

کاهش ابعاد

سید ناصر رضوی www.snrazavi.ir

۱۳۹۷

کاهش ابعاد

□ انگیزه.

□ نمایش داده‌ها

□ فشرده‌سازی داده‌ها

■ کاهش مصرف حافظه

■ استفاده آسان‌تر از مجموعه داده‌ها

■ کاهش هزینه‌های محاسباتی بسیاری از الگوریتم‌ها

■ حذف نویز و افزایش دقت الگوریتم یادگیری

■ ساده‌تر کردن درک نتایج

□ روش‌ها.

□ تحلیل مؤلفه‌های اصلی


□ تحلیل فاکتورها

□ تحلیل مؤلفه‌های مستقل


تحلیل مؤلفه‌های اصلی (PCA)

تحلیل مؤلفه‌های اصلی

۴




تحلیل مؤلفه‌های اصلی



تحلیل مؤلفه‌های اصلی: بیان مسئله


بیان مسئله

□ هدف. کمینه‌سازی مجموع مربعات خطای تابش



بیان مسئله


□ هدف. کمینه‌سازی مجموع مربعات خطای تابش



بیان مسئله

۹


□ کاهش ابعاد از ۲ به ۱. یافتن یک جهت مانند $u^{(1)} \in \mathbb{R}^2$ به طوری که با تصویر کردن نقاط در آن جهت، مجموع مربعات خطا کمینه گردد.




بیان مسئله

۱۰


□ کاهش ابعاد از n به k . یافتن k بردار متعامد مانند $u^{(1)}, u^{(2)}, \dots, u^{(k)} \in \mathbb{R}^n$ به طوری که با تصویر کردن نقاط در آن جهت‌ها، مجموع مربعات خطا کمینه گردد.



PCA همان رگرسیون است؟



رگرسیون خطی



تحلیل مؤلفه‌های اصلی

الكويت PCA

الگوریتم PCA: پیش پردازش

۱۳

□ مجموعه آموزشی.

$$\{x^{(1)}, x^{(2)}, x^{(3)}, \dots, x^{(m)}\}, \quad x^{(i)} \in \mathbb{R}^n$$

□ پیش پردازش.

(۱) حذف میانگین.

$$\mu_j = \frac{1}{m} \sum_{i=1}^m x_j^{(i)}, \quad x_j^{(i)} = x_j^{(i)} - \mu_j$$

(۲) مقیاس بندی. [در صورت نیاز]

$$x_j^{(i)} = \frac{x_j^{(i)} - \mu_j}{s_j}$$

انحراف معیار در ویژگی j

الگوریتم PCA: کاهش ابعاد

□ کاهش ابعاد داده‌ها از n به k .

□ محاسبه «ماتریس کوواریانس»:

$$\Sigma = \frac{1}{m} X^T X = \frac{1}{m} \sum_{i=1}^n x^{(i)} (x^{(i)})^T$$

□ محاسبه «بردارهای ویژه» ماتریس کوواریانس:

$$[U, S, V] = \text{svd}(\Sigma)$$

□ انتخاب k بردار اول از ماتریس U :

$$U = \begin{bmatrix} | & | & \dots & | \\ u^{(1)} & u^{(2)} & \dots & u^{(n)} \\ | & | & \dots & | \end{bmatrix}_{n \times n} \Rightarrow U_{\text{reduced}} = \begin{bmatrix} | & | & \dots & | \\ u^{(1)} & u^{(2)} & \dots & u^{(k)} \\ | & | & \dots & | \end{bmatrix}_{n \times k}$$

□ محاسبه داده‌های جدید با ابعاد k .

$$z_{k \times 1}^{(i)} = \begin{bmatrix} | & | & \dots & | \\ u^{(1)} & u^{(2)} & \dots & u^{(k)} \\ | & | & \dots & | \end{bmatrix}^T \times x_{n \times 1}^{(i)}$$

$$= \begin{bmatrix} - & u^{(1)} & - \\ - & u^{(2)} & - \\ \vdots & \vdots & \vdots \\ - & u^{(k)} & - \end{bmatrix}_{k \times n} \times x_{n \times 1}^{(i)}$$

پیاده سازی در پایتون

۱۶

□ الگوریتم PCA.

□ پس از حذف میانگین و در صورت نیاز مقیاس بندی.

```
def PCA(X, k):
```

```
    m = X.shape[0]
```

```
    Sigma = (X.T @ X) / m
```

```
    U, S, V = svd(Sigma)
```

```
    U_reduced = U[:, :k]
```

```
    Z = X @ U_reduced
```

```
    return Z
```

← مناسبه ماتریس کوواریانس


← مناسبه تجزیه مقادیر منفرد

← انتخاب k مؤلفه اول

← مناسبه داده های برید با k بعد

مثال: کاهش ابعاد

$$Z = X \times U_{reduced}$$




داده‌های اولیه (دو بعدی)




داده‌های جدید (یک بعدی)

مثال: کاهش ابعاد

$$X_{recovered} = Z * U_{reduced}^T + means$$



داده‌های اولیه (دو بعدی)



داده‌های بازسازی شده

الگوریتم PCA: حذف میانگین

۱۹

```
X = np.array([[1, 1, 1, 0, 0],  
              [2, 2, 2, 0, 0],  
              [1, 1, 1, 0, 0],  
              [5, 5, 5, 0, 0],  
              [1, 1, 0, 2, 2],  
              [0, 0, 0, 3, 3],  
              [0, 0, 0, 1, 1]])
```

```
mu = X.mean(axis=0)
```

```
X_norm = X - mu
```

داده‌های اولیه

1	1	1	0	0
2	2	2	0	0
1	1	1	0	0
5	5	5	0	0
1	1	0	2	2
0	0	0	3	3
0	0	0	1	1

الگوریتم PCA: محاسبه بردارهای ویژه

۲۰

```
m = X.shape[0]
Sigma = (X_norm.T @ X_norm) / m
U, S, V = np.linalg.svd(Sigma)

print(S)
```

```
[8.72e+00  1.58e+00  6.69e-02  4.79e-16  1.35e-47]
```

$$S = \begin{bmatrix} s_{11} & 0 & \cdots & 0 \\ 0 & s_{22} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & s_{nn} \end{bmatrix}$$

الگوریتم PCA: کاهش ابعاد

۲۱

```
U_red = U[:, :3]
```

```
X_proj = X_norm * U_red
```

```
[[ 0.17  1.37 -0.01]
 [-1.44  0.74 -0.02]
 [ 0.17  1.37 -0.01]
 [-6.28 -1.17 -0.06]
 [ 1.76 -1.1  0.57]
 [ 3.33 -1.92 -0.35]
 [ 2.3   0.7  -0.11]]
```

الگوریتم PCA: بازسازی داده های اولیه

۲۲

$$X_{\text{approx}} = X_{\text{proj}} @ U_{\text{red}} + \mu$$

```
[[ 1.00  1.00  1.00  0.00  0.00]
 2.00  2.00  2.00  0.00  0.00]
 1.00  1.00  1.00  0.00  0.00]
 5.00  5.00  5.00 -0.00 -0.00]
 1.00  1.00  0.00  2.00  2.00]
 0.00 -0.00  0.00  3.00  3.00]
-0.00 -0.00 -0.00  1.00  1.00]]
```

داده های اولیه

1	1	1	0	0
2	2	2	0	0
1	1	1	0	0
5	5	5	0	0
1	1	0	2	2
0	0	0	3	3
0	0	0	1	1

انتخاب تعداد مؤلفه‌های اصلی

انتخاب تعداد مؤلفه‌های اصلی

□ میانگین مجموع مربعات خطای تابش.

$$\frac{\frac{1}{m} \sum_{i=1}^m \|x^{(i)} - x_{approx}^{(i)}\|^2}{\frac{1}{m} \sum_{i=1}^m \|x^{(i)}\|^2} \leq 0.01$$

مفرد ۹۹ درصد واریانس

$$\frac{\frac{1}{m} \sum_{i=1}^m \|x^{(i)} - x_{approx}^{(i)}\|^2}{\frac{1}{m} \sum_{i=1}^m \|x^{(i)}\|^2} \leq 0.05$$

مفرد ۹۵ درصد واریانس

$$\frac{\frac{1}{m} \sum_{i=1}^m \|x^{(i)} - x_{approx}^{(i)}\|^2}{\frac{1}{m} \sum_{i=1}^m \|x^{(i)}\|^2} \leq 0.10$$

مفرد ۹۰ درصد واریانس

انتخاب تعداد مؤلفه‌های اصلی

۲۵

یک الگوریتم غیر کارا

$k = 0$

repeat

{

$k = k + 1$

try $PCA(X)$ with k components

compute $U_{reduced}, z^{(1)}, z^{(2)}, \dots, z^{(m)}, x_{approx}^{(1)}, x_{approx}^{(2)}, \dots, x_{approx}^{(m)}$

until $\frac{\frac{1}{m} \sum_{i=1}^m \|x^{(i)} - x_{approx}^{(i)}\|^2}{\frac{1}{m} \sum_{i=1}^m \|x^{(i)}\|^2} \leq 0.01$

انتخاب تعداد مؤلفه‌های اصلی

۲۶


```
m, n = X.shape
X = X - X.mean(axis=0)
Sigma = (X.T @ X) / m
U, S, V = np.linalg.svd(Sigma)

for k in range(1, n + 1):
    total_var = np.sum(S[:k]) / np.sum(S)
    if total_var >= 0.99: break
return k
```

$$S = \begin{bmatrix} S_{11} & 0 & \cdots & 0 \\ 0 & S_{22} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & S_{nn} \end{bmatrix}$$

```
[8.72e+00  1.58e+00  6.69e-02  4.79e-16  1.35e-47]
```

انتخاب تعداد مؤلفه‌های اصلی: ارقام ۸ در ۸




انتخاب تعداد مؤلفه‌های اصلی

□ داده‌های مربوط به نیمه‌های [۵۹۰ ویژگی]

تعداد مؤلفه‌ها	درصد واریانس	درصد تجمعی
۱	۵۹/۲	۵۹/۲
۲	۲۴/۱	۸۳/۴
۳	۹/۲	۹۲/۵
۴	۲/۳	۹۴/۸
۵	۱/۵	۹۶/۳
۶	۰/۵	۹۶/۸
۷	۰/۳	۹۷/۱
۲۰	۰/۰۸	۹۹/۳

انتخاب تعداد مؤلفه‌های اصلی



استفاده نادرست از PCA: مقابله با بیش‌برازش

۳۰

□ روش نادرست.

- استفاده از $z^{(i)}$ به جای $x^{(i)}$ باعث کاهش تعداد ویژگی‌ها از n به k می‌شود؛
- در نتیجه، با داشتن ویژگی‌های کمتر، احتمال بیش‌برازش کاهش می‌یابد.

□ روش درست.

- PCA در هنگام کاهش ابعاد، اطلاعات مربوط به خروجی را استفاده نمی‌کند.
- برای مقابله با بیش‌برازش از تنظیم استفاده کنید.

$$\min_{\theta} \frac{1}{m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)})^2 + \frac{\lambda}{2m} \sum_{j=1}^n \theta_j^2$$

□ طراحی یک سیستم یادگیری ماشین.

□ ایجاد مجموعه آموزشی به صورت $\{(x^{(1)}, y^{(1)}), (x^{(2)}, y^{(2)}), \dots, (x^{(m)}, y^{(m)})\}$

□ استفاده از PCA به منظور کاهش ابعاد $x^{(i)}$ ها و به دست آوردن $z^{(i)}$ ها

□ اجرای مرحله آموزش بر روی $\{(z^{(1)}, y^{(1)}), (z^{(2)}, y^{(2)}), \dots, (z^{(m)}, y^{(m)})\}$

□ آزمایش فرضیه با استفاده از مجموعه آزمایشی: نگاشت $x_{test}^{(i)}$ به $z_{test}^{(i)}$ و محاسبه $h_{\theta}(z)$ برای هر یک از داده‌های مجموعه آزمایشی.

□ یک پرسش مهم. اگر فرآیند فوق را بدون استفاده از PCA انجام دهیم چه می‌شود؟

□ همواره ابتدا فرآیند بالا را بدون استفاده از PCA انجام دهید.

□ اگر به پاسخ مطلوب نرسیدید، آنگاه استفاده از PCA را آزمایش کنید.

کاربردها

کاربردهای PCA

□ به تصویر کشیدن داده‌ها.

□ انتخاب تعداد مؤلفه‌ها: $k = 2$ یا $k = 3$

□ فشرده‌سازی داده‌ها.


□ کاهش حافظه مورد نیاز برای ذخیره‌سازی داده‌ها

□ افزایش سرعت اجرای الگوریتم یادگیری

□ انتخاب تعداد مؤلفه‌ها: بر اساس درصد واریانس حفظ شده

کاربردها: به تصویر کشیدن داده‌ها

۳۴



نگاشت داده‌ها از فضای ۶۴ بعدی به فضای ۲ بعدی
به منظور به تصویر کشیدن و درک بهتر داده‌ها

کاربردها: فشرده‌سازی

k = 100, variance = 0.91

5 0 4 1 9 2 1 3 1 4
3 5 3 6 1 7 2 8 6 9
4 0 9 1 1 2 4 3 2 7
3 8 6 9 0 5 6 0 7 6
1 8 7 9 3 9 8 5 9 3
3 0 7 4 9 8 0 9 4 1
4 4 6 0 4 5 6 1 0 0
1 7 1 6 3 0 2 1 1 7
8 0 2 6 7 8 3 9 0 4
6 7 4 6 8 0 7 8 3 1

Original Data

5 0 4 1 9 2 1 3 1 4
3 5 3 6 1 7 2 8 6 9
4 0 9 1 1 2 4 3 2 7
3 8 6 9 0 5 6 0 7 6
1 8 7 9 3 9 8 5 9 3
3 0 7 4 9 8 0 9 4 1
4 4 6 0 4 5 6 1 0 0
1 7 1 6 3 0 2 1 1 7
8 0 2 6 7 8 3 9 0 4
6 7 4 6 8 0 7 8 3 1

کاربردها: فشرده‌سازی

k = 150, variance = 0.95

5 0 4 1 9 2 1 3 1 4
3 5 3 6 1 7 2 8 6 9
4 0 9 1 1 2 4 3 2 7
3 8 6 9 0 5 6 0 7 6
1 8 7 9 3 9 8 5 9 3
3 0 7 4 9 8 0 9 4 1
4 4 6 0 4 5 6 1 0 0
1 7 1 6 3 0 2 1 1 7
8 0 2 6 7 8 3 9 0 4
6 7 4 6 8 0 7 8 3 1

Original Data

5 0 4 1 9 2 1 3 1 4
3 5 3 6 1 7 2 8 6 9
4 0 9 1 1 2 4 3 2 7
3 8 6 9 0 5 6 0 7 6
1 8 7 9 3 9 8 5 9 3
3 0 7 4 9 8 0 9 4 1
4 4 6 0 4 5 6 1 0 0
1 7 1 6 3 0 2 1 1 7
8 0 2 6 7 8 3 9 0 4
6 7 4 6 8 0 7 8 3 1

کاربردها: فشرده‌سازی

k = 200, variance = 0.97

5 0 4 1 9 2 1 3 1 4
3 5 3 6 1 7 2 8 6 9
4 0 9 1 1 2 4 3 2 7
3 8 6 9 0 5 6 0 7 6
1 8 7 9 3 9 8 5 9 3
3 0 7 4 9 8 0 9 4 1
4 4 6 0 4 5 6 1 0 0
1 7 1 6 3 0 2 1 1 7
8 0 2 6 7 8 3 9 0 4
6 7 4 6 8 0 7 8 3 1

Original Data

5 0 4 1 9 2 1 3 1 4
3 5 3 6 1 7 2 8 6 9
4 0 9 1 1 2 4 3 2 7
3 8 6 9 0 5 6 0 7 6
1 8 7 9 3 9 8 5 9 3
3 0 7 4 9 8 0 9 4 1
4 4 6 0 4 5 6 1 0 0
1 7 1 6 3 0 2 1 1 7
8 0 2 6 7 8 3 9 0 4
6 7 4 6 8 0 7 8 3 1

کاربردها: فشرده‌سازی



□ مجموعه آموزشی.

□ ۴۰۰ تصویر چهره (خاکستری)

□ ابعاد تصاویر.

□ ۶۴ در ۶۴ پیکسل

□ تعداد ویژگی‌ها.

□ ۴۰۹۶ ویژگی

کاربردها: فشرده‌سازی

$k = 50$, variance = 0.87



Original Faces



کاربردها: فشرده‌سازی

۴۰

$k = 100$, variance = 0.93



Original Faces



کاربردها: فشرده‌سازی

$k = 150$, variance = 0.96



Original Faces



کاربردها: فشرده سازی

k = 200, variance = 0.98




Original Faces



کاربردها: فشرده‌سازی (مؤلفه‌های اصلی)

$k = 25$, variance = 0.79



$k = 36$, variance = 0.84



کاربردها: فشرده‌سازی (بازسازی تصاویر)

۴۴

Principal Components



$k = 25$, variance = 0.79



Original face



کاربردها: فشرده‌سازی (بازسازی تصاویر)

Principal Components



$k = 36$, variance = 0.84




Original face



کاربردها: فشرده‌سازی (بازسازی تصاویر)

۴۶

Principal Components



$k = 100$, variance = 0.93



Original face



پيوسٽ ۱: تجزيه مقادير منفرد

تجزیه مقادیر منفرد

□ انگیزه.

- ساده‌سازی داده‌ها
- حذف نویز و افزونگی
- بهبود نتایج الگوریتم

□ کاربردهای مثالی.

- جستجو و بازیابی اطلاعات [شاخص گذاری معنایی نهان]
- سیستم‌های توصیه‌گر

تجزیه مقادیر منفرد

□ تجزیه مقادیر منفرد.

$$Data_{m \times n} = U_{m \times m} \Sigma_{m \times n} V_{n \times n}^T$$

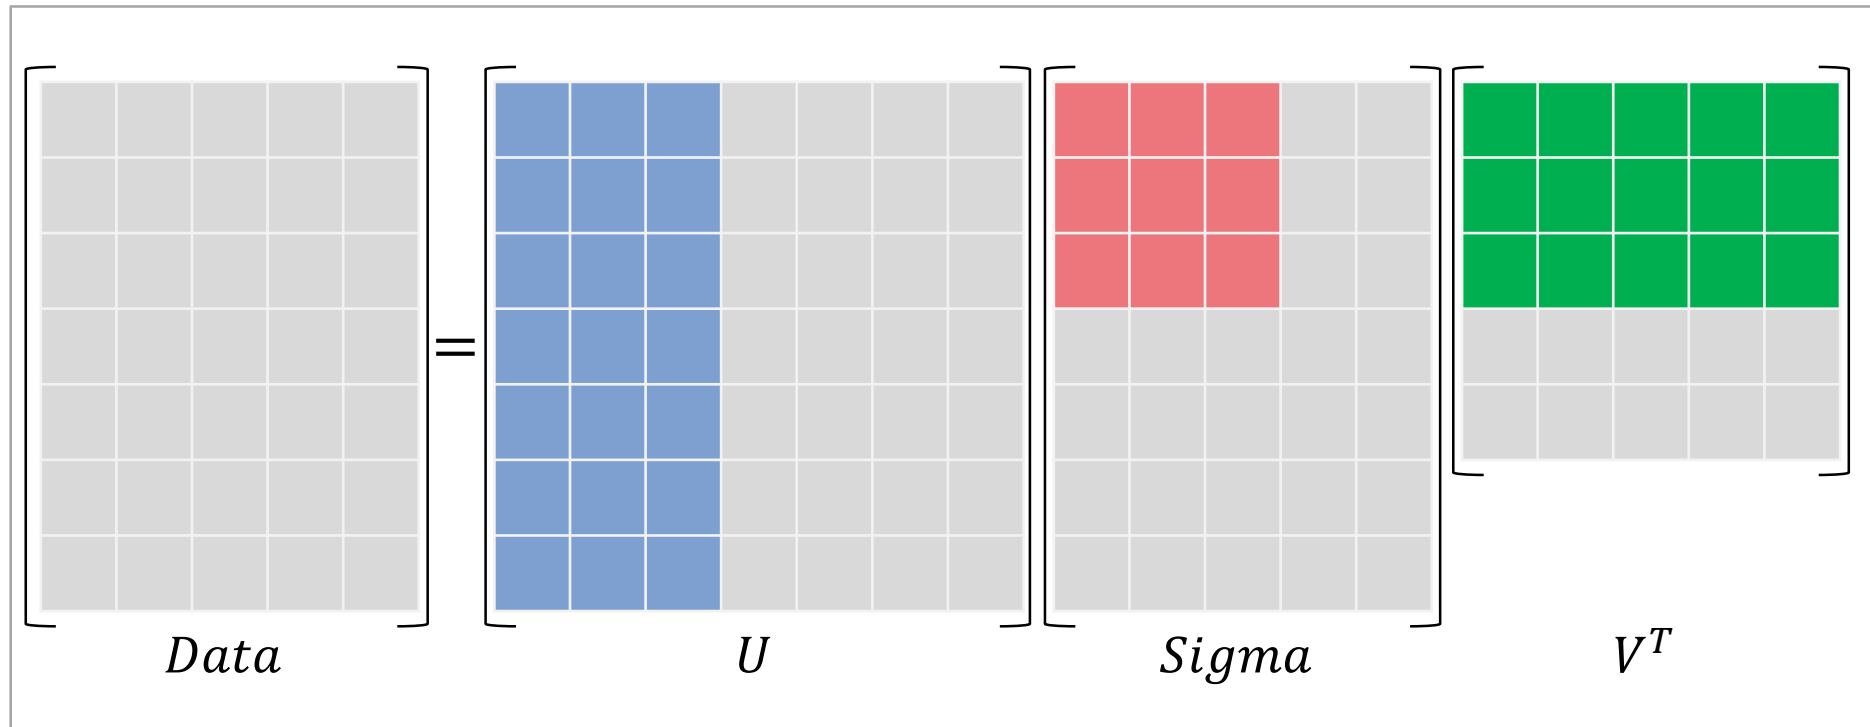
↑
ماتریس مقادیر منفرد

□ ماتریس مقادیر منفرد.

- یک ماتریس قطری که در آن مقادیر منفرد به صورت کاهشی مرتب هستند.
- مقادیر منفرد از یک اندیس مانند r به بعد دارای مقدار صفر هستند.
- مقادیر منفرد ریشه دوم مقادیر ویژه ماتریس $Data \times Data^T$ هستند.

تجزیه مقادیر منفرد: مثال

$$Data_{m \times n} \approx U_{m \times 3} \Sigma_{3 \times 3} V^T_{3 \times n}$$



تجزیه مقادیر منفرد: مثال

۵۱

```
X = np.array([[1, 1, 1, 0, 0],
              [2, 2, 2, 0, 0],
              [1, 1, 1, 0, 0],
              [5, 5, 5, 0, 0],
              [1, 1, 0, 2, 2],
              [0, 0, 0, 3, 3],
              [0, 0, 0, 1, 1]])
```

```
# Singular Value Decomposition
```

```
U, Sigma, VT = svd(X)
```

```
print(Sigma)
```

```
[9.72e+00 5.29e+00 6.84e-01 4.12e-16 1.36e-16]
```

داره‌های اولیه

1	1	1	0	0
2	2	2	0	0
1	1	1	0	0
5	5	5	0	0
1	1	0	2	2
0	0	0	3	3
0	0	0	1	1

تجزیه مقادیر منفرد: مثال

۵۲

```
X_approx = U[:, :1] @ np.diag(Sigma)[:, :1] @ VT[:, :1]
```

$SSE \approx 28.5$

```
print("SSE = {:.2f}".format(np.linalg.norm(X - X_approx) ** 2))
```

```
X_approx = U[:, :2] @ np.diag(Sigma)[:, :2] @ VT[:, :2]
```

$SSE \approx 0.47$

```
print("SSE = {:.2f}".format(np.linalg.norm(X - X_approx) ** 2))
```

```
X_approx = U[:, :3] @ np.diag(Sigma)[:, :3] @ VT[:, :3]
```

$SSE \approx 0.00$

```
print("SSE = {:.2f}".format(np.linalg.norm(X - X_approx) ** 2))
```

تعیین تعداد مقادیر منفرد

□ تعیین یک تعداد مناسب برای مقادیر منفرد.

□ مشابه با تعیین تعداد مؤلفه‌های اصلی

□ یک روش تجربی. انتخاب کوچک‌ترین k به طوری که:

$$\frac{\sum_{i=1}^k S_{ii}^2}{\sum_{i=1}^n S_{ii}^2} \geq 0.90$$

$k = 1.$ energy = 0.768

$k = 2.$ energy = 0.996

$k = 3.$ energy = 1.000

9.72	0	0	0	0
0	5.29	0	0	0
0	0	0.68	0	0
0	0	0	0	0
0	0	0	0	0
0	0	0	0	0
0	0	0	0	0

پیوست ۲: مقادیر ویژه و بردارهای ویژه

مقادیر ویژه و بردارهای ویژه

□ حاصل ضرب ماتریس مربعی A را در بردار x در نظر بگیرید:

$$Ax = y$$

□ ماتریس A همانند یک تابع بردار x را به بردار جدید y تبدیل می‌کند.

□ بردار ویژه. بردار x یک بردار ویژه است اگر با بردار Ax موازی باشد:

$$Ax = \lambda x$$

مقدار ویژه مقدار ویژه

□ مقدار ویژه. در رابطه بالا، λ مقدار ویژه متناظر با بردار ویژه x است.

مقادیر ویژه و بردارهای ویژه

□ مثال. اگر A یک ماتریس جایگشت به صورت زیر باشد:

$$A = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}$$

□ در این صورت:

$$A \begin{bmatrix} 1 \\ 1 \end{bmatrix} = 1 \times \begin{bmatrix} 1 \\ 1 \end{bmatrix} \Rightarrow \lambda = 1$$

$$A \begin{bmatrix} -1 \\ 1 \end{bmatrix} = (-1) \times \begin{bmatrix} -1 \\ 1 \end{bmatrix} \Rightarrow \lambda = -1$$

$$\text{trace}(A) = 0 + 0 = 1 + (-1)$$

□ توجه. مجموع مقادیر ویژه با مجموع عناصر قطر اصلی (اثر) برابر است.

محاسبه مقادیر ویژه و بردارهای ویژه

۵۷

□ محاسبه مقادیر ویژه.

$$Ax = \lambda x \Rightarrow (A - \lambda I)x = 0$$

□ بنابراین ماتریس $A - \lambda x$ یک ماتریس منفرد است. [زیرا بردار پوچ دارد]

$$\det(A - \lambda I) = 0$$

□ در نتیجه:

□ مثال. محاسبه مقادیر ویژه

$$A = \begin{bmatrix} 3 & 1 \\ 1 & 3 \end{bmatrix}$$

$$\det(A - \lambda I) = \det \left(\begin{bmatrix} 3 - \lambda & 1 \\ 1 & 3 - \lambda \end{bmatrix} \right) = \lambda^2 - \overset{\text{trace}(A)}{6\lambda} + \overset{\det(A)}{8} = 0 \Rightarrow \lambda = 4, 2$$

محاسبه مقادیر ویژه و بردارهای ویژه

□ محاسبه بردارهای ویژه.

□ مثال.

$$A = \begin{bmatrix} 3 & 1 \\ 1 & 3 \end{bmatrix} \Rightarrow \lambda_1 = 4, \lambda_2 = 2$$

$$(A - 4I)x_1 = \begin{bmatrix} -1 & 1 \\ 1 & -1 \end{bmatrix} x_1 = 0 \Rightarrow x_1 = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$$

$$(A - 2I)x_2 = \begin{bmatrix} 1 & 1 \\ 1 & 1 \end{bmatrix} x_2 = 0 \Rightarrow x_2 = \begin{bmatrix} -1 \\ 1 \end{bmatrix}$$

□ مشاهده.

$$Ax = \lambda x \Rightarrow (A + 3I)x = Ax + 3x = \lambda x + 3x = (\lambda + 3)x$$

تجزیه ماتریس A: قطری سازی

□ فرض کنید S ماتریسی باشد که ستون‌های آن بردارهای ویژه ماتریس A هستند.

$$\begin{aligned} AS &= A \begin{bmatrix} | & | & \cdots & | \\ x_1 & x_2 & \cdots & x_n \\ | & | & \cdots & | \end{bmatrix} \\ &= \begin{bmatrix} | & | & \cdots & | \\ \lambda_1 x_1 & \lambda_2 x_2 & \cdots & \lambda_n x_n \\ | & | & \cdots & | \end{bmatrix} \\ &= \begin{bmatrix} | & | & \cdots & | \\ x_1 & x_2 & \cdots & x_n \\ | & | & \cdots & | \end{bmatrix} \begin{bmatrix} \lambda_1 & 0 & \cdots & 0 \\ 0 & \lambda_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \lambda_n \end{bmatrix} \\ &= S\Lambda \end{aligned}$$

$$AS = S\Lambda \Rightarrow S^{-1}AS = \Lambda$$

$$AS = S\Lambda \Rightarrow A = S\Lambda S^{-1}$$

تجزیه ماتریس A: قطری سازی

۶۰

□ مشاهده. اگر ماتریس A را به توان دو برسانیم، مقادیر ویژه به توان دو می‌رسند و بردارهای ویژه تغییر نمی‌کنند.

$$A = S\Lambda S^{-1} \Rightarrow A^2 = S\Lambda S^{-1} S\Lambda S^{-1} = S\Lambda^2 S^{-1}$$

□ به طور کلی.

$$A = S\Lambda S^{-1} \Rightarrow A^k = S\Lambda^k S^{-1}$$

تجزیه ماتریس متقارن

□ در یک ماتریس متقارن حقیقی:

□ مقادیر ویژه حقیقی هستند.

□ بردارهای ویژه متعامد نرمال هستند.

$$A = Q\Lambda Q^{-1} = Q\Lambda Q^T$$

$$A = \begin{bmatrix} | & | & \dots & | \\ q_1 & q_2 & \dots & q_n \\ | & | & \dots & | \end{bmatrix} \begin{bmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \lambda_n \end{bmatrix} \begin{bmatrix} - & q_1^T & - \\ - & q_2^T & - \\ \vdots & \vdots & \vdots \\ - & q_n^T & - \end{bmatrix}$$
$$= \lambda_1 q_1 q_1^T + \lambda_2 q_2 q_2^T + \dots + \lambda_n q_n q_n^T$$

□ مشاهده. هر ماتریس متقارن ترکیب خطی یک مجموعه از ماتریس‌های پروجکشن متعامد است.

ماتریس‌های مثبت معین متقارن

۶۲

□ ماتریس مثبت معین. ماتریس A مثبت معین است اگر به ازای هر بردار غیر صفر مانند x :

$$x^T A x > 0$$

□ در یک ماتریس مثبت معین متقارن:

□ مقادیر ویژه همگی مثبت هستند.

□ محورها همگی مثبت هستند.

□ دترمینان‌ها همگی (دترمینان زیرماتریس‌های مقدم) مثبت هستند.

□ مثال.

$$A = \begin{bmatrix} 5 & 2 \\ 2 & 3 \end{bmatrix} \Rightarrow \lambda = 4 \pm \sqrt{5}, p_1 = 5, p_2 = \frac{11}{5}, \det(A) = 11$$