

...

Robert Susmaga

Instytut Informatyki

ul. Piotrowo 2

Poznań

kontakt mail'owy

Robert.Susmaga@CS.PUT.Poznan.PL

kontakt osobisty

Centrum Wykładowe, „blok informatyki”, pok. 7

## **Wyłączenie odpowiedzialności**


Prezentowane materiały, będące dodatkiem pomocniczym do wykładów, z konieczności fragmentarycznym i niedopracowanym, należy wykorzystywać z pełną świadomością faktu, że mogą nie być pozbawione przypadkowych błędów, braków, wypaczeń i przeinaczeń :-)

Autor


...

# Iloczyny wektorów




- Iloczyn skalarny wektorów:
  - wierszowy jest mnożony przez kolumnowy
  - długości wektorów muszą być równe
  - wynikiem jest skalar



- Iloczyn macierzowy wektorów:
  - kolumnowy jest mnożony przez wierszowy
  - długości wektorów nie muszą być równe
  - wynikiem jest macierz



# „Mechanika” iloczynu skalarnego



# „Mechanika” iloczynu macierzowego

$x_1$	$x_2$	$x_3$	$x_4$
-------	-------	-------	-------

$y_1$
$y_2$
$y_3$




$y_1x_1$	$y_1x_2$	$y_1x_3$	$y_1x_4$
$y_2x_1$	$y_2x_2$	$y_2x_3$	$y_2x_4$
$y_3x_1$	$y_3x_2$	$y_3x_3$	$y_3x_4$

# Iloczyn macierzy: złożenie iloczynów skalarnych wektorów

- Iloczyn macierzy może być przedstawiony jako:
  - iloczyn skalarny wektorów
    - każdy element macierzy wynikowej jest ilorazem skalarnym odpowiednich wektorów będących elementami mnożonych macierzy
  - iloczyn macierzowy wektorów
    - macierz wynikowa jest sumą pewnych macierzy (tzw. warstw) powstałych jako ilorazy macierzowe odpowiednich wektorów będących elementami mnożonych macierzy



# Iloczyn macierzy: złożenie iloczynów skalarnych wektorów



# Iloczyn macierzy: złożenie iloczynów skalarnych wektorów

$y_{11}$	$y_{12}$
$y_{21}$	$y_{22}$
$y_{31}$	$y_{32}$

$x_{11}$	$x_{12}$	$x_{13}$
$x_{21}$	$x_{22}$	$x_{23}$

$+ x_{11}y_{11}$ $+ x_{12}y_{21}$ $x_{13}y_{31}$	$+ x_{12}y_{12}$ $+ x_{12}y_{22}$ $x_{13}y_{32}$
$+ x_{21}y_{11}$ $+ x_{22}y_{21}$ $x_{23}y_{31}$	$+ x_{21}y_{12}$ $+ x_{22}y_{22}$ $x_{23}y_{32}$

# Iloczyn macierzy: suma iloczynów macierzowych wektorów

$x_1$	$x_2$	$x_3$	$x_4$
-------	-------	-------	-------

$y_{12}$	$y_{12}x_{21}$	$y_{12}x_{22}$	$y_{12}x_{23}$	$y_{12}x_{24}$
$y_{22}$	$y_{22}x_{21}$	$y_{22}x_{22}$	$y_{22}x_{23}$	$y_{22}x_{24}$
$y_{32}$	$y_{32}x_{21}$	$y_{32}x_{22}$	$y_{32}x_{23}$	$y_{32}x_{24}$

# Iloczyn macierzy: suma iloczynów macierzowych wektorów

$x_{11}$	$x_{12}$	$x_{13}$	$x_{14}$
$x_{21}$	$x_{22}$	$x_{23}$	$x_{24}$

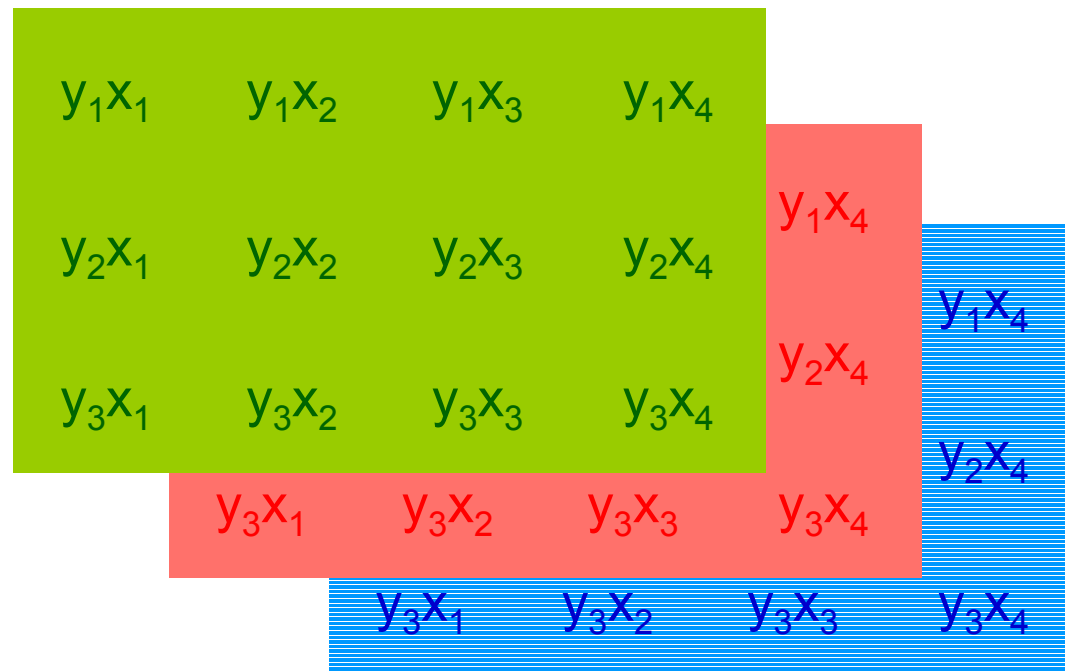
$y_{11}$	$y_{12}$
$y_{21}$	$y_{22}$
$y_{31}$	$y_{32}$

$y_{11}x_{11} + y_{12}x_{21}$	$y_{11}x_{12} + y_{12}x_{22}$	$y_{11}x_{13} + y_{12}x_{23}$	$y_{11}x_{14} + y_{12}x_{24}$
$y_{21}x_{11} + y_{22}x_{21}$	$y_{21}x_{12} + y_{22}x_{22}$	$y_{21}x_{13} + y_{22}x_{23}$	$y_{21}x_{14} + y_{22}x_{24}$
$y_{31}x_{11} + y_{32}x_{21}$	$y_{31}x_{12} + y_{32}x_{22}$	$y_{31}x_{13} + y_{32}x_{23}$	$y_{31}x_{14} + y_{32}x_{24}$

# Iloczyn macierzy: suma iloczynów macierzowych wektorów

$x_1$	$x_2$	$x_3$	$x_4$
$x_1$	$x_2$	$x_3$	$x_4$
$x_1$	$x_2$	$x_3$	$x_4$

$y_1$	$y_1$	$y_1$
$y_2$	$y_2$	$y_2$
$y_3$	$y_3$	$y_3$



## Iloczyn „skalowany”

- O „skalowanym” iloczynie macierzy **X** i **Z** można mówić w sytuacji sytuacji, gdy wykonywana jest operacja **XDZ**, gdzie **D** jest macierzą diagonalną

– Dla **W = XZ** (iloczyn „nieskalowany”)


- zachodzi:  $w_{kl} = \sum_i x_{ki} \cdot z_{il}$

– Dla **W = XDZ** (iloczyn „skalowany”)

- zachodzi:

$$w_{kl} = \sum_i x_{ki} \cdot d_{ii} \cdot z_{il} = \sum_i d_{ii} \cdot x_{ki} \cdot z_{il}$$

# „Mechanika” skalowanego iloczynu macierzy




# Skalowany iloczyn macierzy

5		
	3	
		1

$x_1$	$x_2$	$x_3$	$x_4$
$x_1$	$x_2$	$x_3$	$x_4$
$x_1$	$x_2$	$x_3$	$x_4$

$y_1$	$y_1$	$y_1$
$y_2$	$y_2$	$y_2$
$y_3$	$y_3$	$y_3$






# Skalowany iloczyn macierzy

5		
	3	
		1



$x_1$	$x_2$	$x_3$	$x_4$
$x_1$	$x_2$	$x_3$	$x_4$
$x_1$	$x_2$	$x_3$	$x_4$

$y_1$	$y_1$	$y_1$
$y_2$	$y_2$	$y_2$
$y_3$	$y_3$	$y_3$



# Iloczyn trzech macierzy jako iloczyn skalowany

...	...	...
...	$d_{ij}$	...
...	...	...



$d_{ij}y_1x_1$	$d_{ij}y_1x_2$	$d_{ij}y_1x_3$	$d_{ij}y_1x_4$
$d_{ij}y_2x_1$	$d_{ij}y_2x_2$	$d_{ij}y_2x_3$	$d_{ij}y_2x_4$
$d_{ij}y_3x_1$	$d_{ij}y_3x_2$	$d_{ij}y_3x_3$	$d_{ij}y_3x_4$

# Iloczyn „skalowany”

- Przypadek skalowania
  - lewostronnego
    - $\mathbf{W} = (\mathbf{XD})\mathbf{Z}$  (macierzą  $\mathbf{D}$  skalujemy macierz po lewej)
  - prawostronnego
    - $\mathbf{W} = \mathbf{X}(\mathbf{DZ})$  (macierzą  $\mathbf{D}$  skalujemy macierz po prawej)
  - „równomiernego” (jednocześnie lewo- i prawostronnego)
    - $\mathbf{W} = (\mathbf{XD}^{0.5})(\mathbf{D}^{0.5}\mathbf{Z})$
- przykładowe zastosowanie: macierz  $\mathbf{X} = \mathbf{KL}^{(0.5)}$  w MDS
  - wtedy  $\mathbf{X}$  jest (poszukiwaną) macierzą spełniającą  $\mathbf{XX}^T = \mathbf{B}$ , ponieważ
$$\begin{aligned}\mathbf{XX}^T &= \mathbf{KL}^{(0.5)}(\mathbf{KL}^{(0.5)})^T = \mathbf{KL}^{(0.5)}(\mathbf{L}^{(0.5)})^T\mathbf{K}^T = \\ &= \mathbf{KL}^{(0.5)}\mathbf{L}^{(0.5)}\mathbf{K}^T = \mathbf{KL}^{(1)}\mathbf{K}^T = \mathbf{KLK}^T = \mathbf{B}\end{aligned}$$

...

# Przybliżenia macierzy dzięki rozkładowi EVD

- Niech  $\mathbf{A}$  będzie macierzą danych, oraz niech istnieją macierze  $\mathbf{X}$ ,  $\mathbf{D}$  i  $\mathbf{Z}$  takie, że:  $\mathbf{A} = \mathbf{XDZ}$ , przy czym  $\mathbf{D}$  jest macierzą diagonalną o wartościach  $d_{ii}$  na przekątnej:
  - jeżeli pewne wartości  $d_{ii}$  są co do wartości bezwzględnej małe w porównaniu z innymi  $d_{ii}$ , to elementy te wraz z:
    - odpowiadającymi im kolumnami macierzy  $\mathbf{X}$
    - odpowiadającymi im wierszami macierzy  $\mathbf{Z}$mogą zostać pominięte (uznane za równe zero)
  - otrzymany w rezultacie takiej operacji, uproszczony iloczyn macierzowy będzie przybliżeniem (lepszym lub gorszym) oryginalnej macierzy  $\mathbf{A}$
- Stworzenie takiego przybliżenia może być celem samym w sobie, ponieważ może doprowadzić do m.in.:
  - „odszumienia” obrazu reprezentowanego przez macierz  $\mathbf{A}$
  - zredukowanie reprezentacji pamięciowej macierzy  $\mathbf{A}$
- W praktyce operacja taka jest możliwa dzięki rozkładowi  $\mathbf{A} = \mathbf{K}\mathbf{L}\mathbf{K}^T$ , w którym macierz  $\mathbf{L}$  z definicji jest macierzą diagonalną

...

## Uogólnienie EVD: rozkład SVD

- Niech dana będzie macierz symetryczna  $\mathbf{A}$  oraz jej rozkład EVD postaci  $\mathbf{A} = \mathbf{K}\mathbf{L}\mathbf{K}^T$
- Pytanie, czy rozkład powyższej postaci, lub jakieś jego uogólnienie, może być zagwarantowany/e dla macierzy, które:
  - nie są symetryczne?
  - nie są kwadratowe?
  - nie są rzeczywiste?

# Uogólnienie EVD: rozkład SVD

- Dana jest macierz  $\mathbf{A}$  o rozmiarach  $m \times n$ 
  - jeżeli  $m = n$ , to niektóre  $\mathbf{A}$  można rozłożyć na iloczyn czynników  $\mathbf{K}\mathbf{L}\mathbf{K}^{-1}$  (o ile  $\mathbf{K}^{-1}$  istnieje, jeżeli tak to w szczególnym przypadku może zachodzić:  $\mathbf{K}^{-1} = \mathbf{K}^T$ ) wykorzystując do tego macierze złożone z wartości własnych ( $\mathbf{L}$ ) i wektorów własnych ( $\mathbf{K}$ ) macierzy  $\mathbf{A}$
  - pytanie, czy jeżeli  $m \neq n$  to także można wykorzystać jakieś wartości i wektory własne do znalezienia takiego rozkładu?
  - jak znaleźć te wartości jeżeli wiadomo, że wartości/wektory własne oblicza się jedynie dla macierzy kwadratowych?
- W celu uogólnienia rozkładu macierzy niekwadratowej na iloczyn trzech czynników wykorzystuje się następujący fakt:
  - nawet jeżeli  $\mathbf{A}$  nie jest macierzą symetryczną ani kwadratową (czyli gdy  $m \neq n$ ) to można wykorzystać tę macierz do utworzenia dwóch macierzy:
    - $\mathbf{C} = \mathbf{A}^T\mathbf{A}$  (odpowiednik macierzy kowariancji kolumn), o rozmiarach  $n \times n$
    - $\mathbf{R} = \mathbf{A}\mathbf{A}^T$  (odpowiednik macierzy kowariancji wierszy), o rozmiarach  $m \times m$



# Uogólnienie EVD: rozkład SVD

- Macierze utworzone z dowolnej macierzy  $\mathbf{A}$  poprzez wykonanie operacji  $\mathbf{A}^T\mathbf{A}$  oraz  $\mathbf{A}\mathbf{A}^T$  nazywa się macierzami Grama
  - ogólnie macierz Grama tworzy się stosując formę (czyli funkcję, której argumentami są wektory) postaci  $f: \mathbb{R}^n \times \mathbb{R}^n \rightarrow \mathbb{R}$  (np.  $f(\mathbf{x}, \mathbf{y}) = \mathbf{x}^T \mathbf{A} \mathbf{y}$ ) do każdej pary wektorów ze zbioru  $[\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_m]$ , w rezultacie czego powstaje macierz (składająca się z wartości formy) o rozmiarach  $m \times m$ 
    - iloczyn skalarny wektorów, który jest wykorzystany do stworzenia macierzy  $\mathbf{A}^T\mathbf{A}$  oraz  $\mathbf{A}\mathbf{A}^T$  jest szczególnym przypadkiem takiej formy:  $\langle \mathbf{x}, \mathbf{y} \rangle = \mathbf{x}^T \mathbf{y} = \mathbf{x}^T \mathbf{I} \mathbf{y}$
    - przekształceniu przez tę formę podlegają kolumny/wiersze macierzy  $\mathbf{A}$
  - jeżeli forma  $f(\mathbf{x}, \mathbf{y})$  jest dodatnio określona to stworzona macierz Grama ma wyznacznik nieujemny
    - iloczyn skalarny wektorów spełnia warunek dodatniej określoności
  - wyznacznik macierzy Grama utworzonej dla wektorów  $\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_m$  nie zależy od kolejności tych wektorów
    - tzn. np.  $\det([\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_m]) = \det([\mathbf{w}_2, \mathbf{w}_1, \dots, \mathbf{w}_m])$
    - uzasadnienie: macierz Grama utworzoną dla  $[\mathbf{w}_2, \mathbf{w}_1, \dots, \mathbf{w}_m]$  można utworzyć z macierzy Grama utworzonej dla  $[\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_m]$  przez zamianę miejscami pierwszych dwóch wierszy i pierwszych dwóch kolumn

# Uogólnienie EVD: rozkład SVD

- Wartości wyznaczników obu macierzy Grama (utworzonych jako  $\mathbf{C} = \mathbf{A}^T \mathbf{A}$  oraz  $\mathbf{R} = \mathbf{A} \mathbf{A}^T$ ) są uzależnione od rzędu macierzy  $\mathbf{A}$  (który świadczy o zależności/niezależności kolumn/wierszy tej macierzy)
  - jeżeli kolumny macierzy  $\mathbf{A}$  są liniowo niezależne to
$$\det(\mathbf{C}) = \det(\mathbf{A}^T \mathbf{A}) > 0,$$
w przeciwnym przypadku
$$\det(\mathbf{C}) = \det(\mathbf{A}^T \mathbf{A}) = 0$$
  - jeżeli wiersze macierzy  $\mathbf{A}$  są liniowo niezależne to
$$\det(\mathbf{R}) = \det(\mathbf{A} \mathbf{A}^T) > 0,$$
w przeciwnym przypadku
$$\det(\mathbf{R}) = \det(\mathbf{A} \mathbf{A}^T) = 0$$
- Wartości własne macierzy Grama są nieujemne
  - wynika to z faktu, macierze grama są kwadratowymi macierzami symetrycznymi

# Uogólnienie EVD: rozkład SVD

- Szczególne przypadki
  - dla kwadratowej macierzy  $\mathbf{A}$  wyznacznik macierzy  $\mathbf{A}^T\mathbf{A}$  jest kwadratem wyznacznika macierzy  $\mathbf{A}$  (co determinuje jego nieujemność)
    - $\det(\mathbf{A}^T\mathbf{A}) = \det(\mathbf{A}^T)\det(\mathbf{A}) = \det(\mathbf{A})\det(\mathbf{A}) = (\det(\mathbf{A}))^2$
  - za bardzo szczególny przypadek macierzy Grama można uznać macierz jednostkową  $\mathbf{I}$ , która jest wynikiem operacji  $\mathbf{K}^T\mathbf{K}$ , gdzie  $\mathbf{K}$  jest macierzą ortogonalną
    - oczywiście dla obu macierzy Grama utworzonych dla macierzy ortogonalnej  $\mathbf{K}$  zachodzi:
      - $\det(\mathbf{C}) = \det(\mathbf{K}^T\mathbf{K}) = \det(\mathbf{I}) = 1 > 0$
      - $\det(\mathbf{R}) = \det(\mathbf{K}\mathbf{K}^T) = \det(\mathbf{I}) = 1 > 0$

# Uogólnienie EVD: rozkład SVD

- Pomimo iż  $\mathbf{C} = \mathbf{A}^T \mathbf{A}$  i  $\mathbf{R} = \mathbf{A} \mathbf{A}^T$  są różnymi macierzami to posiadają one wiele cech wspólnych, m.in.:
  - $\mathbf{C}^T = \mathbf{C}$ :  $\mathbf{C}$  jest kwadratową macierzą symetryczną
  - $\mathbf{R}^T = \mathbf{R}$ :  $\mathbf{R}$  jest kwadratową macierzą symetryczną
  - $\text{spec}(\mathbf{C}) \geq 0$ : wartości własne macierzy  $\mathbf{C}$  są nieujemne
  - $\text{spec}(\mathbf{R}) \geq 0$ : wartości własne macierzy  $\mathbf{R}$  są nieujemne
  - $\text{rank}(\mathbf{C}) = \text{rank}(\mathbf{R})$ : rzędy macierzy  $\mathbf{C}$  i  $\mathbf{R}$  są takie same
  - $\text{trace}(\mathbf{C}) = \text{trace}(\mathbf{R})$ : ślady macierzy  $\mathbf{C}$  i  $\mathbf{R}$  są takie same
  - $\text{spec}_{\neq 0}(\mathbf{C}) = \text{spec}_{\neq 0}(\mathbf{R})$ : zbiory niezerowych wartości własnych macierzy  $\mathbf{C}$  i  $\mathbf{R}$  są takie same
  - zbiory wektorów własnych obu macierzy są związane ze sobą pewną zależnością liniową

# Uogólnienie EVD: rozkład SVD

- Inne cechy macierzy  $\mathbf{C} = \mathbf{A}^T\mathbf{A}$  i  $\mathbf{R} = \mathbf{A}\mathbf{A}^T$  to:
  - jeżeli  $m < n$  to:
    - $\det(\mathbf{C}) = 0$
    - $\text{rank}(\mathbf{C}) < n$
  - jeżeli  $m > n$  to:
    - $\det(\mathbf{R}) = 0$
    - $\text{rank}(\mathbf{R}) < m$

# Uogólnienie EVD: rozkład SVD

- Wykorzystując EVD macierzy  $\mathbf{C} = \mathbf{A}^T\mathbf{A}$  i  $\mathbf{R} = \mathbf{A}\mathbf{A}^T$  można zapisać zależności:

$$\mathbf{C} = \mathbf{V}\mathbf{L}_V\mathbf{V}^{-1} \text{ i } \mathbf{R} = \mathbf{U}\mathbf{L}_U\mathbf{U}^{-1}$$

gdzie:

- $\mathbf{V}$  i  $\mathbf{L}_V$  są macierzami (odpowiednio) wektorów i wartości własnych macierzy  $\mathbf{C}$ 
  - $\mathbf{C}$  jest symetryczna, a więc  $\mathbf{V}^{-1}$  istnieje, i dodatkowo:  $\mathbf{V}^{-1} = \mathbf{V}^T$
- $\mathbf{U}$  i  $\mathbf{L}_U$  są macierzami (odpowiednio) wektorów i wartości własnych macierzy  $\mathbf{R}$ 
  - $\mathbf{R}$  jest symetryczna, a więc  $\mathbf{U}^{-1}$  istnieje, i dodatkowo:  $\mathbf{U}^{-1} = \mathbf{U}^T$

czyli

$$\mathbf{C} = \mathbf{V}\mathbf{L}_V\mathbf{V}^T \text{ i } \mathbf{R} = \mathbf{U}\mathbf{L}_U\mathbf{U}^T$$

- Ostatecznie można zapisać:

$$\mathbf{A}^T\mathbf{A} = \mathbf{V}\mathbf{L}_V\mathbf{V}^T \text{ oraz } \mathbf{A}\mathbf{A}^T = \mathbf{U}\mathbf{L}_U\mathbf{U}^T$$

# Uogólnienie EVD: rozkład SVD

- Macierze  $\mathbf{C}$  i  $\mathbf{R}$  charakteryzują się identycznymi zbiorami niezerowych wartości własnych:

$$\text{spec}_{\neq 0}(\mathbf{C}) = \text{spec}_{\neq 0}(\mathbf{R})$$

- Załóżmy, że

–  $m > n$ , wtedy:

- $\text{spec}(\mathbf{C}) \subset \text{spec}(\mathbf{R})$  – zbiór wartości własnych macierzy  $\mathbf{R}$  zawiera wszystkie wartości własne macierzy  $\mathbf{C}$  oraz  $m-n$  dodatkowych wartości zerowych, czyli:

$$\text{spec}(\mathbf{C}) \cup \{0, 0, \dots, 0\} = \text{spec}(\mathbf{R})$$

– oczywiście dla  $m < n$  zachodzi:

- $\text{spec}(\mathbf{R}) \subset \text{spec}(\mathbf{C})$
- $\text{spec}(\mathbf{R}) \cup \{0, 0, \dots, 0\} = \text{spec}(\mathbf{C})$

# Uogólnienie EVD: rozkład SVD

- Zależności pomiędzy zbiorami wartości własnych macierzy  $\mathbf{C}$  i  $\mathbf{R}$  przekładają się na zależności pomiędzy macierzami  $\mathbf{L}_V$  i  $\mathbf{L}_U$
- Dla  $m > n$  mamy:
  - $\mathbf{L}_V = \text{diag}(\text{spec}(\mathbf{C}))$ 
    - przekątna macierzy  $\mathbf{L}_V$  (o rozmiarach  $n \times n$ ) zawiera  $n$  wartości własnych macierzy  $\mathbf{C}$
  - $\mathbf{L}_U = \text{diag}(\text{spec}(\mathbf{C}) \cup \{0, 0, \dots, 0\})$ 
    - przekątna macierzy  $\mathbf{L}_U$  (o rozmiarach  $m \times m$ ) zawiera  $n$  wartości własnych macierzy  $\mathbf{C}$  oraz  $m - n$  wartości zerowych
- Dla  $m < n$  mamy:
  - $\mathbf{L}_U = \text{diag}(\text{spec}(\mathbf{R}))$ 
    - przekątna macierzy  $\mathbf{L}_U$  (o rozmiarach  $m \times m$ ) zawiera  $m$  wartości własnych macierzy  $\mathbf{C}$
  - $\mathbf{L}_V = \text{diag}(\text{spec}(\mathbf{R}) \cup \{0, 0, \dots, 0\})$ 
    - przekątna macierzy  $\mathbf{L}_V$  (o rozmiarach  $n \times n$ ) zawiera  $m$  wartości własnych macierzy  $\mathbf{C}$  oraz  $n - m$  wartości zerowych







# Uogólnienie EVD: rozkład SVD

- Diagonalne elementy macierzy  $\mathbf{T}$  oblicza się jako pierwiastki wartości własnych obliczonych dla macierzy  $\mathbf{A}^T\mathbf{A}$  lub  $\mathbf{A}\mathbf{A}^T$ 
  - diagonalne elementy macierzy  $\mathbf{T}$  są więc zdeterminowane przez macierze  $\mathbf{A}^T\mathbf{A}$  lub  $\mathbf{A}\mathbf{A}^T$  (są pierwiastkami ich wartości własnych)
  - ponieważ jednak  $\mathbf{A}^T\mathbf{A}$  lub  $\mathbf{A}\mathbf{A}^T$  powstają z macierzy  $\mathbf{A}$ , można powiedzieć, że diagonalne elementy macierzy  $\mathbf{T}$  są zdeterminowane przez macierz  $\mathbf{A}$  – nazywamy je wartościami osobliwymi tej macierzy
- Dzięki specjalnej budowie macierzy  $\mathbf{T}$  (o rozmiarach  $m \times n$ ) zachodzą związki:
  - $\mathbf{T}^T\mathbf{T} = \mathbf{L}_V$  (rozmiar  $n \times n$ )
  - $\mathbf{T}\mathbf{T}^T = \mathbf{L}_U$  (rozmiar  $m \times m$ )

# Uogólnienie EVD: rozkład SVD


- Tworzymy iloczyn:  $\mathbf{B} = \mathbf{U}\mathbf{T}\mathbf{V}^T$  z macierzy
  - $\mathbf{U}$ : rozmiar  $m \times m$
  - $\mathbf{T}$ : rozmiar  $m \times n$
  - $\mathbf{V}$ : rozmiar  $n \times n$

/

# Uogólnienie EVD: rozkład SVD

- Tworzymy iloczyn:  $\mathbf{B} = \mathbf{UTV}^T$  z macierzy
  - $\mathbf{U}$ : rozmiar  $m \times m$
  - $\mathbf{T}$ : rozmiar  $m \times n$
  - $\mathbf{V}$ : rozmiar  $n \times n$
- Iloczyn ten można wykorzystać dalej do obliczenia:  $\mathbf{B}^T\mathbf{B}$  oraz  $\mathbf{B}\mathbf{B}^T$ :  
 $\mathbf{B}^T\mathbf{B} = (\mathbf{UTV}^T)^T(\mathbf{UTV}^T) = \mathbf{VT}^T\mathbf{U}^T\mathbf{UTV}^T = \mathbf{VT}^T\mathbf{I}\mathbf{TV}^T = \mathbf{VT}^T\mathbf{TV}^T = \mathbf{V}\mathbf{L}_V\mathbf{V}^T$ 
  - wynika z tego, że  $\mathbf{B}^T\mathbf{B} = \mathbf{A}^T\mathbf{A}$ $\mathbf{B}\mathbf{B}^T = (\mathbf{UTV}^T)(\mathbf{UTV}^T)^T = \mathbf{UTV}^T\mathbf{VT}^T\mathbf{U}^T = \mathbf{U}\mathbf{T}\mathbf{I}\mathbf{T}^T\mathbf{U}^T = \mathbf{U}\mathbf{T}\mathbf{T}^T\mathbf{U}^T = \mathbf{U}\mathbf{L}_U\mathbf{U}^T$ 
  - wynika z tego, że  $\mathbf{B}\mathbf{B}^T = \mathbf{A}\mathbf{A}^T$
- Na tym etapie można podejrzewać, że  $\mathbf{B} = \mathbf{A}$ , czyli że wyrażenie postaci  $\mathbf{UTV}^T$  jest poszukiwanym rozkładem macierzy  $\mathbf{A}$  (bo  $\mathbf{UTV}^T = \mathbf{B} = \mathbf{A}$ )
  - ale:  $a = b \Rightarrow a^2 = b^2$ , jednak  $a^2 = b^2 \not\Rightarrow a = b$
  - a więc równości  $\mathbf{B}^T\mathbf{B} = \mathbf{A}^T\mathbf{A}$  oraz  $\mathbf{B}\mathbf{B}^T = \mathbf{A}\mathbf{A}^T$  nie implikują  $\mathbf{A} = \mathbf{B}$

# „Mechanika” rozkładu SVD



# Uogólnienie EVD: rozkład SVD

- Podsumowanie:
  - iloczyn  $\mathbf{UTV}^T$  wyraża macierz  $\mathbf{B}$  taką, że  $\mathbf{B}^T\mathbf{B} = \mathbf{A}^T\mathbf{A}$  oraz  $\mathbf{BB}^T = \mathbf{AA}^T$
  - i chociaż nie wynika z tego natychmiast fakt, że  $\mathbf{B} = \mathbf{A}$ , to w praktyce możliwe jest takie dobranie macierzy  $\mathbf{U}$  i  $\mathbf{V}$  aby zachodziło  $\mathbf{B} = \mathbf{UTV}^T = \mathbf{A}$
- Wniosek:
  - dowolną macierz  $\mathbf{A}$  można przedstawić w postaci iloczynu macierzy  $\mathbf{UTV}^T$ , które są utworzone z odpowiednio dobranych wektorów i wartości własnych macierzy  $\mathbf{A}^T\mathbf{A}$  oraz  $\mathbf{AA}^T$

# Uogólnienie EVD: rozkład SVD

- Rozkład  $\mathbf{A} = \mathbf{U}\mathbf{T}\mathbf{V}^T$  nazywa się rozkładem macierzy na wartości osobliwe (ang. Singular Value Decomposition, SVD)
- Przedstawiony sposób uzyskania rozkładu SVD macierzy  $\mathbf{A}$  poprzez dokonanie rozkładów EVD macierzy  $\mathbf{A}^T\mathbf{A}$  oraz  $\mathbf{A}\mathbf{A}^T$  nie jest stosowany w praktyce
  - problemy stanowią:
    - konieczność dobierania macierzy  $\mathbf{U}$  i  $\mathbf{V}$
    - stabilność numeryczna



# Przykład rozkładu SVD

- Symetryczna macierz kwadratowa 2x2

$$\mathbf{A} = \begin{bmatrix} 2 & 1 \\ 1 & 2 \end{bmatrix}$$

$$\mathbf{A} = \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & -1 \\ 1 & 1 \end{bmatrix} \mathbf{U} * \begin{bmatrix} 3 & 0 \\ 0 & 1 \end{bmatrix} \mathbf{T} * \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & 1 \\ -1 & 1 \end{bmatrix} \mathbf{V}^T$$

## Przykład rozkładu SVD

$$C = \begin{matrix} \mathbf{A}^T \\ \begin{bmatrix} 2 & 1 \\ 1 & 2 \end{bmatrix} \end{matrix} * \begin{matrix} \mathbf{A} \\ \begin{bmatrix} 2 & 1 \\ 1 & 2 \end{bmatrix} \end{matrix} = \begin{bmatrix} 5 & 4 \\ 4 & 5 \end{bmatrix}$$

$$C = \begin{matrix} \mathbf{K} \\ \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & -1 \\ 1 & 1 \end{bmatrix} \end{matrix} * \begin{matrix} \mathbf{L} \\ \begin{bmatrix} 9 & 0 \\ 0 & 1 \end{bmatrix} \end{matrix} * \begin{matrix} \mathbf{K}^T \\ \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & 1 \\ -1 & 1 \end{bmatrix} \end{matrix}$$

$$R = \begin{matrix} \mathbf{A} \\ \begin{bmatrix} 2 & 1 \\ 1 & 2 \end{bmatrix} \end{matrix} * \begin{matrix} \mathbf{A}^T \\ \begin{bmatrix} 2 & 1 \\ 1 & 2 \end{bmatrix} \end{matrix} = \begin{bmatrix} 5 & 4 \\ 4 & 5 \end{bmatrix}$$

$$R = \begin{matrix} \mathbf{K} \\ \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & -1 \\ 1 & 1 \end{bmatrix} \end{matrix} * \begin{matrix} \mathbf{L} \\ \begin{bmatrix} 9 & 0 \\ 0 & 1 \end{bmatrix} \end{matrix} * \begin{matrix} \mathbf{K}^T \\ \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & 1 \\ -1 & 1 \end{bmatrix} \end{matrix}$$

## Przykład rozkładu SVD

$$\mathbf{T} = \begin{array}{|c|c|} \hline 3 & 0 \\ \hline 0 & 1 \\ \hline \end{array}$$

$$\mathbf{U} = \frac{1}{\sqrt{2}} \begin{array}{|c|c|} \hline 1 & -1 \\ \hline 1 & 1 \\ \hline \end{array}$$

$$\mathbf{V} = \frac{1}{\sqrt{2}} \begin{array}{|c|c|} \hline 1 & -1 \\ \hline 1 & 1 \\ \hline \end{array}$$

$$\frac{1}{\sqrt{2}} \begin{array}{|c|c|} \hline \mathbf{U} & \\ \hline 1 & -1 \\ \hline 1 & 1 \\ \hline \end{array} * \begin{array}{|c|c|} \hline \mathbf{T} & \\ \hline 3 & 0 \\ \hline 0 & 1 \\ \hline \end{array} * \frac{1}{\sqrt{2}} \begin{array}{|c|c|} \hline \mathbf{V}^T & \\ \hline 1 & 1 \\ \hline -1 & 1 \\ \hline \end{array} = \begin{array}{|c|c|} \hline 2 & 1 \\ \hline 1 & 2 \\ \hline \end{array} = \mathbf{A}$$

## Przykład rozkładu SVD

- Niesymetryczna macierz kwadratowa 2x2

$$\mathbf{A} = \begin{bmatrix} 2 & 1 \\ 2 & 1 \end{bmatrix}$$

$$\mathbf{A} = \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix} \mathbf{U} * \begin{bmatrix} \sqrt{10} & 0 \\ 0 & 0 \end{bmatrix} \mathbf{T} * \frac{1}{\sqrt{5}} \begin{bmatrix} 2 & 1 \\ 1 & -2 \end{bmatrix} \mathbf{V}^T$$

## Przykład rozkładu SVD

$$C = \begin{matrix} \mathbf{A}^T \\ \begin{bmatrix} 2 & 2 \\ 1 & 1 \end{bmatrix} \end{matrix} * \begin{matrix} \mathbf{A} \\ \begin{bmatrix} 2 & 1 \\ 2 & 1 \end{bmatrix} \end{matrix} = \begin{bmatrix} 8 & 4 \\ 4 & 2 \end{bmatrix}$$

$$C = \begin{matrix} \mathbf{K} \\ \frac{1}{\sqrt{5}} \begin{bmatrix} 2 & 1 \\ 1 & -2 \end{bmatrix} \end{matrix} * \begin{matrix} \mathbf{L} \\ \begin{bmatrix} 10 & 0 \\ 0 & 0 \end{bmatrix} \end{matrix} * \begin{matrix} \mathbf{K}^T \\ \frac{1}{\sqrt{5}} \begin{bmatrix} 2 & 1 \\ 1 & -2 \end{bmatrix} \end{matrix}$$

$$R = \begin{matrix} \mathbf{A} \\ \begin{bmatrix} 2 & 1 \\ 2 & 1 \end{bmatrix} \end{matrix} * \begin{matrix} \mathbf{A}^T \\ \begin{bmatrix} 2 & 2 \\ 1 & 1 \end{bmatrix} \end{matrix} = \begin{bmatrix} 5 & 5 \\ 5 & 5 \end{bmatrix}$$

$$R = \begin{matrix} \mathbf{K} \\ \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix} \end{matrix} * \begin{matrix} \mathbf{L} \\ \begin{bmatrix} 10 & 0 \\ 0 & 0 \end{bmatrix} \end{matrix} * \begin{matrix} \mathbf{K}^T \\ \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix} \end{matrix}$$

# Przykład rozkładu SVD

$$\mathbf{T} = \begin{bmatrix} \sqrt{10} & 0 \\ 0 & 0 \end{bmatrix}$$

$$\mathbf{U} = \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix}$$

$$\mathbf{V} = \frac{1}{\sqrt{5}} \begin{bmatrix} 2 & 1 \\ 1 & -2 \end{bmatrix}$$

$$\frac{1}{\sqrt{2}} \begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix} * \begin{bmatrix} \sqrt{10} & 0 \\ 0 & 0 \end{bmatrix} * \frac{1}{\sqrt{5}} \begin{bmatrix} 2 & 1 \\ 1 & -2 \end{bmatrix} = \begin{bmatrix} 2 & 1 \\ 2 & 1 \end{bmatrix} = \mathbf{A}$$

## Przykład rozkładu SVD

- Niesymetryczna macierz prostokątna 1x2

$$A = \begin{bmatrix} 1 & 2 \end{bmatrix}$$

$$A = \begin{matrix} \mathbf{U} \\ \begin{bmatrix} 1 \end{bmatrix} \end{matrix} * \begin{matrix} \mathbf{T} \\ \begin{bmatrix} \sqrt{5} & 0 \end{bmatrix} \end{matrix} * \frac{1}{\sqrt{5}} \begin{matrix} \mathbf{V}^T \\ \begin{bmatrix} 1 & 2 \\ 2 & -1 \end{bmatrix} \end{matrix}$$

# Przykład rozkładu SVD

$$\mathbf{C} = \begin{matrix} \mathbf{A}^T \\ \boxed{1} \\ \boxed{2} \end{matrix} * \begin{matrix} \mathbf{A} \\ \boxed{1} \quad \boxed{2} \end{matrix} = \begin{matrix} \boxed{1} & \boxed{2} \\ \boxed{2} & \boxed{4} \end{matrix}$$

$$\mathbf{C} = \frac{1}{\sqrt{5}} \begin{matrix} \mathbf{K} \\ \boxed{1} \quad \boxed{2} \\ \boxed{2} \quad \boxed{-1} \end{matrix} * \begin{matrix} \mathbf{L} \\ \boxed{5} \quad \boxed{0} \\ \boxed{0} \quad \boxed{0} \end{matrix} * \frac{1}{\sqrt{5}} \begin{matrix} \mathbf{K}^T \\ \boxed{1} \quad \boxed{2} \\ \boxed{2} \quad \boxed{-1} \end{matrix}$$

$$\mathbf{R} = \begin{matrix} \mathbf{A} \\ \boxed{1} \quad \boxed{2} \end{matrix} * \begin{matrix} \mathbf{A}^T \\ \boxed{1} \\ \boxed{2} \end{matrix} = \boxed{5}$$

$$\mathbf{R} = \begin{matrix} \mathbf{K} \\ \boxed{1} \end{matrix} * \begin{matrix} \mathbf{L} \\ \boxed{5} \end{matrix} * \begin{matrix} \mathbf{K}^T \\ \boxed{1} \end{matrix}$$



## Przykład rozkładu SVD

$$\mathbf{T} = \begin{bmatrix} \sqrt{5} & 0 \end{bmatrix}$$

$$\mathbf{U} = \begin{bmatrix} 1 \end{bmatrix}$$

$$\mathbf{V} = \frac{1}{\sqrt{5}} \begin{bmatrix} 1 & 2 \\ 2 & -1 \end{bmatrix}$$

$$\begin{array}{c} \mathbf{U} \\ \begin{bmatrix} 1 \end{bmatrix} \end{array} * \begin{array}{c} \mathbf{T} \\ \begin{bmatrix} \sqrt{5} & 0 \end{bmatrix} \end{array} * \begin{array}{c} \mathbf{V}^T \\ \frac{1}{\sqrt{5}} \begin{bmatrix} 1 & 2 \\ 2 & -1 \end{bmatrix} \end{array} = \begin{bmatrix} 1 & 2 \end{bmatrix} = \mathbf{A}$$

# Uogólnienie EVD: rozkład SVD

- Szczególnym przypadkiem rozkładu SVD jest rozkład EVD
  - dla macierzy symetrycznej zachodzi:  $\mathbf{A}^T = \mathbf{A}$ , z czego wynika, że:  
 $\mathbf{C} = \mathbf{A}^T \mathbf{A} = \mathbf{A} \mathbf{A} = \mathbf{A}^2$   
 $\mathbf{R} = \mathbf{A} \mathbf{A}^T = \mathbf{A} \mathbf{A} = \mathbf{A}^2$ 
    - czyli  $\mathbf{C} = \mathbf{R}$
  - obliczając  $\mathbf{A}^2$  z wykorzystaniem rozkładu  $\mathbf{A} = \mathbf{K} \mathbf{L} \mathbf{K}^T$  mamy:  
 $\mathbf{A}^2 = \mathbf{K} \mathbf{L} \mathbf{K}^T \mathbf{K} \mathbf{L} \mathbf{K}^T = \mathbf{K} \mathbf{L} \mathbf{L} \mathbf{K}^T = \mathbf{K} \mathbf{L}^2 \mathbf{K}^T$
  - wniosek:
    - wartościami własnymi macierzy  $\mathbf{A}^2$  są kwadraty wartości własnych macierzy  $\mathbf{A}$ , a więc wartości osobliwymi symetrycznej macierzy  $\mathbf{A}$  są wartości własne (ze znakiem plus) macierzy  $\mathbf{A}$
    - wektorami osobliwymi symetrycznej macierzy  $\mathbf{A}$  są jej wektory własne

# Uogólnienie EVD: rozkład SVD

- Podsumowanie:
  - po rozłożeniu symetrycznej macierzy  $\mathbf{A}$  na  $\mathbf{K}\mathbf{L}\mathbf{K}^T$  (rozkład EVD) oraz  $\mathbf{U}\mathbf{T}\mathbf{V}^T$  (rozkład SVD) mamy:  
 $\mathbf{A} = \mathbf{K}\mathbf{L}\mathbf{K}^T = \mathbf{U}\mathbf{T}\mathbf{V}^T$ 
    - jednocześnie zachodzi:  
 $\mathbf{U} = \mathbf{K}$  oraz  $\mathbf{V}^T = \mathbf{K}^T$ 
      - z czego wynika, że  $\mathbf{U} = \mathbf{V}$
  - ale uwaga:
    - $\mathbf{K}$  (a tym samym  $\mathbf{U}$  i  $\mathbf{V}$ ) są określone z dokładnością do znaku kolumn (czyli znaku zawartych w nich wektorów własnych)

# Uogólnienie EVD: rozkład SVD

- Problem ze znakiem wektorów własnych
  - wektory własne macierzy są określone z dokładnością do znaku, tzn. jeżeli zachodzi:  $\mathbf{A} = \mathbf{K}\mathbf{L}\mathbf{K}^T$ , gdzie  $\mathbf{K}$  jest macierzą ortogonalną (czyli  $\mathbf{K}^T\mathbf{K} = \mathbf{I}$ ) a dodatkowo:
    - macierz  $\mathbf{Q}$  różni się od macierzy  $\mathbf{K}$  znakiem dowolnej liczby kolumn ( $\mathbf{Q} = \mathbf{K} \cdot \text{diag}(\pm 1, \pm 1, \dots, \pm 1)$  – prawostronne mnożenie przez macierz diagonalną zawierającą  $-1$  zmienia znak odpowiedniej kolumny)
  - to zachodzi także  $\mathbf{A} = \mathbf{Q}\mathbf{L}\mathbf{Q}^T$  oraz  $\mathbf{Q}^T\mathbf{Q} = \mathbf{I}$
- Niejednoznaczność znaku kolumn macierzy  $\mathbf{K}$  nie ma wpływu na  $\mathbf{K}\mathbf{L}\mathbf{K}^T$  (rozkład EVD macierzy  $\mathbf{C} = \mathbf{A}^T\mathbf{A}$ ), ma jednak wpływ na  $\mathbf{U}\mathbf{T}\mathbf{V}^T$ , gdzie za  $\mathbf{V}$  przyjmuje się  $\mathbf{K}$  (rozkład SVD macierzy  $\mathbf{A}$ ), czyli:
  - jeżeli  $\mathbf{Q} = \mathbf{K} \cdot \text{diag}(\pm 1, \pm 1, \dots, \pm 1)$  ( $\mathbf{Q}$  różni się od  $\mathbf{K}$  znakami kolumn), to:  $\mathbf{K}\mathbf{L}\mathbf{K}^T = \mathbf{Q}\mathbf{L}\mathbf{Q}^T$ , ale  $\mathbf{U}\mathbf{T}\mathbf{K}^T \neq \mathbf{U}\mathbf{T}\mathbf{Q}^T$  (macierze  $\mathbf{K}$  i  $\mathbf{Q}$  podstawiono pod  $\mathbf{V}$  w wyrażeniu  $\mathbf{U}\mathbf{T}\mathbf{V}^T$ )
- Sytuacja wygląda analogicznie, gdy za  $\mathbf{U}$  przyjmuje się macierz  $\mathbf{K}$  wynikającą z rozkładu EVD macierzy  $\mathbf{R} = \mathbf{A}\mathbf{A}^T$ 
  - jeżeli  $\mathbf{Q} = \mathbf{K} \cdot \text{diag}(\pm 1, \pm 1, \dots, \pm 1)$  to  $\mathbf{K}\mathbf{L}\mathbf{K}^T = \mathbf{Q}\mathbf{L}\mathbf{Q}^T$ , ale  $\mathbf{K}\mathbf{T}\mathbf{V}^T \neq \mathbf{Q}\mathbf{T}\mathbf{V}^T$

# Przykład rozkładu SVD

- Przykład: macierz  $\mathbf{A}$  oraz odpowiadająca jej  $\mathbf{C} = \mathbf{A}^T \mathbf{A}$

$$\mathbf{A} = \begin{bmatrix} 2 & 1 \\ 2 & 1 \end{bmatrix} \quad \mathbf{C} = \begin{matrix} \mathbf{A}^T & & \mathbf{A} \\ \begin{bmatrix} 2 & 2 \\ 1 & 1 \end{bmatrix} & * & \begin{bmatrix} 2 & 1 \\ 2 & 1 \end{bmatrix} \\ \end{matrix} = \begin{bmatrix} 8 & 4 \\ 4 & 2 \end{bmatrix}$$

- rozkład macierzy  $\mathbf{C}$  na  $\mathbf{K} \mathbf{L} \mathbf{K}^T$  jest niejednoznaczny:
  - zmiana znaku dowolnej kolumny w macierzy  $\mathbf{K}$  (a tym samym: wiersza macierzy  $\mathbf{K}^T$ ) nie zmienia wartości wyrażenia  $\mathbf{K} \mathbf{L} \mathbf{K}^T$

$$\begin{matrix} \mathbf{K} & & \mathbf{L} & & \mathbf{K}^T \\ \frac{1}{\sqrt{5}} \begin{bmatrix} 2 & 1 \\ 1 & -2 \end{bmatrix} & * & \begin{bmatrix} 10 & 0 \\ 0 & 0 \end{bmatrix} & * & \frac{1}{\sqrt{5}} \begin{bmatrix} 2 & 1 \\ 1 & -2 \end{bmatrix} \\ \end{matrix} = \begin{bmatrix} 8 & 4 \\ 4 & 2 \end{bmatrix} = \mathbf{C}$$

$$\begin{matrix} \mathbf{Q} & & \mathbf{L} & & \mathbf{Q}^T \\ \frac{1}{\sqrt{5}} \begin{bmatrix} -2 & 1 \\ -1 & -2 \end{bmatrix} & * & \begin{bmatrix} 10 & 0 \\ 0 & 0 \end{bmatrix} & * & \frac{1}{\sqrt{5}} \begin{bmatrix} -2 & -1 \\ 1 & -2 \end{bmatrix} \\ \end{matrix} = \begin{bmatrix} 8 & 4 \\ 4 & 2 \end{bmatrix} = \mathbf{C}$$

– itd.

## Przykład rozkładu SVD

- Przykład: c.d.
  - niejednoznaczność znaku kolumn macierzy  $\mathbf{K}$  nie ma wpływu na wynik wyrażenia  $\mathbf{K}\mathbf{L}\mathbf{K}^T$  (rozkład EVD macierzy  $\mathbf{C} = \mathbf{A}^T\mathbf{A}$ ), ma jednak wpływ na wynik wyrażenia  $\mathbf{U}\mathbf{T}\mathbf{V}^T$ , gdzie za  $\mathbf{V}$  przyjmuje się  $\mathbf{K}$  (rozkład SVD macierzy  $\mathbf{A}$ )

$$\begin{array}{c}
 \mathbf{U} \qquad \mathbf{T} \qquad \mathbf{V}^T = \mathbf{K}^T \\
 \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix} * \begin{bmatrix} \sqrt{10} & 0 \\ 0 & 0 \end{bmatrix} * \frac{1}{\sqrt{5}} \begin{bmatrix} 2 & 1 \\ 1 & -2 \end{bmatrix} = \begin{bmatrix} 2 & 1 \\ 2 & 1 \end{bmatrix} = \mathbf{A} \\
 \\
 \mathbf{U} \qquad \mathbf{T} \qquad \mathbf{V}^T = \mathbf{Q}^T \\
 \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix} * \begin{bmatrix} \sqrt{10} & 0 \\ 0 & 0 \end{bmatrix} * \frac{1}{\sqrt{5}} \begin{bmatrix} -2 & -1 \\ 1 & -2 \end{bmatrix} = \begin{bmatrix} -2 & 1 \\ -2 & 1 \end{bmatrix} \neq \mathbf{A}
 \end{array}$$

# Uogólnienie EVD: rozkład SVD

- Problem niejednoznaczności znaku kolumn można rozwiązać wykorzystując dwie postaci zależności pomiędzy wektorami własnymi macierzy  $\mathbf{A}^T\mathbf{A}$  oraz  $\mathbf{A}\mathbf{A}^T$

$$\mathbf{A} = \mathbf{U}\mathbf{T}\mathbf{V}^T \text{ // (prawostr.)} * \mathbf{V}$$

$$\mathbf{A}\mathbf{V} = \mathbf{U}\mathbf{T}\mathbf{V}^T\mathbf{V}$$

$$\mathbf{A}\mathbf{V} = \mathbf{U}\mathbf{T}\mathbf{I}$$

$$\mathbf{A}\mathbf{V} = \mathbf{U}\mathbf{T}$$

$$\mathbf{A}\mathbf{V} = \mathbf{U}\mathbf{T} \text{ // (prawostr.)} * (\mathbf{T}_{\square})^{-1}$$

$$\mathbf{A}\mathbf{V}(\mathbf{T}_{\square})^{-1} = \mathbf{U}\mathbf{T}(\mathbf{T}_{\square})^{-1}$$

$$\mathbf{A}\mathbf{V}(\mathbf{T}_{\square})^{-1} = \mathbf{U}$$

$$\mathbf{A} = \mathbf{U}\mathbf{T}\mathbf{V}^T \text{ // (lewostr.)} * \mathbf{U}^T$$

$$\mathbf{U}^T\mathbf{A} = \mathbf{U}^T\mathbf{U}\mathbf{T}\mathbf{V}^T$$

$$\mathbf{U}^T\mathbf{A} = \mathbf{I}\mathbf{T}\mathbf{V}^T$$

$$\mathbf{U}^T\mathbf{A} = \mathbf{T}\mathbf{V}^T$$

$$\mathbf{U}^T\mathbf{A} = \mathbf{T}\mathbf{V}^T \text{ // (lewostr.)} * (\mathbf{T}_{\square})^{-1}$$

$$(\mathbf{T}_{\square})^{-1}\mathbf{U}^T\mathbf{A} = (\mathbf{T}_{\square})^{-1}\mathbf{T}\mathbf{V}^T$$

$$(\mathbf{T}_{\square})^{-1}\mathbf{U}^T\mathbf{A} = \mathbf{V}^T$$

# Uogólnienie EVD: rozkład SVD

- Uwaga: zapis  $(\mathbf{T}_{\square})^{-1}$  oznacza złożenie dwóch operacji:
  - $\mathbf{X}_{\square}$  oznacza pewną nieformalną operację służącą do przekształcenia prostokątnej macierzy  $\mathbf{X}$  w macierz kwadratową, która polega na:
    - usunięciu ostatnich wierszy (jeżeli liczba ta przekracza liczbę kolumn)
    - usunięciu ostatnich kolumn (jeżeli liczba ta przekracza liczbę wierszy)
  - z kolei zapis  $\mathbf{X}^{\sim 1}$  oznacza pseudo-odwrotność macierzy  $\mathbf{X}$ 
    - jeżeli  $\mathbf{X} = \text{diag}([x_{11}, x_{22}, \dots, x_{nn}])$  to  $\mathbf{X}^{\sim 1} = \text{diag}([y_{11}, y_{22}, \dots, y_{nn}])$ , przy czym
      - $y_{ii} = 1/x_{ii}$  dla  $x_{ii} \neq 0$
      - $y_{ii} = 0$  dla  $x_{ii} = 0$



## Uogólnienie EVD: rozkład SVD

- Wniosek:  $\mathbf{U}$  i  $\mathbf{V}$  muszą być tak dobrane, aby zachodziło:  $\mathbf{AV} = \mathbf{UT}$  oraz  $\mathbf{U}^T\mathbf{A} = \mathbf{TV}^T$ , można więc:
  - ustalić  $\mathbf{U}$  jako macierz wektorów własnych dla  $\mathbf{AA}^T$  oraz  $\mathbf{V}$  jako macierz wektorów własnych dla  $\mathbf{A}^T\mathbf{A}$ , a następnie zmieniać znaki kolumn macierzy  $\mathbf{U}$  i  $\mathbf{V}$  aż do osiągnięcia  $\mathbf{UTV}^T = \mathbf{A}$

# Uogólnienie EVD: rozkład SVD

- Lepszy (choć bardziej złożony) pomysł
  - gdy  $\mathbf{A}$  ma rozmiary  $m \times n$ , przy czym  $m > n$ 
    - najpierw utworzyć macierz  $\mathbf{V}$  a potem wykorzystać ją do utworzenia macierzy  $\mathbf{U}$  wykonując operację:  $\mathbf{AV}(\mathbf{T}_{\neq 0})^{-1}$ 
      - jeżeli wszystkie diagonalne elementy macierzy  $\mathbf{T}$  są różne od 0, to operacja ta generuje  $n$  początkowych kolumn macierzy  $\mathbf{U}$
      - jeżeli  $r < n$  diagonalnych elementów macierzy  $\mathbf{T}$  wynosi 0, to operacja ta generuje  $r$  początkowych kolumn macierzy  $\mathbf{U}$  i  $n-r$  wektorów zerowych (kolumny zerowe nie mogą być użyte jako kolumny macierzy  $\mathbf{U}$ )
    - macierz  $\mathbf{U}$  należy utworzyć wykonując procedurę ortogonalizacji Grama-Schmidt'a na macierzy wektorów  $[\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_p, \mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_r]$ , gdzie:
      - $\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_p$  są niezerowymi kolumnami macierzy  $\mathbf{AV}(\mathbf{T}_{\neq 0})^{-1}$ 
        - » uwaga:  $\{\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_p\}$  jest zbiorem wektorów niezależnych
      - $\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_r$  jest zbiorem dowolnych wektorów takich, że  $\{\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_p, \mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_r\}$  jest zbiorem wektorów niezależnych
        - » wektory  $\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_r$  są więc niezależne od siebie oraz od wektorów  $\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_p$
      - dowolnymi wektorami, przy czym  $r = m-p$
  - gdy  $\mathbf{A}$  ma rozmiary  $m \times n$ , przy czym  $m < n$ 
    - tworzy się najpierw macierz  $\mathbf{U}$ , a na jej podstawie macierz  $\mathbf{V}$

# Przykład rozkładu SVD

- Symetryczna macierz kwadratowa 2x2

$$\begin{array}{c}
 \mathbf{A} = \begin{array}{|c|c|} \hline 2 & 1 \\ \hline 2 & 1 \\ \hline \end{array} \quad \mathbf{C} = \begin{array}{|c|c|} \hline 8 & 4 \\ \hline 4 & 2 \\ \hline \end{array} \quad \mathbf{R} = \begin{array}{|c|c|} \hline 5 & 5 \\ \hline 5 & 5 \\ \hline \end{array} \\
 \\
 \mathbf{C} = \frac{1}{\sqrt{5}} \begin{array}{|c|c|} \hline 2 & 1 \\ \hline 1 & -2 \\ \hline \end{array} * \begin{array}{|c|c|} \hline 10 & 0 \\ \hline 0 & 0 \\ \hline \end{array} * \frac{1}{\sqrt{5}} \begin{array}{|c|c|} \hline 2 & 1 \\ \hline 1 & -2 \\ \hline \end{array} \\
 \mathbf{K} \quad \mathbf{L} \quad \mathbf{K}^T \\
 \\
 \mathbf{R} = \frac{1}{\sqrt{2}} \begin{array}{|c|c|} \hline 1 & 1 \\ \hline 1 & -1 \\ \hline \end{array} * \begin{array}{|c|c|} \hline 10 & 0 \\ \hline 0 & 0 \\ \hline \end{array} * \frac{1}{\sqrt{2}} \begin{array}{|c|c|} \hline 1 & 1 \\ \hline 1 & -1 \\ \hline \end{array} \\
 \mathbf{U} \quad \mathbf{T} \quad \mathbf{V}^T \\
 \\
 \mathbf{A} = \frac{1}{\sqrt{2}} \begin{array}{|c|c|} \hline 1 & 1 \\ \hline 1 & -1 \\ \hline \end{array} * \begin{array}{|c|c|} \hline \sqrt{10} & 0 \\ \hline 0 & 0 \\ \hline \end{array} * \frac{1}{\sqrt{5}} \begin{array}{|c|c|} \hline 2 & 1 \\ \hline 1 & -2 \\ \hline \end{array}
 \end{array}$$

## Przykład rozkładu SVD

- Symetryczna macierz kwadratowa 2x2 c.d.
  - założmy, że obliczono najpierw  $\mathbf{C}=\mathbf{A}^T\mathbf{A}$  oraz jej rozkład  $\mathbf{K}\mathbf{L}\mathbf{K}^T$

$$\mathbf{C} = \frac{1}{\sqrt{5}} \begin{array}{|c|c|} \hline \mathbf{K} & \\ \hline 2 & 1 \\ \hline 1 & -2 \\ \hline \end{array} * \begin{array}{|c|c|} \hline \mathbf{L} & \\ \hline 10 & 0 \\ \hline 0 & 0 \\ \hline \end{array} * \frac{1}{\sqrt{5}} \begin{array}{|c|c|} \hline \mathbf{K}^T & \\ \hline 2 & 1 \\ \hline 1 & -2 \\ \hline \end{array}$$

- obliczona w ten sposób macierz  $\mathbf{K}$  będzie pełniła rolę macierzy  $\mathbf{V}$
- natomiast obliczona w ten sposób macierz  $\mathbf{L}$  posłuży do utworzenia macierzy  $\mathbf{T}$  (wynikowa macierz  $\mathbf{T}$  byłaby identyczna, gdyby do jej utworzenia zastosować macierz  $\mathbf{L}$  powstałą podczas rozkładu macierzy  $\mathbf{R} = \mathbf{A}\mathbf{A}^T$ )

## Przykład rozkładu SVD

- Symetryczna macierz kwadratowa 2x2 c.d.
  - obliczamy  $\mathbf{AV}$

$$\mathbf{AV} = \begin{matrix} & \mathbf{A} & & & \mathbf{V} & & \\ & \begin{matrix} 2 & 1 \\ 2 & 1 \end{matrix} & * & \frac{1}{\sqrt{5}} & \begin{matrix} 2 & 1 \\ 1 & -2 \end{matrix} & = & \frac{1}{\sqrt{5}} & \begin{matrix} 5 & 0 \\ 5 & 0 \end{matrix} \end{matrix}$$

- tworzymy macierz  $\mathbf{T}$

$$\mathbf{T} = \begin{matrix} \begin{matrix} \sqrt{10} & 0 \\ 0 & 0 \end{matrix} \end{matrix}$$

- i macierz  $\mathbf{T}_{\square} = \mathbf{T}$  (ponieważ  $\mathbf{T}$  jest macierzą kwadratową)

$$\mathbf{T}_{\square} = \begin{matrix} \begin{matrix} \sqrt{10} & 0 \\ 0 & 0 \end{matrix} \end{matrix}$$

## Przykład rozkładu SVD

- Symetryczna macierz kwadratowa 2x2 c.d.
  - obliczamy  $(\mathbf{T}_{\neq 0})^{-1}$

$$\mathbf{T} = \frac{1}{\sqrt{10}} \begin{array}{|c|c|} \hline 1 & 0 \\ \hline 0 & 0 \\ \hline \end{array}$$

- obliczamy  $\mathbf{AV}(\mathbf{T}_{\neq 0})^{-1}$

$$\mathbf{AV}(\mathbf{T}_{\neq 0})^{-1} = \frac{1}{\sqrt{2}} \begin{array}{|c|c|} \hline 1 & 0 \\ \hline 1 & 0 \\ \hline \end{array}$$

- macierz  $\mathbf{AV}(\mathbf{T}_{\neq 0})^{-1}$  zawiera jedną niezerową kolumnę
  - jest to pierwsza kolumna tworzonej macierzy  $\mathbf{U}$
  - pozostałe kolumny tworzonej macierzy  $\mathbf{U}$  mogą być dowolnymi wektorami, które „uzupełnią”  $\mathbf{U}$  do macierzy ortogonalnej (tzn. po dodaniu tych kolumn  $\mathbf{U}$  musi spełniać  $\mathbf{U}^T \mathbf{U} = \mathbf{I}$ )

## Przykład rozkładu SVD

- Symetryczna macierz kwadratowa 2x2 c.d.
  - unormowanymi wektorami ortogonalnymi do wektora:

$$\mathbf{u} = \frac{1}{\sqrt{2}} \begin{bmatrix} 1 \\ 1 \end{bmatrix}$$

- są wektory:

$$\mathbf{v} = \frac{1}{\sqrt{2}} \begin{bmatrix} 1 \\ -1 \end{bmatrix} \quad \text{oraz} \quad \mathbf{w} = -\mathbf{v} = \frac{1}{\sqrt{2}} \begin{bmatrix} -1 \\ 1 \end{bmatrix}$$

- ostatecznie macierz  $\mathbf{U}$  może przyjąć jedną z postaci:

$$\mathbf{U}_1 = \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix} \quad \text{lub} \quad \mathbf{U}_2 = \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & -1 \\ 1 & 1 \end{bmatrix}$$

# Przykład rozkładu SVD

- Symetryczna macierz kwadratowa 2x2 c.d.
  - dla obu postaci (tzn.  $\mathbf{U}_1$ ,  $\mathbf{U}_2$ ) tak ustalonej macierzy  $\mathbf{U}$  zachodzi:

$$\frac{1}{\sqrt{2}} \begin{matrix} \mathbf{U}_1 \\ \begin{array}{|c|c|} \hline 1 & 1 \\ \hline 1 & -1 \\ \hline \end{array} \end{matrix} * \begin{matrix} \mathbf{T} \\ \begin{array}{|c|c|} \hline \sqrt{10} & 0 \\ \hline 0 & 0 \\ \hline \end{array} \end{matrix} * \frac{1}{\sqrt{5}} \begin{matrix} \mathbf{V}^T \\ \begin{array}{|c|c|} \hline 2 & 1 \\ \hline 1 & -2 \\ \hline \end{array} \end{matrix} = \begin{matrix} \mathbf{A} \\ \begin{array}{|c|c|} \hline 2 & 1 \\ \hline 2 & 1 \\ \hline \end{array} \end{matrix} = \mathbf{A}$$

$$\frac{1}{\sqrt{2}} \begin{matrix} \mathbf{U}_2 \\ \begin{array}{|c|c|} \hline 1 & -1 \\ \hline 1 & 1 \\ \hline \end{array} \end{matrix} * \begin{matrix} \mathbf{T} \\ \begin{array}{|c|c|} \hline \sqrt{10} & 0 \\ \hline 0 & 0 \\ \hline \end{array} \end{matrix} * \frac{1}{\sqrt{5}} \begin{matrix} \mathbf{V}^T \\ \begin{array}{|c|c|} \hline 2 & 1 \\ \hline 1 & -2 \\ \hline \end{array} \end{matrix} = \begin{matrix} \mathbf{A} \\ \begin{array}{|c|c|} \hline 2 & 1 \\ \hline 2 & 1 \\ \hline \end{array} \end{matrix} = \mathbf{A}$$

- uwaga: że względu na zerowy element przekątnej macierzy  $\mathbf{T}$  druga kolumna  $\mathbf{U}$  jest określona na tyle niejednoznacznie, że może przyjąć dowolne (niekoniecznie unormowane) wartości

$$\frac{1}{\sqrt{2}} \begin{matrix} \mathbf{U}_2 \\ \begin{array}{|c|c|} \hline 1 & 250 \\ \hline 1 & -97 \\ \hline \end{array} \end{matrix} * \begin{matrix} \mathbf{T} \\ \begin{array}{|c|c|} \hline \sqrt{10} & 0 \\ \hline 0 & 0 \\ \hline \end{array} \end{matrix} * \frac{1}{\sqrt{5}} \begin{matrix} \mathbf{V}^T \\ \begin{array}{|c|c|} \hline 2 & 1 \\ \hline 1 & -2 \\ \hline \end{array} \end{matrix} = \begin{matrix} \mathbf{A} \\ \begin{array}{|c|c|} \hline 2 & 1 \\ \hline 2 & 1 \\ \hline \end{array} \end{matrix} = \mathbf{A}$$



## Przykład rozkładu SVD

- Symetryczna macierz kwadratowa 2x2 c.d.
  - niejednoznaczność drugiej kolumny macierzy  $\mathbf{U}$ 
    - wynika ona z faktu, że macierz  $\mathbf{U}$  mnożona jest przez macierz  $\mathbf{T}$ , w której drugi element głównej przekątnej wynosi zero
    - element ten „zeruje” więc drugą warstwę iloczynu (która powstaje z drugiej kolumny macierzy  $\mathbf{U}$  i drugiego wiersza macierzy  $\mathbf{V}^T$ )
    - oznacza to jednocześnie, że (z tego samego powodu) drugi wiersz macierzy  $\mathbf{V}^T$  jest także określony niejednoznacznie
    - wniosek: druga kolumna macierzy  $\mathbf{U}$  i drugi wiersz macierzy  $\mathbf{V}^T$  nie są ze sobą związane i mogą przyjmować zupełnie dowolne wartości
    - w praktyce oczywiście dobiera je jednak się tak, żeby:
      - pierwsza kolumna macierzy  $\mathbf{U}$  była unormowana i ortogonalna do pozostałych kolumn tej macierzy ( $\mathbf{U}^T\mathbf{U} = \mathbf{I}$ )
      - pierwszy wiersz macierzy  $\mathbf{V}^T$  był unormowany i ortogonalny do pozostałych wierszy tej macierzy ( $\mathbf{V}^T\mathbf{V} = \mathbf{I}$ )

# Przykład rozkładu SVD

- Symetryczna macierz kwadratowa 2x2 c.d.
  - niejednoznaczność powyższa nie dotyczy całej macierzy  $\mathbf{U}$ , a jedynie drugiej kolumny
  - w odróżnieniu od niej pierwsza kolumny macierzy  $\mathbf{U}$  jest wyznaczona jednoznacznie
    - pierwsza kolumna macierzy  $\mathbf{U}$  jest związana z pierwszym wierszem macierzy  $\mathbf{V}^T$  zależnością  $\mathbf{AV} = \mathbf{UT}$ , co oznacza, że zarówno pierwsza kolumna macierzy  $\mathbf{U}$  jak i pierwszy wiersz macierzy  $\mathbf{V}^T$  muszą być tak dobrane, aby zachodziło jednocześnie:
      - pierwsza kolumna macierzy  $\mathbf{U}$  musi być unormowana i ortogonalna do pozostałych kolumn tej macierzy ( $\mathbf{U}^T\mathbf{U} = \mathbf{I}$ )
      - pierwszy wiersz macierzy  $\mathbf{V}^T$  musi być unormowany i ortogonalny do pozostałych wierszy tej macierzy ( $\mathbf{V}^T\mathbf{V} = \mathbf{I}$ )
      - pomiędzy znakami pierwszej kolumny macierzy  $\mathbf{U}$  i pierwszego wiersza macierzy  $\mathbf{V}^T$  musi zachodzić zgodność ( $\mathbf{AV} = \mathbf{UT}$ )

...

# Stratna kompresja obrazu

- Dzięki rozkładowi  $\mathbf{A} = \mathbf{UTV}^T$  możliwe jest tworzenie różnych przybliżeń dowolnej macierzy  $\mathbf{A}$  (elementami skalującymi w tym iloczynie są tzw. wartości osobliwe macierzy  $\mathbf{A}$ , umieszczone na przekątnej macierzy  $\mathbf{T}$ )
- Niech rozmiarem macierzy  $\mathbf{A}$  będzie  $m \times n$ , wtedy odpowiednie rozmiary czynników iloczynu przedstawiają się następująco:
  - $\mathbf{U}$ :  $m \times m$
  - $\mathbf{T}$ :  $m \times n$
  - $\mathbf{V}$ :  $n \times n$
- Do zapamiętania
  - macierzy  $\mathbf{A}$  potrzeba  $m \cdot n$  wartości
  - macierzy  $\mathbf{U}$ ,  $\mathbf{T}$  i  $\mathbf{V}^T$  potrzeba  $m \cdot m + \min(m, n) + n \cdot n$  wartości
  - przybliżenia macierzy  $\mathbf{A}$  za pomocą  $p$  składowych ( $p < \min(m, n)$ ), czyli:
    - $p$  kolumn macierzy  $\mathbf{U}$ ,
    - $p$  wartości macierzy  $\mathbf{T}$
    - $p$  wierszy macierzy  $\mathbf{V}$potrzeba  $p \cdot (m + n + 1)$  wartości

# Macierz $\mathbf{UTV}^T$ jako obraz

- Ponieważ obraz (dwuwymiarowy) można traktować jako pewną macierz, obrazy mogą być poddawane operacjom macierzowym
- Takie traktowanie danych obrazowych ma wyraźną przewagę nad postępowaniem polegającym na klasycznym stosowaniu PCA
  - pomija fazę tworzenia cech opisujących obraz (np. zmiennych RGB)
  - w naturalny sposób traktuje obraz jako strukturę dwuwymiarową
    - uwaga: obrazu nie trzeba traktować jako struktury dwuwymiarowej, szczególnie wtedy, gdy dysponuje się dobrymi cechami wyższych rzędów, tak jest jednak bardzo rzadko, dlatego traktowanie obrazu jako struktury dwuwymiarowej jest dobrym kompromisem
- Bardzo szczególne obrazy (kwadratowe i symetryczne), przedstawione w postaci macierzy  $\mathbf{A}$ , mogą być przetwarzane dzięki rozkładowi  $\mathbf{A} = \mathbf{K}\mathbf{L}\mathbf{K}^T$  (metoda EVD)
- W ogólności jednak do przetwarzania obrazów (niekoniecznie kwadratowych i symetrycznych), przedstawionych w postaci macierzy  $\mathbf{B}$ , stosuje się (ogólniejszy) rozkład  $\mathbf{B} = \mathbf{UTV}^T$  (metoda SVD)


## Przykłady rozkładu macierzy-obrazu

- Obraz oryginalny #1 -- definicja:  
 $\mathbf{A1} = [a_{ij}]$ ,  $i = 1..100$ ,  $j = 1..100$ , gdzie:  
 $a_{ij} = \sin(\pi/50 \cdot i) \sin(\pi/50 \cdot j)$
- Obraz oryginalny #2 -- definicja:  
 $\mathbf{A2} = \mathbf{A1} + \text{zakłócenia}$
- Obraz oryginalny #2 -- definicja:  
 $\mathbf{A3} = \mathbf{A1} + \mathbf{F}$ , gdzie  $\mathbf{F}$  jest pewną macierzą  
(przedstawiającą rodzaj drobnej „kratki”)

(rozmiary we float'ach [wartościach rzeczywistych])


# Rozkład obrazu #1, metoda SVD

- Obraz oryginalny



# Rozkład obrazu #1, metoda SVD


- 100 warstw (201.00% oryginału)






# Rozkład obrazu #1, metoda SVD

- 10 warstw (20.10% oryginału)




# Rozkład obrazu #1, metoda SVD

- 1 warstwa (2.01% oryginału)




## Rozkład obrazu #2, metoda SVD

- Obraz oryginalny




## Rozkład obrazu #2, metoda SVD

- 10 warstw (20.10% oryginału)




## Rozkład obrazu #2, metoda SVD

- 3 warstwy (6.03% oryginału)




## Rozkład obrazu #2, metoda SVD

- 1 warstwa (2.01% oryginału)




# Rozkład obrazu #3, metoda SVD

- Obraz oryginalny



## Rozkład obrazu #3, metoda SVD


- 6 warstw (12.06% oryginału)






## Rozkład obrazu #3, metoda SVD

- 3 warstwy (6.03% oryginału)



## Rozkład obrazu #3, metoda SVD

- 1 warstwa (2.01% oryginału)



...

# EVD a SVD

- Macierze określone
  - nieujemnie
  - dodatnio
  - niedodatnio
  - ujemnie
- Równoważność EVD i SVD
  - jeżeli  $\mathbf{A}$  jest macierzą nieujemnie określoną, to jej rozkłady EVD i SVD są tożsame

...