

به نام خدا

برآور迪ابی در مدلهاي متغير نهان

با استفاده از تحلیل مؤلفه های اصلی و تحلیل تناظر

به وسیله‌ی:

حمیدرضا خورشیدی

۰۱۵۹۹۱

پایان نامه

ارائه شده به معاونت تحصیلات تکمیلی به عنوان بخشی از  
فعالیتهای تحصیلی لازم برای اخذ درجه کارشناسی ارشد

در رشته‌ی:

آمارریاضی

از دانشگاه شیراز

شیراز

جمهوری اسلامی ایران

ارزیابی و تصویب شده توسط کمیته پایان نامه با درجه: بسیار خوب

دکتر عبدالرسول برهانی حقیقی، استادیار بخش آمار (رئیس کمیته)

دکتر جواد بهبودیان، استاد بخش آمار

دکترناهید سنجری فارسی پور، دانشیار بخش آمار

مهر ماه ۱۳۸۰

۳۹۱۰

تقدیم به:

## پدر و مادر مهربانم

## سپاسگزاری

در ابتدای کلام ، پروردگاری که زیباییش را در آموختن، دیدن و شنیدن بر من نمایان ساخت سپاس می گویم.

و از استاد گرامی خود، دکتر عبدالرسول برهانی حقیقی که راهنمایی های ایشان مرا در تدوین این پایان نامه موفق ساخت، و استاد فرزانه دکتر جواد بهبودیان و خانم دکتر ناهید سنجری که در طول دوران تحصیل از آموخته های ایشان استفاده فراوان نمودم، بسیار قدر دانی می کنم. همچنین از خانواده خود و دوست عزیزم، مجید عظیم محسنی، که همیشه در کنار من بوده اند تشکر فراوان دارم.

## چکیده

# برآوردیابی در مدل‌های متغیر نهان با استفاده از تحلیل مؤلفه‌های اصلی و تحلیل تناظر

به وسیله‌ی :

حمیدرضا خورشیدی

تحلیل مؤلفه‌های اصلی(PCA) و تحلیل تناظر (CA) اغلب در تحلیل داده‌های چندمتغیره بکار می‌روند. در PCA  $n$  مشاهده از  $m$  متغیر اولیه در یک ترکیب خطی به مشاهداتی با بعد کمتر تبدیل می‌شوند. این تبدیل بوسیله بردار ویژه‌های ماتریس کواریانس نمونه‌ای  $S$  صورت می‌گیرد. CA نیز معادل با PCA برای داده‌های طبقه‌ای با ویژگی کاهش بعد می‌باشد. با این تفاوت که در CA بردار ویژه‌های یک ماتریس وزنی از مشاهدات در تحلیل مورد استفاده قرار می‌گیرند.

در این پایان نامه بکار گیری بردار ویژه های اصلی، که حاوی بهترین اطلاعات از مشاهدات هستند، برای برآورد پارامتر مدلها متفاوت نهان مدنظر میباشد. این پایان نامه شامل شش فصل میباشد. فصل اول مروری دارد بر تاریخچه همچنین در این فصل نقش بردار ویژه ها در تجزیه مقدار منفرد (SVD) آمده است.

تعریف PCA و CA، و ارتباط آنها با تجزیه مقدار منفرد، در فصل دوم مورد بحث میباشد و بردار ویژه های مرتبط با SVD بعنوان شاخصهای سطری و ستونی PCA و CA تعریف میشوند.

در فصل سوم با تعریف کوتاهی از مدلها خطی تعمیم یافته، دو مدل از این کلاس معرفی میشوند که در آنها تابع پیش بینی کننده به صورت یک تابع خطی و یا درجه دوم از متغیر های نهان میباشد. پیش بینی کننده های خطی در این مدلها بصورتهای  $\eta_{ij} = \alpha_j + \beta_j x_i$  و یا  $\eta_{ij} = a_j - b_j(x_i - u_j)^2$  تعریف شده اند، جاییکه  $x_i$  یک متغیر نهان و  $i = 1, 2, \dots, n; j = 1, 2, \dots, m$  میباشد و برای متغیر های پاسخ در این مدلها، توزیعهای نرمال، پواسن و یا برنولی مفروض است.

در فصل چهارم نشان داده میشود که PCA با برآورد MLE برای  $\beta$  در مدل خطی گاووسی معادل است، و همچنین CA میتواند در تقریب برآورد MLE برای  $\alpha$  بکار رود.

سازگاری حدی برآورد گرها پیشنهادی، در فصل پنجم مورد ارزیابی قرار میگیرد و در انتها، در فصل ششم کاربرد بخشی از نتایج فوق برای داده های محیط زیستی بیان میگردد.

## فهرست مطالب

صفحه	عنوان
هشت	فهرست جدول ها
نه	فهرست شکل ها
۱	فصل اول : مقدمه
۶	فصل دوم : تحلیل مؤلفه های اصلی و تحلیل تناظر
۷	۱-۲ : مقدمه
۹	۲-۲ : تحلیل مؤلفه های اصلی
۱۳	۲-۱-۲ : SVD در ارتباط با PCA
۱۵	۳-۲ : تحلیل تناظر
۱۵	۱-۳-۲ : CA در جداول توافقی
۱۸	۲-۳-۲ : CA در ارتباط با SVD
۲۲	فصل سوم : معرفی مدل
۲۳	۱-۳ : مدل های خطی تعمیم یافته
۲۶	۲-۳ : مدل های متغیر نهان
۳۱	فصل چهارم : برآورد یابی در مدل های (۱) و (۲)

۳۲	۴-۱: ارتباط MLE با PCA در مدل (۱)
۳۶	۴-۲: ارتباط CA با MLE در مدل (۲)
۴۱	فصل پنجم: سازگاری
۴۲	۱-۵: مقدمه
۴۳	۵-۲: برآوردهای PCA
۴۴	۵-۳: برآوردهای CA
۵۹	۴-۴: یک بررسی نموداری
۶۵	فصل ششم: آمار در محیط زیست
۶۶	۶-۱: شبیه سازی
۶۹	۶-۲: داده های محیط زیستی
۷۲	مراجع

چکیده انگلیسی

## فهرست جدول ها

صفحه	عنوان
۲۷	جدول ۱-۳: جدول کلاس بندی مدل‌های متغیر نهان
۶۸	جدول ۱-۶: جدول ضرائب همبستگی میان پارامتر و برآوردها

## فهرست شکل ها

عنوان	صفحة
شکل ۱-۵: رسم مؤلفه‌های $\pi$ در مقابل پارامتر مدل (۱)	۶۳
شکل ۱-۵: رسم مؤلفه‌های $\pi$ در مقابل پارامتر مدل (۲)	۶۴

## مقدمه

فرض می کنیم برای  $n$  شی متمایز از یک جامعه  $m$  ویژگی (متغیر تصادفی) مورد نظر باشد. مشاهدات حاصل از  $m$  متغیر را برای هر کدام از  $n$  شی می توان به شکل آرایش ماتریسی نمایش داد بگونه ای که سطر  $i$  ام، شامل  $m$  ویژگی شی  $i$  ام می باشد، که آن را ماتریس مشاهدات مینامیم. هدف یک مطالعه بهترین استنباط از این ماتریس برای جامعه آماری مورد نظر است.

یک محقق ممکن است علاوه بر در دست داشتن مشاهدات فوق، یک سری فرضیات تئوری را نیز از تأثیر متغیرهای دیگر (متغیرهای کمکی) بر این مشاهدات (متغیرهای پاسخ) در نظر بگیرد. که منجر به استفاده از تئوری مدلها در مطالعه او می گردد که در این تئوری کشف ارتباط بین متغیرهای کمکی و پاسخ بر اساس جمع آوری مشاهداتی از هر دو متغیر صورت میگیرد. اگر به هر دلیل امکان مشاهده متغیر کمکی وجود نداشته باشد. این مدل در اصطلاح یک "مدل متغیرنهان" میباشد. که در آن متغیر کمکی به عنوان یک متغیر نهان (بی مشاهده) حضور دارد. از جهت دیگر یک محقق ممکن است از تحلیل مؤلفه های اصلی (PCA) و تحلیل تناظر (CA) برای مشاهدات خود استفاده نماید. PCA و CA دو روش مرتبط با یکدیگر در کاهش بعد و توجیه ساختار داده های چند متغیره میباشند. در PCA، اولین محورهای اصلی ماتریس کواریانس  $S$  بعنوان محورهایی که در یک بعد کمتر حداکثر بار اطلاعاتی موجود در  $S$  را به همراه دارند بعنوان مختصات جدید برای تصویر داده های اولیه بکار میروند. CA را نیز

معادل با PCA برای داده‌های طبقه‌ای میدانند. که در آن بجای ماتریس کواریانس  $S$  اولین محورهای اصلی یک ماتریس وزنی از مشاهدات (که در فصل دوم به تعریف آن می‌پردازیم) بعنوان محورهای مختصات جدید مورد نظر می‌باشد. محورهای اصلی در اینجا بردار ویژه‌های ماتریسهای مذکور هستند. همانگونه که میدانیم در جبر ماتریسهای مقادیر و بردار ویژه‌های هر ماتریس بیشترین نقش را در تجزیه‌های گوناگون آن دارند. از جمله این تجزیه‌ها می‌توان از تجزیه مقدار منفرد (SVD) نام برد، که تعمیم تجزیه طیفی ماتریسهای متقاضی برای ماتریسهای غیر مربعی است و در آن هر ماتریس  $A_{n \times m} \equiv [a_{ij}]$  با رتبه  $k$  به حاصلضرب دو ماتریس متعامد  $n \times k$  و  $m \times k$  و یک ماتریس قطری  $k \times k$  بصورت  $A = P \Delta Q^T = \sum_{r=1}^k \lambda_r p_r q_r^T$  تجزیه می‌گردد، که مقادیر منفرد ماتریس  $A$  بترتیب نزولی  $\lambda_1 > \lambda_2 > \dots > \lambda_k$  در نظر گرفته می‌شوند. برای آنکه نقش این تجزیه در جبر ماتریسهای بیشتر نمایان شود به قضیه‌ای در این

ارتباط توجه می‌کنیم:

قضیه(۱-۱): برای هر ماتریس  $A$  با تجزیه فوق و هر مقدار صحیح و مثبت  $\rho$  که

کوچکتر از  $k$  باشد، خواهیم داشت:  $\min_{B_{n \times m}: \text{Rank}(B) \leq \rho} \|A - B\|^2 = \sum_{r=\rho+1}^k \lambda_r^2$  ، اگر و تنها اگر

$B = \sum_{r=1}^{\rho} \lambda_r p_r q_r^T$  باشد، که در آن نماد  $\|\cdot\|$  برابر نرم اقلیدسی است (Gabriel-1978).

بنابراین در میان ماتریسهایی با رتبه کمتر از  $k$  نزدیکترین ماتریس به  $A$  در اندازه اقلیدسی، با مجموع اولین جملات در SVD ماتریس  $A$  برابر است و هر اندازه که اولین مقادیر منفرد ماتریس  $A$  که در این مجموع شرکت دارند در مقایسه با دیگر مقادیر بزرگ باشند، این نزدیکی به ماتریس  $A$  بیشتر خواهد بود. نقش اولین بردارهای ویژه در این قضیه، برای ماتریس کواریانس نمونه‌ای  $S$  در تحلیل مؤلفه‌های اصلی و معادل آن برای ماتریس وزنی از مشاهدات در تحلیل تناظر ظاهر می‌شود. که این موضوع در فصل دوم پایان‌نامه مورد بررسی قرار می‌گردد.

هدف ما نشان دادن این نقش و بکارگیری PCA و CA در برآورد مدلهای متغیر نهان میباشد. که برای این منظوردو کلاس از مدلهای خطی تعمیم یافته در نظر گرفته میشوند، که در آنهاتابع پیش‌بینی کننده یک تابع خطی یا درجه دوم از متغیرهای نهان میباشد. در مدل اول متغیرهای پاسخ  $z_{ij}$  باوسیله تابع پیش‌بینی کننده  $\eta_{ij}$  و بصورت زیر به مدل در آمده اند:

$$\eta_{ij} = \text{Link}(\mu_{ij}) = \alpha_j + x_i \beta_j \quad ; \quad i=1, \dots, n; j=1, \dots, m \quad (1)$$

بگونه‌ای که  $E(z_{ij}) = \mu_{ij}$  و  $x_i$  به عنوان یک عامل ثابت در شکل متغیر نهان در مدل میباشد. توجه ما به توزیعهای نرمال، پواسن و برنولی است. برای توزیع نرمال معادله (1) بعضی اوقات یک مدل آنالیز فاکتور تابعی نامیده میشود (Anderson-1988)، و در حالت برنولی نیز با یک مدل دو پارامتری راش که در تئوری پاسخ و در روانشناسی کاربرد دارد منطبق میگردد (Andersen-1980). اگر در عمل خطی بودن مورد انتظار نباشد میتوان  $\eta_{ij}$  را یک تابع درجه دو بصورت زیر در نظر گرفت:

$$\eta_{ij} = \alpha_j - \frac{1}{2} \frac{(x_i - u_j)^2}{t_j^2} \quad (2).$$

این مدل و این پارامترگذاری در کاربردهای محیط زیستی متداول است و قابلیهای  $m$  گونه مختلف از گیاهان و یا حیوانات (بعوان  $m$  ویژگی ماتریس مشاهدات) در  $n$  مکان مختلف (بعنوان  $n$  نمونه) بصورت تک مدل (Unimodall) بر حسب بعضی عوامل محیطی (متغیر نهان) تغییر میکند.

استفاده از مدلهای متغیر نهان، همچنین در زمینه‌های مطالعاتی اقتصاد، علوم اجتماعی و روانشناسی کاربرد دارد و اغلب، چنین مدلهایی در بهتر دانستن عوامل مؤثر در تغییرات داده‌ها به محقق کمک مینماید. فصل سوم این پایان‌نامه شامل معرفی مدلهای مذکور میباشد. نویسنده‌گان متعددی به مقایسه CA و PCA با برآورد گر درستنمایی (MLE) و کمترین مربعات در مدلهای متغیر نهان پرداخته‌اند (Gauch, chase, whittaker- 1974)، اما

در مورد ویژگی این برآوردها کار عمدہ‌ای صورت نگرفته است. همچنین مشخص شده است که PCA برای یک مدل خطی نرمال معادل است با MLE و پیشنهادهایی در بکارگیری CA (Ter Braak- 1985) بعنوان تقریب MLE در مدل‌های خطی تعمیم یافته نیز ارائه شده است. فصل چهارم پایان‌نامه به این موضوع اختصاص دارد. در این فصل به طور مشخص شاخصهای سنتونی CA و PCA (که در فصل بعد تعریف خواهند شد) بعنوان برآوردهای پارامترهای مدل‌های معرفی شده در نظر گرفته می‌شوند. زیرا همانطور که خواهیم دید شاخصهای سطحی، اطلاعات مربوط به متغیر نهان را در خود دارند، که در تعریف تابعی پیش‌بینی کننده مدل نیازی به دانستن آنها نیست. در فصل پنجم به ارزیابی سازگاری برآوردهای حاصل خواهیم پرداخت. یکی از دلایل توجه به سازگاری وجود "مسئله پارامترهای انتشاری" است که در مقدمه این فصل چگونگی آن آمده است. در این فصل سازگار بودن یا نبودن برآوردهای برآورد یک تغییر مقیاس و مبدأ از پارامترها مورد نظر است. یعنی پاسخ به این پرسش که آیا برآورد ارائه شده در یک ارتباط خطی مجانبی از پارامترها قرار دارد و یا خیر؟ که نتایج حاصل از این بررسی در دو قضیه و یک روش نموداری خلاصه شده اند و بیانگر سازگاری برآوردهای PCA در حالت نرمال و بشرط وجود گشتاورهای متغیر نهان و ناسازگاری برآوردها در حالت‌های دیگر هستند. فصل ششم نیز با شبیه سازی مشاهداتی از مدل (۲)، به مقایسه سازگاری برآوردهای PCA و CA در نمونه‌ای با حجم معین می‌پردازد که در کاربرد بیشتر مورد توجه است. همچنین در این فصل تعریفی از آمار محیط زیستی و کاربردی خشی از مطالب فوق در این زمینه تحقیقی آمده است.

#### مباحث این پایان‌نامه:

فصل دوم: این فصل شامل تعریف و کاربرد تحلیل مؤلفه‌های اصلی و تحلیل تناظر و مفاهیمی است که می‌تواند در ارتباط با یک مدل آماری باشد.

فصل سوم: هدف این فصل معرفی دو مدل مشخص از مدل‌های متغیر نهان است که با فرمولبندی مدل‌های خطی تعمعم یافته ارائه می‌شوندو برآورد پارامتر آنها در ارتباط با مطالب فصل دوم مورد نظر می‌باشد.

فصل چهارم: در این فصل با تشکیل تابع درستنمایی حاصل از مدل‌های معرفی شده به بررسی ارتباط MLE با PCA و CA پرداخته می‌شود.

فصل پنجم: این فصل با ارائه شاخصهای ستونی PCA و CA بعنوان برآورد پارامتر مدل‌های مورد نظر به ارزیابی سازگاری آنها نسبت به یک تغییر مقیاس و مبدأ از پارامترها و مقایسه سازگاری در حالتهای گوناگون می‌پردازد.

فصل ششم: از آنجا که انتخاب مدل‌های متغیر نهان و استفاده از CA در آنها به کاربردی در تحقیقات محیط زیستی باز می‌گردد، در این فصل تعریف داده‌های محیط زیستی و کاربرد بخشی از موضوعات مطرح شده در فصلهای قبل در این زمینه تحقیقی مورد بررسی قرار می‌گیرد.

## فصل دوم

تحلیل مؤلفه‌های اصلی و تحلیل تناظر