



دانشگاه شاهرود

دانشکده علوم پایه

گروه ریاضی کاربردی و علوم کامپیوتر

پایان نامه

کارشناسی ارشد در رشته

ریاضی کاربردی، گرایش آنالیز عددی

عنوان

به روزسازی مؤلفه‌های اصلی هسته

استاد راهنما

دکتر مرتضی رحمانی


استاد مشاور

دکتر بهنام زریپاک

نگارش

نسیم خسروی

شهریور ۱۳۸۹



تقديم به

آيه سبز مصحف عشق

يا ايها العزيز منا و اعلنا الضر و جئنا بضعه فرجاة فاوف لنا الكليل و تصدق علينا انا الله يجرى المتصدقين

(سوره يوسف آيه ۸۸)

سپاس

پروردگارا

تو را سپاس می گویم که عظمت و قدرت خویش را چنان بر من نموده ای که جز از تو استعانت نخواهم و برای  
سنگرزاری از تو، خود را برین منت همه آن بانی بدانم که بزرگوارانه در سامان یافتن این رساله یاریم کردند.  
ابتدا دوست دارم از آقای دکتر مرتضی رحمانی به خاطر رهنمود ایشان طی دو سال اخیر تشکر کنم.

استاد گرامی، راهبانی با حمایت های بی دریغ شما همراه با اخلاق پسندیده در بسیاری از زمان های انجام این پژوهش، همواره موجب دلگرمی  
بوده و صمیمانه از شما سپاس گذاری می کنم.

از راهبانی های ارزنده استاد عالیقدر جناب آقای دکتر بهنام زرپاک که مشاورت پایان نامه را بر عهده داشتند، قدر دانی می نمایم.  
از اعضای محترم داوران جناب آقای دکتر سید حمید حاجی سید جوادی و دکتر علی محمد نظری که زحمات مطالعه و داوری پایان نامه را بر  
عهده داشتند، نهایت تشکر را دارم.

از پدر و مادرم که صبورانه در لحظه لحظه های امیدواری و ناامیدی در کنارم بودند و پیوسته یاریم کردند سپاسگزارم.  
امیدوارم روزگار مرا به جبران زحمات بانی که برای یکایک عزیزان فراهم آورده ام، توفیق دهد.

## چکیده

تحلیل مؤلفه‌های اصلی ( $PCA$ )، یک روش مشهور برای تشخیص نمونه، تحلیل داده و کاهش بعد (سیستم) است. این روش یک تبدیل متعامد است که جهت‌های دارای بیشترین واریانس در داده را نشان می‌دهد. ماتریس تبدیل، دورانی است که محورهای مختصات را به جهت مؤلفه‌های اصلی، مرتب می‌کند. روش آن، بدست آوردن ماتریس پایه‌هایی است که ستون‌های آن ماتریس، مؤلفه‌های اصلی هستند. در این پایان‌نامه، ابتدا  $PCA$  و روش‌های هسته‌ای برای  $PCA$  غیرخطی ( $KPCA$ ) مطالعه شده است. به منظور غلبه بر محدودیت‌های  $KPCA$ ، روش محاسباتی  $IKPCA$ ،  $KPCA$  افزایشی استفاده شده است. روش آن کاهش پیچیدگی محاسباتی  $KPCA$  و انجام  $KPCA$  با ظرفیت به روزرسانی داده‌های قبلی با داده‌های موردنظر است. انجام  $IKPCA$  در فضای القایی هسته و به کارگیری مجموعه کاهش‌یافته برای ثابت نگه داشتن سرعت به‌روزرسانی مورد مطالعه قرار می‌گیرد. سپس روی  $SVD$  افزایشی و ارتباط آن با  $IKPCA$  متمرکز می‌شویم. در ادامه، یک الگوریتم برای بهبودبخشیدن  $IKPCA$  به منظور بدست آوردن خطای نسبی کمتر بین ماتریس واقعی در فرایند روش  $IKPCA$  و ماتریس تقریب حاصل از ضرب ماتریس‌های به‌روزشده‌ی فرایند  $PCA$  و  $SVD$  پیشنهاد شده است.

در پایان، الگوریتم پیشنهادی برای بدست آوردن نتایج عددی برای ۲ هسته آزمایش کردیم: هسته همانی و هسته گاوسی بررسی شده است.

**واژگان کلیدی:** تحلیل مؤلفه‌های اصلی هسته به روش افزایشی، تجزیه مقادیرتکین، بسط مجموعه کاهش‌یافته، کاهش پیچیدگی زمانی

## مقدمه

با گسترش روزافزون و همه جانبه عصر ارتباطات و تلاش برای انتقال اطلاعات در کوتاه‌ترین زمان ممکن، نیاز به یافتن ویژگی‌های فشرده‌سازی داده‌ها، غیر قابل انکار است. متأسفانه واسطه‌های ارتباطی بسیاری از ویژگی‌های موضوعات را حین تبدیل ماشینی آن‌ها به داده‌های عددی از دست می‌دهند. به همین دلیل تحقیقات زیادی در زمینه‌های مرتبط، برای یافتن الگوهایی در بین این حجم عظیم از داده‌ها متمرکز شده است تا با استخراج ویژگی‌های مختص یک موضوع و فشرده‌سازی و پارامتری کردن آن‌ها، تحلیل و طبقه‌بندی این موضوعات به آسانی انجام پذیرد. از آنجایی که به دلیل محدودیت‌های فیزیکی و زمانی به دنبال توصیف کوتاه از موضوعات و مسائل پیچیده هستیم، لذا ضرورت بحث حاضر و پژوهش در آن از جایگاه ویژه‌ای برخوردار است.

داده‌ها زمانی می‌توانند مفید واقع شوند که پردازش شده باشند. در قبال این گسترش سریع حجم داده‌ها، دیدگاه‌های مختلفی برای پردازش آن‌ها وجود دارد: به کارگیری روش‌های کلاسیک، طراحی ساختارهای به مراتب قوی محاسباتی مانند محاسبات غیرمتمرکز، پردازش‌های چند هسته‌ای، ابر کامپیوترها و غیره. با توجه به رشد حجم و پیچیدگی داده‌های قابل ذخیره نسبت به رشد قدرت محاسبات - تقریباً معادل دو برابر - لزوم تحقیق و پژوهش در حوزه دستیابی به روش‌های کارا تر ولی ساده را محرز می‌نماید.

برای مثال به کارگیری زیرفضاهای غالب به وسیله تجزیه مقادیر تکین (منفرد، ویژه)<sup>۱</sup> ( $SVD$ ) [۱۹] به عنوان بهترین مدل برای کاهش پیچیدگی داده‌ها و سیستم‌های پیچیده پیشنهاد شده است که در مقایسه با روش‌های مشابه با همان پیچیدگی کمترین خطا را (نسبت به برخی اندازه‌ها) داراست. اما  $PCA$  علیرغم ارتباط تنگاتنگی که با  $SVD$  دارد، واجد ویژگی‌هایی است که تکنیک‌های مربوط به  $SVD$  چنین نیستند. در فصل ۲ به این ویژگی‌ها اشاره خواهد شد. مدل  $PCA$  و یا در حالت غیرخطی  $KPCA$  بردارهای اصلی یک سیستم، به منظور پردازش، کدنگاری و فشرده‌سازی مشخص می‌شوند.

ارتباط نزدیک و برتری این روش نسبت به تجزیه مقادیر تکین از اصلی‌ترین دلایلی است که توجه متخصصین امر را به منظور به کارگیری و ارتقاء این روش سوق داده است. همچنین بدلیل کاربردهای فراوان این روش در انواع سیستم‌های خطی و غیرخطی و کارایی بالایی که برای علوم مختلف دارد، به روزرسانی این روش مورد توجه خاصی برخوردار شده است.

در این پایان‌نامه چگونگی به روزرسانی  $KPCA$ <sup>۲</sup> به کمک به روزرسانی ( $SVD$ ) مورد بررسی قرار می‌گیرد. این کار با کاهش پیچیدگی الگوریتم  $IKPCA$  همراه است.

روش افزایشی به روزسازی مؤلفه‌های اصلی ماتریس هسته‌ای داده‌ها<sup>۳</sup> این امکان را فراهم می‌کند که بدون از سرگیری محاسبات پیشین، با استفاده از اطلاعات داده‌های اولیه موجود، تنها با به کارگیری داده‌های جدید بردارهای اصلی کل سیستم، بدست آیند.

<sup>۱</sup> Singular Value Decomposition

<sup>۲</sup> Kernel Principal Component Analysis

<sup>۳</sup> Incremental Kernel Principal Component Analysis

مسأله تورم و تأثیر آن روی سیاست‌گذاری‌های کلان کشور بسیار حائز اهمیت است. درصد تغییر سالیانه و یا ماهیانه‌ی بهای کالاها و خدمات مصرفی هرکدام سهم خاصی در تعیین شاخص‌های نرخ تورم دارد. تعیین سهم تأثیر گذاری گروه‌های اصلی کالا و خدمات مصرفی می‌تواند در مدیریت، برنامه ریزی و همچنین هزینه‌های تعیین شاخص تورم تأثیرگذار باشد. در این مجموعه، به منظور بدست آوردن گروه‌های اصلی شاخص بها در هر دوره، و تعیین تأثیرات تورمی کالاها و خدمات در شاخص کل، از روش *IKPCA* بهره می‌بریم.

# فهرست مطالب

چ	لیست جداول
ح	لیست تصاویر
۱	۱ یادآوری
۱	۱.۱ تعاریف و قضایای مورد نیاز
۱	۱.۱.۱ مفاهیم موردنیاز ماتریس و بردار
۳	۲.۱.۱ مقدارهای ویژه و بردارهای ویژه
۵	۳.۱.۱ نرم‌ها
۱۲	۴.۱.۱ برخی ویژگی‌های مهم و کاربردی ماتریس‌های متقارن
۱۴	۲ آشنایی با $PCA$ خطی
۱۴	۱.۲ معرفی $PCA$ خطی
۱۷	۱.۱.۲ الگوریتم اول $PCA$ خطی
۱۷	۲.۱.۲ مثال عددی برای الگوریتم اول
۲۰	۲.۲ ارتباط $SVD$ و $PCA$
۲۳	۱.۲.۲ الگوریتم دوم $PCA$ خطی با به‌کارگیری $SVD$
۲۴	۲.۲.۲ الگوریتم سوم $PCA$ خطی با به‌کارگیری $SVD$
۲۴	۳.۲.۲ محدودیت‌های $PCA$
۲۴	۴.۲.۲ $PCA$ از دیدگاه آماری
۲۵	۵.۲.۲ کاربردهای $PCA$
۲۸	۳ $PCA$ در فضای غیرخطی
۲۸	۱.۳ مقدمات لازم



۳۰	.....	آشنایی با فضای هیلبرت	۱.۱.۳
۳۱	.....	هسته تبدیلات	۲.۱.۳
۳۳	.....	بازتولید نقشه هسته	۳.۱.۳
۳۴	.....	فضای برداری مطلوب	۴.۱.۳
۳۶	.....	تشکیل هسته‌ها از ضابطه اصلی	۵.۱.۳
۳۶	.....	ایده هسته	۶.۱.۳
۳۷	.....	بازتولید فضای هیلبرت مرتبط با هسته‌ها	۷.۱.۳
۳۸	.....	ضابطه هسته <i>mercer</i>	۸.۱.۳
۴۱	.....	مقدمات لازم برای <i>KPCA</i>	۹.۱.۳
۴۳	.....	مراحل عملیات <i>KPCA</i>	۱۰.۱.۳
۴۶	.....	الگوریتم <i>KPCA</i>	۱۱.۱.۳
۴۸		<b>۴ <i>KPCA</i> ی افزایشی</b>	
۴۸	.....	ضرورت به کارگیری روش جدید <i>KPCA</i> ی افزایشی:	۱.۴
۴۹	.....	کارهای صورت گرفته	۲.۴
۵۰	.....	خروجی فضای اصلی <i>KPCA</i>	۳.۴
۵۳	.....	محاسبه <i>KPCA</i> ی افزایشی	۴.۴
۵۳	.....	جواب پیشنهادی: روش <i>KPCA</i> ی افزایشی	۱.۴.۴
۵۹	.....	ثابت نگه داشتن سرعت به روزرسانی	۲.۴.۴
۶۰	.....	مجموعه کاهش یافته	۳.۴.۴
۶۳	.....	باز متعامدسازی پایه‌های <i>KPCA</i>	۴.۴.۴
۶۴	.....	انتخاب پارامترها	۵.۴.۴
۶۵	.....	تحلیل پیچیدگی	۶.۴.۴
۶۶	.....	$A$ دقت تقریب	۷.۴.۴
۶۸	.....	الگوریتم <i>IKPCA</i> با معین بودن ضابطه $\phi(\cdot)$	۸.۴.۴
۶۹	.....	الگوریتم اول <i>IKPCA</i> بدون معین بودن ضابطه $\phi(\cdot)$	۹.۴.۴
۷۰	.....	الگوریتم دوم <i>IKPCA</i> بدون معین بودن ضابطه $\phi(\cdot)$	۱۰.۴.۴
۷۱	.....	الگوریتم پیشنهادی <i>IKPCA</i>	۱۱.۴.۴
۷۱	.....	۱.۱۱.۴.۴ مثال عددی برای الگوریتم ۸	
۱۰۹	.....	۱۲.۴.۴ خواص توابع <i>RBF</i>	

۱۱۰	۵	روش‌های ساخت یک هسته معین مثبت
۱۱۰	۱.۵	محاسبه زوایای اصلی بین دو زیرفضا در فضای $\mathcal{F}$
۱۱۲	۱.۱.۵	الگوریتم گرام‌اشمیت هسته برای محاسبه زوایای اصلی دو زیرفضا
۱۱۵	۲.۱.۵	محاسبه زوایای اصلی هسته
۱۱۵	۲.۵	ضابطه‌های جانشین کمتر کارآمد
۱۱۶	۱.۲.۵	ضابطه‌سازی لاگرانژ
۱۱۷	۲.۲.۵	تقریب تجزیه ویژه
۱۱۹	۳.۲.۵	الگوریتم یافتن زوایای اصلی دو فضا بر پایه تجزیه ویژه ماتریس‌های سازنده آن‌ها
۱۱۹	۳.۵	تشکیل یک هسته معین مثبت با به کارگیری زوایای اصلی
۱۲۴	۶	نتایج عددی
۱۳۴	۷	نتیجه‌گیری و پیشنهادات
۱		الف نمادگذاری
۳		ب ماتریس نمونه
۵		پ برنامه‌های کامپیوتری

## لیست جداول

- ۱.۶ میزان خطای نسبی ماتریس  $[\hat{A}^r \quad \tilde{E}]$  و تقریب آن با به کارگیری ماتریس هسته همانی . . . . . ۱۲۷
- ۲.۶ میزان خطای نسبی ماتریس  $[\hat{A}^r \quad \tilde{E}]$  و تقریب آن با به کارگیری ماتریس هسته گاوسی . . . . . ۱۲۷
- ۳.۶ میزان خطای نسبی ماتریس  $[\hat{A}^r \quad \tilde{E}]$  و تقریب آن با به کارگیری ماتریس هسته گاوسی با الگوریتم پیشنهادی ۱۲۸
- ۴.۶ مقایسه رتبه برخی از مهمترین ماتریس‌ها با به کارگیری هسته همانی و گاوسی برای  $r = 4$  . . . . . ۱۲۸
- ۵.۶ ۵ ستون از ماتریس  $[\hat{A}^r \quad \tilde{E}]$  با به کارگیری هسته گاوسی و با  $r = 8$  . . . . . ۱۲۹
- ۶.۶ ۵ ستون از تقریب ماتریس  $[\hat{A}^r \quad \tilde{E}]$  با به کارگیری هسته گاوسی و با  $r = 8$  . . . . . ۱۲۹
- ۷.۶ ۵ ستون از ماتریس  $[\hat{A}^r \quad \tilde{E}]$  با به کارگیری هسته همانی و با  $r = 4$  . . . . . ۱۳۰
- ۸.۶ ۵ ستون از تقریب ماتریس  $[\hat{A}^r \quad \tilde{E}]$  با به کارگیری هسته همانی و با  $r = 4$  . . . . . ۱۳۰

# لیست تصاویر

۱۶	بررسی حرکت فنر از جهات مختلف	۱.۲
۱۸	نمودار داده‌های اولیه	۲.۲
۱۹	نمودار داده‌های نرمال‌شده و بردارویژه‌ها و مقادیر ویژه ماتریس کوواریانس	۳.۲
۲۰	نمودار داده‌های تغییر یافته با دو بردارویژه	۴.۲
۲۰	نمودار داده‌ها پس از به‌کارگیری یک بردارویژه مهم	۵.۲
۲۹	دسته‌بندی خطی داده‌ها	۱.۳
۴۶	داده‌ها در فضای جدید	۲.۳
۴۷	تبدیل کردن داده‌ها می‌تواند آن‌ها را به صورت خطی جداسدنی کند	۳.۳
۱۲۶	مقایسه بیشترین روند بیشترین مقدار تکین شاخص ماهانه کلی ده گروه کالا با شاخص ماهانه هر کالا	۱.۶
۱۲۷	روند بیشترین مقدار تکین شاخص کل ماهانه هر یک از گروه‌های اصلی	۲.۶
۱۲۸	مقایسه روند بیشترین مقدار تکین هر گروه اصلی با افزودن چندین ماه	۳.۶
۱۳۱	روند بیشترین مقدار تکین تراکمی ماتریس اولیه	۴.۶
۱۳۲	روند بیشترین مقدار تکین تراکمی ماتریس کلی به‌روزرسانی شده	۵.۶

# فصل ۱

## یادآوری

### ۱.۱ تعاریف و قضایای مورد نیاز

در این فصل به بیان تعاریف و مفاهیم اصلی مورد نیاز در پایان نامه می پردازیم. غالب قضایا و نتایج بدون اثبات بیان شده است.

#### ۱.۱.۱ مفاهیم مورد نیاز ماتریس و بردار

**تذکره:** ماتریس حقیقی  $m \times n$  یک جدول  $m$  سطری و  $n$  ستونی از اعداد حقیقی است. در صورت تساوی تعداد ستون ها و سطرهای یک ماتریس به آن ماتریس مربعی اطلاق می شود. مجموعه تمام ماتریس های حقیقی  $m \times n$  با  $\mathbb{R}^{m \times n}$  نشان داده می شود. در این پایان نامه تمام ماتریس ها حقیقی هستند و از حروف بزرگ برای نشان دادن آنها استفاده می شود.

**تعریف ۱.۱.** رتبه ماتریس  $A$  از مرتبه  $m \times n$  بعد زیرفضای تولید شده توسط ستون های  $A$  تعریف می شود:

$$\text{rank}(A) = \dim(\text{span}(A_{:1}, A_{:2}, \dots, A_{:n})) \leq \min(m, n).$$

و یا به عبارتی ماکزیمم تعداد سطرهای مستقل خطی (ماکزیمم تعداد ستون های مستقل خطی) رتبه ماتریس<sup>۱</sup> نامیده می شود.

که در آن  $A_i$  ها ستون های ماتریس  $A$  نامیده می شوند.

---

<sup>۱</sup> Matrix Rank

تعریف ۲.۰۱. ماتریس  $A$  نامنفرد<sup>۲</sup> می‌باشد هرگاه ماتریسی مانند  $B$  یافت شود به طوری که

$$AB = BA = I$$

تعریف ۳.۰۱. هرگاه ماتریس  $A_{n \times n}$  نامنفرد نباشد، منفرد<sup>۳</sup> نامیده می‌شود.

تعریف ۴.۰۱. ماتریس مربعی  $A$ ، معکوس‌پذیر نامیده می‌شود هرگاه ماتریسی مانند  $B$  چنان موجود باشد که:  $B$  معکوس ماتریس  $A$  نامیده می‌شود و با  $B = A^{-1}$  نشان می‌دهیم. از آن جایی که تمامی ماتریس‌ها معکوس‌پذیر نیستند، معکوس تعمیم‌یافته (یا معکوس تعمیم‌یافته مور - پنروز)<sup>۴</sup> تعمیمی از آن است که حتی برای ماتریس‌های غیر مربعی نیز تعریف می‌شود. معکوس تعمیم‌یافته منحصر به فرد<sup>۵</sup>  $A^+$  برای ماتریس  $A$  دارای چهار شرط زیر است:

$$AA^+A = A, \quad A^+AA^+ = A^+, \quad (AA^+)^T = AA^+ \quad \text{و} \quad (A^+A)^T = A^+A.$$

به ویژه اگر  $A^T A$  معکوس‌پذیر باشد آن‌گاه  $A^+ = (A^T A)^{-1} A^T$ .

تعریف ۵.۰۱. ماتریس متقارن  $A$  معین مثبت<sup>۵</sup> است هرگاه:  $\forall x \neq 0 \quad x^T A x > 0$   
و  $A$  نیمه معین مثبت<sup>۶</sup> است هرگاه:  $\forall x \quad x^T A x \geq 0$

تعریف ۶.۰۱. برای هر  $i, j$  ضرب داخلی دو بردار حقیقی  $x, y \in \mathbb{R}^n$  به صورت تابع حقیقی زیر تعریف می‌شود:

$$\langle x, y \rangle = \sum_{i=1}^n x_i y_i = x^T y.$$

تعریف ۷.۰۱. بردارهای ناصفر  $x, y \in \mathbb{R}^n$  متعامد نامیده می‌شوند هرگاه حاصل ضرب داخلی آن‌ها برابر صفر باشد:

$$\langle x, y \rangle = 0$$

<sup>۲</sup> Nonsingular

<sup>۳</sup> Singular

<sup>۴</sup> Moore Penderose

<sup>۵</sup> Positive Definite

<sup>۶</sup> Positives Semi definite

**تعریف ۸.۰.۱.** حاصل ضرب داخلی دو ماتریس حقیقی هم مرتبه به صورت زیر تعریف می شود:

$$\langle A, B \rangle = \text{vec}(A)^T \text{vec}(B) = \sum_{ij} A_{ij} B_{ij} = \text{trace}(A^T B)$$

که در آن منظور از  $\text{trace}(A)$  مجموع عناصر قطری ماتریس  $A$  است.

### ۲.۱.۱ مقدارهای ویژه و بردارهای ویژه

**تعریف ۹.۰.۱.** مقدارهای ویژه و بردارهای ویژه: یکی از مباحث اصلی در جبر خطی و آنالیز ماتریس، مقدارهای ویژه و بردارهای ویژه ماتریس های مربعی هستند که اطلاعات اساسی درباره ماتریس در اختیار ما قرار می دهند. مفهوم مرتبط برای ماتریس های مستطیلی مقدارهای تکین و بردارهای تکین نامیده می شوند که نقش تعیین کننده ای در تقریب رتبه پایین ماتریس بازی می کنند و مشخصات مهم ماتریس اصلی را معین می کنند.

**تعریف ۱۰.۰.۱.** اسکالر  $\lambda \in \mathbb{C}$  مقدار ویژه ماتریس  $A \in \mathbb{C}^{n \times n}$  است، هرگاه بردار ناصفر  $x \in \mathbb{C}^n$  موجود باشد به طوری که  $Ax = \lambda x$ . بردار  $x$  بردار ویژه متناظر به مقدار ویژه  $\lambda$  نامیده می شود.

یک ماتریس مربعی از مرتبه  $n \times n$  با احتساب تعداد تکرار، دارای  $n$  مقدار ویژه است. مجموعه تمام مقدارهای ویژه با  $\sigma(A)$  نشان داده می شود. شعاع طیفی  $A$  بیشینه مقدار قدر مطلق  $\sigma(A)$  است و با  $\rho(A)$  نشان داده می شود:

$$\rho(A) = \max\{|\lambda|; \lambda \in \sigma(A)\}.$$

یک ابزار بسیار مفید در آنالیز ماتریس، تجزیه مقدار ویژه (مقدار تکین) است که در قضیه بعدی تعریف می شود:

**قضیه ۱۰.۱.** برای هر ماتریس  $A \in \mathbb{R}^{m \times n}$ ، ماتریس های متعامد  $U \in \mathbb{R}^{m \times m}$  و  $V \in \mathbb{R}^{n \times n}$  چنان وجود دارند که

$$A = U \Sigma V^T$$

و

$$\Sigma = \begin{pmatrix} \sigma_1 & & & 0 \\ & \ddots & & \\ & & \sigma_r & \\ 0 & & & O_{r \times (n-r)} \\ & O_{(m-r) \times r} & & O_{(m-r) \times (n-r)} \end{pmatrix}$$

که در آن مقدارهای تکین  $\sigma_i$  اسکالرهایی حقیقی هستند و

$$\sigma_1 \geq \dots \geq \sigma_r > 0.$$

ستون‌های  $U$  و  $V$  به ترتیب بردارهای ویژه  $A^T A$  و  $AA^T$  هستند. [۱۸] برای اثبات وجود و الگوریتم‌های مربوط به تجزیه مقدارهای تکین به مرجع [۱۹] رجوع شود.

ویژگی‌های تجزیه مقدار ویژه: فرض کنید  $A = U\Sigma V^T$  در آن صورت:

$$\begin{aligned} A^T &= V\Sigma U^T \Rightarrow A^T A = V\Sigma U^T U \Sigma V^T = V\Sigma^2 V^T \\ &\Rightarrow A^T A V = V\Sigma^2 V^T V = V\Sigma^2 \end{aligned}$$

از طرف دیگر داریم:

$$\begin{aligned} AA^T &= U\Sigma V^T V \Sigma U^T = U\Sigma^2 U^T \\ AA^T U &= U\Sigma^2 U^T U = U\Sigma^2 \end{aligned}$$

اگر  $\mathcal{N}(A)$  نمایشگر فضای پوچ  $A$  باشد؛ آنگاه  $\mathcal{N}(A^T A) \subseteq \mathcal{N}(A)$  زیرا

$$\begin{aligned} x \in \mathcal{N}(A) : Ax = 0 &\Rightarrow A^T Ax = 0 \Rightarrow x \in \mathcal{N}(A^T A) \Rightarrow \mathcal{N}(A) \subseteq \mathcal{N}(A^T A) \\ x \in \mathcal{N}(A^T A) : A^T Ax = 0 &\Rightarrow \langle x, A^T Ax \rangle = 0 \Rightarrow \|Ax\|^2 = 0 \Rightarrow \\ Ax = 0 : x \in \mathcal{N}(A) &\Rightarrow \mathcal{N}(A^T A) \subseteq \mathcal{N}(A) \end{aligned}$$

#### نتیجه:

- ستون‌های  $V$  بردار ویژه  $A^T A$  می‌باشند.
- ستون‌های  $U$  بردار ویژه  $AA^T$  می‌باشند.
- مربع مقادیر تکین، مقدار ویژه  $A^T A$  و  $AA^T$  می‌باشند.
- فضای پوچ  $A = \mathcal{N}(A^T A)$ .

**تعریف ۱۱.۱.** برای ماتریس حقیقی و متقارن  $A$ ، اینرسی<sup>۷</sup> با سه تایی  $(\rho, \nu, \zeta)$  تعریف می‌شود که  $\rho$  و  $\nu$  و  $\zeta$  به ترتیب تعداد مقادیر ویژه‌های مثبت، منفی و صفر ماتریس  $A$  می‌باشند [۱۸].

#### قضیه ۲.۱. قانون سیلوستر از اینرسی<sup>۸</sup>

فرض کنید  $A$  ماتریس مربعی، متقارن از مرتبه  $n$  با درایه‌های حقیقی و  $S$  ماتریس نامنفرد باشد به طوری که ماتریس

<sup>۷</sup>Inertia

<sup>۸</sup>Sylvester's law of Inertia



$D$  با رابطه  $D = SAS^T$  یک ماتریس قطری باشد، در آن صورت ماتریس  $A$  و  $D$  اینرسیای یکسان دارند (ماتریس قطری  $D$  تنها درایه‌های  $\{-1, 0, 1\}$  حول قطر دارد. قانون فوق بیان می‌نماید برای هر ماتریس وارون‌پذیر  $S$ ، تعداد عناصر مثبت، منفی در ماتریس  $A$  با تعداد عناصر مثبت، منفی در ماتریس  $D$  یکسان می‌باشند).

### ۳.۱.۱ نرم‌ها

نرم اسکالری است که به یک بردار یا یک ماتریس نسبت داده می‌شود. یک نرم برداری روی  $\mathbb{R}^n$  تابعی حقیقی و خطی مانند  $\|\cdot\|$  روی  $\mathbb{R}^n$  با خواص زیر است:

$$\begin{aligned} \|x\| &\geq 0, \forall x \in \mathbb{R}^n \\ \|x\| &= 0 \iff x = 0; \\ \|\alpha x\| &= |\alpha| \|x\|, \forall x \in \mathbb{R}^n \text{ و } \forall \alpha \in \mathbb{R}; \\ \|x + y\| &\leq \|x\| + \|y\|, \forall x, y \in \mathbb{R}^n \end{aligned}$$

به‌همین ترتیب یک نرم ماتریسی مانند  $\|\cdot\|$  تابعی حقیقی و خطی روی  $\mathbb{R}^{m \times n}$  با خواص زیر می‌باشد:

$$\begin{aligned} \|X\| &\geq 0, \forall X \in \mathbb{R}^{m \times n}; \\ \|X\| &= 0 \iff X = 0; \\ \|\alpha X\| &= |\alpha| \|X\|, \forall X \in \mathbb{R}^{m \times n} \text{ و } \forall \alpha \in \mathbb{R}; \\ \|X + Y\| &\leq \|X\| + \|Y\|, \forall X, Y \in \mathbb{R}^{m \times n}, \\ \|XY\| &\leq \|X\| \|Y\|, \forall X \in \mathbb{R}^{m \times n} \text{ و } \forall Y \in \mathbb{R}^{n \times k}. \end{aligned}$$

در بسیاری از کاربردها ماتریس‌ها و بردارها توأم با یکدیگر مطرح می‌شوند، به‌همین دلیل خواص نرم ماتریسی همراه با یک شرط کمکی می‌تواند برای تعریف نرم وابسته به نرم برداری تعریف می‌شود. چنین نرمی را نرم ماتریسی سازگار می‌نامیم که به‌صورت زیر تعریف می‌شود:

$$|A| = \sup_{|x| > 0} \frac{|Ax|}{|x|} = \sup_{|x|=1} |Ax|$$

شرط فوق معادل شرط زیر است:

$$\|Ax\| \leq \|A\| \|x\|.$$

یک نرم متداول برداری یا ماتریسی نرم اقلیدسی یا نرم فرینیوس<sup>۹</sup> است که از ضرب داخلی حاصل می‌شود:

$$\|x\|_F = \sqrt{\langle x, x \rangle},$$

که در آن  $x$  یک بردار یا ماتریس است. این نرم نقش محوری در مسائل کمترین مربعات بازی می‌کند و به عنوان معیار کاهش خطا در حل این مسائل به کار می‌رود.

نرم‌های برداری که بیشتر استفاده می‌شوند مثال‌هایی از نرم معروف هولدر<sup>۱۰</sup>  $(p - \text{نرم})$  هستند:

$$\|x\|_p = \left( \sum_{i=1}^n |x_i|^p \right)^{1/p}, \quad p = 1, 2, \dots$$

این نرم بازای  $p = 1$ ،  $p = 2$  و  $p = \infty$  از کاربرد بیشتری برخوردار است:

$$\|x\|_1 = |x_1| + |x_2| + \dots + |x_n|,$$

$$\|x\|_2 = \sqrt{|x_1|^2 + |x_2|^2 + \dots + |x_n|^2},$$

$$\|x\|_\infty = \max_i |x_i|.$$

برای بردارها، نرم  $2$  همان نرم فرینیوس است. اما  $p - \text{نرم}$  ماتریسی به صورت نرم تبعی از  $p - \text{نرم}$  برداری حاصل می‌شود:

$$\|A\|_p = \max_{x \neq 0} \frac{\|Ax\|_p}{\|x\|_p}.$$

به راحتی می‌توان اثبات نمود که:

$$\|A\|_1 = \max_j \sum_i |A_{ij}|$$

$$\|A\|_2 = [\rho(A^T A)]^{1/2}$$

$$\|A\|_\infty = \max_i \sum_j |A_{ij}|.$$

تعریف ۱۲.۰۱.  $PCA$ <sup>۱۱</sup> یک تبدیل خطی متعامد است که با انتخاب محورها و یا (عواملی) که بیشترین اهمیت را در سیستم دارند، عوامل اضافی را حذف می‌کند و بعد مسأله را کاهش می‌دهد.

<sup>۹</sup> Frobenius

<sup>۱۰</sup> Holder

<sup>۱۱</sup> Principal Component Analysis

**تعریف ۱۳.۱.** ماتریس تباهیده: ماتریس مربعی که دترمینان آن صفر است.

**تعریف ۱۴.۱.** فاصله ماهالانوبیس<sup>۱۲</sup>: فاصله‌ای برای تعیین میزان شباهت یک نمونه از داده‌ها به یک مجموعه‌ی شناخته‌شده، که به ماتریس کوواریانس داده‌ها وابسته می‌باشد:

$$D_M(x) = \sqrt{(x - \mu)^T S^{-1} (x - \mu)}$$

$$d(\vec{x}, \vec{y}) = \sqrt{(\vec{x} - \vec{y})^T S^{-1} (\vec{x} - \vec{y})}$$

$$d(\vec{x}, \vec{y}) = \sqrt{\sum_{i=1}^N \frac{(x_i - y_i)^2}{\sigma_i^2}}$$

که در این روابط، ماتریس کوواریانس داده‌ها با  $S$  نشان داده شده است.

**تعریف ۱۵.۱.** کد: تابعی که به هر عنصر از دنباله‌ی هدف یک رشته دودویی را اختصاص می‌دهد. با این فرض که این نمایش منحصرأ قابل رمزگشایی است.

**تعریف ۱۶.۱.** آشفنگی<sup>۱۳</sup> (عدم قطعیت): کمیتی که شامل محتوای اطلاعات می‌باشد و حدود طول رمز بهینه را مشخص می‌کند.

**تعریف ۱۷.۱.** حشو (زیادی)<sup>۱۴</sup>: یکی از دو نوع آلودگی داده‌ها است که به کمیت کوواریانس داده‌ها مرتبط و شامل داده‌های اضافی سیستم می‌شود.

**تعریف ۱۸.۱.** اختلال<sup>۱۵</sup>: نوع دیگری از آلودگی داده‌ها که یک پدیده ذاتی در هر سیستم الکترونیکی است. به‌ویژه اگر داده‌های ورودی بسیار کوچک باشند. یک اختلال یک مجموعه از اغتشاشات داده است که باید پایین (کم) باشد یا بیشتر از روش تحلیل سیستم و اطلاعات سیستم نباشد. یک معیار سنجش اختلال سیستم، اندازه زیر است که مقایسه این کسر با عدد ۱ میزان دقت داده‌ها را نشان می‌دهد:

$$SNR = \frac{\sigma_{signal}^2}{\sigma_{noise}^2}$$

$$SNR \gg 1 \quad \equiv \quad noise \uparrow$$

$$SNR \ll 1 \quad \equiv \quad noise \downarrow$$

<sup>۱۲</sup> Mahalanobis

<sup>۱۳</sup> Entropy

<sup>۱۴</sup> Redundancy

<sup>۱۵</sup> Noise

**تعریف ۱۹.۰.۱.** واریانس<sup>۱۶</sup>: معیاری برای سنجش میزان پراکندگی داده‌ها از میانگین آن‌ها است و در کاهش آلودگی نوع اول (اختلال) داده‌ها به کار می‌رود.

**تعریف ۲۰.۰.۱.** واریانس تعدادی داده توسط رابطه زیر محاسبه می‌شود:

$$\sigma^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n - 1}$$

**تعریف ۲۱.۰.۱.** کوواریانس<sup>۱۷</sup>: معیاری برای سنجش میزان پراکندگی داده‌ها از میانگین آن‌ها نسبت به یکدیگر است و در کاهش آلودگی نوع دوم داده‌ها (حشو) به کار می‌رود.

**تعریف ۲۲.۰.۱.** ماتریس کوواریانس یک ماتریس: فرض کنید  $X$  یک ماتریس از اندازه  $m \times n$  باشد

$$\begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_m \end{pmatrix}$$

آن‌گاه ماتریس کوواریانس آن به این شکل محاسبه می‌شود  $S_X = \frac{1}{n-1} X X^T$

$$COV(x, y) = \begin{pmatrix} cov(x_1, y_1) & \dots & \dots \\ cov(x_2, y_1) & \dots & \dots \\ \vdots & \vdots & \ddots \end{pmatrix}$$

که در آن کوواریانس بین هر دو بردار یک ماتریس به شکل زیر محاسبه می‌شود:

$$cov(x_i, y_i) = \frac{\sum_{j=1}^m (x_{i_j} - \bar{x}_i)(y_{i_j} - \bar{y}_i)}{m - 1}$$

**تعریف ۲۳.۰.۱.** تجزیه<sup>۱۸</sup>: دقت و وضوح بالا در تجزیه تصویر بدلیل تقسیمات بسیار ریز تصویر.

**تعریف ۲۴.۰.۱.** سیگنال<sup>۱۹</sup>: در لغت به معنای علامت و در علوم ریاضی و مهندسی به معنی هرگونه تغییر وارد شده به محیط است.

<sup>۱۶</sup> Variance

<sup>۱۷</sup> Covariance

<sup>۱۸</sup> High resolution

<sup>۱۹</sup> Signal