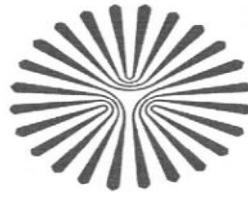


الله
يَعْلَمُ مَا يَعْمَلُونَ



دانشگاه پیام نور
دانشکده علوم پایه

پایان نامه
برای دریافت مدرک کارشناسی ارشد
رشته آمار ریاضی
گروه آمار

عنوان پایان نامه:
استوار سازی معادلات برآوردگر تعمیم یافته
سعید معدنی

استاد راهنما:
دکتر مسعود یار محمدی

استاد مشاور:
دکتر پرویز نصیری

شهریور ۹۰



جمهوری اسلامی ایران
وزارت علوم تحقیقات و فناوری

جمعیت علوم پایه و کشاورزی



دانشگاه پیام نور

دانشگاه پیام نور استان تهران

الله علیک السلام و الحمد لله

شماره

تاریخ

پیوست

صورتجلسه دفاع از پایان نامه کارشناسی ارشد

جلسه دفاع از پایان نامه کارشناسی ارشد آقای سعید معدنی
دانشجوی رشته آمار ریاضی به شماره دانشجویی: ۸۶۷۱۰۵۲۶۶

تحت عنوان:

"استوار سازی معادلات برآوردگر تعمیم یافته"

جلسه دفاع با حضور داوران نامبرده ذیل در روز دوشنبه مورخ: ۹۰/۰۶/۰۷ ساعت: ۹-۱۰ در محل

مجتمع علوم پایه و کشاورزی برگزار شد. و پس از بررسی پایان نامه مذکور با نمره به عدد ۱۲/۴/۵

به حروف ~~جهت رسیدگی~~ و با درجه ارزشیابی عالی مورد قبول واقع شد نشد

ردیف	نام و نام خانوادگی	هیات داوران	مرتبه دانشگاهی	دانشگاه موسسه	امضاء
۱	دکتر مسعود یارمحمدی	استاد راهنمای	دستیار	دانشگاه پیام نور	
۲	دکتر پرویز نصیری	استاد مشاور	دستیار	دانشگاه پیام نور	
۳	دکتر صادق رضایی	استاد داور	دستیار	دانشگاه پیام نور	
۴	دکتر سیما نصری	نماینده علمی گروه	دستیار	دانشگاه پیام نور	
۵	دکتر سیما نصری	نماینده تحصیلات تکمیلی	دستیار	دانشگاه پیام نور	

تهران، خیابان استاد نجات اللهی
خیابان شهید فلاح بور، بلاک ۲۷

تلفن: ۸۸۸۰۰۲۵۲
دورنگار: ۸۸۳۱۹۴۷۵

WWW.TPNU.AC.IR
science.agri@tpnu.ac.ir

اینجانب سعید معدنی دانشجوی ورودی سال ۱۳۸۶ مقطع کارشناسی ارشد رشته آمار ریاضی گواهی می نمایم چنانچه در پایان نامه خود از فکر، ایده و نوشه دیگری بهره گرفته ام با نقل قول مستقیم یا غیر مستقیم منبع و مأخذ آن را نیز در جای مناسب ذکر کرده ام. بدیهی است مسئولیت تمامی مطالبی که نقل قول دیگران نباشد بر عهده خویش میدانم و جوابگوی آن خواهم بود.

سعید معدنی

اینجانب سعید معدنی دانشجوی ورودی سال ۱۳۸۶ مقطع کارشناسی ارشد رشته آمار ریاضی گواهی می نمایم چنانچه بر اساس مطالب پایان نامه خود اقدام به انتشار مقاله، کتاب، و...نمایم ضمن مطلع نمودن استاد راهنما ، بانظر ایشان نسبت به نشر مقاله، کتاب، و...و به صورت مشترک و با ذکر نام استاد راهنما مبادرت نمایم .

سعید معدنی

کلیه حقوق مادی مترتب از نتایج مطالعات ، آزمایشات و نوآوری ناشی از تحقیق این پایان نامه متعلق به دانشگاه پیام نور می باشد

شهریور ۱۳۹۰

به پاس گرمای امید بخش وجودشان

این مجموعه را به همسر و دخترم تقدیم می کنم.

تقدیر و تشکر

در آغاز بر خود واجب میدانم که از زحمات بی دریغ استاد بزرگوار جناب آقای دکتر مسعود یار محمدی که باراهنمایی های راهگشای خود مرا در تهیه و تدوین این اثر همراهی کردند سپاسگزاری کنم.

همچنین از استاد بزرگوار جناب آقای دکتر پرویز نصیری که در مسیر تدوین پایان نامه از مشاوره ارزنده ایشان بهره گرفته ام تشکر می کنم.

چکیده

معادلات برآورده‌گر تعمیم یافته ارایه شده توسط لیانگ و زیگر (۱۹۸۶)، روشی برای برآورده‌گر تعمیم یافته است، هنگامی که همبستگی نامشخصی در میان مشاهدات پارامترها در مدل‌های خطی تعمیم یافته است، هنگامی که همبستگی نامشخصی در میان مشاهدات موجود باشد. این روش در برابر داده‌های غیر معمول و نقاط دورافتاده تحت تاثیر قرار دارد. روش‌های تشخیصی و روش‌های استوارسازی روش‌هایی هستند که به ترتیب جهت شناسائی نقاط دورافتاده و نیز کاهش اثرات این نقاط به کار می‌روند.

در این تحقیق دو روش شناسائی داده‌های دورافتاده و استوارسازی را مورد بررسی قرار داده و آنها را در مورد معادلات برآورده‌گر تعمیم یافته به کار می‌بریم. روش‌های تشخیصی به کاررفته تعمیم روش‌هایی می‌باشند که توسط کوک (۱۹۷۷) و بلسلی و همکاران (۱۹۸۰) در رابطه با رگرسیون خطی مطرح شده‌اند. روش استوارسازی به کار رفته که در اینجا آنرا معادلات برآورده‌گر تعمیم یافته استوار می‌نماییم از روش معادلات برآورده‌گر تعمیم یافته می‌باشد که در برابر داده‌هایی با قدرت نفوذ بالا استوار است. همچنین با ارائه یک مثال کاربردی روش‌های تشخیصی و روش‌های استوارسازی را بررسی کرده و با استفاده از روش شبیه سازی روش‌های استوار را با روش معادلات برآورده‌گر تعمیم یافته مقایسه خواهیم کرد.

واژه‌های کلیدی: معادلات برآورده‌گر تعمیم یافته – معادلات برآورده‌گر تعمیم یافته استوار

فهرست مطالب

۱.....	مقدمه
۵.....	فصل اول: معادلات برآورده تعمیم یافته
۵.....	۱-۱ مقدمه
۶.....	۲-۱ مدل‌های خطی تعمیم یافته
۷.....	۲-۲-۱ توزیع متغیر پاسخ
۸.....	۲-۲-۱ پیشگوی خطی
۸.....	۲-۲-۲ تابع پیوند (تابع ربط)
۹.....	۳-۱ معادلات درستنایی برای الگوهای خطی تعمیم یافته
۱۰.....	۴-۱ روش حداقل مربعات تعمیم یافته و وزن
۱۳.....	۵-۱ روش شبه درستنایی
۱۳.....	۶-۱ معادلات برآورده تعمیم یافته
۱۴.....	۱-۶-۱ ساختار داده ها و نمادگذاری
۱۵.....	۲-۶-۱ تشریح اجزاء معادلات برآورده
۱۷.....	۳-۶-۱ ساختارهای مختلف ماتریس همبستگی کاری
۲۰.....	۴-۶-۱ برآورد پارامتر برآورده
۲۱.....	۵-۶-۱ روش حل معادلات برآورده تعمیم یافته
۲۲.....	۶-۶-۱ مراحل برآورد β در روش معادلات برآورده تعمیم یافته
۲۵.....	فصل دوم: بروزی تأثیر و میزان نفوذ داده‌های دورافتاده روشهای «تشخیصی» و روشهای «استوارسازی»
۲۵.....	۱-۲ مقدمه
۲۶.....	۲-۲ مدل‌های خطی یک متغیره
۳۰.....	۱-۲-۲ حذف مجموعه ای از مشاهدات
۳۰.....	۲-۲-۲ رگرسیون استوار
۳۵.....	۳-۲ مدل‌های خطی تعمیم یافته
۳۹.....	۱-۳-۲ رگرسیون استوار در مدل‌های خطی تعمیم یافته
۴۳.....	۴-۲ مدل با پاسخ همبسته
۴۴.....	۱-۴-۲ رگرسیون استوار در مدل‌های همبسته
۴۹.....	فصل سوم: روشهای «تشخیصی» برای شناسائی نقاط دورافتاده و نقاط با نفوذ در معادلات برآورده تعمیم یافته
۴۹.....	۱-۳ مقدمه
۵۰.....	۲-۳ برآورد پارامترها در معادلات برآورده تعمیم یافته، به روش کمترین مربعات دوباره وزنی شده تکراری
۵۳.....	۳-۳ اندازه‌گیری میزان نفوذ بر مبنای روش حذفی
۵۴.....	۱-۳-۳ ارزیابی میزان نفوذ در حالت حذفی روی $\hat{\beta}$
۵۹.....	۲-۳-۳ تعیین میزان نفوذ در حالت حذفی روی مقادیر برازش داده شده

۶۱.....	۴-۳ یک مثال کاربردی.....
۶۲.....	۴-۴-۱ تعیین مشخصات مدل.....
۶۳.....	۴-۴-۲ برنامه مورد استفاده در محیط SAS و نتایج آن.....
۶۶.....	۴-۴-۳ استفاده از روش‌های تشخیص برای یافتن نقاط دورافتاده و نقاط پرنفوذ.....
۷۷.....	فصل چهارم: معادلات برآورده‌گر تعییم یافته‌ی استوار
۷۷.....	۱-۴ مقدمه
۷۸.....	۴-۴ معادلات برآورده‌گر تعییم یافته‌ی استوار
۸۰.....	۴-۲-۱ برآورده‌پارامترهای رگرسیون و برآورده‌واریانس
۸۰.....	۴-۲-۲ طبقه‌بندی برآوردها
۸۲.....	۴-۲-۳ برآورده‌پارامترهای مزاحم
۸۳.....	۴-۲-۴ روش مالوس در مقایسه با روش شوئیپ
۸۴.....	۴-۲-۵ معادلات برآورده‌گر تعییم یافته‌ی استوار برای پاسخ‌های دودویی همیسته
۸۵.....	۴-۳ مقایسه معادلات برآورده‌گر تعییم یافته با معادلات برآورده‌گر تعییم یافته‌ی استوار به روش شبیه سازی
۸۸.....	۴-۳-۱ مقایسه مقدار اریبی روشهای معادلات برآورده‌گر تعییم یافته استوار با روش GEE در برآورده ₁ β_1
۹۰.....	۴-۳-۲ مقایسه میانگین مربعات خطای برآورده ₁ β_1 در معادلات برآورده‌گر تعییم یافته و روشهای استوار آن
۹۳.....	۴-۴ مرور مجدد داده‌های پزشکی
۹۴.....	۴-۴-۱ معادلات برآورده‌گر تعییم یافته‌ی استوار در کلاس «کاهش وزن مشاهده‌ی مالوس و شوئیپ»
۹۷.....	۴-۴-۲ مقایسه نتایج بدست آمده در روش‌های استوار مالوس و شوئیپ با روش GEE
۹۸.....	نتیجه‌گیری

مقدمه

معادلات برآورده‌گر تعمیم یافته^۱ (GEE) که توسط لیانگ^۲ و زیگر^۳ (۱۹۸۶) ارایه شده است امروزه به طور وسیعی در بیولوژی و پزشکی به کار رفته و کاربرد آن در رشته‌های علمی دیگر مانند کشاورزی و صنایعی که در تحلیل داده‌های آنها همبستگی بین مشاهدات وجود دارد دیده می‌شود. به عنوان مثال در کشاورزی ممکن است داده‌های جمع آوری شده روی یک کرت از زمین دارای همبستگی باشند و یا در تحقیقات صنعتی مشاهدات جمع آوری شده مربوط به یک کوره مجموعه‌ای از داده‌های همبسته را بوجود آورند.

هرگاه از هر عضو نمونه در چند موقعیت مکانی یا زمانی مشاهداتی جمع آوری شود، این داده‌ها را اندازه‌گیری‌های مکرر^۴ می‌نامیم. داده‌های مربوط به هر عضو مجموعه‌ای از مشاهدات همبسته را تشکیل می‌دهند که آنها را خوش نامیده و داده‌های مکرر را که در آن موقعیت تکرار مشاهدات، نقاط زمانی هستند، داده‌های طولی و مطالعات از این نوع را مطالعات طولی می‌نامند. در مطالعات طولی اغلب بین متغیرهای درون هر خوش همبستگی وجود داشته و به همین دلیل برای تحلیل این نوع از داده‌ها باید تمهدات خاصی را به کار برد که روش معادلات برآورده‌گر تعمیم یافته یکی از آنها است.

به علت کاربرد زیاد روش (GEE) در برآورد پارامترهای مدل‌های خطی تعمیم یافته بررسی تأثیر مشاهدات جمع آوری شده روی برآورد پارامترها مهم بوده و اینکه مشاهدات دور افتاده کدامند و تأثیر آنها روی برآورد پارامترها چیست حائز اهمیت است.

^۱. generalized estimating equations

^۲. liang

^۳. zeger

^۴. Repeated measurements

به منظور بررسی و تشخیص اینکه در اثر حذف مشاهدات یا خوش‌ها چه تغییراتی در برازش مدل اتفاق می‌افتد، روش‌های تشخیصی رگرسیون را بکاربرده ایم. استفاده از روش‌های تشخیصی برای اثرات داده‌ها، خصوصاً در مدل‌های چند متغیره کارایی بالائی نداشته بعلاوه شناسائی نقاط دور افتاده و تشخیص آن در رگرسیون دودویی که در آنها متغیر پاسخ به صورت دو حالتی ۰ یا ۱ مطرح می‌شود از تشخیص هویت آنها در داده‌ها پیوسته دشوارتر است.

از آنجا که هدف از روش‌های استوارسازی شناسایی و کاهش اثر داده‌ها دور افتاده و پرنفوذ است، در این تحقیق ابتدا روش‌های شناسائی نقاط دور افتاده و پرنفوذ را مطرح کرده و اثر داده‌ها غیرمتجانس را روی پارامترهای مدل‌های خطی تعمیم یافته که به روش GEE تحلیل می‌شوند مورد بررسی قرار می‌دهیم. سپس روش‌های استوارسازی را به منظور کاهش اثر نقاط دور افتاده و پرنفوذ مورد توجه قرار داده و آنرا معادلات برآورده‌گرتعمیم یافته استوار و به اختصار^۱ (REGEE) می‌نماییم. این روشها بر اساس وزن دهی به مشاهدات بر مبنای میزان تأثیر آنها روی برآورد پارامترهای مدل طراحی شده‌اند. روش‌های برآورده‌گرتعمیم یافته در (REGEE) توسعه یافته‌ی روش‌های استوارسازی مدل‌های خطی تعمیم یافته‌اند که توسط پرگیبون (1982)^۲ و کارول و پدرسن (1993)^۳ در استوارسازی رگرسیون لوزیستیک و پرایسرو کاکیش (1995)^۴ در استوارسازی مدل‌هایی با پاسخ همبسته مطرح شده‌اند، در این روش‌ها کاهش وزن مشاهدات با استفاده از الگوریتم معینی انجام شده و برای هر مشاهده وزنی بین ۰ و ۱ در نظر گرفته می‌شود که این وزن متناسب با اثر آن مشاهده روی برآورده‌گرتعمیم مدل است.

^۱.Resistant generalized estimating equations

^۲Pergibon

^۳Carroll and Pederson

^۴Preisser and Qaqish

در فصل اول راجع به مدل‌های خطی تعمیم یافته و روش معادلات برآورده‌گر تعمیم یافته بحث می‌شود. روش‌های تشخیصی و اصول استوارسازی در فصل دوم مورد بررسی قرار می‌گیرد. در فصل سوم روشهای تشخیصی را برای معادلات برآورده‌گر تعمیم یافته مورد بحث قرار داده و مثالی کاربردی از داده‌های پزشکی را تحلیل خواهیم کرد، روشهای استوارسازی را برای معادلات برآورده‌گر تعمیم یافته در فصل چهارم مورد بررسی قرار داده و با استفاده از شبیه‌سازی و یک مثال کاربردی روشهای استوار معادلات برآورده‌گر تعمیم یافته را با روش معمول آن مقایسه خواهیم کرد.

فصل اول

معادلات برآوردگر تعمیم یافته

فصل اول: معادلات برآورده‌گر تعمیم یافته

۱-۱ مقدمه

با توجه به کاربرد فراوان الگوهای خطی تعمیم یافته وضعیت های بسیاری وجود دارد که پاسخ های تکراری از یک واحد مشاهداتی همبسته را به وجود می آورد. مثالی از این مورد را می توان در مطالعات طولی که در آن پاسخها روی یک آزمودنی در طول زمان به تکرار اندازه گیری می شوند در نظر گرفت. بدیهی است که مشاهدات روی یک آزمودنی همبسته اند و در نظر گرفتن همبستگی میان مشاهدات مشکلاتی را بوجود می آورد. در واقع وجود همبستگی استفاده از روش‌های حداکثر درستنایی معمول را مشکل کرده و لازم است از روش های شبه درستنایی و یا تعمیمی از آن که روش معادلات برآورده‌گر تعمیم یافته است استفاده شود. در این فصل ابتدا مدل‌های خطی تعمیم یافته، روش شبه درستنایی و در پایان روش معادلات برآورده‌گر تعمیم یافته را معرفی می کنیم.

۲-۱ مدل‌های خطی تعمیم یافته

در الگوهای رگرسیون خطی و غیر خطی توزیع نرمال نقش محوری داشته و در برخی از روش‌های استنباطی مربوط به رگرسیون خطی و غیر خطی فرض آن است که متغیر پاسخ Y از توزیع نرمال پیروی می‌کند. اما مثال‌های کاربردی زیادی وجود دارد که این فرض حتی به طور تقریبی هم برقرار نیست. مثلاً زمانی که متغیر پاسخ یک متغیر گسسته و شمارشی است این فرض نقض می‌گردد. به عنوان مثال در مدل‌هایی با پاسخ‌های دوتاوی نیز که فقط دو حالت موفقیت (۱) و شکست (۰) مورد نظر است فرض نرمال بودن نقض شده است. مواردی وجود دارد که متغیر پاسخ پیوسته بوده ولی فرض نرمال بودن برقرار نیست به عنوان مثال می‌توان به توزیع فشار در اجزاء مکانیکی و یا زمان زوال اجزای الکترونیکی اشاره کرد.

الگوهای خطی تعمیم یافته^۱ (GLM) برای برازش الگوهای رگرسیون به داده‌هایی هستند که متغیر پاسخ در آنها از توزیع خانواده نمایی تبعیت می‌کنند. خانواده توزیع‌های نرمال، دوجمله‌ای، پواسون، هندسی، دو جمله‌ای منفی، نمایی، گاما، از این نوع هستند. شکل کلی مدل خطی تعمیم یافته به صورت زیر است:

$$g(\mu) = g[E(y)] = X'\beta \quad (1-1)$$

X بردار متغیرهای کمکی و β بردار پارامترها یا ضرایب رگرسیون است. g تابع پیوند یا ربط می‌باشد می‌توان گفت هر الگوی خطی تعمیم یافته سه جزء اصلی دارد:

۱. توزیع متغیر پاسخ.
۲. پیشگوی خطی که متغیرهای برگشت یا کمکی را شامل می‌شود.

^۱. Generalized Linear model.

۳. تابع پیوند g که پیشگوی خطی را به میانگین متغیر پاسخ مربوط می کند.

۱-۲-۱ توزیع متغیر پاسخ

همانطورکه گفته شد متغیر پاسخ y با میانگین $\mu = E(y)$ در مدلهاي خطی تعیین یافته دارای تابع چگالی از خانواده نمایی می باشد. این تابع چگالی به صورت کلی زیر مطرح می شود.

$$f(y, \theta, \phi) = \exp\left\{ \frac{y\theta - b(\theta)}{a(\phi)} + c(y, \phi) \right\} \quad (2-1)$$

اگر تابع لگاریتم درستنمایی را $L(\theta)$ بنامیم ، داریم :

$$L(\theta) = \sum \left\{ \frac{y_i \theta_i - b(\theta_i)}{a(\phi)} + c(y_i, \phi) \right\}$$

و از اصول استنباط آماری خواهیم داشت :

$$E\left(\frac{\partial L(\theta)}{\partial \theta}\right) = 0 \quad \Rightarrow \quad \mu = E(y) = \frac{db(\theta)}{d\theta} = b'(\theta)$$

$$\text{var}(y) = \frac{d^2 b(\theta)}{d\theta^2} a(\phi) = b''(\theta) a(\phi) = \frac{d\mu}{d\theta} a(\phi)$$

خانواده تابع چگالی نمایی روش یکسانی را برای برآورد پارامترها در مدلهاي خطی تعیین یافته

فراهم می کند . مثلاً توزیع نرمال که برجسته ترین عضو خانواده نمایی است دارای تابع چگالی به

صورت زیر است :

$$f(y, \mu, \sigma) = \exp\left\{ \frac{-(y - \mu)^2}{2\sigma^2} \right\} \cdot \frac{1}{\sqrt{2\pi\sigma^2}}$$

$$= \exp\left\{ \frac{\left[y\mu - \frac{\mu^2}{2} \right]}{\sigma^2} - \frac{1}{2} \left[\frac{y^2}{\sigma^2} + \ln(2\pi\sigma^2) \right] \right\}$$

با توجه به صورت کلی توزیع نمایی در (۱-۱) داریم:

$$\theta = \mu \quad b(\theta) = \frac{\mu^2}{2} \quad a(\phi) = \phi = \sigma^2$$

$$c(y, \phi) = -\frac{1}{\gamma} \left[\frac{y^2}{\sigma^2} + L_n(\gamma \pi \sigma^2) \right]$$

و یا در مورد توزیع دو جمله‌ای داریم:

$$\begin{aligned} f(y, n, p) &= \binom{n}{y} p^y (1-p)^{n-y} \\ &= \exp \left\{ L_n \left(\frac{n}{y} \right) + y L_n p + (n-y) L_n (1-p) \right\} \\ \theta &= L_n \left(\frac{p}{1-p} \right) & b(\theta) &= n L_n \left(1 + e^\theta \right) & \phi &= 1 & c(\cdot) &= L_n \left(\frac{n}{y} \right) & a(\theta) &= 1 \end{aligned}$$

۱-۲-۲ پیشگوی خطی

پیشگوی خطی یا همان مؤلفه سیستماتیک متغیرهایی مانند X را نشان می‌دهد که نقش

متغیرهای تبیینی را در رگرسیون به عهده دارند. فرض کنیم $(y) = E(y) = \mu$ میانگین احتمال باشد مقدار

μ در GLM با تغییر متغیرهای تبیینی تغییر می‌کند. به طور کلی مؤلفه سیستماتیک به صورت زیر مطرح می‌شود.

$$X'\beta = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n \quad (3-1)$$

این ترکیب خطی، متغیرهای پیشگو نامیده می‌شود.

۱-۲-۳ تابع پیوند (تابع ربط)

یک تابع پیوند چگونگی وابستگی $\mu = E(y)$ را به $X'\beta$ شرح می‌دهد و معمولاً به صورت

$g(\mu)$ نوشته می‌شود که یک تابع غیر خطی بوده و به صورت زیر مطرح می‌شود.

$$g(\mu) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n = X' \beta \quad (4-1)$$

ساده ترین تابع پیوند دارای شکل $\mu = g(\mu)$ است که پیوند همانی نامیده می شود. این تابع میانگین را به طور مستقیم مدلسازی کرده و مدلی شبیه مدل رگرسیون معمولی پدید می آورد که معمولاً برای پاسخ های پیوسته مورد استفاده قرار می گیرد.

$$\mu = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n = X' \beta \quad (5-1)$$

از جمله توابع پیوند دیگر $g(\mu) = \log(\mu)$ است که مدل را بر حسب لگاریتم میانگین بیان می کند. انتخاب توابع پیوند بستگی به ماهیت متغیر پیشامد کنترل دارد. انواع توابع ربط (پیوند) برای توزیع های مختلف در جدول (1-1) آمده است.

جدول ۱-۱

توزیع	پیوند متعارف
نرمال	$\eta_i = \mu_i$ (پیوند همانی)
دو جمله ای	$\eta_i = L_n \left(\frac{p_i}{1-p_i} \right)$ (پیوند لوچیت)
پواسون	$\eta_i = L_n (\mu_i)$ (پیوند لگاریتمی)
نمایی	$\eta_i = \left(\frac{1}{\mu_i} \right)$ (پیوند وارون)
گاما	$\eta_i = \left(\frac{1}{\mu_i} \right)$ (پیوند وارون)

۳-۱ معادلات درستنمایی برای الگوهای خطی تعمیم یافته

روش برآورد پارامترها در GLM، روش حداقل درستنمایی می باشد ولی تغییرات واقعی حداقل درستنمایی به الگوریتمی می رسد که برایه روش تکراری کمترین مربعات وزنی قرار دارد. در

صورتی که از پیوند متعارف $\eta_i = g[\mu_i] = X'_i \beta$ استفاده کنیم،تابع لگاریتم درستنمایی عبارت

است از:

$$\begin{aligned} L = \log L(y, \beta) &= \sum_{i=1}^n \left\{ \frac{(y_i \theta_i - b(\theta_i))}{a(\phi)} + c(y_i, \phi) \right\} \\ \frac{\partial L}{\partial \beta} &= \frac{\partial L}{\partial \theta_i} \times \frac{\partial \theta_i}{\partial \beta} = \sum_{i=1}^n \frac{1}{a(\phi)} \left[y_i - \frac{db(\theta_i)}{d\theta_i} \right] X_i = \sum_{i=1}^n \frac{1}{a(\phi)} (y_i - \mu_i) X_i \\ &= \sum_{i=1}^n \frac{1}{a(\phi)} (y_i - \mu_i) X_i \end{aligned} \quad (6-1)$$

می توانیم برآوردهای حداکثر درستنمایی پارامترها را با حل دستگاه معادلات زیر برای β پیدا

کنیم از آنجا که در بیشتر موارد $a(\phi)$ یک عدد ثابت است، این معادلات به صورت زیر در می آیند:

$$\sum_{i=1}^n (y_i - \mu_i) X_i = 0 \quad (7-1)$$

این دستگاه دارای $p = k + 1$ معادله بوده و هر معادله برای یک پارامتر الگو می باشد. شکل

ماتریسی این معادله به صورت زیر است :

$$X'(y - \mu) = 0 \quad (8-1)$$

که در آن $\mu' = [\mu_1, \mu_2, \dots, \mu_n]$ می باشد. این معادلات را معادلات امتیاز حداکثر درستنمایی

می نامند.

۱-۴ روش حداقل مربعات تعمیم یافته و موزون

در مدل رگرسیون خطی $y = X\beta + \varepsilon$ مفروضاتی مانند $V(\varepsilon) = \sigma^2 I$ و $E(\varepsilon) = 0$ در نظر

گرفته می شود گاهی این مفروضات قابل اجرا نیستند . به عنوان مثال اگر $V(\varepsilon) = \sigma^2 V$ که V یک

ماتریس $n \times n$ شناخته شده باشد اصلاحاتی باید روی روش حداقل مربعات معمولی در نظر گرفته

شود. می دانیم که اگر V یک ماتریس قطری باشد اما اعضای قطر مساوی نباشد در اینصورت متغیرهای y ناهمبسته اند اما واریانس‌های مساوی ندارند. اگر بعضی از اعضای غیر قطر اصلی صفر نباشد مشاهدات همبسته بوده و برآورد حداقل مربعات معمولی $\hat{\beta} = (X'X)^{-1}X'y$ بهینه نیست.

چون $V^2 \sigma^2$ ماتریس کوواریانس خطاهای می باشد، V بایستی ناویژه و معین مثبت باشد بنابراین ماتریس $n \times n$ ناویژه متقارن k موجود است به طوری که $V = kk' = k'k$. ماتریس k ریشه دوم

نامیده می شود. متغیرهای زیر را در نظر می گیریم:

$$Z = k^{-1}y \quad B = k^{-1}X \quad g = k^{-1}\varepsilon$$

به عبارت دیگر مدل رگرسیون $y = X\beta + \varepsilon$ به صورت زیر خواهد شد

$$k^{-1}y = k^{-1}X\beta + k^{-1}\varepsilon$$

$$Z = B\beta + g \quad (9-1)$$

خطاهای تبدیل یافته در مدل جدید دارای امید ریاضی صفر بوده و ماتریس کوواریانس g هم به صورت زیر خواهد بود.

$$\begin{aligned} V(g) &= E\left\{ [g - E(g)][g - E(g)]' \right\} = E(gg') \\ &= E(k^{-1}\varepsilon\varepsilon'k^{-1}) = k^{-1}E(\varepsilon\varepsilon')k^{-1} = \sigma^2 k^{-1}V k^{-1} = \sigma^2 k^{-1}kk^{-1} = \sigma^2 I \end{aligned}$$

بنابراین اعضای g دارای میانگین صفر و واریانس ثابت بوده و ناهمبسته می باشند. چون خطاهای g در مدل $Z = B\beta + g$ و در مفروضات معمول صدق می کند می توانیم روش حداقل مربعات معمول را برای آن به کار ببریم.تابع حداقل مربعات و درنتیجه معادلات نرمال به صورت زیر خواهد بود.

$$S(\beta) = g'g = \varepsilon'V^{-1}\varepsilon = (y - X\beta)'V^{-1}(y - X\beta) \quad (10-1)$$