

مدل از خطی تعمیم یافته

مضل کجایم

$$E(y|X) = XB$$

هدف از ارائه عبارات در طرفه دست چپ و در طرفه راست تعین پیوند بررسی اثر متغیر مستقل بر روی متغیر پاسخ بر روی هر دو طرف از این مدل استفاده از مدل آماری مناسب برای تحلیل داده است

مدل های خطی تعمیم یافته

مدل های خطی تعمیم یافته از این به بعد با GLM (Generalized linear models) نامیده می شوند

۱. مؤلفه تصادفی Random component

۲. مؤلفه سیستماتیک systematic component

۳. تابع ربط (لینک) link function

خانواده GLM شامل داده گسترده از مدل های آماری است و مدل ANOVA

برای مقایسه داده پیوسته نیز هستند در این درس GLM برای داده رسته از بررسی می شود

مؤلفه تصادفی: این مؤلفه شامل متغیر تصادفی y_i از توزیع تصادفی y با توزیع از این خانواده نمایی طبیعی به صورت زیر است. منظور از مؤلفه تصادفی GLM، تعین متغیر پاسخ y و انتخاب توزیع آن برای y_1, \dots, y_n است.

$$f(y_i, \theta_i) = a(\theta_i) b(y_i) \exp\{y_i \eta(\theta_i)\}$$

که $\eta(\theta)$ را پارامتر طبیعی می نامند. به عبارتی از توزیع η می توان این متغیر تصادفی را تعین کرد. مثلاً می توانیم از این خانواده می نامند. ما توکم η متغیر تصادفی مناسب انتخاب می شود برای مثال برای y در حالتی است و حجم نمونه ثابت است فرض می شود توزیع درجه اول است.

$$PAPCO \quad f(x) = \frac{e^{-\lambda} \lambda^x}{x!} \rightarrow -\lambda + x \ln \lambda - \ln x! \quad \Rightarrow \quad e^{-\lambda} \times e^{x \ln \lambda}$$

$$f(x) = \pi^x (1-\pi)^{1-x} \rightarrow x \ln \pi + (1-x) \ln(1-\pi) = e^{x \ln \pi + (1-x) \ln(1-\pi)}$$

Subject:

Year. Month. Date. ()

مؤلفه ستیاتیکی: مؤلفه ستیاتیکی GLM، مقدر استیاتیکی و مقدر استیاتیکی را می‌گویند که در آن یک بردار η است که ترکیبی خطی از متغیر استیاتیکی است.

$$\eta = \mathbf{x}'\beta = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k$$

این ترکیب خطی از متغیر استیاتیکی خطی نامیده می‌شود. $\mathbf{x} = (x_1, \dots, x_k)$ و $\beta = (\beta_0, \dots, \beta_k)$ یک بردار از مقدر استیاتیکی و β یک بردار از پارامتر است.

نکته: مقدر استیاتیکی در GLM می‌تواند از نوع پیوسته و دسته‌ای یا از هر دو نوع باشد.

تابع ربط: ارتباط بین مؤلفه ستیاتیکی و مقدار مورد انتظار مسئله را بیان می‌کند.

را به‌عنوان فرض کنید مقدار مورد انتظار Y ، $\mu = E(Y)$ باشد به‌شکل

$$i = 1, \dots, n \quad \mu_i = E(Y_i)$$

Y_i	x_{i1}	x_{i2}	...	x_{ik}	μ_i
	\mathbf{x}_i				
Y_n	x_{n1}	x_{n2}	...	x_{nk}	μ_n
	\mathbf{x}_n				

$$Y_i | \mathbf{x}_i \sim N(\beta_0 + \beta_1 x_{i1} + \dots + \beta_k x_{ik}, \sigma^2) \quad g(\mu_i) = \mathbf{x}_i' \beta = \sum_{j=0}^k x_{ij} \beta_j$$

$$E(Y_i | \mathbf{x}_i) = \beta_0 + \beta_1 x_{i1} + \dots + \beta_k x_{ik}$$

به‌شکل $g(\mu) = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k$ می‌توان نوشت. $g(\mu)$ تابع ربط نامیده می‌شود که مقدار μ را به‌شکل $\mu = g(\mu)$ بیان می‌کند.

به g تابع ربط می‌گویند که تابع مستقیم نیز می‌تواند باشد. ساده‌ترین تابع ربط

$$g(\mu) = \mu \quad \text{تابع ربط همبستگی مفرد است}$$

رابطه‌های دیگری نیز وجود دارد مثل $g(\mu) = \log(\mu)$ که در GLM از رابط همبستگی

استفاده کند مدل تک خطی کدیسید (برای مقادیر غیر منفی μ)

$$g(\mu) = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k$$

یا اگر $g(\mu) = \frac{\mu}{1 + \mu}$ باشد، رابطه بهر ربطی که موجب نامیده می شود دو مدل

GLM ای که از ربطی که موجب استفاده می کند مدل که موجب کدیسید (برای مقادیر غیر منفی)

که μ صفر و یکی است
مثلاً در برخی μ احتمال است

نکته: اگر $g(\mu; \theta) = Q(\theta; \mu)$ یعنی اگر تابع ربط با پارامتر طبیعی توزیع نهایی باشد

$$f(y) = \pi^{y-1} (1-\pi)^{n-y} \quad \text{و} \quad \mu = E(y) = \pi$$

رابطه گاوسی نامیده می شود

انواع مختلف مدل های خطی تقسیم یافته: انواع GLM بر جدول زیر درج شده است.

مدل	مؤلفه تقسیم یافته	تابع ربط	مؤلفه تقسیمی
ردرسیون	پویسته	همانی	نرمال
مدل واریانس	رسته ای	همانی	نرمال
مدل کواریانس	پویسته - رسته ای	دوگانه ای	نرمال
ردرسیون کواریانس (داره آدورین)	پویسته - رسته ای	لوجیت	برنولی
مدل خطی (داره آرتورین)	پویسته - رسته ای	تفاریق	پواسن
بازسخت اسمی با چند سطح	پویسته - رسته ای	لوجیت تقسیم یافته	خند تقسیم

ردرسیون اسمی از فرض آراس کی نرمال بودن و ثابت بودن واریانس غرضناح است
که در صورتی که داده نرمال نباشد از تبدیل های استفاده و یا تغییرات می کنند اما در عمل با فرض
تبدیلی که هم داده آراس کی کند و هم واریانس ثابت باشد تقریباً ناممکن است و همچنین
در این اکثر مدل های خطی ساده مدل ردرسیون اسمی از اینجا که تبدیل هم خودی برآیند نمی شود
اما در مدل های خطی تقسیم یافته (GLM) انتخاب تابع ربط از استقار

Subject: $y \sim \text{ber}(\pi)$ $E(y) = \pi$ $V(y) = \pi(1-\pi)$ $v(y) = \pi(1-\pi)$ $v(y) = XB(1-XB)$
 Year: Month: Date: $E(y|x) = \pi = XB$ $\rightarrow v(y) = XB(1-XB)$
 اسکالر نه از ماتریس واصله X است و از فرمول $v(y) = XB(1-XB)$ \rightarrow $v(y) = XB(1-XB)$

مؤلفه تقاضای خنجر است و همچنین در ارزش GLM با توجه به مؤلفه تقاضای آنتی بزرگه از روش کراسیم در سنجش استفاده می شود بین GLM (لغت تأثیر نزول بود/تولیدی شوند) چون داده GLM معتبر است چون نمایی بودن و وابسته به زمان بودن در اکثر نرم افزارها از آمارهای خطی به هم قابل مقایسه پذیرش هستند.

GLM که برابر با شیخ دودویی:

بجای از مقیاس یا شیخ رسته ای (y) سؤال درسته هستند آنها را با صفر و یک شخصی می هم. یا شیخ دودویی در واقع یک مقیوس تقاضای بزرگی است؛ بطوریکه

$$P(y=1) = \pi, \quad P(y=0) = 1-\pi$$

که می دانیم این توزیع دارای میانگین $E(y) = \pi$ و $var(y) = \pi(1-\pi)$ است
 * برای n مشاهد مستقل یا شیخ دودویی با پارامتر π ، تعداد موفقیت k در این توزیع دیکرمان با پارامتر n و π است. برابر مقیوس تقاضای دودویی با توزیع مینومی:

$$P(y_i; \pi_i) = \pi_i^{y_i} (1-\pi_i)^{1-y_i} = (1-\pi_i) \left(\frac{\pi_i}{1-\pi_i} \right)^{y_i}$$

$$= (1-\pi_i) \exp \left\{ y_i \log \left(\frac{\pi_i}{1-\pi_i} \right) \right\} \quad y_i = 0, 1$$

که نشان می دهد P مقیوس جانزاده \log های طبیعی با پارامتر π_i که π_i است π_i است و بعد کانونی است.

رگرسیون خط برابر با شیخ (یعنی): $g(\pi_i) = \text{logit}(\pi_i) = \log \left(\frac{\pi_i}{1-\pi_i} \right) = X' \beta$
 $Q(\pi_i) = \text{number}(\pi_i) \rightarrow \pi_i = \frac{e^{X' \beta}}{1 + e^{X' \beta}}$

برای برآیند GLM برابر با شیخ GLM دودویی رابطه غیر خطی بین X و π_i را می کند.

نکته: معمولاً مقدار π می تواند با توجه به مقدار مشخص X از X تعیین گردد از کار

$\pi(x)$ به جای π استفاده می شود. پس GLM برابر با شیخ دودویی:

PAPCO

$$g(E(y)) = \log \left(\frac{\pi(x)}{1-\pi(x)} \right) = X' \beta = B_0 + B_1 x_1 + \dots + B_k x_k$$

رگرسیون لوجیستیک

در این نوع GLM، تابع رابطه بین پارامتر صحن توزیع صحنی لوجیت $\pi(x)$ است یعنی:


$$\text{logit}(\pi(x)) = \text{log}\left(\frac{\pi(x)}{1-\pi(x)}\right) = x'B$$

$$\Rightarrow \pi(x) = \frac{\exp(x'B)}{1 + \exp(x'B)}$$

که این تابع را هم رگرسیون لوجیستیک می گویند.

بین مولفه تعدادی در این مدل برونوی (سنگت و صفت) است تابع رابطه آل متر لوجیت است. مدل های رگرسیونی لوجیستیک مدل های لوجیت نیز نامیده می شوند.

پارامتر B نرخ افزایش یا کاهش محض را تعیین می کند (جایی که منطقی تغییر مثبت داریم)



عوض کنیم مقدار یک متغیر نسبی را در سمت راست

$$\pi(x) = \frac{\exp(B_0 + B_1 x)}{1 + \exp(B_0 + B_1 x)}$$

نحوه نوشتن

$$\frac{\pi(x)}{1-\pi(x)} = \exp(B_0 + B_1 x)$$

که در این مدل دو صفت است: $e^{B_0} \rightarrow$ صفت

نکته: برای تعیین یک شکل مناسب برای مولفه استیجاب در یک مدل رگرسیونی لوجیستیک

رسم نمودار و آنگاه لوجیت آن نمودار را برابر $B_0 + B_1 x$ قرار دهیم که در این صورت

$$\text{logit } y_i = \text{log} \frac{y_i}{n_i - y_i} \rightarrow \text{لوجیت محض برای}$$

PAPCO

که تعدادات مرات در این است $\sum_{i=1}^n y_i = 1$

* تعداد = y_1, y_2 n_1, n_2 x_1, x_2

و چون $y_i = 0$ و $y_i = 1$ وجود ندارد و در این صورت تجزیه استفاده می‌کنیم

$$\log \left(\frac{y_i + 1/2}{n_i - y_i + 1/2} \right) = \text{لوجیت تجزیه}$$

نکته: اگر x پیوسته باشد باید محاسبه لوجیت در تجزیه را در x بپذیرد.

نکته: مدل‌های غیر خطی در برش $\pi(x) = F(x'B)$ وجود دارند، در بازه $[a, b]$ تعریف

می‌کنند تا به آن توزیع تجزیه منتهی از $F(x)$ هستند که دارای این خاصیت می‌باشند که عبارتی در

$$F^{-1}(x) = \pi(x) \quad * \text{ در این } F^{-1} \text{ تابع ربط } GLM \text{ می‌باشد}$$

مدل پروبیت: اگر در مدل $\pi(x) = F(x'B)$ جای F از Φ (تابع توزیع تجزیه)

نرمال استفاده شود، استفاده از مدل پروبیت حاصل می‌شود پس در این مدل پروبیت

$$\pi(x) = \Phi(x'B) \xrightarrow{\text{برای } \Phi^{-1}} \Phi^{-1}(\pi(x)) = B_0 + B_1 x$$

در این مدل F تابع توزیع تجزیه است و برابر آن $\pi(x)$ توزیع F قرار است.

$$F_x(x) = P(X \leq x) \quad -\infty < x < \infty$$

$$P(Y=y) = \begin{cases} 0 & x > x \\ 1 & x \leq x \end{cases} \quad \pi(x) = P(X \leq x) = F(x)$$

نکته در اغلب مثال‌های کاربرد در مکتب که در کورس‌های پروبیت بسیار دیده می‌شود به طور کلی
 برای درک سبب ورودی‌ها در سبب خروجی تقریباً در حدود ۰.۶ تا ۰.۲ برابر سبب در مدل‌های
 پروبیت است و اغلب این در مدل‌های $\pi(x)$ در حالتی که سرعت میل کردن $\pi(x)$
 به صفر نزدیک برابر باشد مناسب است در حالتی که $\pi(x)$ سرعتی متفاوت
 در نزدیکی ۰ به صفر دارد نامناسبی باشند.

$$\Phi^{-1}(\pi(x)) = B_0 + B_1 x$$

$$\log \left(\frac{\pi(x)}{1 - \pi(x)} \right) = B_0 + B_1 x \quad \text{نکته}$$

$$\pi(x) = B_0 + B_1 x \quad \text{مدل خطی معمولی}$$

15

$E(Y|X) = B_0 + B_1X \leftarrow Y \sim N(B_0 + B_1x, 62)$

Subject: _____
 Year: _____ Month: _____ Date: _____

$Y = \begin{cases} 1 & \pi \\ 0 & 1-\pi \end{cases} \rightarrow E(Y|X) = \pi$
 $\pi(x) = B_0 + B_1x$

مثال: بررسی ارتباط بین میزان کسب و بجاری علمی این مقاله بزرگی 2484 نفر

انگاره است	$Y < 1$ (بجاری علمی)	$Y = 0$ (میزان کسب)
0 هرگز	24	1355
2 نگاه گاهی	35	603
4 تقریباً هر وقت	21	192
5 هر وقت	30	224

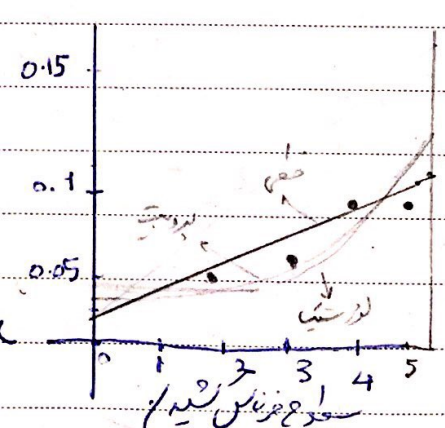
$E(Y|X) = \pi(x)$
 $\pi(x) = B_0 + B_1x$ مدل احتمال خطی (معمولاً احتمال موفقیت به طور خطی با تغییر x تغییر می کند)
 1) مدل مدتهاست :
 $\pi_2(x) = \frac{\exp(B_0 + B_1x)}{1 + \exp(B_0 + B_1x)}$ یا $\text{logit}(\pi(x)) = \frac{\ln(\frac{\pi(x)}{1-\pi(x)})}{1-\pi(x)}$
 2) $\text{propit}(\pi(x))$
 3) $\pi(x) = \Phi(B_0 + B_1x)$

مانند انفرار برادر در ML می سیم می شوند (برآورد در ML در GLM اغلب در اسی قابل می سیم نیستند و از روش های عددی استفاده می شود)

$\hat{\pi}_2 = 0.0172 + 0.0198x$

$\text{logit}(\hat{\pi}_2) = -3.87 + 0.4x$

$\text{probit}(\hat{\pi}_2) = -2.061 + 0.188x$



نکته: اگر استیاز از انتخاب شده سطح کسب و بجاری علمی با غیر از 2484 نفر در آن گرفته شود مقدار کسب و بجاری علمی در هر باره و میزان کسب و بجاری علمی خواهد بود

Complementary-log-log

مدل لگ-لگ مکمل

در مدل لگ-لگ مکمل تابع رابطه صورت $\log\{-\log(1-\pi(x))\}$ است یعنی مدل صورت

$$\log\{-\log(1-\pi(x))\} = x'B \Rightarrow -\log(1-\pi(x)) = e^{x'B}$$

است یا هم طور معادل $\log(1-\pi(x)) = -e^{x'B}$
 $\Rightarrow (1-\pi(x)) = \exp\{-\exp(x'B)\}$

$$\pi(x) = 1 - \exp\{-\exp(x'B)\}$$

این فقط یک معادله است نه بیشتر

$$\log\{-\log(1-\pi(x))\} = \beta_0 + \beta_1 x \rightarrow \pi(x) = 1 - \exp\{-\exp(\beta_0 + \beta_1 x)\}$$

آنگاه $\beta_1 < 0$ مدل برای $\pi(x)$ نزولی را می‌دهد (از آنجا که $\beta_1 > 0$ مدل صعودی است).
 تفسیر مدل: فرض کنید x در مقدار x_1 و x_2 طی شود.

$$\log\{-\log(1-\pi(x_2))\} - \log\{-\log(1-\pi(x_1))\} = \beta_1(x_2 - x_1)$$

$$\Rightarrow \log \frac{\log(1-\pi(x_2))}{\log(1-\pi(x_1))} = \beta_1(x_2 - x_1)$$

$$\Rightarrow \frac{\log(1-\pi(x_2))}{\log(1-\pi(x_1))} = \exp\{\beta_1(x_2 - x_1)\}$$

$$\log(1-\pi(x_2)) = \{\log(1-\pi(x_1))\} \exp\{\beta_1(x_2 - x_1)\}$$

$$\Rightarrow (1-\pi(x_2)) = (1-\pi(x_1)) \exp\{\beta_1(x_2 - x_1)\}$$

پس احتمال شکست در x_2 برابر است با احتمال شکست در x_1 به توان e^{β_1} به ازای هر یک واحد فاصله بین x_1 و x_2 .

نکته: در مدل لگ-لگ مکمل سرعت رسیدن $\pi(x)$ به 1 از سرعت رسیدن $\pi(x)$ به صفر بیشتر است.

$$\log\{-\log(1-\pi(x))\} = x'B$$

نکته: در مدل لگ-لگ معنی

$$\Rightarrow \pi(x) = 1 - \exp\{-\exp(x'B)\} \Rightarrow \pi(x) = 1 - \exp\{-\exp(B_0 + B_1x)\}$$

اگر $B_1 < 0$ مدل برای $\pi(x)$ نزولی و با افزایش $B_1 > 0$ مدل صعودی است.

نکته ۲: اگر $\pi(x) = F(x'B)$ در تقابل با F تابع توزیع گامیل (تقریباً بهریم مدل لگ-لگ معنی بدست می آید)

$$G(x) = \exp\{-\exp(-\frac{x-a}{b})\} \quad b > 0, -\infty < a < \infty$$

$$E(X) = a + 0.577b \quad \sqrt{V(X)} = \frac{\pi b}{\sqrt{6}}$$

مدل لگ-لگ به صورت زیر تعریف می شود

$$\log\{-\log \pi(x)\} = x'B \Rightarrow \pi(x) = \exp\{-\exp(x'B)\}$$

$$\Rightarrow e^{x'B} = -\log \pi(x)$$

و اگر یک ضریب مثبت داشته باشیم

$$\pi(x) = \exp\{-\exp(B_0 + B_1x)\} \Rightarrow \log(-\log \pi(x)) = B_0 + B_1x$$

یک GLM با بهرابط لگ-لگ

در مدل لگ-لگ برعکس لگ-لگ معنی سرعت رسیدن $\pi(x)$ به صفر بیشتر از سرعت رسیدن به یک است و

هنگامی که $B_1 > 0$ باشد معنی $\pi(x)$ نزولی و وقتی $B_1 < 0$ معنی صعودی خواهد بود.

مدل لگ-لگ را می توان به صورت $\pi(x) = F(x'B)$ تقریب کرد F حالت خاصی از توزیع گامیل با $a = 0$

و $b = 1$ است.

استنباط بررسی مدل:

همان طوری که گفتیم براعقب GLM با پاسخ آرسته ای، میسیم برای ردای ML یا اگر بسیار پیچیده

هستند و از روشهای عددی استفاده می شود. در این قسمت در روش درستی و شبه درستیهای بهر

حاصله بیک از می شود که اغلب حل معادلات با نرم افزار اصفا کزین بر است.

روش درستی:

Subject :

Date

$$y \quad \begin{matrix} y_1 & x_1 \rightarrow y_1 \sim \text{ber}(\pi_1) \\ \vdots & \vdots \\ y_n & x_n \rightarrow y_n \sim \text{ber}(\pi_n) \end{matrix}$$

فرض کنید مدل لجستیک مرتبه اول را در نظر بگیرید

$$\log\left(\frac{\pi(x_i)}{1-\pi(x_i)}\right) = \beta_0 + \beta_1 x_i$$

$$L(B; y, x) = \prod_{i=1}^n [\pi(x_i)]^{y_i} [1-\pi(x_i)]^{1-y_i}$$

(B_0, B_1)

$$= \prod_{i=1}^n \left[(1-\pi(x_i)) \left(\frac{\pi(x_i)}{1-\pi(x_i)} \right)^{y_i} \right]$$

$$= \prod_{i=1}^n \exp\left\{ \log(1-\pi(x_i)) + y_i \log \frac{\pi(x_i)}{1-\pi(x_i)} \right\} \quad (1)$$

$$\log\left(\frac{\pi(x_i)}{1-\pi(x_i)}\right) = \beta_0 + \beta_1 x_i$$

$$\Rightarrow \exp\{\beta_0 + \beta_1 x_i\} = \frac{\pi(x_i)}{1-\pi(x_i)}$$

$$\pi(x_i) = \exp\{\beta_0 + \beta_1 x_i\} - \pi(x_i) \exp\{\beta_0 + \beta_1 x_i\}$$

$$\Rightarrow \pi(x_i) = \frac{\exp\{\beta_0 + \beta_1 x_i\}}{1 + \exp\{\beta_0 + \beta_1 x_i\}} \Rightarrow 1 - \pi(x_i) = \frac{1}{1 + \exp\{\beta_0 + \beta_1 x_i\}} \quad (2)$$

$$L(B; y, x) = \exp\left\{ \sum_{i=1}^n \left[\log(1-\pi(x_i)) + y_i \log \frac{\pi(x_i)}{1-\pi(x_i)} \right] \right\}$$

$$= \exp\left\{ \sum_{i=1}^n \left[-\log(1 + \exp(\beta_0 + \beta_1 x_i)) + y_i (\beta_0 + \beta_1 x_i) \right] \right\}$$

$$l(B) = \sum_{i=1}^n [y_i (\beta_0 + \beta_1 x_i)] - \sum_{i=1}^n [\log(1 + \exp(\beta_0 + \beta_1 x_i))]$$

$$\frac{\partial l(B)}{\partial \beta_0} = \sum_{i=1}^n y_i - \sum_{i=1}^n \frac{\exp(\beta_0 + \beta_1 x_i)}{1 + \exp(\beta_0 + \beta_1 x_i)}$$

$$\frac{\partial l(B)}{\partial \beta_1} = \sum_{i=1}^n x_i y_i - \sum_{i=1}^n \frac{x_i \exp(\beta_0 + \beta_1 x_i)}{1 + \exp(\beta_0 + \beta_1 x_i)}$$

$$\sum_{i=1}^n y_i - \sum_{i=1}^n \pi(x_i) = 0$$

$$\sum_{i=1}^n (x_i y_i - x_i \pi(x_i)) = \sum_{i=1}^n x_i (y_i - \pi(x_i)) = 0$$

مثال: فرض کنید مدل خطی تقسیم یافته $\text{logit}(\pi(x_i)) = \beta_0 + \beta_1 x_i$ با داده‌های زیر مواجه شده‌اید. فرض کنید

و جدول زیر بدست آمده است. برآوردگر β_0 و β_1 (بدست آورده) و $H_0: \beta_1 = 0$ را آزمون کنید.

	n	0	1	x
$n_1 \leftarrow 100$	50	50	0	x_1
$n_2 \leftarrow 100$	70	40	1	x_2

$$\pi(x_1) = \frac{\exp\{\beta_0 + \beta_1 x_1\}}{1 + \exp\{\beta_0 + \beta_1 x_1\}} \Rightarrow \pi(0) = \frac{e^{\beta_0}}{1 + e^{\beta_0}}$$

$$\pi(x_2) = \pi(1) = \frac{e^{\beta_0 + \beta_1}}{1 + e^{\beta_0 + \beta_1}}$$

از معادله نزول

$$\begin{cases} \sum_{i=1}^{200} [y_i - \pi(x_i)] = 0 & (1) \\ \sum_{i=1}^{200} x_i [y_i - \pi(x_i)] = 0 & (2) \end{cases}$$

از معادله اول:

$$\sum_{i=1}^{100} y_i - \sum_{i=1}^{100} \pi(0) + \sum_{i=1}^{100} y_i - \sum_{i=1}^{100} \pi(1) = 0$$

در سطر اول $x=0$ در سطر دوم $x=1$

$$50 - 100\pi(0) + 40 - 100\pi(1) = 0 \Rightarrow \pi(0) + \pi(1) = \frac{90}{100}$$

(2)

از معادله دوم:

$$\sum_{i=1}^{100} x_i y_i - \sum_{i=1}^{100} x_i \pi(0) + \sum_{i=1}^{100} x_i y_i - \sum_{i=1}^{100} x_i \pi(1) = 0$$

$x=0$ 40 100

$$= +40 - 100\pi(1) = 0 \Rightarrow \hat{\pi}(1) = 0.4$$

$$\hat{\pi}(0) = 0.15$$

(3)

$$\hat{\pi}(0) = \frac{e^{\beta_0}}{1 + e^{\beta_0}} = 0.15 \Rightarrow \hat{\beta}_0 = 0$$

MICRO

$$\hat{\pi}(1) = \frac{e^{0 + \beta_1}}{1 + e^{0 + \beta_1}} = 0.4 \Rightarrow \frac{1}{1 + e^{-\beta_1}} = 0.4 \Rightarrow e^{-\beta_1} = \frac{1}{4} \Rightarrow \hat{\beta}_1 = \log\left(\frac{1}{4}\right)$$

$$\log \left(\frac{\pi(x)}{1-\pi(x)} \right) = \beta_0 + \beta_1 x$$

پارامتری فرض $H_0: \beta_1 = 0$

$$\theta = \frac{\pi(60)/1-\pi(60)}{\pi(11)/1-\pi(11)} = \frac{e^{\beta_0}}{1+e^{\beta_0}} = 1 \quad ; \quad H_0$$

تحت $H_0: \beta_1 = 0$ معادل است با $\theta = 1$ و می توانیم از فرض H_0 استفاده کنیم

روش شبه درستی :

شبه درستی به اولین بار توسط ودرین (1974) و سپس مکوله (1983) ارائه شد. روش شبه درستی روشی است برای برآوردگرها با افتدگر از روشی است که تفاوت این با درستی است که در درستی شکل توزیع باید مشخص باشد ولی در شبه درستی فقط روابط بین متغیرهای مستقل و وابسته میانیس و در این مورد معلوم باشد که عبارات در شبه درستی فقط برای توزیع خاصی در باره توزیع قدر است و در اینجا است و در اینجا معین شده بدینجهت است. (تبع روابط مشخص باشد و نه دقیقاً توزیع)

$$l(\beta) = \sum_{i=1}^n \left[y_i \log \left(\frac{\pi(x_i)}{1-\pi(x_i)} \right) + \log(1-\pi(x_i)) \right]$$

$$\theta_i = \text{logit}(\pi(x_i)) = \log \left(\frac{\pi(x_i)}{1-\pi(x_i)} \right)$$

$$\log \frac{\pi(x_i)}{1-\pi(x_i)} = \theta_i \Rightarrow \exp(\theta_i) = \frac{\pi(x_i)}{1-\pi(x_i)} \Rightarrow 1 + \exp(\theta_i) = \frac{1}{1-\pi(x_i)}$$

$$\pi(x_i) = \frac{\exp(\theta_i)}{1 + \exp(\theta_i)} \Rightarrow \log(1-\pi(x_i)) = -\log(1 + \exp(\theta_i)) \quad (*)$$

$$\frac{\partial l_i}{\partial \beta} = \left(\frac{\partial \pi_i}{\partial \beta} \right) \cdot \frac{\partial \theta_i}{\partial \pi_i} \cdot \frac{\partial l_i}{\partial \theta_i} \quad (**)$$

$$\frac{\partial \theta_i}{\partial \pi_i} = \frac{\partial \log \frac{\pi_i}{1-\pi_i}}{\partial \pi_i} = \frac{1}{\pi_i(1-\pi_i)} = \frac{1}{\pi_i(1-\pi_i)} = \mathcal{V}_i^{-1} \Rightarrow \text{var}(y_i) = \mathcal{V}_i$$

$$\frac{\partial l_i}{\partial \theta_i} = \frac{\partial}{\partial \theta_i} \left[\theta_i y_i - \log(1 + \exp(\theta_i)) \right] = y_i - \frac{e^{\theta_i}}{1 + e^{\theta_i}} = y_i - \pi_i$$

$$(**) \quad \frac{\partial l_i}{\partial \beta} = \left(\frac{\partial \pi_i}{\partial \beta} \right)' \mathcal{V}_i^{-1} \{ y_i - \pi_i \}$$

به آماره Z^2 ، آماره والد گویند.

دو سری دین آزمون از سنت دو کسیم تابع درستی استقاده می شود آماره آزمون سنت درستی استقاده می شود.

۱۱) کسیم بر روی مقدار ممکن یا کمتر بشرط برقرار فرهن منفی و

۱۲) کسیم بر روی مجموع ابر بزرگتر بدین در کمتر فرهن منفی یا فرهن مقابل

پس فرهن سنرا L_0 مقدار کسیم تابع درستی برابر ملک کامل و L_1 مقدار کسیم درستی تحت فرهن صفر باشد هوار $L_0 = 1, L_1 = 0$ است. آماره آزمون سنت درستی برابر است با

$$[\log L_0 - \log L_1] = -2 \log (L_0 / L_1) = -2 \log 2$$

$$= -2 (1 - 0) = -2$$

که می دانیم دارار توزیع χ^2_1 است

سوسر آزمون که آماره استیاز کارا مشور است و دارار توزی کارا است در اغلب نرم افزارها محاسب می شود در این حرف تعوی می شود.

نکته: هر که آماره برابر حجم نمونه بزرگ دارار توزیع χ^2 هستند اصطلاحاً درنتارک نی دارند اما برار نمونه از کوچک استقاده از آن صغر سنت درستی قابل اعتماد است

با قیانه که ر مدلسار لوجست:

فرهن سنرا π_i معرف تکواصوفت π_i در نا امن مویدت در n_i آزمون باشد

$$h_i \pi_i = E(y_i)$$

— با داده بدینی

پس می توان با قیانه که ر ادیک GLM با مولفه تعدادی در تمام الی صورت زیر تعریف کرد. با قیانه پرسن در صوفت با ام می گویند $\hat{\pi}_i$

$$y_i = \frac{d_i - n_i \hat{\pi}_i}{\sqrt{n_i \hat{\pi}_i (1 - \hat{\pi}_i)}}$$

$$\sum_i r_{pi}^2 = \chi^2$$

r_{pi} ها طیار توزیع توپمی نرغال هستند و آنر بل بولازش نرغال مناسب است به معنی نرغال دارای اصیر را یعنی صفر و مارا سنی کو حکیر از نرغال هستند.

معمولاً بلال بیری یک مدل مناسب مانده در خاک یعنی $e_i = y_i - n\pi_i$ اسم می گویند اینر نظر دارم روند نرغال شده است. ولی عیون این مانده است نرغال نرغال بلال کصفر نقاط دور افتاده همینی یعنی نرغال از نرغال استفاده کرد مانده در است نرغال را هموند از نرغال مانده در سیرس و ب صورت زیر محاسب می کنند

$$r_{pi}^* = \frac{r_{pi}}{\sqrt{1 - H_{ii}}}$$

که در آن H_{ii} درایر دری قمار ماتریس کله دور هستند به صورت زیر تقریبی شود

$$H = W^{1/2} X (X'WX)^{-1} X'W^{1/2}$$

که در آن W ماتریس قمار و عنطر $\left(\frac{\partial \pi_i}{\partial \eta_i}\right)^2$ است و η_i و π_i و n_i

$$\eta_i = \log \frac{\pi_i}{1 - \pi_i} = \sum_j \beta_j x_{ij}$$

سین بلال کصفر نقاط دور افتاده متادیر r_{pi}^* با سب و نرغال نرغال از نرغال در لندانه استخس می کنند.

نرغال نرغال

π_i

Subject:

Year. Month. Date. ()

مقایم دریا :

برای مقایم در مدل می توان از آماره نسبت درستی استفاده کرد که از اختلاف کسری درستی می آید. فرض کنید در مدل M_0 و M_1 می خواهیم مقایم شوند

استدلال فرض کنید می خواهیم مدل M_1 را بررسی کنیم :
فرض کنید $(y; \mu)$ لانت / هندسه گارتم درستی بر حسب

$$\mu = (\mu_1 - \mu_0) \quad \mu \text{ برابر یک برآورد از } (y_1 - y_0) = y \text{ باشد } y; \hat{\mu}_m$$

گوارتم درستی داریم تحت فرض مناسب بودن مدل M_1 باشد (یعنی یک مدل مناسب M_1 در نظر بگیریم و $\hat{\mu}_m$ را برآورد کنیم). در گوارتم درستی

حاکم بر مدل می باشد و برآورد از μ است (مدل استع است) برابر $(y; \hat{\mu}_m)$ باشد که با جایگزینی $y; \hat{\mu}_m = y; \mu$ در $(\mu; y)$ درستی آمده است در این صورت کسری مدل M_1 به صورت زیر تقریب می شود:

$$D(\mu_1) = 2 [l(y; \mu) - l(\hat{\mu}_m; y)] \text{ Deviance}$$

$$= -2 \ln \Lambda = ?$$

$$y_i \sim \text{bin}(n_i, \pi_i) \quad i=1, \dots, m \quad \text{رسته } P \text{ متوالی برآورد}$$

$$P(y_i) = \binom{n_i}{y_i} \pi_i^{y_i} (1 - \pi_i)^{n_i - y_i}$$

$$l(\mu; y) = k + \sum [y_i \ln \pi_i + (n_i - y_i) \ln (1 - \pi_i)]$$

$$\text{محت مدل } M : \hat{\mu}_i = n_i \hat{\pi}_i \Rightarrow \hat{\pi}_i = \hat{y}_i / n_i \quad \text{Ⓢ}$$

$$\text{محت مدل استع } \hat{\mu}_i = n_i \hat{\pi}_i = n_i \frac{y_i}{n_i} = y_i$$

(18)

Subject:

Year. Month. Date. ()

$$2 \left[\ell(y; y) - \ell(\hat{\mu}_1, y) \right] = 2 \left[2 \sum_{i=1}^m y_i \ln y_i - 2 \sum_{i=1}^m y_i \ln \hat{y}_i \right. \\ \left. + 2 \sum_{i=1}^m (n_i - y_i) \ln (n_i - y_i) - 2 \sum_{i=1}^m (n_i - y_i) \ln (n_i - \hat{y}_i) \right]$$

$$\sim \chi^2_{m-p} \quad (M_1 \text{ برآورد } p \text{ رسته } m)$$

M_1 روتنی M_1 برآورد است یعنی یکت
در این توزیع مجانبی χ^2 است

$$\ell(y; y) = \sum \left[y_i \ln \frac{y_i}{n_i} + (n_i - y_i) \ln \left(1 - \frac{y_i}{n_i} \right) \right]$$

$$= \sum \left[y_i \ln y_i - y_i \ln n_i + (n_i - y_i) \ln (n_i - y_i) \right.$$

$$\left. - (n_i - y_i) \ln n_i \right] = \sum \left[y_i \ln y_i - (n_i - y_i) \ln (n_i - y_i) \right.$$

$$\left. - n_i \ln n_i \right]$$

$$\ell(\hat{y}; y) = \sum \left[y_i \ln \frac{\hat{y}_i}{n_i} + (n_i - y_i) \ln \left(1 - \frac{\hat{y}_i}{n_i} \right) \right]$$

$$= \sum \left[y_i \ln \hat{y}_i - y_i \ln n_i + (n_i - y_i) \ln (n_i - \hat{y}_i) \right.$$

$$\left. - (n_i - y_i) \ln n_i \right]$$

$$= \sum \left(y_i \ln \hat{y}_i - (n_i - y_i) \ln (n_i - \hat{y}_i) - n_i \ln n_i \right)$$

Subject :

Year. Month. Date. ()

برابر مقدار در مدل M_0 و M_1 با بزرگترین زیر اجماعی است (به طوری که M_1

باید کمتر بزرگتر است به M_0 دارد)

$$2 [l(y; \hat{\theta}_{M_1}) - l(y; \hat{\theta}_{M_0})]$$

$$= 2 [l(y; \hat{\theta}_{M_1}) - l(y; \hat{\theta}_{M_0})] - 2 [l(y; \hat{\theta}_{M_1}) - l(y; \hat{\theta}_{M_0})]$$

$$= D(M_0) - D(M_1)$$

نویسند اختلاف کسری در مدل M_0 و M_1 است / می دهد اگر این

اختلاف کوچک باشد این معنایست که در مدل خوب هستند.

مدل M_0 این اختلاف برابر بود با بزرگترین توزیع گامی دوبار در M_0 اختلاف پس باید کمتر از در مدل M_0 و M_1 است.

اگر اختلاف بزرگ باشد مدلی بهتر است / کسری کوچکتری دارد.

مثال: بررسی این روزهای مختلف (در سولیدترین بر روی سولید)

تعداد سولید	تعداد سولید	تعداد سولید	تعداد سولید	تعداد سولید	تعداد سولید	تعداد سولید	تعداد سولید
n_1	n_2	n_3	n_4	n_5	n_6	n_7	n_8
59	60	62	56	63	59	62	60
1.691	1.724	1.755	1.784	1.81	1.837	1.861	1.884
3.5	3.4	3.4	3.6	3.8	4.6	5.3	5.8
5.7	5.6	5.6	5.6	5.6	5.6	5.6	5.6
53	47	44	28	11	6	1	0
6	13	18	2.8	52	53	61	60
11.3	20.9	30.3	47.7	54.2	61.1	61.1	59.9
10.7	10.7	10.7	10.7	10.7	10.7	10.7	10.7
9.8	9.8	9.8	9.8	9.8	9.8	9.8	9.8
22.4	23.4	23.8	23.8	23.8	23.8	23.8	23.8
33.7	33.7	33.7	33.7	33.7	33.7	33.7	33.7
50	44.6	44.6	44.6	44.6	44.6	44.6	44.6
53.3	53.4	53.4	53.4	53.4	53.4	53.4	53.4
59.2	59.7	59.7	59.7	59.7	59.7	59.7	59.7
58.8	59.2	59.2	59.2	59.2	59.2	59.2	59.2

مثال موش گمترین - ص ۷۱ - نتیجه گیری

سه مدل مختلف، لوجیت، پروبیت، و برازش سنج و مقایسه کنید در مدل لوجیت در
 سطوح مختلف x نسبت به جزئیات را بدست آورید.

minitab: Stat / Regression / Binary Logistic Regression

option \rightarrow logit / probit / doglog } { number of event y_i
 number of trial n_i
 model x_i

لوجیت : $\hat{\beta}_0 = -60.74$ $\hat{\beta}_1 = 34.2859$
 پروبیت : $\hat{\beta}_0 = -34.96$ $\hat{\beta}_1 = 19.74$
 سنج : $\hat{\beta}_0 = -39.52$ $\hat{\beta}_1 = 22.01$

$$\text{logit } \pi = \log\left(\frac{\hat{\pi}(x)}{1 - \hat{\pi}(x)}\right) = -60.74 + 34.2859x$$

$$\Rightarrow \hat{\pi}(x) = \frac{\exp(-60.74 + 34.2859x)}{1 + \exp(-60.74 + 34.2859x)}$$

عبارت محاسب $\hat{\pi}(x)$ برای هر سطح x $\rightarrow \hat{\mu}_i = \hat{y}_i = n_i \hat{\pi}_i$

$y=0$	$y=1$	n_i		
53	6	59	1.691	در سطح

$$\frac{55.5}{59 - 3.5} = 59 \times \hat{\pi}(1) = 3.5$$

probit : $\Phi^{-1}(\hat{\pi}(x)) = -34.96 + 19.74x \rightarrow \hat{\pi}(x) = \Phi(-34.96 + 19.74x)$

doglog : $\log(-\log(1 - \hat{\pi}(x))) = -39.52 + 22.01x$
 $\Rightarrow \hat{\pi}(x) = 1 - \exp(-\exp(-39.52 + 22.01x))$

عدد y_i بدست آمده می توانست χ^2 ، آمارت آردی
 دست-سنج برای دستول $(\hat{y}_i = 0 \text{ و } \hat{y}_i = 1)$
 کتبه سنج شده با \hat{y}_i کتبه سنج شده
 جمع سته شور

$$\chi^2_{\log y_i+} = 9.9 \quad \chi^2_{\text{probit}+} = 9.4 \quad \chi^2_{\text{cloglog}} = 3.35$$

ظاهر جدول آزمون میسر مقدار برایش کرده نزدیک به مقدار واقعی است انقول می توانیم Deviance (کسین) را برای هر مدل مرتبه در

$$D(M) = 2 [4 \log_e 4 + \dots + 60 \log_e 60] - 2 [4 \log_e 5.7 + \dots + 60 \log_e 59.9] + 2 [(59-6) \log_e (59-6) + \dots] - 2 [(59-6) \ln (59-5.7) + \dots]$$

محاسبه χ^2 و Deviance: $\frac{y_i}{n_i - y_i} \ln \frac{y_i}{n_i - y_i}$

y_i	$n_i - y_i$	$\frac{y_i}{n_i - y_i}$	$\ln \frac{y_i}{n_i - y_i}$	$y_i \ln \frac{y_i}{n_i - y_i}$
59	4	53	0.17	53.3
40	13	47	1.13	41.7
42	18	44	2.09	41.1
54	21	21	3.03	20.17
43	52	11	47.17	15.13
59	53	4	54.2	4.1
42	41	1	41.1	0.9
40	40	0	59.9	0.1

$$\chi^2_{\text{cloglog}} = \frac{(4-53)^2}{53} + \dots + \frac{(40-47)^2}{47} + \frac{(53-54)^2}{54} + \dots + \frac{(40-40)^2}{40} = 3.35$$

" χ^2 کسین نزدیک به مقدار واقعی است"

$$\text{Deviance } e = 2 \sum y_i \ln y_i - 2 \sum y_i \ln \hat{y}_i + 2 \sum (n_i - y_i) \ln (n_i - y_i) - 2 \sum (n_i - y_i) \ln (n_i - \hat{y}_i)$$

$$= 2 [4 \ln 4 + \dots + 40 \ln 40] - 2 [4 \ln 5.7 + \dots + 40 \ln 59.9] + 2 [(59-6) \ln (59-6) + \dots + (40-40) \ln (40-40)] - 2 [(59-4) \ln (59-4) + \dots + (40-40) \ln (40-59.9)] = 3.35$$

مدل‌های خطی تعمیم یافته برای داده‌های شمارشی (رگرسیون پوان)

تاکنون در مورد مدل‌های منطقی با پاسخ‌های عددی صحبت کردیم و مدل‌های مختلف جهت برآورد این داده‌ها مثل لوجیت و پروبیت و نت نت (نکته) را بیان کردیم اما در مدل‌های گامی اوقات متغیرهای پاسخ گسسته، به صورت شمارشی هستند مثلاً تعداد اتومبیل‌های سرت‌سنگ در سال 200 در تعدادی از شهرهای ایران، ... در این بخش GLM های رگرسیونی شمارشی بررسی می‌شوند. این هدف مدل‌های منطقی با پاسخ‌های شمارشی است. (در GLM با پاسخ‌های شمارشی فرض بر این است که مولفه تعدادی دارای توزیع پوان است چون شمارش متغیری هستند که می‌توانند مقدار صحیح غیر منفی را بپذیرند پس توزیع پوان برای داده‌های شمارشی مناسب است)

رگرسیون پوان:

$$P(y_i; \mu_i) = \frac{e^{-\mu_i} \mu_i^{y_i}}{y_i!}$$

$$\rightarrow e^{-\mu_i} \frac{e^{-\log y_i!} \exp\{y_i \log \mu_i\}}{1}$$

(μ_i) ← پارامتری ← رابطه مانندی

$$\log \mu = \beta_0 + \beta_1 x \rightarrow \mu = \exp\{\beta_0 + \beta_1 x\}$$

$$= e^{\beta_0} e^{\beta_1 x}$$

و برای مدل این مدل هر چه افزایش در x دارای اثر مثبتی e^{β_1} بر μ است پس می‌توانیم y در $x+1$ برابر می‌شود y در x ضرب در e^{β_1} است

اگر $\beta_1 = 0$ پس $\mu = e^{\beta_0}$ و می‌توانیم x را تغییر ندهیم یعنی اگر $\beta_1 = 0$ و β_0 داده

اگر $\beta_1 > 0$ و می‌توانیم x را افزایش دهیم یا در x $\beta_1 < 0$ با افزایش x می‌توانیم

گاهی می‌تواند

نکته ۱: گاهی در عمل از رگرسیون پویان به راجع همانی استفاده می شود

$$\mu = \beta_0 + \beta_1 x$$

نکته ۲: اگر هر یک از متغیرهای x دارای شاخص (مانند اندازه جمعیت) t باشد نرخ μ

مکونه ای آن t است و مقدار مورد انتظار μ/t است و مدل به صورت

$$\ln(\mu/t) = \beta_0 + \beta_1 x$$

$$\Rightarrow \ln \mu - \ln t = \beta_0 + \beta_1 x$$

که به این مقدار $\ln t$ می گویند

$$\Rightarrow \mu = t \exp(\beta_0 + \beta_1 x)$$

معنی β_1 تغییرات t و مقدار β_1 تغییرات μ متناسب است تناسب دارد به ازای مقدار x

تأثیر x در برابر کردن t به مثابه β_1 تغییرات مقدار مورد انتظار μ می شود

$$\frac{\text{تعداد سرقت}}{\text{جمعیت}} = \text{نرخ سرقت}$$

مدل ۱۲ آبرستی

`cbind(y, n-y)`



GLM در `splm`

`glm(y ~ x, Family = binomial(link = logit))`

↓
gaussian
poisson

↓
Probit

Gamma
?

`data = data.frame(y, x)`

۱۰
مدل‌های خطی

تاکنون مدل‌های مختلفی مورد توجه بودند که متغیر پاسخ یکی از متغیرهای خود متغیره بود تا آنکه متغیرهای درجه اول
متغیرهای تفسیری بر روی این متغیر مورد بررسی قرار می‌گرفت.

مدل‌های خطی حالت خاص از مدل‌های GLM هستند برای تعیین میزان وابستگی شمارش به سطح متغیرهای
رسته‌ای به کار می‌روند به عبارت دیگر در مدل‌های تک خطی تا آنکه متغیرهای رده بندی شود به مقدار
مورد انتظار تعداد رخ‌ها در خانه مورد بررسی قرار می‌گیرد هم اثرات اصلی و هم اثرات متقابل متغیرها
می‌باشد. تعداد رخ‌ها در عنوان یک متغیر پاسخ شمارشی در تقاطع متغیرهای مورد بررسی صورت می‌گیرد
برای مدل تا آنکه اصلی هر متغیر متقابل آن (مدل‌های رسته) که مدل‌های رسته

مدل‌های خطی در جدول‌ها در صفحه

جدول توافق $I \times J$ را در نظر بگیرید که n عنصر اصلی در تقاطع رسته‌ای X و Y به صورت متقاطع
رسته بندی شده اند اگر X و Y مستقل باشند یعنی

$$\pi_{ij} = \pi_{i+} \pi_{+j} \quad i=1, \dots, I \quad j=1, \dots, J$$

دری رانج $\mu_{ij} = n \pi_{ij}$ پس تحت نظر $\mu_{ij} = n \pi_{i+} \pi_{+j}$ (*)

در مدل‌های خطی در ارتباطها از μ و λ به جای π استفاده می‌شود فرض کنید که
خانه i و j دارای توزیع پواسن به میانگین λ_i و λ_j هستند.

بالمعاریتم فرض کنید از رابطه (*) رابطه ضربی به صورت یک رابطه جمعی می‌شود (هولتوری)

نزدیک مدل از رابطه جمعی استفاده می‌شود $\Rightarrow \ln \mu_{ij} = \ln n + \ln \pi_{i+} + \ln \pi_{+j}$

$$\Rightarrow \log(\mu_{ij}) = \lambda + \lambda_i^X + \lambda_j^Y \quad (1)$$

اثر ستونی اثر ستون λ_j^Y و میانگین λ

مبنی زین \ln به صورت محلی رابطه حجم نمونه، احتمال در سطح α و احتمال در سطح $1-\alpha$ زین

است و برآورد استقلال به صورت رابطه λ نیز می تواند در تعریف شود.

به مدل λ معمول که حتی استقلال حداقل توافق در طرف نامیده می شود.

تأثیر دانه بندی تغییر λ در سطح α بر روی تعداد شمارش $\rightarrow \lambda_i^x$

(هر چه زیاده باشد زکوانی مورد انتقاد در این سطح بیشتر می شود)

- مدل تک حقی ملی: برای n فرض تا اثر سطوح مختلف در صف X و Y بر تعداد شمارشی

(مستقلاتی)

خانه i, j :

$$\ln \mu_{ij} = \alpha + \lambda_i^x + \lambda_j^y + \lambda_{ij}^{xy} \quad i=1, \dots, I$$

$$j=1, \dots, J$$

مدل تکامل یا مدل مستقل λ اثر متقابل سطح α و β نام Y

$\lambda_{ij}^{xy} = 0$ مدل به مدل استقلال تبدیل می شود. در مدل 2 برای این 2 تعداد پارامتر

حد اکثر به تعداد خانه که برابر شده در محدودتهای بر روی مدل اعمال شود

درجه 2 و تعدادش $I \cdot J$: $I \cdot J$

$$= 1 + I + J + I \cdot J$$

تعداد پارامتر مدل $(I \cdot J)$

$$\lambda_{ij}^{xy} = 0 \quad \forall i, j$$

تأثیر سطح α بر تغییر Y صفر است

$$\lambda_{I}^x = 0$$

تأثیر سطح α بر تغییر λ صفر است

$$\lambda_{Ij}^{xy} = 0 \quad \forall j$$

$$: \text{تعداد پارامتر} = 1 + (I-1) + (J-1) + (I-1)(J-1) = I \cdot J$$

در این صورت با اعمال محدودیتها، به مدل ۲ که تعداد پارامترها با تعداد خانه‌ها برابر است می‌تواند مدل تک‌حقی استنتاج شود.

بررسی شرط استقلال مدل تک‌حقی استنتاجی (I=2 و J=2)

می‌دانیم $\theta = 1$ شرط استقلال است یا $\ln \theta = 0$ پس داریم:

$$\ln \theta = \ln \left(\frac{\mu_{11} \mu_{22}}{\mu_{12} \mu_{21}} \right) = \ln \mu_{11} + \ln \mu_{22} - \ln \mu_{12} - \ln \mu_{21}$$

$$D = \frac{\pi_{11} \pi_{22}}{\pi_{12} \pi_{21}} = \frac{n_{11} \cdot n_{22}}{n_{12} \cdot n_{21}}$$

$$\theta = \frac{\pi_{11} / (1 - \pi_{11})}{\pi_{21} / (1 - \pi_{21})} = \frac{n_{11} n_{22}}{n_{12} n_{21}}$$

از مدل $\lambda = (\lambda + \lambda_1^x + \lambda_1^y + \lambda_{11}^{xy}) + \dots - (\lambda + \lambda_2^x + \lambda_1^y + \lambda_{21}^{xy})$

J=2 $\lambda_{12}^{xy} = \lambda_{22}^{xy} = 0$

I=2 $\lambda_{11}^{xy} = \lambda_{21}^{xy} = 0$

در نتیجه $\lambda_{11}^{xy} + \lambda_{22}^{xy} - \lambda_{12}^{xy} - \lambda_{21}^{xy} = \lambda_{11}^{xy}$
با اعمال محدودیتها

$\Rightarrow \ln \theta = 0 \iff \lambda_{11}^{xy} = 0$

در این مدل استقلال معادل است.

حقت پذیرش فرض استقلال و ارجح:

بنابراین احتمال نوشتن λ_1^y به صورت λ در این صورت $\text{logit}(\pi(x_i)) = \lambda_1^y = \beta$

$$\text{logit}(\pi(x_i)) = \ln \frac{\pi(x_i)}{1 - \pi(x_i)} = \ln \frac{P(Y=1 | X=i)}{P(Y=2 | X=i)}$$

$$= \frac{\ln P(Y=1, X=i)}{P(Y=2, X=i)} = \ln \frac{\pi_{i1}}{\pi_{i2}} = \ln \frac{\mu_{i1}}{\mu_{i2}}$$

$$= \ln \mu_{i1} - \ln \mu_{i2} \stackrel{\text{فرض استقلال}}{=} (\lambda + \lambda_1^x + \lambda_1^y) - (\lambda + \lambda_1^x + \lambda_2^y)$$

و مدل ۱
در نتیجه $\lambda_2^y = 0$

$= \lambda_1^y$

نکته: ابعاد محدودتهای توانده به صورت λ_i^x در نظر گرفته شود

$$\sum_i \lambda_i^x = \sum_j \lambda_j^y = \sum_{i,j} \lambda_{ij}^{xy} = \sum_{i,j} \lambda_{ij}^{yz} = 0$$

$\underbrace{\hspace{10em}}_{\text{تعداد پارامتر آزاد} = I-1} + \underbrace{\hspace{10em}}_{J-1} = \underbrace{\hspace{10em}}_{(I-1)(J-1)}$

عددهای منفی برابر محدودتهای هر طرفه

فرض کنید X, Y, Z به ترتیب I, J, K ابعاد دارند مدل منفی کامل:

$$\ln \mu_{ijk} = \lambda + \lambda_i^x + \lambda_j^y + \lambda_k^z + \lambda_{ij}^{xy} + \lambda_{jk}^{yz} + \lambda_{ik}^{xz} + \lambda_{ijk}^{xyz}$$

و ابعاد محدودتهای مدل زیر تعداد پارامتر مدل را تعیین می کند

$i = 1 \dots I$
 $j = 1 \dots J$
 $k = 1 \dots K$



برابری شود



$$\lambda_i^x = \lambda_j^y = \lambda_k^z = 0$$

$$\forall j \quad \lambda_{ij}^{xy} = \lambda_{jk}^{yz} = 0$$

$$\forall i, j, k \quad \lambda_{ijk}^{xyz} = 0$$

$$\forall i \quad \lambda_i^{xy} = \lambda_i^{xz} = 0$$

$$\forall i, k \quad \lambda_{ik}^{xz} = 0$$

$$\forall k \quad \lambda_{ik}^{xz} = \lambda_{jk}^{yz} = 0$$

$$\forall j, k \quad \lambda_{ijk}^{xyz} = 0$$

در این صورت تعداد پارامتر مدل:

$$1 + (I-1) + (J-1) + (K-1) + (I-1)(J-1) + (I-1)(K-1) + (J-1)(K-1) + (I-1)(J-1)(K-1) = IJK$$

و مدل ۳ به یک مدل اشباع شده تبدیل می شود برای نمایش مدل ۳ رخ کار XYZ


(برای مدل اشباع شده حالتی مختلف به شرح زیر بررسی می شوند):

استفاده می شود
اشباع لودر

$$\forall i, j, k \quad \lambda_{ijk}^{xyz} = 0$$


۱- در مدل ۳ رخ

نمایش داده می شود (XY, XZ, YZ)



۲- اگر $\lambda_{ijk}^{xyz} = 0$ و $\lambda_{j,k}^{yz} = 0$

جواب: $\ln \mu_{ijk} = \lambda + \lambda_i^x + \lambda_j^y + \lambda_k^z + \lambda_{ij}^{xy} + \lambda_{ik}^{xz}$




در این حالت $IJK = (j-1)(k-1) - (i-1)(j-1)(k-1)$

۳- عبارت دیگر در این مدل: $\pi_{jk|i} = \pi_{j+|i} \pi_{+k|i}$

در این صورت $\lambda_{ik}^{xz} = 0$ ، $\lambda_{jk}^{yz} = 0$ ، $\lambda_{ijk}^{xyz} = 0$


در این صورت $\ln \mu_{ijk} = \lambda + \lambda_i^x + \lambda_j^y + \lambda_k^z + \lambda_{ij}^{xy}$



$\pi_{ijk} = \pi_{ij+} + \pi_{++k}$

۴- مدل استقلال: $\lambda_{ij}^{xy} = 0$ ، $\lambda_{ijk}^{xyz} = 0$

$\ln \mu_{ijk} = \lambda + \lambda_i^x + \lambda_j^y + \lambda_k^z$



$\pi_{ijk} = \pi_{i++} + \pi_{+j+} + \pi_{++k}$

۵- با علامه‌های موارد $\lambda_k^z = 0$ یا $\lambda_k^x = 0$

$$\ln \mu_{ijk} = \lambda + \lambda_i^x + \lambda_j^y \quad (i=1 \dots I, j=1 \dots J)$$


نمادها: $(X \oplus Y \oplus Z, Z=U) \Leftarrow (X, Y) \Leftarrow X \cdot Y \cdot Z$

می‌دانیم $\sum_i \sum_j \sum_k \pi_{ijk} = 1$ در این $\pi_{ijk} = C \pi_{i++} \pi_{+j+}$ بنابراین π_{ijk} برابر با $\frac{1}{k}$ است


$$\sum_i \sum_j \sum_k C \pi_{i++} \pi_{+j+} = 1 \Rightarrow \sum_k C = 1$$

$$\Rightarrow C = \frac{1}{k}$$

$$\Rightarrow \pi_{ijk} = \frac{\pi_{i++} \pi_{+j+}}{k}$$



در بعضی مدل‌ها دیگر: $Z \oplus Y | X$



$X \oplus Y | Z$



$X \oplus Y, Z$

برای مقایسه مدل‌های مختلف می‌توانید از χ^2 یا G^2 استفاده کنید

بر آورده برآورد: برای هر کدام از مدل‌ها تحت شرایطی قدرتمندی توان برآورد رده‌های

بهرت آوردن فرض کنید مدل (XZ, YZ) می‌تواند به مدل:

$$\ln \mu_{ijk} = \lambda + \lambda_i^x + \lambda_j^y + \lambda_k^z + \lambda_{ik}^{xz} + \lambda_{jk}^{yz}$$

$$\pi_{ijk} = \pi_{i+|k} \cdot \pi_{+j|k}$$

(14)

Subject
Date

$$L = \prod_i \prod_j \prod_k \frac{e^{-\mu_{ijk}} (\mu_{ijk})^{n_{ijk}}}{n_{ijk}!}$$

$$\ln L \Rightarrow l = \sum_i \sum_j \sum_k n_{ijk} \ln \mu_{ijk} - \sum_i \sum_j \sum_k \mu_{ijk}$$

در این معادله، $\ln \mu_{ijk}$ را می‌توان به صورت $\ln e^{\lambda + \dots} = \lambda + \dots$ نوشت.

$$\frac{\partial l}{\partial \lambda_{ik}} = n_{i+k} - \mu_{i+k} = 0 \Rightarrow \hat{\mu}_{i+k} = n_{i+k}$$

$$\frac{\partial l}{\partial \lambda_{jk}} = n_{+jk} - \mu_{+jk} = 0 \Rightarrow \hat{\mu}_{+jk} = n_{+jk}$$

- برعکس از بار آمار است

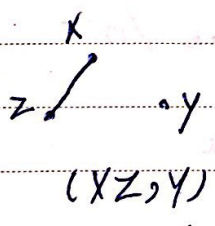
از طرفی داریم:

$$\pi_{ijk} = \frac{\pi_{ijk}}{\pi_{++k}} \Rightarrow \pi_{i+k} \pi_{+jk} = \pi_{ijk} / \pi_{++k}$$

$$\Rightarrow \frac{\pi_{i+k}}{\pi_{++k}} \cdot \frac{\pi_{+jk}}{\pi_{++k}} = \frac{\pi_{ijk}}{\pi_{++k}}$$

$$\Rightarrow \pi_{ijk} = \frac{\pi_{i+k} \pi_{+jk}}{\pi_{++k}} \Rightarrow n \pi_{ijk} = \frac{n \pi_{i+k} n \pi_{+jk}}{n \pi_{++k}}$$

$$\Rightarrow \hat{\mu}_{ijk} = \frac{\hat{\mu}_{i+k} \hat{\mu}_{+jk}}{\hat{\mu}_{++k}} = \frac{n_{i+k} n_{+jk}}{n_{++k}}$$



$y \oplus x, z$ (در این معادله)

$$\hat{\mu}_{ijk} = \frac{n_{+j+} \cdot n_{i+k}}{n}$$

در این معادله $\pi_{ijk} = \pi_{+j+} \pi_{i+k} \Rightarrow n \pi_{ijk} = n \pi_{+j+} n \pi_{i+k} / n$

$$\Rightarrow \hat{\mu}_{ijk} = \hat{\mu}_{+j+} \hat{\mu}_{i+k}$$

$$\Rightarrow \hat{\mu}_{ijk} = \frac{n_{+j+} \cdot n_{i+k}}{n}$$

P4PCO

- برآورد μ_{ijk} در مدل $X \cdot Y \cdot Z$ در صورت آردی

$$\ln \mu_{ijk} = \lambda + \lambda_i^x$$

معنی می رانیم $\sum_i \sum_j \sum_k \pi_{ijk} = 1$ π_{i++} را C می نامیم

$$C \sum_i \sum_j \sum_k \pi_{i++} = 1$$

$$\Rightarrow C = \frac{1}{J_k}$$

$$\Rightarrow \pi_{ijk} = \frac{\pi_{i++}}{J_k}$$

$$\rightarrow n \pi_{ijk} = \frac{n \pi_{i++}}{J_k}$$

$$\rightarrow \hat{\mu}_{ijk} = \frac{\hat{\mu}_{i++}}{J_k} = \frac{n_{i++}}{J_k}$$

- برآورد μ_{ijk} در مدل $X \cdot Y \cdot Z$

$$\ln \mu_{ijk} = \lambda + \lambda_i^x + \lambda_j^y + \lambda_k^z$$

$$\pi_{ijk} = \pi_{i++} \pi_{+j+} \pi_{++k}$$

$$n \pi_{ijk} = n \pi_{i++} \cdot n \pi_{+j+} \cdot n \pi_{++k} / n^2$$

$$\Rightarrow \hat{\mu}_{ijk} = \frac{\hat{\mu}_{i++} \hat{\mu}_{+j+} \hat{\mu}_{++k}}{n^2}$$

سازش درستی تعریف آماره آسیده

$$\hat{\mu}_{i++} = n_{i++} \quad \hat{\mu}_{+j+} = n_{+j+} \quad \hat{\mu}_{++k} = n_{++k}$$

پروج (1963) / آئی. اے. سی. / ایم. اے. / ایم. اے. / ایم. اے.

$$\ln \mu_{ijk} = \lambda + \lambda_i^x + \lambda_j^y + \lambda_k^z + \lambda_{ik}^{xz} + \lambda_{jk}^{yz}$$

$$L = \prod \prod \prod e^{-\mu_{ijk}} (\mu_{ijk})^{n_{ijk}} / n_{ijk}!$$

$$\ln L = - \sum \sum \sum \mu_{ijk} + \sum \sum \sum n_{ijk} \ln \mu_{ijk}$$

$$= -n\lambda - \sum_i n_{i++} \lambda_i^x - \sum_j n_{+j+} \lambda_j^y$$

$$- \sum_k n_{++k} \lambda_k^z - \sum_i \sum_k n_{i+k} \lambda_{ik}^{xz}$$

$$- \sum_j \sum_k n_{+jk} \lambda_{jk}^{yz} - \sum \sum \sum \exp\{-\mu_{ijk}\}$$

$$\frac{\partial \ln L}{\partial \lambda_{ik}^{xz}} = n_{i+k} - \sum_j \sum_k \exp\{-\mu_{ijk}\} = 0$$

$$\ln \pi_{i+k} =$$

دیکھیں کہ یہ سب مساویات پارامیٹرز کے اقدار کے لیے ہوتی ہیں۔
یہ مساویات براہِ راست حل نہیں کی جاسکتی ہیں۔

γ	ν	λ
100	124	1
41	30	2
488	408	3

① جدول زیر را در تست آماری برابر مدل

$$\ln \mu_{ij} = \lambda + \lambda_i^x$$

برای مدل μ_{ij} است که λ و λ_i^x پارامترها هستند؟

$$IJK = 4 \quad ?$$

$$4 - 1 - 3 = 0$$

$$\ln \mu_{ij} = \lambda + \lambda_i^x$$

$$(\sum_i \sum_j \pi_{ij} = 1, \pi_{ij} = c \pi_{i+}) \Rightarrow \sum_i \sum_j c \pi_{i+} = 1 \Rightarrow c = \frac{1}{J}$$

$$n \pi_{ijk} = \frac{n}{J} \pi_{i+} \Rightarrow \hat{\mu}_{ijk} = \frac{\hat{\mu}_{i+}}{J} = \frac{n_{i+}}{J}$$

$$\hat{\mu}_{11} = \frac{n_{1+}}{J} = \frac{124 + 100}{2} = \frac{224}{2} = 112$$

$$\hat{\mu}_{12} = \frac{n_{1+}}{J} = \frac{124 + 100}{2} = \frac{224}{2} = 112$$

$$\hat{\mu}_{21} = \frac{n_{2+}}{J} = \frac{30 + 41}{2} = 35.5 \quad \hat{\mu}_{22} = 35.5$$

$$\hat{\mu}_{31} = \frac{n_{3+}}{J} = \frac{408 + 488}{2} = 448 \quad \hat{\mu}_{32} = 448$$

$$\chi^2 = \frac{(124 - 112)^2}{112} + \frac{(100 - 112)^2}{112} + \frac{(30 - 35.5)^2}{35.5} +$$

$$\frac{(41 - 35.5)^2}{35.5} + \frac{(408 - 448)^2}{448} + \frac{(488 - 448)^2}{448} = 10.308$$

$$p\text{-value} = P(\chi^2_{df=2} > 10.308) = 0.005$$

این مدل در تست آماری برابر مدل است

(۲) جدول زیر را در نظر بگیرید.

y	x	
	1	2
100	124	1
91	35	2
908	418	1
494	807	2

الف) برای مدل

$$E_{ijk} = \lambda + \lambda_i^x + \lambda_j^y + \lambda_k^z$$

تعداد پارامترها، نمودار برآورد کنید و رابطه آورید.

ب) با استفاده از داده‌ها در جدول مدل را برازش کنید.

x = 0 y = 0

$$\hat{I}_{jk} = (I-1)(J-1) - (K-1)(J-1) - (I-1)(K-1) - (I-1)(J-1)(K-1)$$

استفاده $\pi_{ijk} = \pi_{i++} + \pi_{+j+} + \pi_{++k}$

$$n\pi_{ijk} = n\pi_{i++} + n\pi_{+j+} + n\pi_{++k} / n^2$$

$$\Rightarrow \hat{\mu}_{ijk} = \frac{\hat{\mu}_{i++} + \hat{\mu}_{+j+} + \hat{\mu}_{++k}}{n^2} = \frac{n_{i++} + n_{+j+} + n_{++k}}{n^2}$$

$$n_{i++} = 124 + 100 + 418 + 908 = 1822$$

$$n_{+j+} = 124 + 35 + 418 + 807 = 1809$$

$$n_{++k} = 124 + 35 + 100 + 41 = 322$$

$$\hat{\mu}_{111} = \frac{(1822)(1809)(322)}{(2022)^2} = 93,08$$

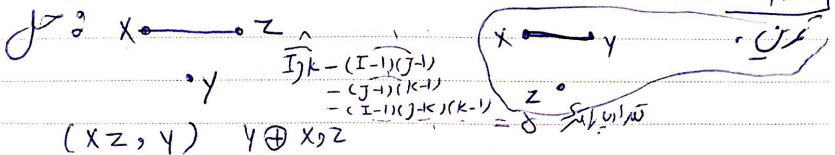
$$\hat{\mu}_{112} = 181,80 \quad \hat{\mu}_{211} = 71,91 \quad \hat{\mu}_{221} = 48,100$$

$$\hat{\mu}_{113} = 147,14 \quad \hat{\mu}_{133} = 797,05 \quad \hat{\mu}_{313} = 965,68$$

$$\hat{\mu}_{333} = 412,48$$

$I_{jk} = \Lambda$ — (x, y)
 $\omega = \pi$

$$\chi^2 = \frac{(114 - 93, 08)^2}{(93, 08)} + \dots + \frac{(494 - 414, 66)^2}{414, 66} = 111, 43$$



$$n \pi_{ijk} = \frac{n \pi_{+j} + n \pi_{i+k}}{n} \rightarrow \hat{\mu}_{ijk} = \frac{\hat{\mu}_{+j} + \hat{\mu}_{i+k}}{n}$$

$$\Rightarrow \hat{\mu}_{ijk} = \frac{n_{+j} + n_{i+k}}{n}$$

$$\hat{\mu}_{111} = \frac{n_{1+} + n_{1+}}{n} = \frac{(114 + 100 + 414 + 494)(114 + 100)}{2222} = 119, 1096$$

$$\hat{\mu}_{112} = 109, 144 \quad \hat{\mu}_{121} = 49, 134 \quad \hat{\mu}_{211} = 49, 44$$

$$\hat{\mu}_{113} = 100, 129 \quad \hat{\mu}_{131} = 114, 109 \quad \hat{\mu}_{311} = 114, 109$$

$$\mu = 100, 129$$

$$\chi^2 = \frac{(114 - 109, 144)^2}{109, 144} + \dots + \frac{(494 - 414, 66)^2}{414, 66} = 111, 43$$

$$p\text{-value} = P(\chi^2_{\pi} > 111, 43) = 0$$

دو سہولتوں کے لیے $\alpha = 1 - \delta = \pi$