



٣٢٧٦٩



دانشگاه صنعتی اصفهان

دانشکده علوم ریاضی

طبقه‌بندی داده‌ها با استفاده از مدل‌های تربیتی

پایان نامه کارشناسی ارشد آمار

آیین سعادت‌ملی

۱۳۷۹

استاد راهنمای

دکتر ایوب ساعی

۱۳۸۰ / ۱ / ۱۰



۱۳۷۹

۳۲۷۴۹



دانشگاه صنعتی اصفهان
دانشکده علوم ریاضی

پایان نامه کارشناسی ارشد رشته آمار خانم آیین سعادت ملی
تحت عنوان

طبقه‌بندی داده‌ها با استفاده از مدل‌های تربیی

در تاریخ ۷۹/۷/۲۵ توسط کمیته تخصصی زیر مورد بررسی و تصویب نهائی قرار گرفت.

دکتر ایوب ساعی

۱- استاد راهنمای پایان نامه

دکتر علی زینل همدانی

۲- استاد مشاور پایان نامه

دکتر مجتبی گنجعلی

۳- استاد داور ۱

دکتر محمد صالحی

۴- استاد داور ۲

دکتر امیر نادری

سرپرست تحصیلات تکمیلی دانشگاه

هذا من فضل ربی

حمد و سپاس خدای بزرگ و مهربان که همواره مرا مورد لطف و عنایت خویش قرار داده و توفیق انجام این پایان نامه را به من عطا فرمود.

بر خود لازم می‌دانم از کلیه عزیزان و سرورانی که مرا در انجام این پایان نامه یاری فرمودند کمال تشکر و قدردانی را بنمایم.

تشکر و سپاس ویژه از

جناب دکتر ایوب ساعی استاد راهنمای ارجمند که با راهنماییهای دلسوزانه و نیز جدیت و پشتکار بسیار، بنده را در ارائه این پایان نامه یاری فرمودند.

جناب دکتر علی همدانی استاد مشاور که کمال همکاری و مساعدت را فرمودند.

جناب دکتر گنجعلی استاد داور ارجمند که زحمت بازخوانی و داوری این پایان نامه را متقبل شدند.

جناب دکتر محمد صالحی که به عنوان استاد داور دانشکده در جلسه دفاع حضور یافته و تذکرات جالب و مفیدی را مطرح کردند و با پیشنهادات ظریف و بجا زمینه هر چه بهتر شدن پایان نامه را فراهم فرمودند.

جا دارد از کلیه اساتید دانشکده ریاضی دانشگاه صنعتی به ویژه دکتر پارسیان استاد گرانقدر و همچنین از کلیه اساتید گروه آمار دانشگاه اصفهان به ویژه دکتر علامتساز و به خصوص از خانواده خوب و فداکارم کمال تشکر و قدردانی را بنمایم.

کلیه حقوق مادی مترتب بر نتایج مطالعات،
ابتكارات و نوآوریهای ناشی از تحقیق موضوع
این پایان نامه (رساله) متعلق به دانشگاه صنعتی
اصفهان است.

تقدیم به

پدر و مادر فدایکاری

خواهر و برادر عزیزخان

فهرست مطالب

صفحه	عنوان
شش	فهرست مطالب
۱	چکیده
۲	فصل صفر - مقدمه
۴	فصل یک - معرفی مدلهایی برای طبقه بندی داده ها
۵	۱ - مدلهای عددی
۹	۱ - ۳ - مدل رگرسیون لجستیک چندگانه
۱۴	۱ - ۴ - مدلهای تشخیصی
۲۱	۱ - ۵ - مدلهای بخت تجمعی
۲۶	۱ - ۶ - مدل نسبت دنالهای
۲۹	۱ - ۷ - فرایند طبقه بندی
۳۵	۱ - ۸ - تحلیل ممیزی بین گروههای مرتب شده
۴۱	۱ - ۹ - تفاوت بین رگرسیون لجستیک و تحلیل ممیزی
۴۸	۱ - ۱۰ - نرخ خطاهای
۴۹	فصل دوم - روشهای شبیه سازی
۵۱	۱ - ۱ - متغیرهای کمکی دوتائی مستقل
	۱ - ۲ - متغیرهای کمکی نرم افزار چند متغیره

۳-۲ - داده‌های PO برای مقایسه فرایندهای PO و ML و AP ۵۱

۴-۲ - داده‌های CR برای مقایسه فرایندهای ML و OL و ND ۵۴

فصل سوم - تحلیل ممیزی مدل‌های آستانه‌ای با اثرات تصادفی

۱-۳ - مقدمه ۵۷

۲-۳ - مدلها و نمادها ۵۸

۳-۳ - برآورد ۷۰

۴-۳ - کاربرد در بررسی بیماریهای پوستی ۷۳

۵-۳ - روش‌های شیوه سازی ۷۷

فصل چهارم - جدولها و نتایج

چکیده

کمبل در سال ۱۹۹۱ یک روش شبیه سازی برای برآش مدل به داده های ترتیبی (Ordinal) انجام داد. نتایج شبیه سازی کمبل نشان داد که وقتی هدف اصلی طبقه بندی کردن داده ها باشد مدل های ترتیبی هیچ مزیتی بر مدل های غیر ترتیبی ندارد. کمبل در مقاله خود شبیه سازی را بدون در نظر گرفتن انواع مختلف داده ها و خواص آنها انجام داده است. در این تحقیق ما موضوع را با دیدگاه دیگری بررسی می کنیم. در این نوشتار با توجه به نوع گستره یا پیوسته بودن متغیر های کمکی مدل های مختلفی را مورد بررسی قرار داده و انواع خطاهایی را که از این طبقه بندی حاصل می شود به دست می آوریم. همچنین نشان داده خواهد شد که مدل های ترتیبی نسبت به مدل های غیر ترتیبی بهتر عمل کنند. در آخر طبقه بندی کردن داده ها را با مدل هایی با اثرات آمیخته مورد بررسی قرار می دهیم.

فصل صفر

مقدمه:

در دهه 60 میلادی ابتدا واکرو دانکن^(۱) مدل‌های مرتب شده را مورد توجه قرار دادند آنها مدل‌های بخت مناسب را مورد توجه قرار دادند پس مکالگ^(۲) (۱۹۸۰) به بسط این مدل‌ها که توسط واکرو دانکن مطرح شده بود پرداخت و آن را به فرم مدل‌های لجستیک و مقدارفرين ماکزيمال و مقدار فريين مينمال بسط داد و به بررسى آنها پرداخت.

در دهه ۷۰ ايشنبيز و آوري^(۳) مدل‌های تحليل مميزی را مورد بررسی قرار دادند که در سالات بعد از آن به مدل‌های تحليل مميزی نرمال با چندين گروه و سپس فرض با عدم همگني، ماترييس واريанс کواريانس آن را بسط داده‌اند که اين مطلب اخير از حوصله اين مقاله خارج است.

در سال ۱۹۸۱ فيليپ و آندرسن^(۴) به بررسی رگرسيون مدل‌های تحليلی مميزی پرداختند و قواعدی برای طبقه‌بندی آن‌ها ارائه کردند.

در سال ۱۹۸۴ ميلادي آندرسن^(۵) به بررسی رگرسيون متغيرهای طبقه‌بندی شده مرتب شده پرداخت.

1- Walker fDuncan

2- Mccullagh

3- Eisenbers f Arery

4- Philips f Anderson

5- Anderson

بعد از آن ریشی و پولک^(۱) به بررسی رگرسیون اینگونه متغیرها در صورت دو تائی بودند همت گماردند و آرمسترانگ و اسلوان^(۲) مدل‌های نسبت متناسب را در سال ۱۹۸۹ ابداع کردند و در آن مسائلی را که مربوط به اپیدمیولوژی بود بررسی کردند. در نهایت کمبل^(۳) به بررسی خطاهای مربوط به مدل‌های مختلف پرداخت. البته او تنها خطای نوع اول که ترتیب را در نظر نمی‌گیرد مورد توجه قرار داد. در مقاله حاضر سه خطای مختلف را که خطای نوع اول آن همان است که کمبل در نظر گرفته بود و ۲ خطای نوع دوم و سوم را مورد بررسی قرار داده است. خطای نوع دوم و سوم خطاهای مربوط به متغیرها را در حالت ترتیبی یعنی زمانی که ترتیب مهم است در نظر گرفته‌ایم. در فصل دوم به روش‌های شبیه سازی در حالتی که متغیرهای کمکی دو تائی یا نرم‌مال چند متغیره است پرداخته‌ایم. در فصل سوم به بررسی همین مدل‌ها در حالتی که متغیرهای تصادفی نیز در مدل می‌باشد پرداخته‌ایم.

در فصل چهارم نتایج کامپیوتری و تحلیل آنها آمده است. تمام محاسبات با استفاده از نرم‌افزار SAS و زیر برنامه PROC IML در آن انجام شده است.

1- Ashby f Pocok

2- Armstrong f sloan

3- cambell

فصل اول

معرفی مدل‌های برای طبقه‌بندی کردن

داده‌ها

۱-۱) مقدمه

متغیرهای پاسخ گستته که بیش از دو طبقه داشته باشند اغلب ترتیبی می‌باشند. بدین معنی که پیشامدهای توصیف شده توسط اعداد طبقه $1, 2, \dots, J$ را می‌توان همچون ترتیب در نظر گرفت. فرض کنید X یک بردار P بعدی از متغیرهای پیش‌بینی کننده باشد و J یک عدد مطابق با گروه عضویت باشد. فرض می‌کنیم که y, J مقدار $1, 2, \dots, J$ را می‌گیرد و به علاوه گروههای $1 = Y, Y = J, \dots, Y = 1$ را به ترتیب بهترین (نرمال) و بدترین (بیمارترین و زیان‌آورترین) خروجی‌ها می‌نامیم. ترتیب پذیری y به توزیع متغیرهای کمکی X منعکس می‌شود با میانگین آنها باید هم خطی چندگانه برای ترتیب پذیری مشاهدات داشته باشد.

ارتباط y, X ممکن است با مدل‌های رگرسیون لجستیک بررسی شود. وقتیکه $J=2$ یک متغیر دوگروهی است؛ گروهها خوب / بد یا قبول / رد می‌باشد و مدل رگرسیون لجستیک دوتائی (MLR) قابل کاربردی است. در عمل $J > 2$ است یک مدل رگرسیون لجستیک چندگروهی (MLR) خواهیم

داشت. یک مثال سیستمهای چندگروهی بد / متوسط / خوب می‌باشد.

انگل^(۱) در سال ۱۹۸۸ گروه‌بندیهای زیر را بکار برد.

۱- مدل‌های عددی: این مدل‌ها شامل تحلیل ممیزی نرمال (ND) و لجستیک چندگانه (ML) که در فصول بعدی شرح بیشتری درباره آن می‌دهیم می‌باشد.

۲- مدل‌های تشخیصی: این مدل‌ها حالت‌هایی که در آنها روی گروه‌هایی که کارشناس تحلیل کرده است، شک و تردید وجود دارد را نشان می‌دهد. مثال این مدل‌ها مدل لجستیک ترتیبی است.

۳- مدل‌های بخت تجمعی: این مدل‌ها فرض می‌کنند که پاسخهای ترتیبی به یک متغیر پیوسته و غیر قابل مشاهده وابسته است و این متغیر پنهان دارای یک توزیع خاص در یکی از فواصل متصل بهم که بانفراط بریدگی معلوم از هم جدا شده است قرار می‌گیرند و با حرکت از یک فاصله به فاصله دیگر متغیر پاسخ تغییر می‌کند.

یک مثال متغیر پنهان مطابق با (سرعت) ملایم / متوسط / سریع می‌باشد. مدل‌های بخت مناسب (PO) و نسبت دنباله‌ای (CR) دو زیر گروه این نوع مدل‌ها می‌باشند.

$\pi_{ij} = P(Y=j \mid X_i)$ در این ارتباط داریم:

بطوریکه در آن π_{ij} از طریق قضیه بیز با عبارتهای برای $P(X_i \mid Y=j)$ بدست می‌آید.

گروه مرجع را $1 =$ زدن نظر می‌گیریم هدف از همه فرایندهایی که در زیر توضیح می‌دهیم برآورد تابع چند جمله‌ای (۱-۱-۱) $\lambda_j(x_i) = \alpha_j + \beta'_j \times i$ می‌باشد.

(۱-۲) مدل‌های عددی:

۱- مدل‌های تحلیل ممیزی (ND):

این مدل توسط آوری^(۲) و ایشینبیز^(۳) (۱۹۷۵) پیشنهاد شد.

۱- Engel

۲- Avery

۳- Eisenbeis

هدف از این تحلیل ممیزی چند متغیره این است که بر اساس اطلاعات قدرت جداسازی نمونه‌ها و یا صفات را بدست آورده و سپس برای مشاهدات جدید توانائی بهترین تخصیص را داشته باشیم. روش تحلیل ممیزی را یک روش جستجوگر و کشف کننده می‌نامیم.

اهداف استفاده از روش تحلیل ممیزی و طبقه‌بندی عبارتند از :

۱- تعیین تشخیص دهنده‌هایی که مقادیر عددی آنها برای مشاهدات چنان باشد که تا حد امکان جدا کردن آنها را ممکن سازد.

۲- مرتب نمودن مشاهدات و یا موضوعهای مورد مطالعه به چندگروه از قبل تعیین شده به طوریکه یک مشاهده را بتوان به صورات بهینه (یعنی حداقل خطا) به گروهی اختصاص داد.

فرمول بندی مسئله تحلیل ممیزی به این صورت است: فرض کنید J جمعیت متمایز π_1, \dots, π_p داریم. می‌خواهیم فردی را با مشاهده $x = (x_1, \dots, x_p)$ با خصوصیت مختلف که فرد را مشخص می‌سازد به یکی از جمعیتها π_1, \dots, π_p بندی کنیم.

وقتی گروه افراد را در نظر می‌گیریم اساساً فرض می‌کنیم که گروه به عنوان کل فقط به یکی از J جمعیت مفروض متعلق است. علاوه بر این فرض خواهیم کرد که هر یک از π ‌ها را می‌توان بوسیله میانگینهای تابع توزیع F که به صورت یک بردار متغیر تصادفی $(X_1, \dots, X_p) = X$ می‌باشد تعیین کرد به قسمی که مؤلفه‌های این بردار تصادفی اندازه‌های تصادفی برای P خصوصیت مختلف را نشان می‌دهند.

تمام فضای P بعدی مقادیر X را به E^P نشان می‌دهیم. اکنون می‌خواهیم برای تقییم E^P به J ناحیه مجزای R_1, \dots, R_p قاعده‌ای تنظیم کنیم به گونه‌ای که اگر X در R_j قرار گیرد فرد را به گروه π_j اختصاص می‌دهیم، بدیهی است که در بکار بردن چنین قاعده‌ای ممکن است با اشتباه رده بندی کردن یک فرد به π_i برای $j \neq i$ وقتی واقعاً فرد به π_i متعلق است مرتكب خطا شویم.

چون حالت K جمعیت نرمال چند متغیره حالت کلی تراز ۲ جمعیت نرمال چند متغیره است ابتدا همان حالت $2 = K$ را بررسی می‌کنیم.

فرض کنید که $\mathbf{z} = \mathbf{y}$ داده شده باشد، \mathbf{X} دارای توزیع نرمال چند متغیره P بعدی با بردار میانگین μ و ماتریس واریانس کوواریانس Σ است. آنگاه تابع داده شد در (۱-۱-۱) را می‌خواهیم برآورد کنیم.

$$F_i(x) = (2\pi)^{-p/2} |\Sigma|^{-1/2} \exp \left[-\frac{1}{2} (x - \mu_i)' \Sigma^{-1} (x - \mu_i) \right]$$

$$\frac{F_1(x)}{F_2(x)} = \exp \left[-\frac{1}{2} (x - \mu_1)' \Sigma^{-1} (x - \mu_1) + \frac{1}{2} (x - \mu_2)' \Sigma^{-1} (x - \mu_2) \right]$$

$$= \exp \left[-\frac{1}{2} (\mu_1 - \mu_2)' \Sigma^{-1} (\mu_1 + \mu_2) + (\mu_1 - \mu_2)' \Sigma^{-1} x \right]$$

$$\ln \frac{F_1(x)}{F_2(x)} = (\mu_1 - \mu_2)' \Sigma^{-1} x - \frac{1}{2} (\mu_1 - \mu_2)' \Sigma^{-1} (\mu_1 + \mu_2)$$

$$L(x) = (\mu_1 - \mu_2)' \Sigma^{-1} \left(x - \frac{1}{2} (\mu_1 + \mu_2) \right)$$

اما از طرفی

پس با مساوی قرار دادن دو عبارت $L(x)$ با هم داریم:

$$\alpha_0 = \frac{1}{2} (\mu_1 - \mu_2)' \Sigma^{-1} (\mu_1 + \mu_2)$$

$$\alpha = \alpha_1 = (\mu_1 - \mu_2)' \Sigma^{-1}$$

که عبارت اخیر یک بردار سطربی می‌باشد.

از اینرو اگر

$$\alpha_0 + \alpha_1 x = (\mu_1 - \mu_2)' \Sigma^{-1} x - \frac{1}{2} (\mu_1 - \mu_2)' \Sigma (\mu_1 + \mu_2)$$

$$\Rightarrow \hat{\alpha}_0 = \frac{1}{2} (\mu_1 - \mu_2)' \Sigma^{-1} (\mu_1 + \mu_2) \quad (1-2-1)$$

$$\hat{\alpha}_1 = (\mu_1 - \mu_2)' \Sigma^{-1} \quad (1-2-2)$$