

**TERMIN ODDANIA: 5.05.2019**

DO ODDANIA: Raport w postaci pliku .pdf oraz plik(i) w Python (ver 3).

UWAGA: Poniżej znajduje się opis co powinno znaleźć się w projekcie. Twój projekt powinien te wszystkie elementy zawierać, ale nie musi się tylko i wyłącznie do nich sprowadzać.

**Część A: Rozkład SVD i kompresja obrazów (10pkt)****Opis projektu**

Wykonaj dekompozycje SVD dla obrazka

[http://www.math.uni.wroc.pl/~lorek/image\\_analysis/images/baboon.bmp](http://www.math.uni.wroc.pl/~lorek/image_analysis/images/baboon.bmp)

oraz dla min. 3 przez siebie wybranych czarno-białych obrazków (najlepiej tego samego rozmiaru bitmapy .bmp) Postaraj się, aby były tam obrazy zarówno skomplikowane (prawie każdy mały obszar ma dużo szczegółów) jak i “proste” (np. jest dużo obszarów o jednakowym lub mało się zmieniającym kolorze)

Każdy obraz  $f$  przedstaw jako

$$f = \sum_{i=1}^r \lambda_i^{\frac{1}{2}} \mathbf{u}_i \mathbf{v}_i$$

Nazwijmy  $\lambda_i^{\frac{1}{2}} \mathbf{u}_i \mathbf{v}_i$  obrazem własnym (eigenimage) odpowiadającym wartości własnej  $\lambda_i$ . Posortujmy wartości własne w taki sposób, by  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_r$ . Oznaczmy  $f_k = \sum_{i=1}^k \lambda_i^{\frac{1}{2}} \mathbf{u}_i \mathbf{v}_i$ . Dla każdego obrazka przedstaw (jako obrazek) kilka pierwszych obrazów własnych oraz  $f_k$  dla kilku wybranych  $k$  (zwiększające się o stałą liczbę).

Przez kompresję obrazu  $f$  metodą rozkładu SVD nazywamy obraz  $f_k$  z odpowiednio dobranym parametrem  $k$ . Wypracuj jakiś sposób wyznaczania tego parametru (np.  $k$  ma być taką liczbą, by  $\lambda_{k+1} + \dots + \lambda_r$  stanowiły maksymalnie jakiś ustalony procent całej sumy  $\sum_{i=1}^r \lambda_i$ , procent ten może być wybrany eksperymentalnie na jednym obrazku).

Następnie wylicz w tak ustalony sposób  $k$  dla każdego obrazka. Czy wielkość  $k$  zależy od stopnia skomplikowania obrazka?

Policz też ile pamięci zajmuje tak skompresowany obraz. Porównaj wynik do obrazów (standardowych) .jpg otrzymanych na chaosie za pomocą komendy:

```
chaos:~$ convert obrazek.bmp obrazek.jpg
```

Zakładamy, że wszystkie obrazy są 8-bitowe (= 1 bajt) (skala szarości 0-255). Zatem np. jeden wektor  $\mathbf{u}_i$  jest wektorem rozmiaru 256, i każdy element to 1 bajt, czyli  $\mathbf{u}_i$  jest

zajmuje 256 bajtów = 0.25 Kb (1 Kb = 1024 bajty). Natomiast dla przykładu: obrazek  $256 \times 256$  trzymany w postaci 8-bitowej bitmapy zajmuje:  $256 \cdot 256 \cdot 8$  bitów =  $524288$  bitów =  $524288 / (1024 \cdot 8) = 64$  Kb.

(UWAGA: rozmiar pliku *.bmp* może być większy z kilku powodów: np. mimo iż obraz jest czarnobiały, to każdy kanał r,g,b jest i tak pamiętany osobno, wtedy rozmiar to będzie  $3 \cdot 64$ Kb, albo może być 16, 24 lub 32-bitowy, trzymane też mogą być informacje o rozdzielczości).

Ścieżka do zdjęcia powinna być parametrem programu (użyj `argparse`).

## Część B: PCA + Klasyfikacja obrazów (10pkt)

Baza twarzy `Olivetti faces` składa się z 400 obrazów (w skali szarości) rozmiaru  $64 \times 64$ . Są to zdjęcia 40 osób (po 10 zdjęć na osobę).

Bazę wczytujemy w następujący sposób:

```
from sklearn.datasets import fetch_olivetti_faces
faces = fetch_olivetti_faces()
```

(zob.: `faces.keys()`, `faces.images.shape`, `faces.data.shape`, `faces.target.shape`)

Do dalszej analizy wybierz tylko zdjęcia 10 (losowo wybranych) osób. Otrzymany zbiór podziel losowo na dwie części

- Zbiór *treningowy*: po 7 zdjęć każdej z 10 osób.
- Zbiór *testowy*: pozostałe zdjęcia (tj. po 3 dla każdej z osób)

Zadania

- Wykonaj na zbiorze treningowym PCA redukując wymiar  $64^2$  do różnych wartości  $d$  (w tym  $d = 0$ , tzn. de facto bez PCA)
- Przekształć punkty ze zbioru testowego za pomocą otrzymanej macierzy przekształcenia z poprzedniego punktu.
- Wykonaj klasyfikację  $k$ NN tak przekształconych obrazów z różnymi wartościami parametru  $k$
- Podaj dla testowanych par  $d$  i  $k$  wynik klasyfikacji (classification rate). Jakie wartości  $d$  i  $k$  dały najlepsze wyniki?

Dodatkowo, dla kilku par  $d$  i  $k$  (w tym dla tej, która dała najlepsze wyniki dla  $k$ NN) zamiast  $k$ NN zastosuj: `GaussianNB`, `RandomForestClassifier`, `SVC`, ich użycie jest takie samo jak  $k$ NN (możesz używać ich domyślnych parametrów), przykładowe użycie jest np. na stronie:

[https://scikit-learn.org/stable/auto\\_examples/classification/plot\\_classifier\\_comparison.html](https://scikit-learn.org/stable/auto_examples/classification/plot_classifier_comparison.html)