

Cvičení z RPZ – Principal Component Analysis

Vojtěch Franc

5. ledna 2005

1 Zadání

Cílem cvičení je implementovat a použít metodu Principal Component Analysis (PCA). Vypracujte následující body zadání:

1. Implementujte metodu PCA. Výsledkem má být funkce `Y = moje_pca(X,d)` jejíž vstupem je matice $X \in \mathbb{R}^{n \times m}$ obsahující vstupní (trénovací) data a dimenze $d < n$ nového prostoru. Výstupem je matice $Y \in \mathbb{R}^{d \times m}$ obsahující nízkodimenzionální reprezentaci dat X .
2. Aplikujte PCA na synteticky vygenerovaná 2-dimenzionální data. Použijte funkci `creatdata` ze Statistical Pattern Recognition Toolboxu. Zobrazte si vstupní a rekonstruovaná data.
3. Aplikujte PCA pro kompresi obrázku `lena.jpg`. Obrázek rozdělte na nepřekrývající se čtvercové oblasti velikosti 16×16 . Každou oblast reprezentujte jako vektor s dimenzí $256 = 16 \times 16$. Takto získané vektory aproximujte v prostoru nižší dimenze (volba dimenze kontroluje komprimaci a kvalitu obrázku). Vektory opět rekonstruujte a zobrazte získaný (dekomprimovaný) obrázek. V odstavci 3 naleznete podrobnější vysvětlení.

Pro rozdělení obrázku použijte funkce `im2col` a `col2im`. Obrázek si zobrazte funkcí `imshow`.

2 Principal Component Analysis

Metoda PCA hledá nízkodimenzionální reprezentaci dat, tak aby rekonstrukční chyba byla minimální. Nechť matice $X = [x_1, \dots, x_m] \in \mathbb{R}^{n \times m}$ obsahuje m vektorů v n -dimenzionálním lineárním prostoru. Nízkodimenzionální reprezentace dat X se získá lineární transformací

$$y = Wx + b, \tag{1}$$

kde $W \in \mathbb{R}^{d \times n}$ je ortonormální matice a $b \in \mathbb{R}$ skalár. Promítnutím vektorů z X pomocí projekce (1) získáme matici $Y = [y_1, \dots, y_m]$ obsahující m vektorů v d -dimenzionálním prostoru, kde $d < n$.

Původní data lze z jejich nízkodimenzionální reprezentace rekonstruovat inverzí transformací k (1), t.j.,

$$\hat{x} = W^T (y - b), \quad (2)$$

kde se využilo, že matice W je ortonormální. Nechť matice $\hat{X} = [\hat{x}_1, \dots, \hat{x}_m] \in \mathbb{R}^{n \times m}$ obsahuje rekonstruovaná data. Rekonstrukční chyba je definována jako

$$\varepsilon = \frac{1}{m} \sum_{i=1}^m \|x_i - \hat{x}_i\|^2.$$

Metoda PCA hledá parametry lineární transformace (1) a (2) tak, aby rekonstrukční chyba ε byla minimální. Optimální řešení této úlohy se získá z vlastních vektorů matice

$$S = \sum_{i=1}^m (x_i - \mu)(x_i - \mu)^T,$$

a z vektoru

$$\mu = \frac{1}{m} \sum_{i=1}^m x_i.$$

K získání vlastních vektorů a čísel je třeba vyřešit problém nalezení skaláru $\lambda > 0$ a vektoru $w \neq 0$ tak, že

$$\lambda w = S w.$$

Řešení tohoto problému je v Matlabu implementováno ve funkci `eig`. Nechť $\lambda_1 \geq \lambda_2 \geq \dots \lambda_d$ je posloupnost d největších vlastních čísel a w_1, w_2, \dots, w_d jsou jejich odpovídající vlastní vektory. Optimální řešení je rovno

$$W = [w_1, w_2, \dots, w_d]^T, \quad \text{a} \quad b = -W \mu. \quad (3)$$

Dosazením (3) do vztahu pro dopřednou (1) a zpětnou (2) transformaci dostaneme

$$y = W (x - \mu), \quad \text{a} \quad \hat{x} = W^T y + \mu.$$

3 Aplikace PCA pro komprimaci obrázku

Vstupní obrázek lena.jpg velikosti 512×512 pixelů.



Trénovací množina $X = [x_1, \dots, x_m]$ obsahuje $m = 1024$ čtvercových oblastí 16×16 representovaných jako vektory $x_i \in \mathbb{R}^n$, $n = 256$.

- **Učení PCA modelu:** Hledá se nová báze $W = [w_1, \dots, w_d]$, $d < n$, v které se dobře aproximují oblasti X .
- **Komprimace obrázku:** Vypočítá se nová reprezentace $Y = [y_1, \dots, y_m]$ oblastí X v bázi W .
- **Dekomprimace obrázku:** Z nové reprezentace Y se rekonstruuují oblasti $\hat{X} = [\hat{x}_1, \dots, \hat{x}_m]$.

$$\text{comp} \dots \text{kompresní poměr } \text{comp} = \frac{(d \cdot m) + (d \cdot n)}{n \cdot m}.$$

$d \dots$ počet bazových vektorů - nová dimenze.


$$\varepsilon \dots \text{střední kvadratická chyba mezi } \varepsilon = \frac{1}{m} \sum_{i=1}^m \|x_i - \hat{x}_i\|^2.$$

Obrázek 1: **Příklady komprimace obrázku** v závislosti na počtu báзовých vektorů.

$d = 2, comp = 1.0\%, \varepsilon = 1.25$



$d = 5, comp = 2.4\%, \varepsilon = 0.67$



$d = 10, comp = 4.9\%, \varepsilon = 0.40$



$d = 50, comp = 24.4\%, \varepsilon = 0.07$

