

# Rozszerzenia bazy

## Piecewise polynomials and splines

Karolina Sopata

21 marca 2022 r.

# Model liniowy

$$E(Y|X) = f(X) = \beta_0 + \beta_1 X_1 + \dots + \beta_p X_p$$

- ▶ prosty w interpretacji
- ▶ nie powoduje overfittingu przy małej liczbie  $N$  i/lub dużym  $p$
- ▶ nie zawsze adekwatny

Przykład kwadratowego modelu regresji:

$$E(Y|X) = \beta_0 + \beta_1 X_1 + \beta_2 X_1^2$$

# Rozszerzenia bazy

$X$  - wektor zmiennych objaśniających o długości  $p$

$h_m(X) : \mathbb{R}^p \rightarrow \mathbb{R}$

$m = 1, \dots, M$

$$E(Y|X) = f(X) = \sum_{m=1}^M \beta_m h_m(X) = \beta_1 h_1(X) + \dots + \beta_M h_M(X)$$

$h_m(X)$  - funkcje bazowe rozpinające przestrzeń funkcji  $f$

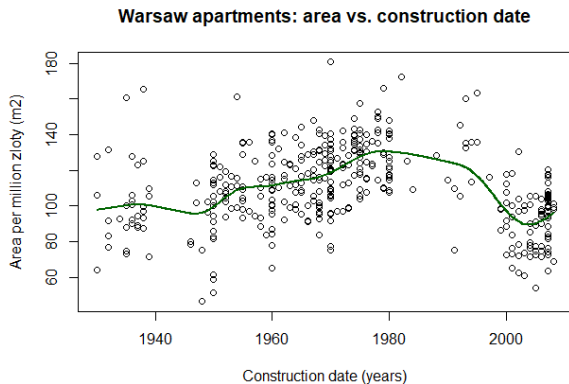
# Przykłady funkcji bazowych

- ▶  $h_m(X) = X_m$ , gdzie  $m=1, \dots, p$
- ▶  $h_m(X) = X_j^2$   
 $h_m(X) = X_j X_k$
- ▶  $h_m(X) = \log(X_j)$   
 $h_m(X) = \sqrt{X_j}$
- ▶  $h_m(X) = \|X\|$
- ▶  $h_m(X) = \mathbb{1}(L_m \leq X_k < U_m)$

# Piecewise polynomials and splines

- przyjmujemy, że wektor  $X$  jest jednowymiarowy
- **piecewise polynomial function** - wielomian odcinkowy - dzielimy dziedzinę  $X$  na rozłączne przedziały, na każdym z przedziałów definiujemy osobną funkcję wielomianową
- **spline** - funkcja sklejana - rzeczywista funkcja gładka, dla której istnieje rodzina podprzedziałów dziedziny taka, że funkcja ta jest wielomianem na każdym z tych podprzedziałów

# Przykład funkcji gładkiej



**Rysunek:** Model powierzchni jaką można nabyć w  $m^2$  za milion złotych w zależności od daty budowy budynku mieszkalnego, 30 funkcji bazowych

# Różne drogi wyboru funkcji bazowych

1. **Restriction methods** - stopień złożoności modelu jest ograniczony poprzez z góry określony limit klas funkcji jakie mogą zostać użyte

$$f(X) = \sum_{j=1}^p f_j(X_j) = \sum_{j=1}^p \sum_{m=1}^{M_j} \beta_{jm} h_{jm}(X_j)$$

2. **Selection methods** - wybór spośród wszystkich funkcji, sprawdzenie które funkcje istotnie zmieniają dopasowanie modelu do danych, np. metoda CART, MARS
3. **Regularization methods** - użycie wszystkich dostępnych funkcji z zastosowaniem pewnych restrykcji, np. ridge regression, LASSO

# Piecewise polynomials - przykład 1

$$h_1(X) = I(X < \xi_1), \quad h_2(X) = I(\xi_1 \leq X < \xi_2), \quad h_3(X) = I(\xi_2 \leq X)$$

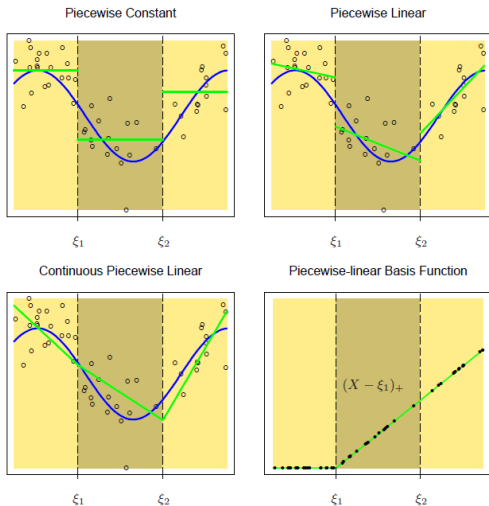
- powyższe funkcje przyjmują dodatnie wartości na rozłącznych przedziałach
- estymator najmniejszych kwadratów dla modelu

$$f(X) = \sum_{m=1}^3 \beta_m h_m(X)$$

sprowadza się do  $\hat{\beta}_m = \bar{Y}_m$  (średnia zmiennych objaśnianych na m-tym przedziale)



# Piecewise polynomials - przykład 1 c.d.



**Rysunek:** W lewym górnym rogu: odcinkowa funkcja stała, w prawym górnym rogu: odcinkowa funkcja liniowa; źródło: *T.Hastie, The elements of statistical learning*

# Piecewise polynomials - przykład 1 c.d.

$$h_1(X) = I(X < \xi_1), \quad h_2(X) = I(\xi_1 \leq X < \xi_2), \quad h_3(X) = I(\xi_2 \leq X)$$

$$h_4(X) = \mathbb{1}(X < \xi_1)X$$

$$h_5(X) = \mathbb{1}(\xi_1 \leq X < \xi_2)X$$

$$h_6(X) = \mathbb{1}(X \leq \xi_2)X$$

Warunek ciągłości w węzłach:

$$f(\xi_i^-) = f(\xi_i^+)$$

Stąd:


$$\beta_1 + \xi_1\beta_4 = \beta_2 + \xi_1\beta_5$$

$$\beta_2 + \xi_2\beta_5 = \beta_3 + \xi_1\beta_6$$

# Truncated power function

Truncated power function dla węzła  $\xi_i$ :

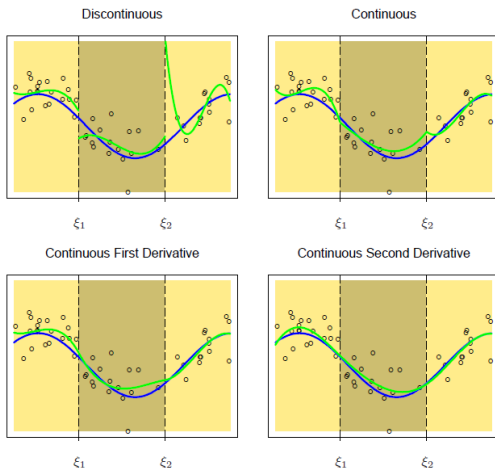
$$h_i(X) = (X - \xi_i)_+^d = \begin{cases} 0, & X < \xi_i \\ (X - \xi_i)^d, & X \geq \xi_i \end{cases}$$



**Rysunek:** Truncated power function dla węzła  $\xi_i = 1$  dla  $d=1$  oraz  $d=3$ ;  
**źródło:** <https://documentation.sas.com>

# Piecewise polynomials - przykład 2

Piecewise Cubic Polynomials



**Rysunek:** Przykłady sześciennych wielomianów odcinkowych dopasowanych do tych samych danych; źródło: *T.Hastie, The elements of statistical learning*

# Cubic spline

## Generalnie:

$$h_j(X) = X^{j-1}, j = 1, \dots, M$$

$$h_{M+l}(X) = (X - \xi_l)_+^{M-1}, l = 1, \dots, K$$

**Funkcje bazowe dla sześcienniej funkcji składanej z dwoma węzłami:**

$$K = 2$$

$$M = 4$$

$$h_1(X) = 1$$

$$h_2(X) = X$$

$$h_3(X) = X^2$$

$$h_4(X) = X^3$$

$$h_5(X) = (X - \xi_1)_+^3$$

$$h_6(X) = (X - \xi_2)_+^3$$

## Model

$$E(Y|X) = f(X) = \beta_1 h_1(X) + \dots + \beta_6 h_6(X)$$

# Splines


- ważnym zagadnieniem jest odpowiedni dobór stopnia funkcji sklejanej, liczby węzłów i ich położenia
- położenie węzłów może być dobrane metodą parametryzacji rodziny funkcji sklejanych według liczby funkcji bazowych lub stopni swobody i wyznaczone na podstawie rozmieszczenia zmiennych

Polecenie w R:

$$bs(x, df=7)$$

generuje macierz funkcji bazowych na podstawie N obserwacji dla funkcji sklejanej stopnia 3 z  $7-3=4$  węzłami.

# Natural cubic splines



**Rysunek:** Krzywe wariancji punktowej dla różnych modeli dopasowanych do danych pochodzących z rozkładu jednostajnego z dodanym szumem o stałej wariancji; źródło: *T.Hastie, The elements of statistical learning*.

# Natural cubic spline

- warunek: funkcja poza węzłami zewnętrznymi jest liniowa
- wprowadzenie takiego warunku powoduje zmniejszenie się wariancji punktowej poza węzłami zewnętrznymi, natomiast dzieje się to kosztem obciążenia

## Przykład

$$N_1(X) = 1, \quad N_2(X) = X, \quad N_{k+2}(X) = d_k(X) - d_{K-1}(X),$$

gdzie:

$$d_k(X) = \frac{(X - \xi_k)_+^3 - (X - \xi_K)_+^3}{\xi_K - \xi_k}$$



# Smoothing splines

- złożoność dopasowania jest kontrolowana przez parametr regularyzacji  $\lambda$
- $\lambda$  - parametr wygładzający

$$RSS(f, \lambda) = \sum_{i=1}^N (y_i - f(x_i))^2 + \lambda \int f''(t)^2 dt$$

## Skrajne przypadki

- ▶  $\lambda = 0$  -  $f$  może być dowolną funkcją, która przybliży rzeczywistą zależność
- ▶  $\lambda = \infty$  - prosta dopasowana metodą najmniejszych kwadratów

# Smoothing splines

Zdefiniowane na poprzednim slajdzie kryterium posiada skończenie wymiarowe unikalne minimum będące naturalnym sześciennym splajnem z węzłami w wartościach  $x_i$ , gdzie  $i = 1, \dots, N$ .

Rozwiązanie - naturalny splajn sześcienny, stąd funkcję  $f$  możemy przedstawić w następującej postaci:

$$f(x) = \sum_{j=1}^N N_j(x)\theta_j$$

gdzie  $N_j(X)$  -  $N$ -wymiarowy zbiór funkcji bazowych reprezentujący daną rodzinę splajnów naturalnych.

# Smoothing splines

Kryterium:

$$RSS(\theta, \lambda) = (y - N\theta)^T (y - N\theta) + \lambda \theta^T \Omega_N \theta$$

gdzie  $\{N\}_{ij} = N_j(x_i)$ ,  
 $\{\Omega_N\}_{jk} = \int N_j''(t) N_k''(t) dt$


Rozwiązanie (uogólniona regresja grzbietowa):

$$\hat{\theta} = (N^T N + \lambda \Omega_N)^{-1} N^T y$$

Stąd:

$$\hat{f}(X) = \sum_{j=1}^N N_j(X) \hat{\theta}_j$$

# Przykład dopasowania funkcji gładkiej



**Rysunek:** Dane: względna zmiana w mineralizacji kości kręgosłupa w ciągu kolejnych dwóch badań w odstępie roku w zależności od wieku badana u młodzieży; *źródło: T.Hastie, The elements of statistical learning.*

Dziękuję za uwagę!