

# Metody regresji liniowej

Melka Kamil

Uniwersytet Wrocławski

14.03.2022

# Plan prezentacji

Metody  
regresji  
liniowej

K. Melka

Wprowadzenie

Metoda naj-  
mniejszych  
kwadratów

Przykład

Błąd średnio-  
kwadratowy

Selekcja  
zmiennych

Regresja  
grzbietowa  
(Ridge  
regression)

LASSO

Porównanie i  
możliwości  
rozszerzenia

- 1 Wprowadzenie
- 2 Metoda najmniejszych kwadratów
- 3 Przykład
- 4 Błąd średniokwadratowy
- 5 Selekcja zmiennych
- 6 Regresja grzbietowa (Ridge regression)
- 7 LASSO
- 8 Porównanie i możliwości rozszerzenia

# Model regresji liniowej

Metody  
regresji  
liniowej

K. Melka

Wprowadzenie

Metoda naj-  
mniejszych  
kwadratów

Przykład

Błąd średnio-  
kwadratowy

Selekcja  
zmiennych

Regresja  
grzbietowa  
(Ridge  
regression)

LASSO

Porównanie i  
możliwości  
rozszerzenia

- Model regresji liniowej zakłada, że funkcja regresji  $E(Y|X)$  jest liniowa względem zmiennych objaśniających  $X_1, \dots, X_p$ .
- $$f(X) = \beta_0 + \sum_{j=1}^p X_j \beta_j.$$
- Zazwyczaj nieskomplikowany sposób liczenia i interpretacji otrzymanych parametrów.
- Dobre własności predykcyjne w przypadku małej liczby danych treningowych, niskiej proporcji sygnału do szumu lub rzadkich danych.

# Rodzaj zmiennych objaśniających

Metody  
regresji  
liniowej

K. Melka

Wprowadzenie

Metoda najmniejszych kwadratów

Przykład

Błąd średniokwadratowy

Selekcja zmiennych

Regresja grzbietowa (Ridge regression)

LASSO

Porównanie i możliwości rozszerzenia

Mimo, że model jest liniowy, to możemy dokonywać pewnych przekształceń na zmiennych objaśniających, które niekoniecznie są liniowe.

- Zmienne ilościowe.
- Przekształcenia typu: logarytm, pierwiastek kwadratowy lub kwadrat zmiennej.
- Rozszerzanie bazy, np.  $X_2 = X_1^2$ ,  $X_3 = X_1^3$  odpowiada za przedstawienie modelu w postaci wielomianowej.
- Zmienne jakościowe przedstawiane za pomocą "dummy variables".
- Interakcje między zmiennymi, np.  $X_3 = X_1 \cdot X_2$ .

# Metoda najmniejszych kwadratów

Metody  
regresji  
liniowej

K. Melka

Wprowadzenie

Metoda naj-  
mniejszych  
kwadratów

Przykład

Błąd średnio-  
kwadratowy

Selekcja  
zmiennych

Regresja  
grzbietowa  
(Ridge  
regression)

LASSO

Porównanie i  
możliwości  
rozszerzenia

Celem metody najmniejszych kwadratów jest dobranie takich wartości  $\beta_j$ , które minimalizują

$$RSS(\beta) = \sum_{i=1}^N (y_i - f(x_i))^2 = \sum_{i=1}^N (y_i - \beta_0 - \sum_{j=1}^p x_{ij}\beta_j)^2.$$

Ze statystycznego punktu widzenia jest sensowne, gdy wektory obserwacji  $(x_i, y_i)$  są niezależnymi losowaniami z populacji lub gdy  $y_i$  jest warunkowo niezależne względem znanych wartości  $x_i$ .

# Geometria metody najmniejszych kwadratów

Metody  
regresji  
liniowej

K. Melka

Wprowadzenie

Metoda naj-  
mniejszych  
kwadratów

Przykład


Błąd średnio-  
kwadratowy

Selekcja  
zmiennych

Regresja  
grzbietowa  
(Ridge  
regression)

LASSO

Porównanie i  
możliwości  
rozszerzenia



**Rysunek:** Regresja liniowa za pomocą metody najmniejszych kwadratów dla  $X \in \mathbb{R}^2$ , źródło: *Elements of statistical learning*, fig. 3.1

# Postać estymatora $\hat{\beta}$

Metody  
regresji  
liniowej

K. Melka

Wprowadzenie

Metoda naj-  
mniejszych  
kwadratów

Przykład

Błąd średnio-  
kwadratowy

Selekcja  
zmiennych

Regresja  
grzbietowa  
(Ridge  
regression)

LASSO

Porównanie i  
możliwości  
rozszerzenia

Niech  $\mathbf{X}$  oznacza macierz rozmiaru  $N \times (p + 1)$ , w której mamy wartości zmiennych objaśniających.

Niech  $\mathbf{y}$  oznacza wektor wartości zmiennej objaśnianej długości  $N$ .

Wtedy:

- $RSS(\beta) = (\mathbf{y} - \mathbf{X}\beta)^T(\mathbf{y} - \mathbf{X}\beta).$
- $\frac{\partial RSS}{\partial \beta} = -2\mathbf{X}^T(\mathbf{y} - \mathbf{X}\beta).$
- $\frac{\partial^2 RSS}{\partial \beta \partial \beta^T} = 2\mathbf{X}^T\mathbf{X}.$
- $\mathbf{X}^T(\mathbf{y} - \mathbf{X}\beta) = 0.$
- $\hat{\beta} = (\mathbf{X}^T\mathbf{X})^{-1}\mathbf{X}^T\mathbf{y}.$

# Geometria metody najmniejszych kwadratów

Metody  
regresji  
liniowej

K. Melka

Wprowadzenie

Metoda naj-  
mniejszych  
kwadratów

Przykład

Błąd średnio-  
kwadratowy

Selekcja  
zmiennych

Regresja  
grzbietowa  
(Ridge  
regression)

LASSO

Porównanie i  
możliwości  
rozszerzenia

- $\hat{\mathbf{y}} = \mathbf{X}\hat{\boldsymbol{\beta}} = \mathbf{X}(\mathbf{X}^T\mathbf{X})^{-1}\mathbf{X}^T\mathbf{y}$
- $\mathbf{H} = \mathbf{X}(\mathbf{X}^T\mathbf{X})^{-1}\mathbf{X}^T$
- Wektory  $\mathbf{x}_0, \mathbf{x}_1, \dots, \mathbf{x}_p$  rozpinają podprzestrzeń przestrzeni  $\mathbb{R}^N$ .
- Metoda najmniejszych kwadratów minimalizuje  $RSS(\boldsymbol{\beta}) = \|\mathbf{y} - \mathbf{X}\boldsymbol{\beta}\|^2$ .
- Zatem optymalne  $\hat{\boldsymbol{\beta}}$  sprawia, że wektor residuów  $\mathbf{y} - \hat{\mathbf{y}}$  jest ortogonalny do wyżej wspomnianej podprzestrzeni.



# Geometria metody najmniejszych kwadratów

Metody  
regresji  
liniowej

K. Melka

Wprowadzenie

Metoda naj-  
mniejszych  
kwadratów

Przykład


Błąd średnio-  
kwadratowy

Selekcja  
zmiennych

Regresja  
grzbietowa  
(Ridge  
regression)

LASSO

Porównanie i  
możliwości  
rozszerzenia



**Rysunek:** Rysunek pokazujący ortogonalność wektora reszduów do przestrzeni rozpiętej przez zmienne objaśniające, źródło: *Elements of statistical learning*, fig. 3.2

# Własności estymatorów

Metody  
regresji  
liniowej

K. Melka

Wprowadzenie

Metoda naj-  
mniejszych  
kwadratów

Przykład

Błąd średnio-  
kwadratowy

Selekcja  
zmiennych

Regresja  
grzbietowa  
(Ridge  
regression)

LASSO

Porównanie i  
możliwości  
rozszerzenia

Niech obserwacje  $y_i$  będą nieskorelowane o tej samej wariancji  $\sigma^2$ . Niech  $x_i$  będą wyznaczone. Wtedy macierz kowariancji wektora  $\hat{\beta}$  ma postać:

$$\text{Var}(\hat{\beta}) = (\mathbf{X}^T \mathbf{X})^{-1} \sigma^2$$

$$\hat{\sigma}^2 = \frac{1}{N - p - 1} \sum_{i=1}^N (y_i - \hat{y}_i)^2$$

Bardzo często zakładamy, że możemy zapisać zmienne objaśniające w postaci:  $Y = \beta_0 + \sum_{j=1}^p X_j \beta_j + \varepsilon$ , gdzie

$$\varepsilon \sim N(0, \sigma^2)$$

# Własności estymatorów

Metody  
regresji  
liniowej

K. Melka

Wprowadzenie

Metoda naj-  
mniejszych  
kwadratów

Przykład

Błąd średnio-  
kwadratowy

Selekcja  
zmiennych

Regresja  
grzbietowa  
(Ridge  
regression)

LASSO

Porównanie i  
możliwości  
rozszerzenia

- $\hat{\beta} \sim N(\beta, (\mathbf{X}^T \mathbf{X})^{-1} \sigma^2)$
- $(N - p - 1) \hat{\sigma}^2 \sim \sigma^2 \chi_{N-p-1}^2$
- $\hat{\beta}$  i  $\hat{\sigma}^2$  są niezależnie statystycznie.
- $z_j = \frac{\hat{\beta}_j}{\hat{\sigma} \sqrt{v_j}}$ , gdzie  $v_j$  jest  $j$ -tym elementem na diagonalu  $(\mathbf{X}^T \mathbf{X})^{-1}$
- Przy  $H_0 : \beta_j = 0$ ,  $z_j$  ma rozkład  $t_{N-p-1}$ .

# Ogon rozkładów

Metody  
regresji  
liniowej

K. Melka

Wprowadzenie

Metoda naj-  
mniejszych  
kwadratów

Przykład


Błąd średnio-  
kwadratowy

Selekcja  
zmiennych

Regresja  
grzbietowa  
(Ridge  
regression)

LASSO

Porównanie i  
możliwości  
rozszerzenia



Rysunek: Ogony rozkładów  $t_{30}$ ,  $t_{100}$  i  $N(0,1)$ , źródło: *Elements of statistical learning*, fig. 3.3

# Testowanie grupy współczynników

Metody  
regresji  
liniowej

K. Melka

Wprowadzenie

Metoda naj-  
mniejszych  
kwadratów

Przykład

Błąd średnio-  
kwadratowy

Selekcja  
zmiennych

Regresja  
grzbietowa  
(Ridge  
regression)

LASSO

Porównanie i  
możliwości  
rozszerzenia

$$F = \frac{(RSS_0 - RSS_1)/(p_1 - p_0)}{RSS_1/(N - p_1 - 1)},$$

gdzie  $RSS_1$  to  $RSS$  dla modelu z  $p_1 + 1$  parametrami, a  $RSS_0$  to  $RSS$  dla zagnieżdżonego modelu z  $p_0 + 1$  parametrami.

Przy założeniu normalności błędów oraz przy  $H_0$ , że mniejszy model jest poprawny, to  $F$  ma rozkład  $F_{p_1 - p_0, N - p_1 - 1}$

# Przedział ufności dla $\beta_j$

Metody  
regresji  
liniowej

K. Melka

Wprowadzenie

Metoda naj-  
mniejszych  
kwadratów

Przykład

Błąd średnio-  
kwadratowy

Selekcja  
zmiennych

Regresja  
grzbietowa  
(Ridge  
regression)

LASSO

Porównanie i  
możliwości  
rozszerzenia

$$(\hat{\beta}_j - z^{(1-\alpha)} \sqrt{v_j} \hat{\sigma}, \hat{\beta}_j + z^{(1-\alpha)} \sqrt{v_j} \hat{\sigma})$$

# Macierz korelacji między zmiennymi objaśniającymi

Metody  
regresji  
liniowej

K. Melka

Wprowadzenie

Metoda naj-  
mniejszych  
kwadratów

Przykład

Błąd średnio-  
kwadratowy

Selekcja  
zmiennych

Regresja  
grzbietowa  
(Ridge  
regression)

LASSO

Porównanie i  
możliwości  
rozszerzenia

**TABLE 3.1.** *Correlations of predictors in the prostate cancer data.*

	lcavol	lweight	age	lbph	svi	lcp	gleason
lweight	0.300						
age	0.286	0.317					
lbph	0.063	0.437	0.287				
svi	0.593	0.181	0.129	-0.139			
lcp	0.692	0.157	0.173	-0.089	0.671		
gleason	0.426	0.024	0.366	0.033	0.307	0.476	
pgg45	0.483	0.074	0.276	-0.030	0.481	0.663	0.757

źródło: *Elements of statistical learning, tab. 3.1*

# Scatterplot

Metody  
regresji  
liniowej

K. Melka

Wprowadzenie

Metoda naj-  
mniejszych  
kwadratów

Przykład


Błąd średnio-  
kwadratowy

Selekcja  
zmiennych

Regresja  
grzbietowa  
(Ridge  
regression)

LASSO

Porównanie i  
możliwości  
rozszerzenia



**Rysunek:** Scatterplot między zmienną objaśnianą, a dwoma zmiennymi objaśniającymi, źródło: *Elements of statistical learning*, fig. 1.1



# Parametry modelu liniowego

Metody  
regresji  
liniowej

K. Melka

Wprowadzenie

Metoda naj-  
mniejszych  
kwadratów

Przykład

Błąd średnio-  
kwadratowy

Selekcja  
zmiennych

Regresja  
grzbietowa  
(Ridge  
regression)

LASSO

Porównanie i  
możliwości  
rozszerzenia

**TABLE 3.2.** *Linear model fit to the prostate cancer data. The Z score is the coefficient divided by its standard error (3.12). Roughly a Z score larger than two in absolute value is significantly nonzero at the  $p = 0.05$  level.*

Term	Coefficient	Std. Error	Z Score
Intercept	2.46	0.09	27.60
lcavol	0.68	0.13	5.37
lweight	0.26	0.10	2.75
age	-0.14	0.10	-1.40
lbph	0.21	0.10	2.06
svi	0.31	0.12	2.47
lcp	-0.29	0.15	-1.87
gleason	-0.02	0.15	-0.15
pgg45	0.27	0.15	1.74

źródło: *Elements of statistical learning*, tab. 3.2

# F-test

Metody  
regresji  
liniowej

K. Melka

Wprowadzenie

Metoda naj-  
mniejszych  
kwadratów

Przykład

Błąd średnio-  
kwadratowy

Selekcja  
zmiennych

Regresja  
grzbietowa  
(Ridge  
regression)

LASSO

Porównanie i  
możliwości  
rozszerzenia

Przeprowadzamy  $F$ -test, aby sprawdzić, czy możemy wyrzucić z modelu nieistotne zmienne.

$$F = \frac{(32.81 - 29.43)/(9 - 5)}{29.43/(67 - 9)} = 1.67$$

$$\Pr(F_{4,58} > 1.67) = 0.17$$

# Średni błąd predykcji

Metody  
regresji  
liniowej

K. Melka

Wprowadzenie

Metoda naj-  
mniejszych  
kwadratów

Przykład

Błąd średnio-  
kwadratowy

Selekcja  
zmiennych

Regresja  
grzbietowa  
(Ridge  
regression)

LASSO

Porównanie i  
możliwości  
rozszerzenia

Średni błąd predykcji na zbiorze testowym wynosi 0.521. Z kolei, dla predykcji opartej na użyciu średniej wartości zmiennej objaśnianej ze zbioru treningowego, otrzymaliśmy 1.057. Oznacza to, że nasz model zredukował bazowy współczynnik błędów o około 50%.

# Błąd średniokwadratowy

Metody  
regresji  
liniowej

K. Melka

Wprowadzenie

Metoda naj-  
mniejszych  
kwadratów

Przykład

Błąd średnio-  
kwadratowy

Selekcja  
zmiennych

Regresja  
grzbietowa  
(Ridge  
regression)

LASSO

Porównanie i  
możliwości  
rozszerzenia

Metoda najmniejszych kwadratów estymuje parametry  $\beta$  z najmniejszą możliwą wariancją z pośród wszystkich nieobciążonych liniowych estymatorów.

$$\blacksquare MSE(\hat{\beta}) = E(\hat{\beta} - \beta)^2 = Var(\hat{\beta}) + [E(\hat{\beta}) - \beta]^2$$

Widać jednak, że może istnieć obciążony estymator z mniejszym błędem średniokwadratowym.

Jakakolwiek metoda, która przesuwaa współczynniki otrzymane z metody najmniejszych kwadratów bliżej 0, może w rezultacie być obciążonym estymatorem.

Błąd średniokwadratowy jest ściśle powiązany z oczekiwanym błędem predykcji:

$$\blacksquare E(Y_0 - \hat{f}(x_0))^2 = \sigma^2 + E(x_0^T \hat{\beta} - f(x_0))^2 = \sigma^2 + MSE(\hat{f}(x_0)).$$

# Po co nam w ogóle selekcja zmiennych?

Metody  
regresji  
liniowej

K. Melka

Wprowadzenie

Metoda naj-  
mniejszych  
kwadratów

Przykład

Błąd średnio-  
kwadratowy

Selekcja  
zmiennych

Regresja  
grzbietowa  
(Ridge  
regression)

LASSO

Porównanie i  
możliwości  
rozszerzenia

- Skuteczność predykcji: pozbywając się niektórych zmiennych (czyli zmieniając jej współczynniki na 0) możemy zwiększyć obciążenie, zmniejszając przy tym wariancję.
- Interpretacja: mniejsza liczba zmiennych pozwala nam na łatwiejszą i trafniejszą interpretację modelu.

# Best-Subset Selection

Metody  
regresji  
liniowej

K. Melka

Wprowadzenie

Metoda naj-  
mniejszych  
kwadratów

Przykład

Błąd średnio-  
kwadratowy


Selekcja  
zmiennych

Regresja  
grzbietowa  
(Ridge  
regression)

LASSO

Porównanie i  
możliwości  
rozszerzenia

Dla każdego  $k \in \{0, 1, 2, \dots, p\}$  znajdujemy podzbiór, dla którego otrzymujemy najmniejszą wartość  $RSS$ .



**Rysunek:** Best-Subset Selection dla danych o raku prostaty, źródło: *Elements of statistical learning, fig. 3.5*

# Forward- i Backward-Stepwise Selection

Metody  
regresji  
liniowej

K. Melka

Wprowadzenie

Metoda naj-  
mniejszych  
kwadratów

Przykład

Błąd średnio-  
kwadratowy

Selekcja  
zmiennych

Regresja  
grzbietowa  
(Ridge  
regression)

LASSO

Porównanie i  
możliwości  
rozszerzenia

- W Forward-Stepwise Selection startujemy z modelu z interceptem i z każdym krokiem dodajemy zmienną, która najmocniej poprawia dopasowanie.
- W Backward-Stepwise Selection startujemy z pełnego modelu i z każdym krokiem odejmujemy zmienną, która ma najmniejszy wpływ na model.

# Porównanie metod

Metody  
regresji  
liniowej

K. Melka

Wprowadzenie

Metoda naj-  
mniejszych  
kwadratów

Przykład


Błąd średnio-  
kwadratowy

Selekcja  
zmiennych

Regresja  
grzbietowa  
(Ridge  
regression)

LASSO

Porównanie i  
możliwości  
rozszerzenia



Rysunek:  $Y = X^T \beta + \varepsilon$ ;  $N = 300$ ;  $p = 31$ ;  $\beta_1, \dots, \beta_{10} \sim N(0, 0.4)$ ,  
pozostałe równe 0;  $\varepsilon \sim N(0, 6.25)$  źródło: *Elements of statistical  
learning, fig. 3.6*



# Ridge regression

Metody  
regresji  
liniowej

K. Melka

Wprowadzenie

Metoda naj-  
mniejszych  
kwadratów

Przykład

Błąd średnio-  
kwadratowy

Selekcja  
zmiennych

Regresja  
grzbietowa  
(Ridge  
regression)

LASSO

Porównanie i  
możliwości  
rozszerzenia

- $\hat{\beta}^R = \operatorname{argmin}_{\beta} \left\{ \sum_{i=1}^N (y_i - \beta_0 - \sum_{j=1}^p x_{ij} \beta_j)^2 + \lambda \sum_{j=1}^p \beta_j^2 \right\}$ .
- $\lambda \geq 0$  - parametr regularyzacyjny: im większa wartość, tym większy stopień obciążenia współczynników w stronę 0.
- $\hat{\beta}^R = \operatorname{argmin}_{\beta} \sum_{i=1}^N (y_i - \beta_0 - \sum_{j=1}^p x_{ij} \beta_j)^2$ , pod warunkiem  $\sum_{j=1}^p \beta_j^2 \leq t$ .

# Postać macierzowa

Metody  
regresji  
liniowej

K. Melka

Wprowadzenie

Metoda naj-  
mniejszych  
kwadratów

Przykład

Błąd średnio-  
kwadratowy

Selekcja  
zmiennych

Regresja  
grzbietowa  
(Ridge  
regression)

LASSO

Porównanie i  
możliwości  
rozszerzenia

- $RSS(\lambda) = (\mathbf{y} - \mathbf{X}\beta)^T(\mathbf{y} - \mathbf{X}\beta) + \lambda\beta^T\beta.$
- $\hat{\beta}^R = (\mathbf{X}^T\mathbf{X} + \lambda\mathbf{I})^{-1}\mathbf{X}^T\mathbf{y}$
- W przypadku ortonormalnym  $\hat{\beta}^R = \hat{\beta}^{LS}/(1 + \lambda).$

# Ridge regression

Metody  
regresji  
liniowej

K. Melka

Wprowadzenie

Metoda naj-  
mniejszych  
kwadratów

Przykład


Błąd średnio-  
kwadratowy

Selekcja  
zmiennych

Regresja  
grzbietowa  
(Ridge  
regression)

LASSO

Porównanie i  
możliwości  
rozszerzenia



Rysunek: Współczynniki obliczone przy pomocy regresji grzbietowej w zależności od wartości  $\lambda$ ; czerwoną linią zaznaczono wartość optymalną wyznaczoną przez krosvalidację, źródło: *Elements of statistical learning*, fig. 3.8

# LASSO

Metody  
regresji  
liniowej

K. Melka

Wprowadzenie

Metoda naj-  
mniejszych  
kwadratów

Przykład

Błąd średnio-  
kwadratowy

Selekcja  
zmiennych

Regresja  
grzbietowa  
(Ridge  
regression)

LASSO

Porównanie i  
możliwości  
rozszerzenia

- $\hat{\beta}^L = \operatorname{argmin} \sum_{i=1}^N \left( y_i - \beta_0 - \sum_{j=1}^p x_{ij} \beta_j \right)^2$ , pod warunkiem

$$\sum_{j=1}^p |\beta_j| \leq t$$

- $\hat{\beta}^L = \operatorname{argmin} \left\{ \frac{1}{2} \sum_{i=1}^N (y_i - \beta_0 - \sum_{j=1}^p x_{ij} \beta_j)^2 + \lambda \sum_{j=1}^p |\beta_j| \right\}$ .

- Gdy  $t > \sum_{j=1}^p |\hat{\beta}_j^{LS}|$ , to  $\hat{\beta}_j^L = \hat{\beta}_j^{LS}$  dla każdego  $j$ .

# LASSO

Metody  
regresji  
liniowej

K. Melka

Wprowadzenie

Metoda naj-  
mniejszych  
kwadratów

Przykład


Błąd średnio-  
kwadratowy

Selekcja  
zmiennych

Regresja  
grzbietowa  
(Ridge  
regression)

LASSO

Porównanie i  
możliwości  
rozszerzenia



**Rysunek:** Współczynniki obliczone przy pomocy LASSO w zależności od wartości  $s = t / \sum_{j=1}^p \hat{\beta}_j$ ; czerwoną linią zaznaczono wartość optymalną wyznaczoną przez krosvalidację, źródło: *Elements of statistical learning*, fig. 3.10

# Estymatory $\beta$ w zależności od wartości $\hat{\beta}^{LS}$

Metody  
regresji  
liniowej

K. Melka

Wprowadzenie

Metoda naj-  
mniejszych  
kwadratów

Przykład

Błąd średnio-  
kwadratowy

Selekcja  
zmiennych


Regresja  
grzbietowa  
(Ridge  
regression)

LASSO

Porównanie i  
możliwości  
rozszerzenia

**TABLE 3.4.** Estimators of  $\beta_j$  in the case of orthonormal columns of  $\mathbf{X}$ .  $M$  and  $\lambda$  are constants chosen by the corresponding techniques;  $\text{sign}$  denotes the sign of its argument ( $\pm 1$ ), and  $x_+$  denotes “positive part” of  $x$ . Below the table, estimators are shown by broken red lines. The 45° line in gray shows the unrestricted estimate for reference.

Estimator	Formula
Best subset (size $M$ )	$\hat{\beta}_j \cdot I( \hat{\beta}_j  \geq  \hat{\beta}_{(M)} )$
Ridge	$\hat{\beta}_j / (1 + \lambda)$
Lasso	$\text{sign}(\hat{\beta}_j)( \hat{\beta}_j  - \lambda)_+$



źródło: *Elements of statistical learning*, tab. 3.4

# Geometria LASSO i regresji grzbietowej

Metody  
regresji  
liniowej

K. Melka

Wprowadzenie

Metoda naj-  
mniejszych  
kwadratów

Przykład


Błąd średnio-  
kwadratowy

Selekcja  
zmiennych

Regresja  
grzbietowa  
(Ridge  
regression)

LASSO

Porównanie i  
możliwości  
rozszerzenia



**Rysunek:** Zaznaczone obszary to kolejno  $|\beta_1| + |\beta_2| \leq t$  i  $\beta_1^2 + \beta_2^2 \leq t^2$ ; czerwone elipsy to kontury funkcji błędów względem metody najmniejszych kwadratów, źródło: *Elements of statistical learning*, fig. 3.11

# Generalizacja regresji grzbietowej i LASSO

Metody  
regresji  
liniowej

K. Melka

Wprowadzenie

Metoda naj-  
mniejszych  
kwadratów

Przykład

Błąd średnio-  
kwadratowy


Selekcja  
zmiennych

Regresja  
grzbietowa  
(Ridge  
regression)

LASSO

Porównanie i  
możliwości  
rozszerzenia

$$\hat{\beta} = \operatorname{argmin}_{\beta} \left\{ \sum_{i=1}^N (y_i - \beta_0 - \sum_{j=1}^p x_{ij} \beta_j)^2 + \lambda \sum_{j=1}^p |\beta_j|^q \right\}, q \geq 0$$



**Rysunek:** Kontury stałej wartości  $\sum_j |\beta_j|^q$  dla danych wartości  $q$ ,  
źródło: *Elements of statistical learning*, fig. 3.12



# Elastic net

Metody  
regresji  
liniowej

K. Melka

Wprowadzenie

Metoda naj-  
mniejszych  
kwadratów

Przykład

Błąd średnio-  
kwadratowy

Selekcja  
zmiennych


Regresja  
grzbietowa  
(Ridge  
regression)

LASSO


Porównanie i  
możliwości  
rozszerzenia

$$\lambda \sum_{j=1}^p (\alpha \beta_j^2 + (1 - \alpha) |\beta_j|)$$

$q = 1.2$



$\alpha = 0.2$



Rysunek: Porównanie kary elastic net i  $\sum_j |\beta_j|^q$  dla  $q = 1.2$ , źródło: *Elements of statistical learning, fig. 3.13*

# Porównanie wyników dla danych o raku prostaty

Metody  
regresji  
liniowej

K. Melka

Wprowadzenie

Metoda naj-  
mniejszych  
kwadratów

Przykład

Błąd średnio-  
kwadratowy

Selekcja  
zmiennych

Regresja  
grzbietowa  
(Ridge  
regression)

LASSO

Porównanie i  
możliwości  
rozszerzenia

**TABLE 3.3.** *Estimated coefficients and test error results, for different subset and shrinkage methods applied to the prostate data. The blank entries correspond to variables omitted.*

Term	LS	Best Subset	Ridge	Lasso
Intercept	2.465	2.477	2.452	2.468
lcavol	0.680	0.740	0.420	0.533
lweight	0.263	0.316	0.238	0.169
age	-0.141		-0.046	
lbph	0.210		0.162	0.002
svi	0.305		0.227	0.094
lcp	-0.288		0.000	
gleason	-0.021		0.040	
pgg45	0.267		0.133	
Test Error	0.521	0.492	0.492	0.479
Std Error	0.179	0.143	0.165	0.164

źródło: *Elements of statistical learning, tab. 3.3*

Dziękuję za uwagę.