

# Błędy predykcji, ocena dopasowania modelu

Karolina Sopata

25 kwietnia 2022

**Selekcja modelu** (*model selection*) - wybór najlepszego spośród rozważanych modeli na podstawie ich dopasowania do danych (do zbioru treningowego)

**Ocena dopasowania modelu** (*model assesement*) - oszacowanie błędu predykcji wybranego modelu na nowych danych (spoza zbioru treningowego)

# Podział danych na zbiory



Przykładowe podziały:

<b>treningowy</b>	<b>walidacyjny</b>	<b>testowy</b>
50%	25%	25%
70%	15%	15%
80%	-	20 %

- ▶ metody wykorzystujące wielokrotnie tą samą próbę
  - ▶ bootstrap
  - ▶ krosvalidacja
- ▶ metody analityczne
  - ▶ kryteria informacyjne: AIC, BIC
  - ▶ regularyzacja: ridge, LASSO

# Błąd predykcji dla obserwacji

$$PE_i = L(y_i, \hat{f}(x_i))$$

$y_i$  - wartość zmiennej objaśnianej dla danej obserwacji

$\hat{f}(x_i)$  - wartość predykcji

$L$  - funkcja straty

$$L(Y, \hat{f}(X)) = \begin{cases} (Y - \hat{f}(X))^2 \\ |Y - \hat{f}(X)| \end{cases}$$

# Rodzaje błędów predykcji

- ▶  $Err$  - oczekiwany błąd predykcji
- ▶  $Err_T$  - oczekiwany błąd predykcji dla ustalonego zbioru treningowego
- ▶  $\bar{err}$  - błąd treningowy
- ▶  $Err_{in}$  - oczekiwany błąd »wewnątrz próby«

# Oczekiwany błąd predykcji

$$Err = E[L(Y, \hat{f}(X))]$$

$Y$  - zmienna objaśniana

$\hat{f}(X)$  - wartość predykcji dla zmiennej/zmiennych objaśniających  $X$

**test error, generalization error** - oczekiwana wartość błędu predykcji dla modelu uczonego na ustalonym zbiorze treningowym  $\tau$

$$Err_{\tau} = E_{X,Y}[L(Y, \hat{f}(X)) | \tau]$$

**Oczekiwany błąd predykcji ( $Err$ )** - wartość oczekiwana  $Err_{\tau}$  po wszystkich możliwych zbiorach treningowych:

$$Err = E[Err_{\tau}] = E[E_{X,Y}[L(Y, \hat{f}(X)) | \tau]]$$




# Błąd treningowy ( $\overline{err}$ )


$\overline{err}$  - uśrednione błędy predykcji dla wszystkich obserwacji ze zbioru treningowego

$$\overline{err} = \frac{1}{N} \sum_{i=1}^N L(y_i, \hat{f}(x_i))$$

$N$ -liczba obserwacji w próbie



# Obciążenie, wariancja, złożoność modelu



# Obciążenie, wariancja, złożoność modelu

$$Y = f(X) + \epsilon$$

gdzie  $E(\epsilon) = 0$ ,  $Var(\epsilon) = \sigma_\epsilon^2$ ,

błąd predykcji dla modelu regresji, dla pewnego ustalonego wektora zmiennych objaśniających  $X = x_0$ :

$$\begin{aligned} \text{Err}(x_0) &= E[(Y - \hat{f}(x_0))^2 | X = x_0] \\ &= \sigma_\epsilon^2 + [E\hat{f}(x_0) - f(x_0)]^2 + E[\hat{f}(x_0) - E\hat{f}(x_0)]^2 \\ &= \sigma_\epsilon^2 + \text{Bias}^2(\hat{f}(x_0)) + \text{Var}(\hat{f}(x_0)) \\ &= \text{Irreducible Error} + \text{Bias}^2 + \text{Variance}. \end{aligned}$$

# Regresja liniowa - błąd predykcji

$$\begin{aligned}\text{Err}(x_0) &= E[(Y - \hat{f}_p(x_0))^2 | X = x_0] \\ &= \sigma_\varepsilon^2 + [f(x_0) - E\hat{f}_p(x_0)]^2 + \|h(x_0)\|^2 \sigma_\varepsilon^2.\end{aligned}$$

gdzie  $h(x_0) = X(X^T X)^{-1}x_0$  - wektor wag, które dają następujące dopasowanie:

$$\hat{f}_p(X_0) = x_0^T (X^T X)^{-1} X^T y$$

Stąd  $\text{Var}[\hat{f}_p(X_0)] = \|h(x_0)\|^2 \sigma_\varepsilon^2$

Błąd "wewnątrz próby" (in-sample error):

$$\frac{1}{N} \sum_{i=1}^N \text{Err}(x_i) = \sigma_\varepsilon^2 + \frac{1}{N} \sum_{i=1}^N [f(x_i) - E\hat{f}(x_i)]^2 + \frac{P}{N} \sigma_\varepsilon^2,$$

# Regresja grzbietowa - błąd predykcji

$\beta_*$  - wektor parametrów dla najlepszego dopasowania liniowego

$$\beta_* = \arg \min_{\beta} E (f(X) - X^T \beta)^2 .$$

$$\begin{aligned} E_{x_0} [f(x_0) - E\hat{f}_{\alpha}(x_0)]^2 &= E_{x_0} [f(x_0) - x_0^T \beta_*]^2 + E_{x_0} [x_0^T \beta_* - E x_0^T \hat{\beta}_{\alpha}]^2 \\ &= \text{Ave}[\text{Model Bias}]^2 + \text{Ave}[\text{Estimation Bias}]^2 \end{aligned}$$

## $Err_{in}$ - in-sample error

$$Err_{in} = \frac{1}{N} \sum_{i=1}^N E_{Y^0} [L(Y_i^0, \hat{f}(x_i)) | \tau]$$

- $x_i \in \tau$  - wartości zmiennych objaśniających z ustalonego zbioru treningowego  $\tau$
- $Y_i^0 \in Y^0$  - nowa wartość zmiennej odpowiedzi dla  $x_i$  (różna od  $y_i$  danych w zbiorze treningowym)

# Optymizm błędu treningowego

Optymizm:

$$op \equiv Err_{in} - \overline{err}$$

Oczekiwany optyzmizm:

$$\omega \equiv E_Y(op)$$

Generalnie:

$$\omega = \frac{2}{N} \sum_{i=1}^N Cov(\hat{y}_i, y_i)$$



## Optymizm błędu treningowego c.d.

$$E_y(Err_{in}) = E_y(\overline{err}) + E_Y(op)$$

$$E_y(Err_{in}) = E_y(\overline{err}) + \omega$$

$$E_y(Err_{in}) = E_y(\overline{err}) + \frac{2}{N} \sum_{i=1}^N Cov(\hat{y}_i, y_i)$$

Dla modelu addytywnego ( $Y = f(X) + \epsilon$ ) upraszczamy:

$$Cov(\hat{y}_i, y_i) = d\sigma_\epsilon^2$$

$d$  - liczba zmiennych w modelu

Wówczas:

$$E_y(Err_{in}) = E_y(\overline{err}) + 2\frac{d}{N}\sigma_\epsilon^2$$

Estymator błędu in-sample:

$$\widehat{Err}_{in} = \overline{err} + \hat{\omega}$$

Stosujemy (gdy  $d$  parametrów jest dopasowanych metodą najmniejszych kwadratów):

$$\widehat{Err}_{in} = \overline{err} + 2\frac{d}{N}\hat{\sigma}_\epsilon^2$$

Dana wielkość znana jako  $C_p$  Mallows'a:

$$C_p = \overline{err} + 2\frac{d}{N}\hat{\sigma}_\epsilon^2$$

# Kryterium AIC

Stosowane, gdy funkcją straty jest funkcja log-wiarogodności.

$$\text{loglik} = \sum_{i=1}^N \log \Pr_{\hat{\theta}}(y_i).$$

$$\text{AIC} = -\frac{2}{N} \cdot \text{loglik} + 2 \cdot \frac{d}{N}$$

# Kryterium BIC

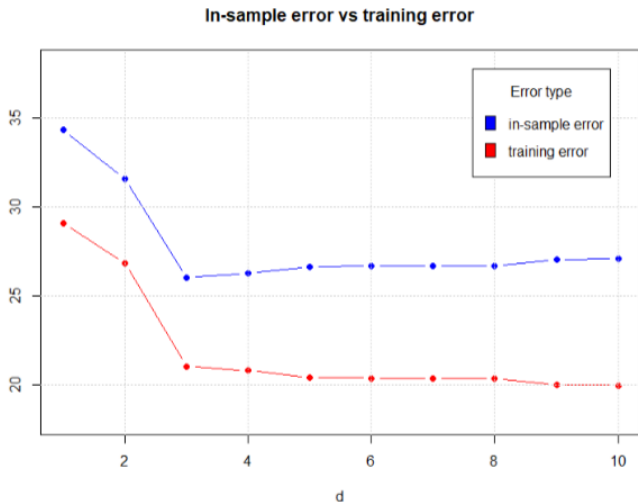
$$\text{BIC} = -2 \cdot \log \text{lik} + (\log N) \cdot d$$

Model gaussowski:

$$\text{BIC} = \frac{N}{\sigma_\varepsilon^2} \left[ \overline{\text{err}} + (\log N) \cdot \frac{d}{N} \sigma_\varepsilon^2 \right]$$

Kryterium BIC jest proporcjonalne do AIC.

# Błąd treningowy a błąd in-sample



Dziękuję za uwagę!