

...

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

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
	y_3x_1	y_3x_2	y_3x_3
	y_3x_1	y_3x_2	y_3x_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

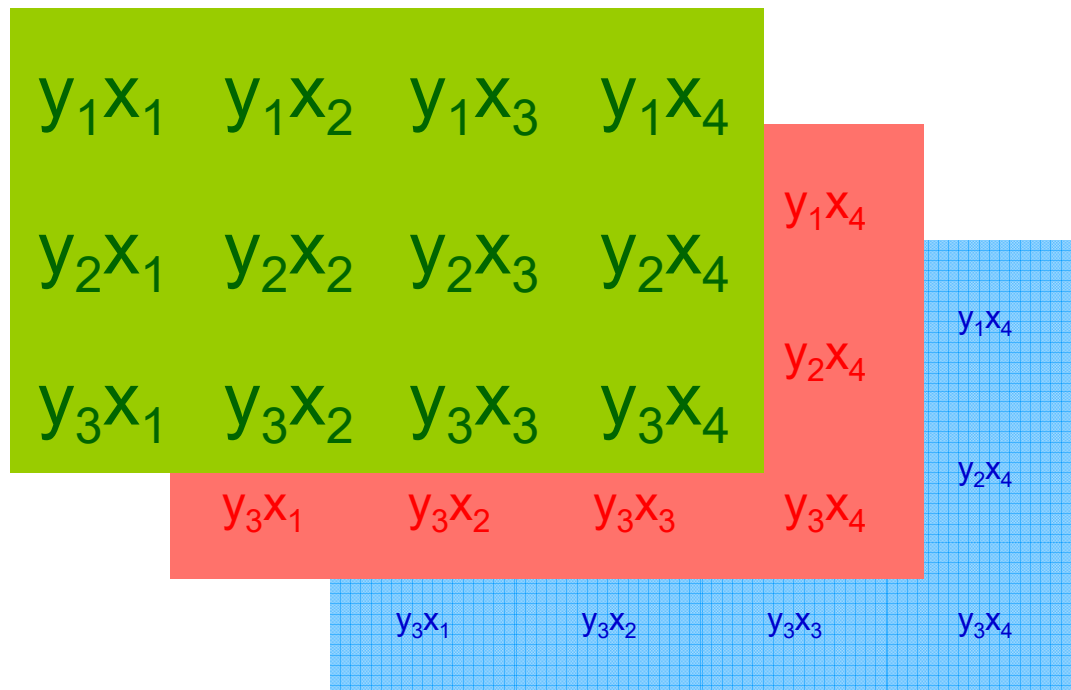
$5y_1x_1$	$5y_1x_2$	$5y_1x_3$	$5y_1x_4$		
$5y_2x_1$	$5y_2x_2$	$5y_2x_3$	$5y_2x_4$	$3y_1x_4$	$1y_1x_4$
$5y_3x_1$	$5y_3x_2$	$5y_3x_3$	$5y_3x_4$	$3y_2x_4$	$1y_2x_4$
	$3y_3x_1$	$3y_3x_2$	$3y_3x_3$	$3y_3x_4$	
	$1y_3x_1$	$1y_3x_2$	$1y_3x_3$	$1y_3x_4$	

Skalowany iloczyn macierzy

5		
	3	
		1

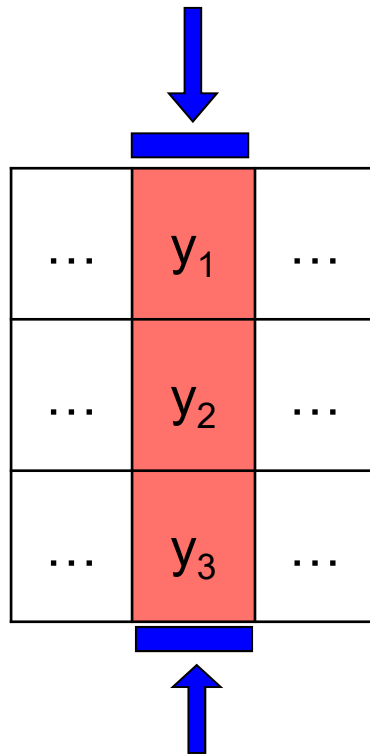

x_1	x_2	x_3	x_4
x_1	x_2	x_3	x_4
x_1	x_2	x_3	x_4

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

- Gdy $m > n$ to macierz \mathbf{L}_U (o rozmiarach $m \times n$) można przedstawić jako macierz \mathbf{L}_V (o rozmiarach $n \times n$) rozszerzoną o $m-n$ kolumn zerowych i $m-n$ wierszy zerowych:
 - zarówno \mathbf{L}_U jak i \mathbf{L}_V pozostają macierzami diagonalnymi

$$\mathbf{L}_U = \begin{array}{c} \left[\begin{array}{cc|cc} & & 0 & 0 \\ & & 0 & 0 \\ & & \dots & \\ & & 0 & 0 \\ \hline 0 & 0 & \dots & 0 \\ 0 & 0 & \dots & 0 \end{array} \right] \left. \begin{array}{l} \left. \begin{array}{l} n \\ m-n \end{array} \right\} \right\} m \\ \left. \begin{array}{l} n \\ m-n \end{array} \right\} \\ m \end{array}$$

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{BB}^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 $\mathbf{B}^T\mathbf{B} = \mathbf{A}^T\mathbf{A}$ $\mathbf{BB}^T = (\mathbf{UTV}^T)(\mathbf{UTV}^T)^T = \mathbf{UTV}^T\mathbf{VT}^T\mathbf{U}^T = \mathbf{U}\mathbf{T}\mathbf{I}\mathbf{T}^T\mathbf{U}^T = \mathbf{U}\mathbf{T}\mathbf{T}^T\mathbf{U}^T = \mathbf{U}\mathbf{L}_U\mathbf{U}^T$
 - wynika z tego, że $\mathbf{BB}^T = \mathbf{AA}^T$
- 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 $\mathbf{BB}^T = \mathbf{AA}^T$ 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

$$\mathbf{A} = \begin{array}{|c|c|} \hline 2 & 1 \\ \hline 1 & 2 \\ \hline \end{array}$$

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

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

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

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

Przykład rozkładu SVD

$$C = \begin{matrix} \mathbf{A}^T \\ \begin{array}{|c|c|} \hline 2 & 2 \\ \hline 1 & 1 \\ \hline \end{array} \end{matrix} * \begin{matrix} \mathbf{A} \\ \begin{array}{|c|c|} \hline 2 & 1 \\ \hline 2 & 1 \\ \hline \end{array} \end{matrix} = \begin{matrix} \begin{array}{|c|c|} \hline 8 & 4 \\ \hline 4 & 2 \\ \hline \end{array} \end{matrix}$$

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

$$R = \begin{matrix} \mathbf{A} \\ \begin{array}{|c|c|} \hline 2 & 1 \\ \hline 2 & 1 \\ \hline \end{array} \end{matrix} * \begin{matrix} \mathbf{A}^T \\ \begin{array}{|c|c|} \hline 2 & 2 \\ \hline 1 & 1 \\ \hline \end{array} \end{matrix} = \begin{matrix} \begin{array}{|c|c|} \hline 5 & 5 \\ \hline 5 & 5 \\ \hline \end{array} \end{matrix}$$

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

Przykład rozkładu SVD

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

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

$$\mathbf{V} = \frac{1}{\sqrt{5}} \begin{array}{|c|c|} \hline 2 & 1 \\ \hline 1 & -2 \\ \hline \end{array}$$

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

Przykład rozkładu SVD

- Niesymetryczna macierz prostokątna 1x2

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

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

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 $\mathbf{C} = \mathbf{A}^T \mathbf{A}$

$$\mathbf{A} = \begin{array}{|c|c|} \hline 2 & 1 \\ \hline 2 & 1 \\ \hline \end{array} \quad \mathbf{C} = \begin{array}{|c|c|} \hline 2 & 2 \\ \hline 1 & 1 \\ \hline \end{array} * \begin{array}{|c|c|} \hline 2 & 1 \\ \hline 2 & 1 \\ \hline \end{array} = \begin{array}{|c|c|} \hline 8 & 4 \\ \hline 4 & 2 \\ \hline \end{array}$$

– 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 $\mathbf{K} \mathbf{L} \mathbf{K}^T$

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

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

– 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 $\mathbf{A}\mathbf{A}^T$

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

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

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

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

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

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

- dla osobliwych \mathbf{T} powyższy „wywód” musi być tutaj zatrzymany, co oznacza, że utworzyliśmy jedynie macierze $\mathbf{U}\mathbf{T}(\mathbf{T}_{\square})^{-1}$ (zamiast \mathbf{U}) względnie $(\mathbf{T}_{\square})^{-1}\mathbf{T}\mathbf{V}^T$ (zamiast \mathbf{V}^T)
 - macierze te dzięki czynnikowi $\mathbf{T}(\mathbf{T}_{\square})^{-1}$ będą miały zerowe kolumny względnie wiersze, będą więc wprawdzie mogły być użyte w konstruowanym rozkładzie, ale nie będą macierzami ortogonalnymi
- dla nieosobliwych \mathbf{T} zachodzi $\mathbf{T}(\mathbf{T}_{\square})^{-1} = \mathbf{I}$, co oznacza, że możliwe jest wykonanie redukcji po prawych stronach powyższych równań, co prowadzi do ostatecznego powstania poszukiwanych macierzy \mathbf{U} i \mathbf{V}^T :

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

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

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

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

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

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

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

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

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

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

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 **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 **T**

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

- i macierz $\mathbf{T}_{\square} = \mathbf{T}$ (ponieważ **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:

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

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

- 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

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

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 [4-bajtowych reprezentacjach liczb rzeczywistych])


Rozkład obrazu #1, metoda SVD

- Obraz oryginalny (100x100, $100 \cdot 100 = 10000$ f)




Rozkład obrazu #1, metoda SVD

- 100 warstw (20100f, 201.00% oryginału)




Rozkład obrazu #1, metoda SVD

- 10 warstw (2010f, 20.10% oryginału)




Rozkład obrazu #1, metoda SVD

- 1 warstwa (201f, 2.01% oryginału)




Rozkład obrazu #2, metoda SVD

- Obraz oryginalny (100x100, $100 \cdot 100 = 10000$ f)




Rozkład obrazu #2, metoda SVD

- 10 warstw (2010f, 20.10% oryginału)




Rozkład obrazu #2, metoda SVD

- 3 warstwy (603f, 6.03% oryginału)




Rozkład obrazu #2, metoda SVD

- 1 warstwa (201f, 2.01% oryginału)




Rozkład obrazu #3, metoda SVD

- Obraz oryginalny (100x100, $100 \cdot 100 = 10000$ f)




Rozkład obrazu #3, metoda SVD

- 6 warstw (1206f, 12.06% oryginału)




Rozkład obrazu #3, metoda SVD

- 3 warstwy (603f, 6.03% oryginału)



Rozkład obrazu #3, metoda SVD

- 1 warstwa (201f, 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

...