

...

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

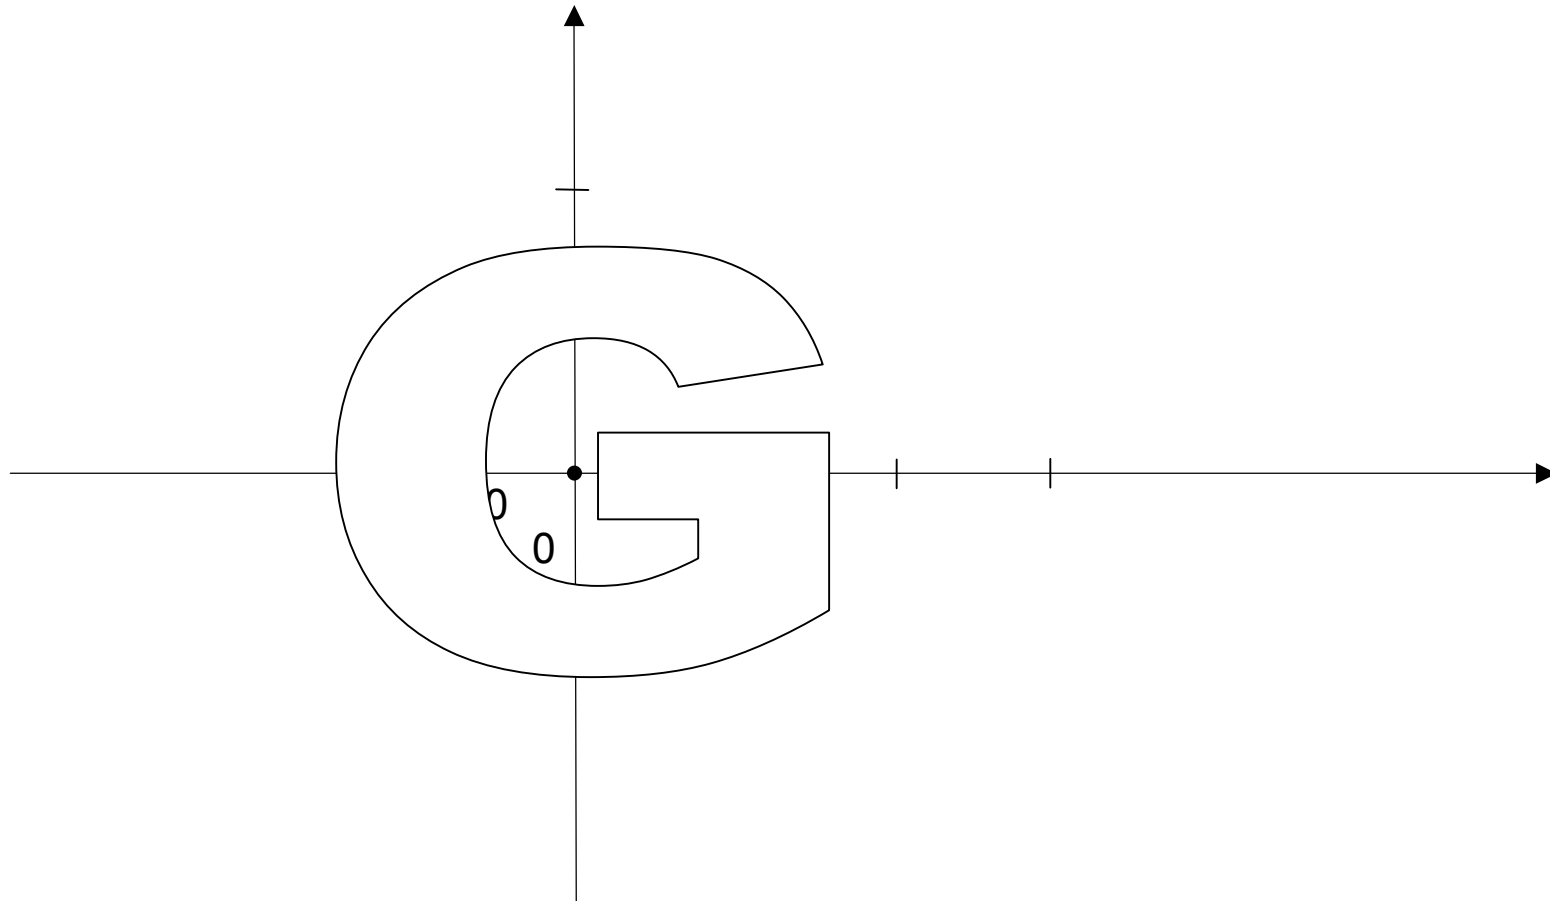
Wyłączenie odpowiedzialności

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

...


Co ujawnia EVD?



Co ujawnia EVD?



Co ujawnia EVD?

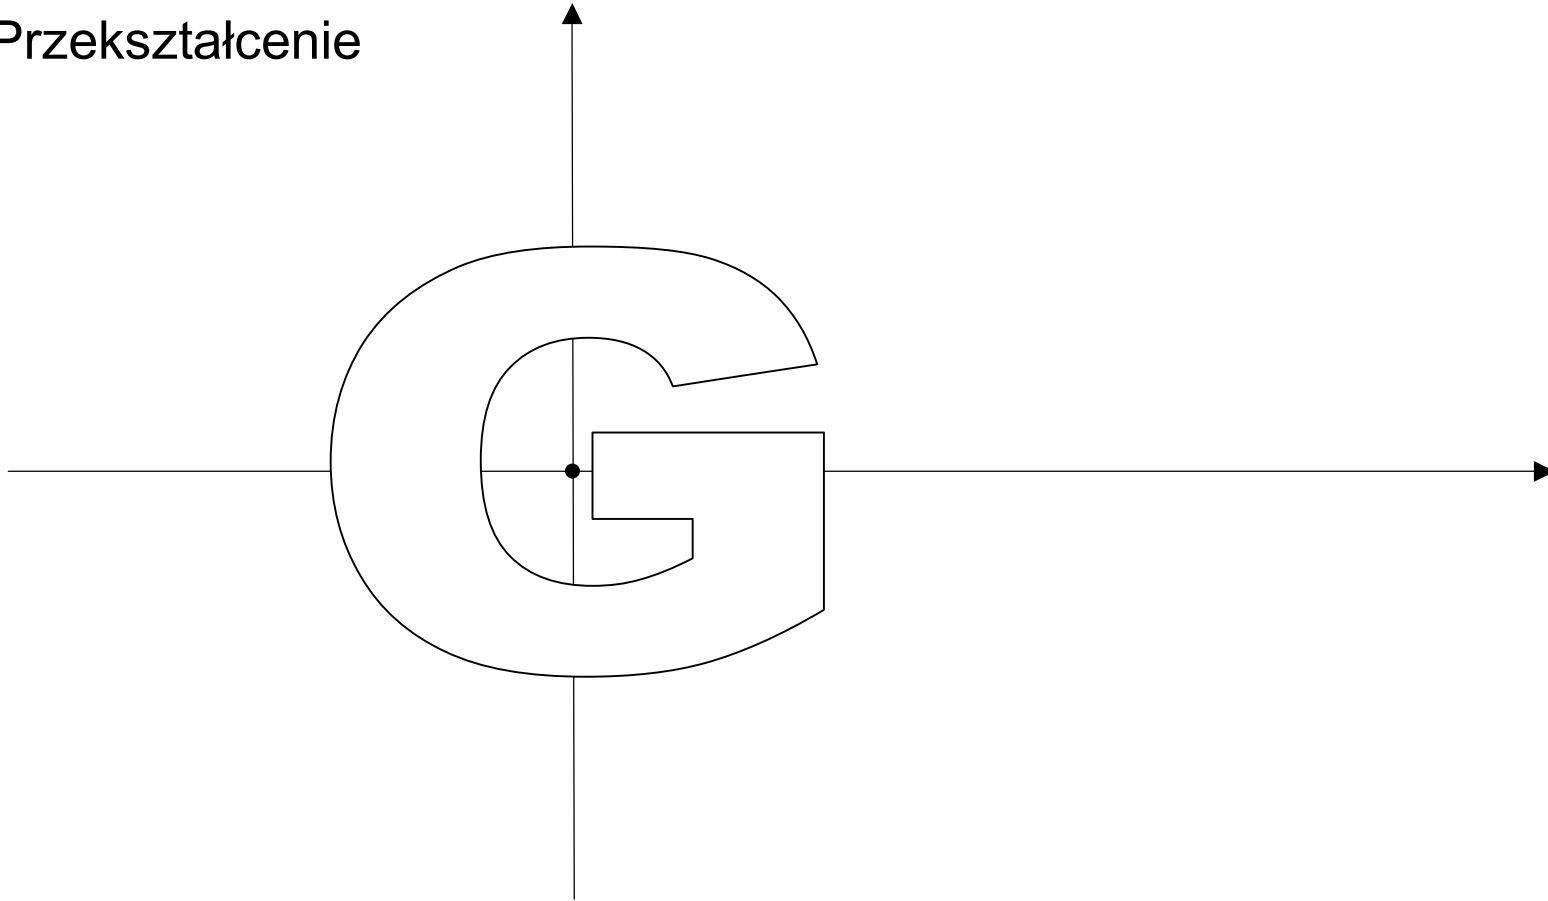


Co ujawnia EVD?

- Uogólniona macierz obrotu:
(macierz obrotów uogólnionych na zmiany znaku)
macierz ortogonalna
 $\mathbf{K}^T \mathbf{K} = \mathbf{I}$
- Przykłady
I: $\mathbf{I}^T = \mathbf{I}$
-I: $(-\mathbf{I})^T(-\mathbf{I}) = (-\mathbf{I})(-\mathbf{I}) = \mathbf{I}$
- I podobnie: jeżeli \mathbf{K} jest ortogonalna, to $-\mathbf{K}$ jest także ortogonalna
 - operacja $-\mathbf{K}$: zmiana znaku wszystkich kolumn/wierszy
- Analogiczne „zjawisko” zachodzi także dla wybranych wierszy/kolumn,
 - jeżeli \mathbf{K} jest ortogonalna, to macierz \mathbf{Z} , powstała z \mathbf{K} przez zmianę znaku wybranych kolumn/wierszy, jest także ortogonalna

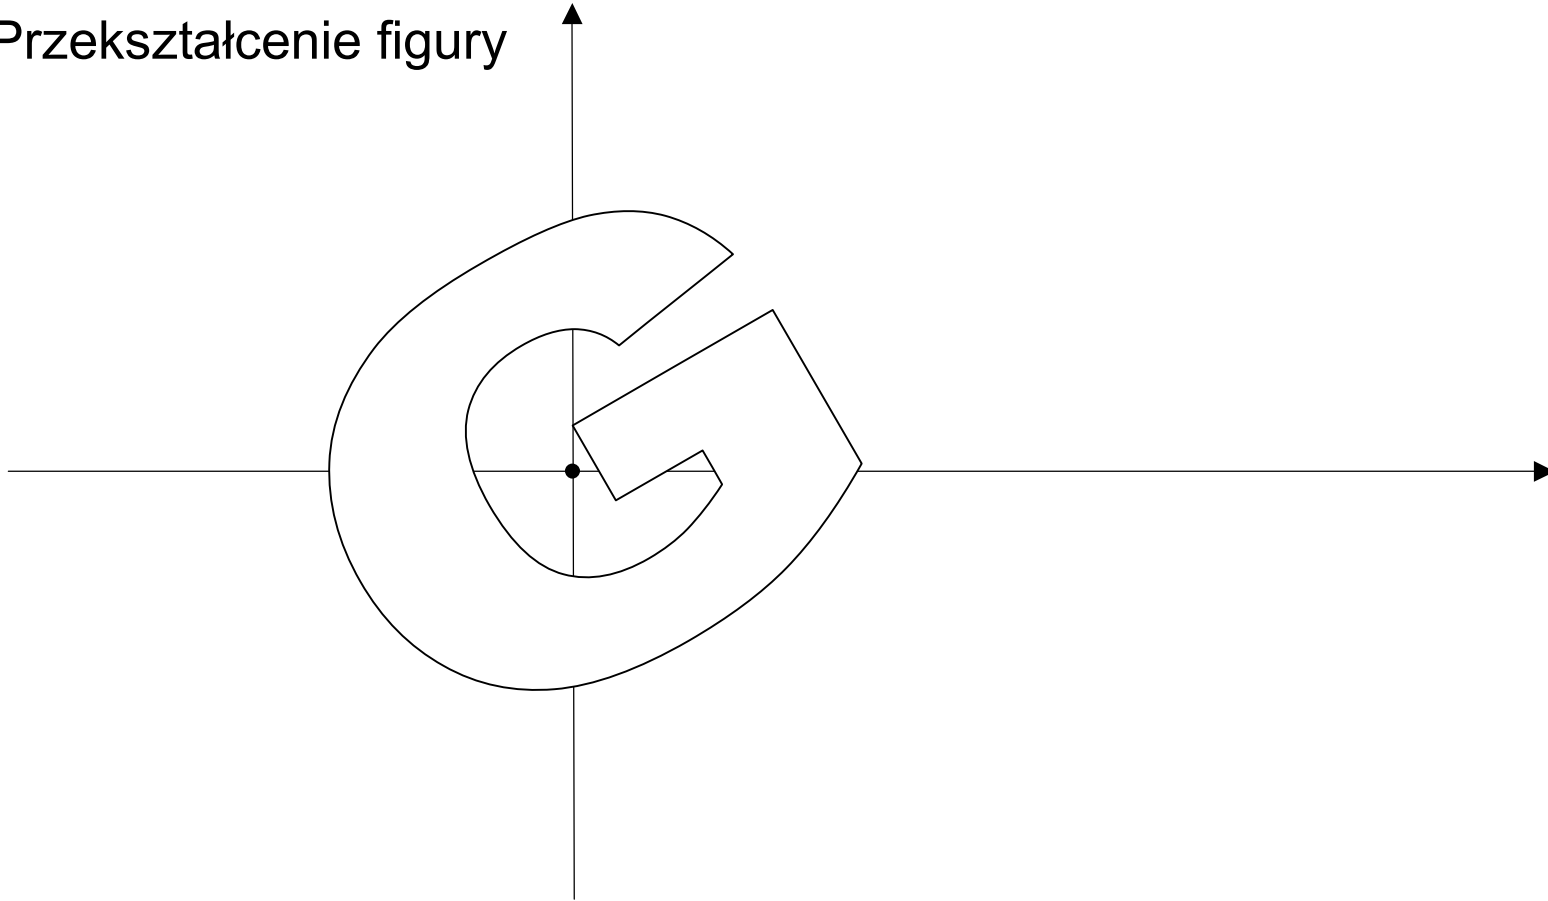
Co ujawnia EVD?

- Przekształcenie



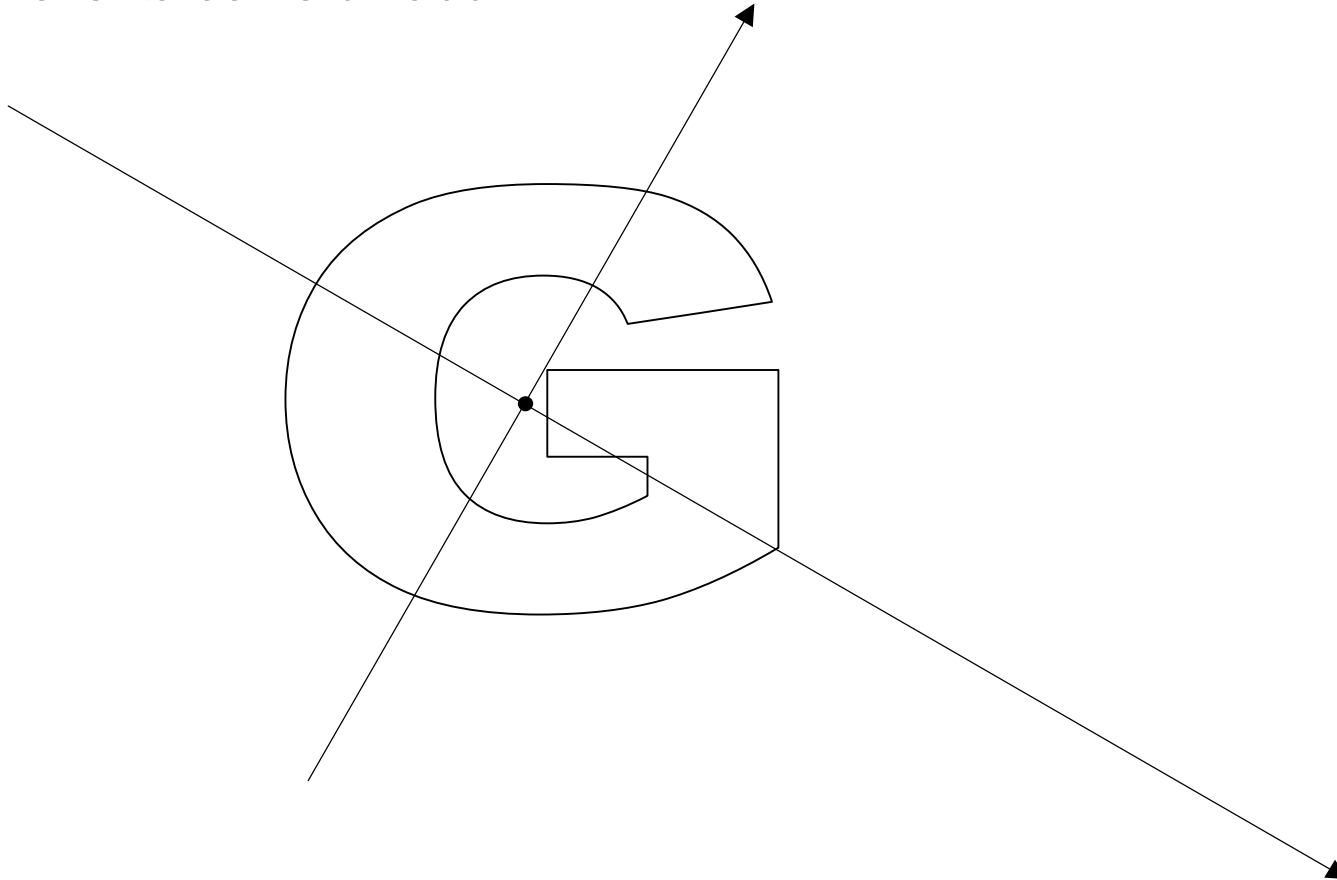
Co ujawnia EVD?

- Przekształcenie figury



Co ujawnia EVD?

- Przekształcenie układu



Co ujawnia EVD?

- Co ujawnia EVD o macierzy przekształcającej?
 - niech dane będzie przekształcenie wektora danych \mathbf{x} polegające na jego (prawostronnym) przemnożeniu przez (przekształcającą) macierz kwadratową \mathbf{A} , produkujące wektor $\mathbf{y} = \mathbf{Ax}$
 - przekształcenie to jest równoważne przekształceniu $\mathbf{y}^T = \mathbf{x}^T \mathbf{A}^T$
 - gdzie \mathbf{A}^T jest także kwadratową macierzą przekształcającą

Co ujawnia EVD?

- Przypadki szczególne
 - jeżeli \mathbf{A} jest macierzą diagonalną, to operacja stanowi jednokładność przeskalowanie wzdłuż poszczególnych osi
 - jeżeli \mathbf{A} jest macierzą ortogonalną, to operacja stanowi uogólnienie obrotu (obrót uogólniony o ewentualne zmiany znaku)
- A co w ogólnym przypadku?
 - (pominięte)

Co ujawnia EVD?

- Pytanie
 - czy rozkład EVD macierzy przekształcającej (o ile istnieje) ujawnia coś więcej o tym przekształceniu?
 - założymy więc, że macierz przekształcająca posiada rozkład EVD


Co ujawnia EVD?

- W przypadku, gdy \mathbf{A} posiada rozkład EVD: $\mathbf{A} = \mathbf{K}\mathbf{L}\mathbf{K}^{-1}$
 - (pominięte)
- W przypadku, gdy \mathbf{A} posiada rozkład EVD: $\mathbf{A} = \mathbf{K}\mathbf{L}\mathbf{K}^T$
 - wtedy $\mathbf{y} = \mathbf{A}\mathbf{x}$ można zapisać jako $\mathbf{y} = \mathbf{K}\mathbf{L}\mathbf{K}^T\mathbf{x}$ i interpretować „po kolei”, wykorzystując $\mathbf{y} = \mathbf{K}\mathbf{v}$, gdzie $\mathbf{v} = \mathbf{L}\mathbf{u}$, gdzie $\mathbf{u} = \mathbf{K}^T\mathbf{x}$
 - czyli $\mathbf{y} = \mathbf{K}(\mathbf{L}(\mathbf{K}^T\mathbf{x}))$
 - pierwsza operacja: $\mathbf{u} = \mathbf{K}^T\mathbf{x}$ (mnożenie \mathbf{x} przez macierz ortogonalną)
 - druga operacja: $\mathbf{v} = \mathbf{L}\mathbf{u}$ (mnożenie \mathbf{u} przez macierz diagonalną)
 - trzecia operacja: $\mathbf{y} = \mathbf{K}\mathbf{v}$ (mnożenie \mathbf{v} przez macierz ortogonalną)
 - ponieważ macierze \mathbf{K} i \mathbf{K}^T są (w tym przypadku) własnymi odwrotnościami, operacja trzecia jest odwrotnością operacji pierwszej
 - pierwsza „przechodzi” do nowego układu współrzędnych
 - pierwsza „wraca” do oryginalnego układu współrzędnych

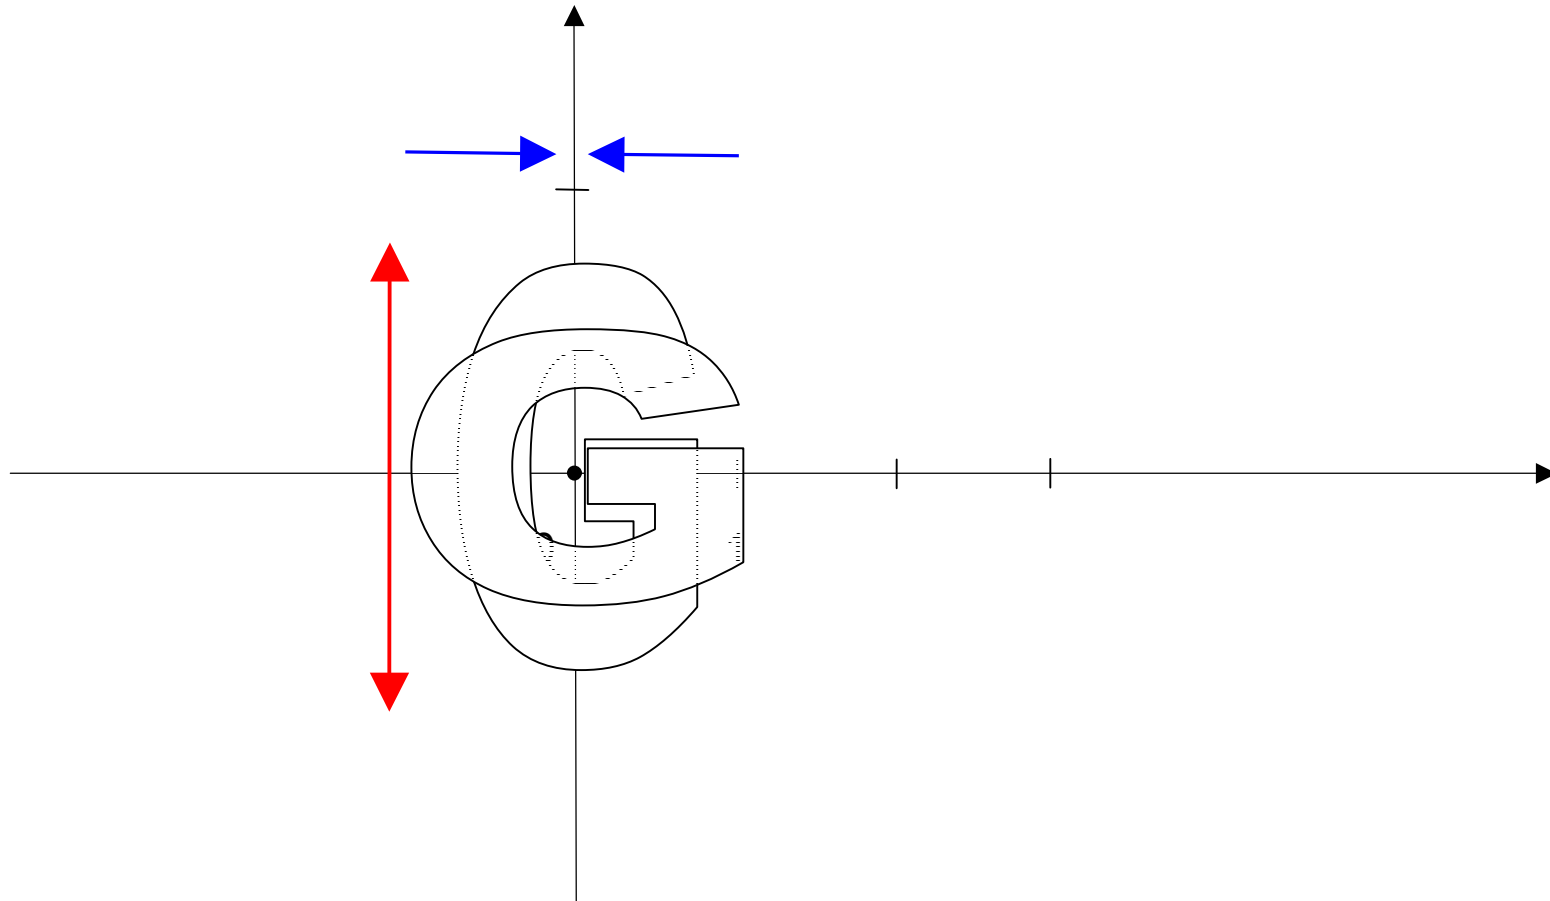
Co ujawnia EVD?

- Wniosek:
 - przekształcenie EVD ujawnia, że w mnożenie przez (zakładaną) macierz przekształcającą „zawiera w sobie” mnożenie przez macierz diagonalną utworzoną z wartości własnych macierzy przekształcającej, co ma oczywiste konsekwencje dla rezultatów przekształcenia
 - wartość własna > 1 : zwiększanie rozmiaru figury wzdłuż danego wymiaru
 - wartość własna < 1 : zmniejszanie rozmiaru figury wzdłuż danego wymiaru
 - wartość własna $= 0$: redukcja danego wymiaru


Co ujawnia EVD?




Co ujawnia EVD?



Co ujawnia EVD?



Co ujawnia EVD?



...

PCA jako transformacja układu współrzędnych

- Właściwości wykorzystywanej w przekształceniu PCA macierzy przekształcającej \mathbf{K} :
 - macierz \mathbf{K} charakteryzuje się:
 - unormowaniem kolumn: $(\mathbf{k}_i)^T \mathbf{k}_i = 1$ dla każdego i
 - ortogonalnością kolumn: $(\mathbf{k}_i)^T \mathbf{k}_j = 0$ dla każdej pary $i \neq j$
 - wniosek: kolumny macierzy \mathbf{K} definiują pewien układ współrzędnych (bazę) – kolumny \mathbf{k}_i są wersorami tego układu
 - ponieważ kolumny \mathbf{k}_i (a tym samym reprezentowane przez nie wersory) są unormowane i ortogonalne, to definiowany układ współrzędnych jest układem kartezjańskim
 - kolumny/wersory \mathbf{k}_i tego układu są tak dobrane, aby reprezentować kierunki wzdłuż których wariancja zmiennych jest maksymalna
- Zadaniem procedury PCA jest więc przekształcenie danych do układu zdefiniowanego przez macierz \mathbf{K}

PCA jako transformacja układu współrzędnych

- Niech będzie dana baza **A** oraz pewien wektor **y**
 - pytanie: jak zdobyć współrzędne wektora **y** w bazie **B**?
 - odpowiedź: współrzędne wektora **y** w bazie **A** przedstawia taki wektor **x**, który spełnia równanie macierzowe **Ax = b**
 - wektor ten jest rozwiązaniem tego równania, a więc można go obliczyć np. jako $\mathbf{x} = \mathbf{A}^{-1}\mathbf{b}$
- Procedura PCA dokonuje przekształcenia danych z macierzy **X** do nowego układu współrzędnych zdefiniowanego przez macierz **K**, jest jednak realizowana przez zwykłe mnożenie macierzy: **Y = XK**
 - zachodzą pytania:
 - na jakim etapie następuje poszukiwanie nowych współrzędnych?
 - kiedy następuje poszukiwanie odwrotności macierzy **K**?

PCA jako transformacja układu współrzędnych

- Jakie są współrzędne danego wektora \mathbf{x} w układzie reprezentowanym przez ortogonalną macierz \mathbf{K} ?
 - (czyli przez wersory będące kolumnami tej macierzy)
 - w ogólności, poszukiwane współrzędne (oznaczenie: \mathbf{y}) spełniają
$$\mathbf{Ky} = \mathbf{x}$$
 - czyli
$$\mathbf{K}^{-1}\mathbf{Ky} = \mathbf{K}^{-1}\mathbf{x}$$
$$\mathbf{Iy} = \mathbf{K}^{-1}\mathbf{x}$$
$$\mathbf{y} = \mathbf{K}^{-1}\mathbf{x}$$

PCA jako transformacja układu współrzędnych

- Jakie są współrzędne danego wektora \mathbf{x} w układzie...
 - ale ortogonalna \mathbf{K} spełnia $\mathbf{K}^{-1} = \mathbf{K}^T$, zatem
$$\mathbf{y} = \mathbf{K}^T \mathbf{x}$$
 - powyższe zachodzi dla wektora \mathbf{x} (kolumnowego), jak to będzie wyglądało dla tego samego wektora w postaci \mathbf{x}^T (wierszowej)?
 - wykorzystując $\mathbf{A} = \mathbf{B} \Leftrightarrow \mathbf{A}^T = \mathbf{B}^T$ mamy
$$\mathbf{y}^T = (\mathbf{K}^T \mathbf{x})^T$$
$$\mathbf{y}^T = \mathbf{x}^T (\mathbf{K}^T)^T$$
$$\mathbf{y}^T = \mathbf{x}^T \mathbf{K}$$

PCA jako transformacja układu współrzędnych

- Jakie są współrzędne danego wektora \mathbf{x} w układzie...
 - czyli dla wektorów $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_m$ zachodzi
$$(\mathbf{y}_1)^T = (\mathbf{x}_1)^T \mathbf{K}$$
$$(\mathbf{y}_2)^T = (\mathbf{x}_2)^T \mathbf{K}$$

...

$$(\mathbf{y}_m)^T = (\mathbf{x}_m)^T \mathbf{K}$$
 - to samo prościej
 - (traktując wektory $(\mathbf{x}_1)^T, (\mathbf{x}_2)^T, \dots, (\mathbf{x}_m)^T$ jako wiersze macierzy \mathbf{X})
$$\mathbf{Y} = \mathbf{XK}$$
- Wniosek:
 - tworząc nowe zmienne (jako $\mathbf{Y} = \mathbf{XK}$), metoda PCA znajduje w praktyce współrzędne wektorów reprezentowanych przez wiersze macierzy \mathbf{X} w układzie reprezentowanym przez kolumny macierzy \mathbf{K}

PCA jako transformacja układu współrzędnych

- Jakie są współrzędne danego wektora \mathbf{x} w układzie...
 - istotną rolę w uproszczeniu powyższego zapisu odgrywa fakt, że macierz \mathbf{K} jest ortogonalna
 - co by było, gdyby nie była to macierz ortogonalna?
 - gdyby \mathbf{K} była osobliwa, to nie mogłaby reprezentować wersorów układu współrzędnych
 - gdyby \mathbf{K} była nieosobliwa (co gwarantuje istnienie \mathbf{K}^{-1}), ale nie byłaby ortogonalna, to zachodziłoby w ogólności

$$\mathbf{y} = \mathbf{K}^{-1}\mathbf{x}$$

- i wtedy

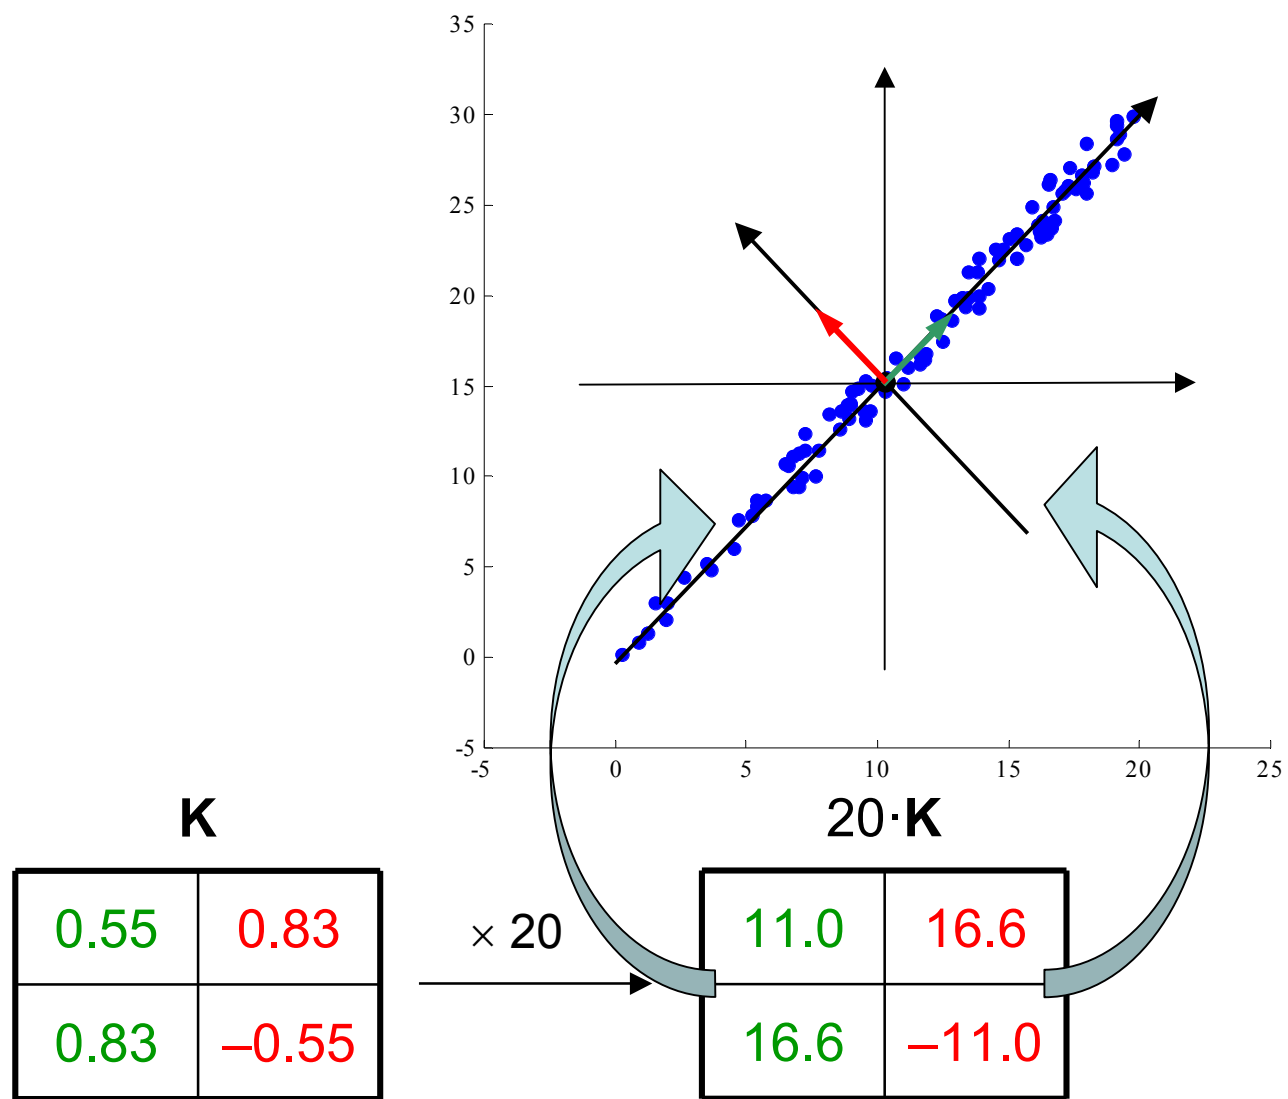
$$\mathbf{y}^T = (\mathbf{K}^{-1}\mathbf{x})^T$$

$$\mathbf{y}^T = \mathbf{x}^T(\mathbf{K}^{-1})^T$$

- a w ogólności


$$\mathbf{Y} = \mathbf{X}(\mathbf{K}^{-1})^T$$

Przykład: PCA dla danych dwuwymiarowych




...

PCA a MNK



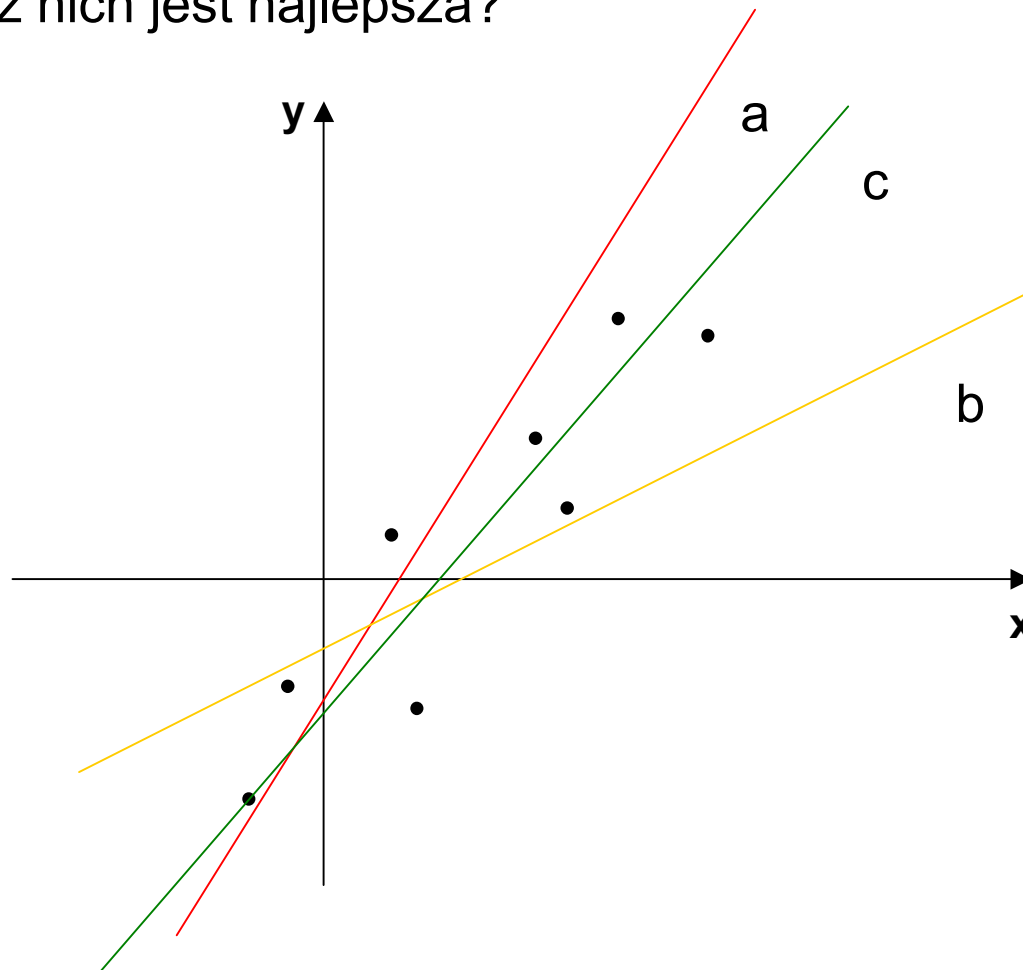
Metoda najmniejszych kwadratów

- Interpretacja geometryczna najmniejszych kwadratów w przestrzeni zmiennych
 - dane punkty



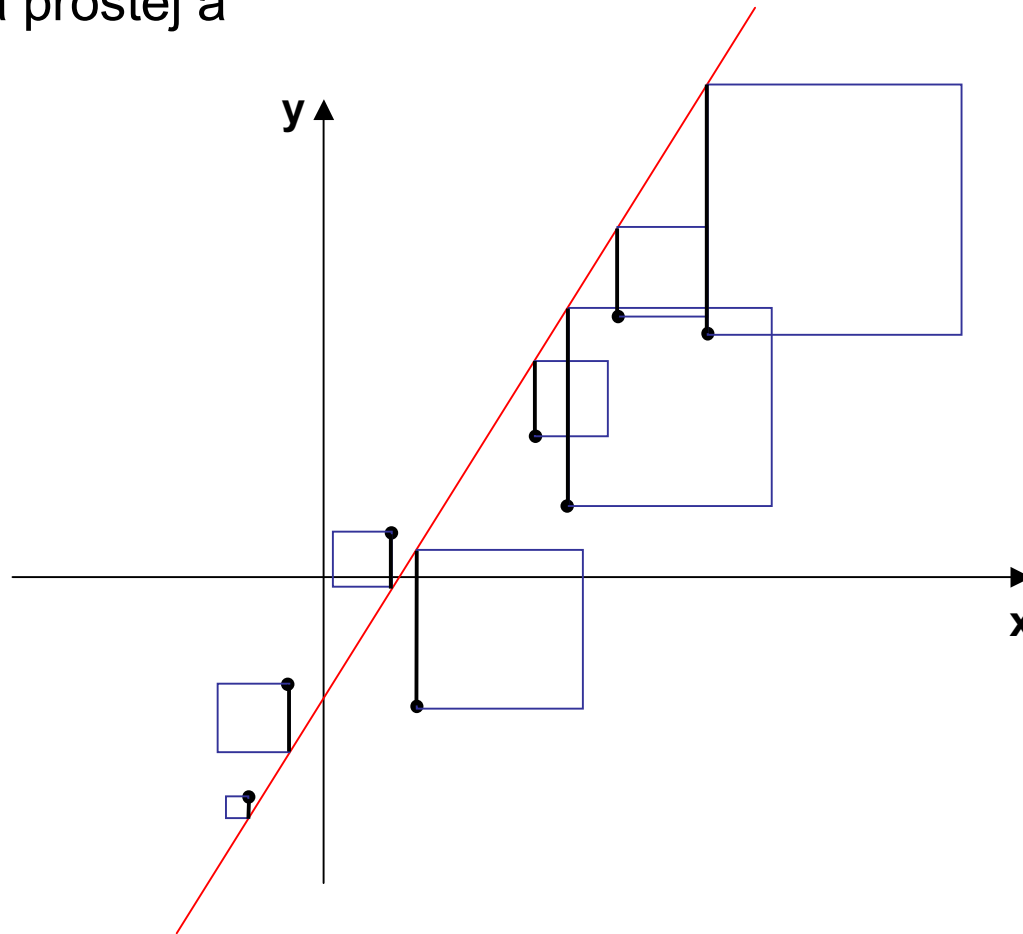
Metoda najmniejszych kwadratów

- Przykładowe modele (proste)
 - która z nich jest najlepsza?



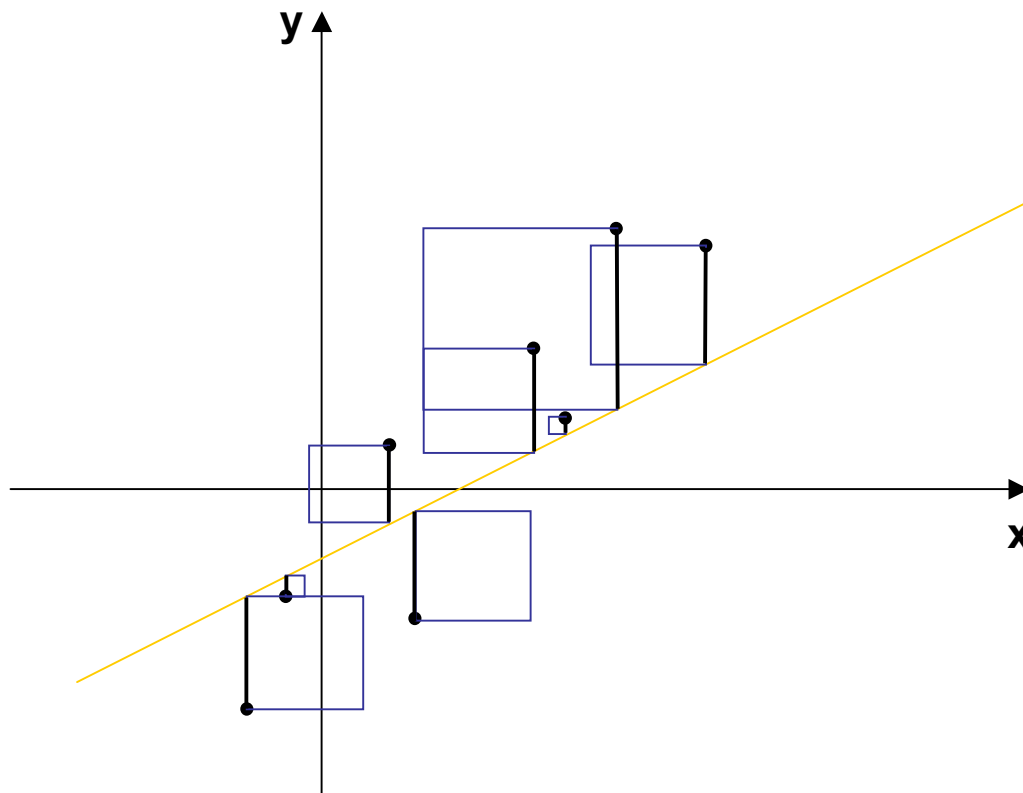
Metoda najmniejszych kwadratów

- Przykładowe modele (proste)
 - ocena prostej a




Metoda najmniejszych kwadratów

- Przykładowe modele (proste)
 - ocena prostej b




Metoda najmniejszych kwadratów

- Przykładowe modele (proste)
 - ocena prostej c




PCA a MNK

- Klasyczna regresja:
 $y = f(x)$




PCA a MNK

- Klasyczna regresja po zamianie zmiennych rolami:
 $x = g(y)$



PCA a MNK

- PCA



PCA a MNK

- MNK
 - wynik (propozycja prostej) uzyskany dla
 - $y = f(x)$ (y zależne od x)
 - $x = g(y)$ (x zależne od y)
 - będzie identyczny dla $f^{-1} = g$
(jest to jednakże bardzo szczególny przypadek)
 - w sytuacji braku jasnej sytuacji co do tego, która zmienna jest zależna od której (czyli: która jest zależna, a która niezależna) mamy dwa różne rozwiązania
 - co więcej, jeżeli występują między nimi różnice, to jedno może być lepsze, a drugie gorsze; niestety, zazwyczaj nie wiadomo, które jest tym lepszym rozwiązaniem!
- PCA
 - jeden wynik (jedna propozycja prostej),
(zarówno dla $[x \ y]$ jak i $[y \ x]$)

...

PCA a EVD

- PCA a EVD
 - podsumowanie
 - PCA: procedura przekształcająca dane: $\mathbf{X} \rightarrow \mathbf{Y}$
 - EVD: procedura rozkładająca macierz \mathbf{A} na iloczyn $\mathbf{K}\mathbf{L}\mathbf{K}^{-1}$ (inaczej: procedura diagonalizująca macierz \mathbf{A})
 - relacja PCA–EVD
 - w procedurze PCA wykorzystuje się procedurę EVD do zdiagnozowania macierzy kowariancji \mathbf{S}_X


...

Metody doboru liczby zmiennych redukowanych

- Niech $\lambda = \{\lambda_1, \lambda_2, \dots, \lambda_n\}$ będzie zbiorem posortowanych nierosnąco wartości własnych macierzy kowariancji
 - znajdź średnią wartość $\bar{\lambda}$ wszystkich λ_i i utwórz tylko zmienne odpowiadające wartościom $\lambda_i \geq \bar{\lambda}$

- utwórz tylko zmienne 1..s, przy minimalnym s, dla którego zachodzi: $\frac{\sum_{i=1}^s \lambda_i}{\sum_{i=1}^n \lambda_i} \geq p$, przy zadanym p

- dobierz wizualnie zmienne na podstawie tzw. wykresu osypiska:



...

Zastosowania PCA: przykład biologiczny

- Jolicoeur i Mosiman (1960) dokonywali pomiarów skorupy żółwi, otrzymując oryginalne zmienne:
 - długość
 - szerokość
 - wysokość
- Ze względu na względnie stałe proporcje powyższych wielkości (duża korelacja) zmienne oryginalne można przekształcić wykorzystując PCA i otrzymując:
 - wielkość (98.64% informacji)
 - kształt-A (0.94%) i kształt-B (0.41%)
- Podobne badania
 - białe leghorny (Wright, 1954)

Zastosowania PCA: przykład psychologiczny

- Birren i Morrison (1961) badali wyniki testów Wechslera (testy na inteligencję dla dorosłych). Obserwowano:
 - wyniki testu (11 zmiennych), oraz dodatkowo
 - wiek i wykształcenie
- W rezultacie przekształcenia PCA otrzymano zmienne, które (po zanalizowaniu korelacji z oryginalnymi wynikami testów) zinterpretowano następująco:
 - ogólna wydajność intelektualna (51.47%)
 - doświadczenie (10.90%)
 - miernik wyobraźni przestrzennej (6.15%)
 - miernik umiejętności rachunkowych (5.48%)

...

Samochody osobowe

- Warianty
 - 15 samochodów osobowych
- Kryteria
 - 4 wybrane parametry
 - zużycie paliwa [l/100 km], zakres: [6,10], typ: strata
 - przyspieszenie do 100km/h [s], zakres: [9,14], typ: strata
 - cena [tys. PLN], zakres: [24, 94], typ: strata
 - wyposażenie [punkty uznaniowe], zakres: [1, 10], typ: zysk

Wizualizacja danych wielowymiarowych

- Oryginalne opisy 15 samochodów (tabela informacyjna)


Marka	Model	Zużycie	Przyspieszenie	Cena	Wyposażenie
Alfa Romeo	156	8,1	9,3	71,14	9
Audi	A4	7,9	11,9	93,35	10
BMW	316I	7,5	12,3	81,79	8
Daewoo	Lanos	8,4	12,2	34,90	3
Honda	Civic	6,7	10,8	48,90	7
Hyunday	Accent	6,4	11,7	35,30	2
Lada	Samara	7,2	13,0	24,90	2
Mitsubishi	Carisma	7,2	12,0	60,60	9
Opel	Astra II	7,0	12,0	56,95	8
Peugeot	206 XR	6,6	13,2	38,36	4
Renault	Megane	7,0	9,9	50,05	9
Saab	9 3S	9,7	11,0	85,35	8
Seat	Cordoba	8,3	10,9	44,99	8
Toyota	Corrola	7,7	10,2	50,36	4
Volkswagen	Golf IV	8,3	9,9	61,62	6

Wizualizacja danych wielowymiarowych

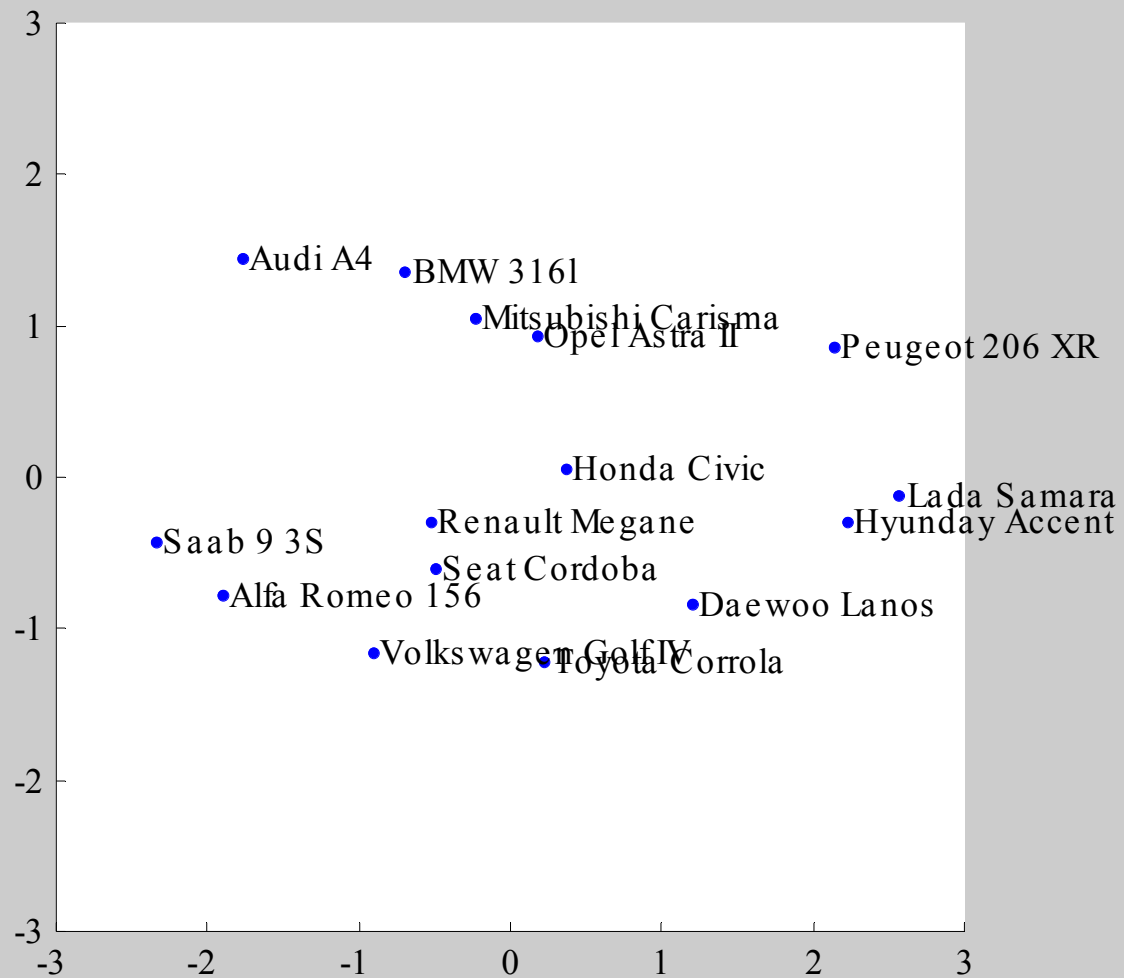
- Znormalizowane opisy 15 samochodów (tabela informacyjna)


Marka	Model	Zużycie	Przyspieszenie	Cena	Wyposażenie
Alfa Romeo	156	0,57	-1,74	0,76	0,93
Audi	A4	0,34	0,46	1,87	1,31
BMW	316I	-0,11	0,80	1,29	0,56
Daewoo	Lanos	0,92	0,72	-1,05	-1,34
Honda	Civic	-1,03	-0,47	-0,35	0,18
Hyunday	Accent	-1,37	0,29	-1,03	-1,34
Lada	Samara	-0,46	1,40	-1,55	-1,72
Mitsubishi	Carisma	-0,46	0,55	0,23	0,93
Opel	Astra II	-0,69	0,55	0,05	0,56
Peugeot	206 XR	-1,14	1,57	-0,88	-0,96
Renault	Megane	-0,69	-1,23	-0,29	0,93
Saab	9 3S	2,40	-0,30	1,47	0,56
Seat	Cordoba	0,80	-0,39	-0,55	0,56
Toyota	Corrola	0,11	-0,98	-0,28	-0,96
Volkswagen	Golf IV	0,80	-1,23	0,29	-0,20


1.0000	-0.3245	0.4872	0.2619
-0.3245	1.0000	-0.2609	-0.3814
0.4872	-0.2609	1.0000	0.7691
0.2619	-0.3814	0.7691	1.0000



-1.9007	-0.7758
-1.7763	1.4540
-0.6978	1.3548
1.2019	-0.8323
0.3599	0.0557
2.2258	-0.2916
2.5666	-0.1197
-0.2338	1.0564
0.1759	0.9305
2.1353	0.8628
-0.5332	-0.2984
-2.3404	-0.4234
-0.4961	-0.5953
0.2245	-1.2162
-0.9117	-1.1617







...