

# Jakość uczenia i generalizacja



# Dokładność uczenia

---

- Jest koncepcją miary w jakim stopniu nasza sieć nauczyła się rozwiązywać określone zadanie
- Dokładność mówi na ile nauczyliśmy się rozwiązywać zadania które już znamy, a generalizacja na ile potrafimy rozwiązywać nowe zadania podobne do tych które znamy ale mogą też być inne

# Miary dokładności uczenia dla problemów klasyfikacyjnych

## □ Macierz konfuzji

		Rzeczywiste	
		Prawda	Fałsz
Oszacowane	Pozytywne	$TP$	$FP$
	Negatywne	$FN$	$TN$

- parametr (ang. true positive)  $TP$
- parametr (ang. true negative)  $TN$
- parametr (ang. false positive)  $FP$
- parametr (ang. false negative)  $FN$
- parametr (ang. positive)  $Pos = TP + FP$
- parametr (ang. negative)  $Neg = TN + FN$
- parametr (ang. true)  $True = TP + TN$
- parametr (ang. false)  $False = FP + FN$

# Miary dokładności uczenia dla problemów klasyfikacyjnych cd.


---

- Dokładność (ang. accuracy)
$$Err = \frac{m^{err}}{m}$$
$$Acc = 1 - Err$$
- Dokładność zbalansowana (ang. Balanced accuracy)
$$BErr = \frac{1}{c} \sum_{i=1}^c \left( \frac{m_i^{err}}{m_i} \right)$$
$$BAcc = 1 - BErr$$
- Czułość lub wrażliwość (ang. sensitivity, recall)  $Se = \frac{TP}{TP+FN}$
- Znamienność (ang. specificity)  $Sp = \frac{TN}{TN+FP}$
- Precyzja (ang. precision)  $P = \frac{TP}{TP+FP}$
- Miara  $F_\beta$  (ang.  $F_\beta$  measure)  $F_\beta = \frac{(\beta^2+1)TP}{(\beta^2+1)TP+FP+\beta^2FN}$ , która dla  $\beta = 1$  przyjmuje postać  $F_{1.0} = \frac{2TP}{2TP+FP+FN} = \frac{2Se \cdot P}{Se+P}$
- Dokładność  $Acc = \frac{TP+TN}{Pos+Neg}$
- Dokładność zbalansowana  $BAcc = \frac{1}{c} \left( \frac{TP}{Pos} + \frac{TN}{Neg} \right)$

# Miary dokładności uczenia

## krzywa ROC i AUC

---



# Miary dokładności uczenia dla problemów regresyjnych

---

- Błąd średniokwadratowy (MSE)

$$e = \frac{1}{n} \sum_{i=1}^n (y_i - d_i)^2$$

- (RMSE)

$$e = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - d_i)^2}$$

- Błąd średni (ME)  $e = \frac{\sum_i |y_i - d_i|}{n}$

- Znormalizowany błąd średniokwadratowy (NMSE)

$$e = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - d_i)^2}}{\sigma_y \sigma_d}$$

# Co to jest generalizacja

---

- Generalizacja – zdolność do uogólniania zdobytej wiedzy
  - Jeśli wszyscy uczyliby się do egzaminu równy okres czasu to i tak będą rozbieżności w ocenach.
  - Dlaczego?
  - Gdyż jedni uczą się szybciej a inni wolniej, jedni uczą się z przyjemnością fizyki, a inni wolą uczyć się na temat malarstwa.
  - To samo zjawisko występuje w SSN i inteligencji obliczeniowej
  - Generalizacja jest więc koncepcją określającą zdolnością do zastosowania zdobytej wiedzy w nowych sytuacjach, z którymi system nie spotkał się dotychczas.


# Co to jest generalizacja

---

Generalizacja  $\neq$  Dokładność




# Generalizacja a dokładność




# Dokładność a generalizacja

- Zbyt duża generalizacja




# Dokładność a generalizacja

## □ Przeuczenie




# Dokładność a generalizacja

- Dobra generalizacja



# Dokładność a generalizacja

---



# Problem rozmiaru sieci

---

- Im mamy bardziej pojemną sieć tym dłużej musimy się uczyć i tym więcej przypadków musimy przeanalizować
  
- Problem
  - Jeżeli mamy bardzo dużą sieć to może dojść do niedouczenia sieci, jak i do przeuczenia się danego problemu
  - Przykład
  - Jeżeli mamy do rozwiązania zadanie z fizyki aby określić drogę jaką przebył kamień spadając przez 10s to można zadanie rozwiązać:
    - a) 
$$s = \frac{g \cdot t^2}{2}$$
    - b) wyliczyć z definicji przyspieszenia iż jest to druga pochodna z drogi po czasie, robiąc odpowiednie przekształcenia i uwzględniając tarcie powietrza itp..

# Metody oceny generalizacji

---

- Zasada minimalnej długości opisu (ang. Minimal description length) - bazuje na analizie rozmiaru zbioru oraz stopnia złożoności modelu  $h$  wyrażonego w bitach

$$h_{MDL} = \arg \min_{h \in H} (L_C(h) + L_C(X|h))$$

Gdzie:

$L_C(h)$  - jest długością opisu modelu  $h$  pod warunkiem kodowania  $C$

$L_C(X|h)$  - jest długością opisu zbioru  $X$  pod warunkiem modelu  $h$  oraz kodowania  $C$ .

# Metody oceny generalizacji cd.

---

- Zasada minimalizacji ryzyka strukturalnego (ang. structural risk minimization, SRM) - Idea współczynnika SRM polega na uwzględnieniu obok dokładności modelu  $h$  drugiego czynnika opisującego jego złożoność, tym samym wariancję modelu

$$R(h) \leq R_{emp}(h) + \sqrt{\left( \frac{VC(h)(\log(2m/VC(h)) + 1) - \log(\eta/4)}{h} \right)}$$

$R(h)$  - Rzeczywisty koszt popełnienia błędu

$R_{emp}(h)$  - Empiryczny koszt popełnienia błędu

$VC(h)$  - Współczynnik Vapnika-Czervonenkisa

$\eta$  - Pewna stała



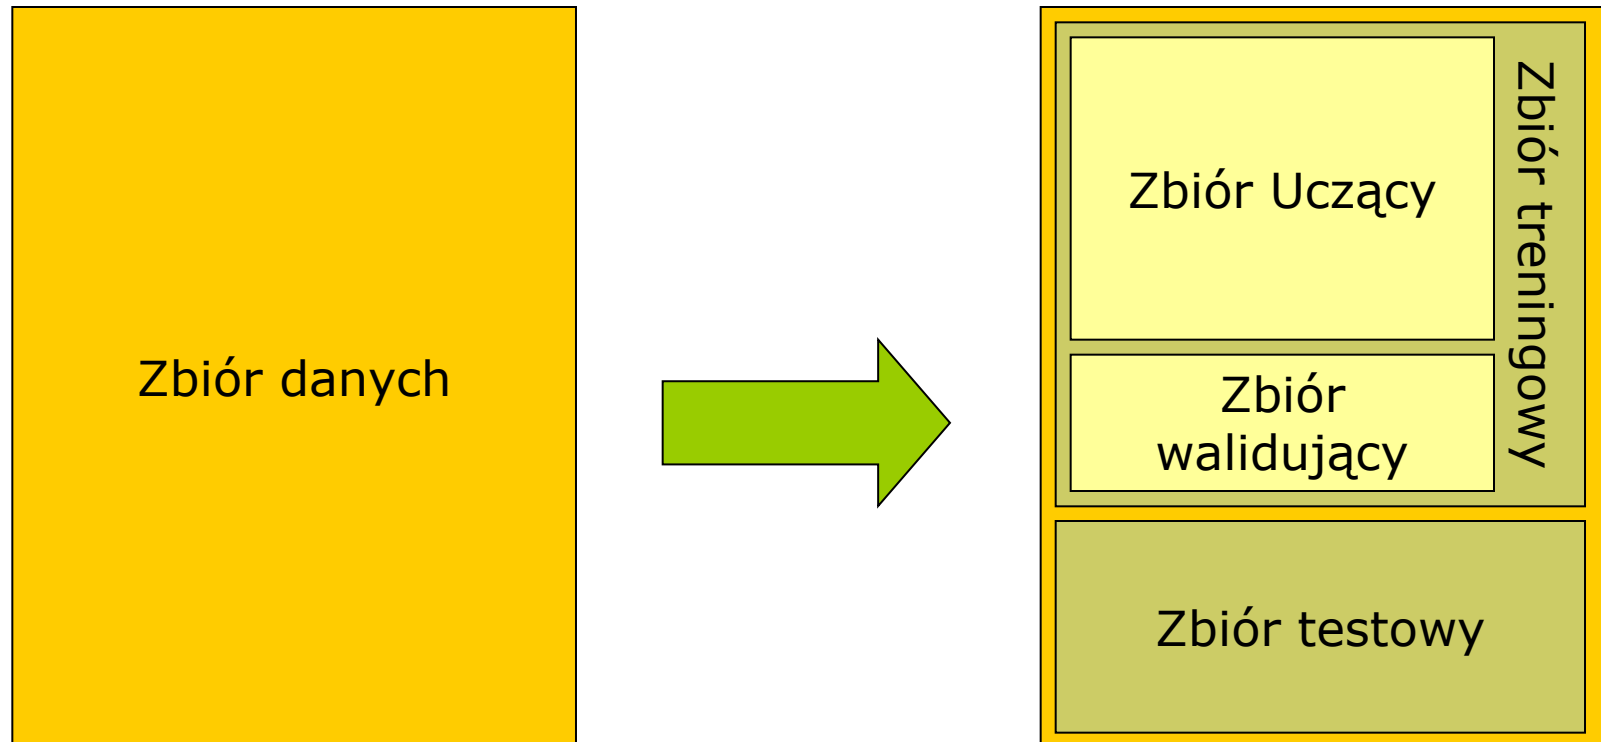
# Empiryczne metody oceny generalizacji

---

- Podział trening/test
- Krosvalidacja (ang cross validation) lub test krzyżowy
- Test typu jeden pozostaw
- Test typu bootstrap

# Podział trening test

- Wydzielenie ze zbioru danych części na której będzie dokonywane uczenie i części na której będzie dokonywana ocena (testowanie) modelu
  - Wada – łatwo może dojść do przeuczenia modelu lub dostosowania modelu do zbioru testowego!!!

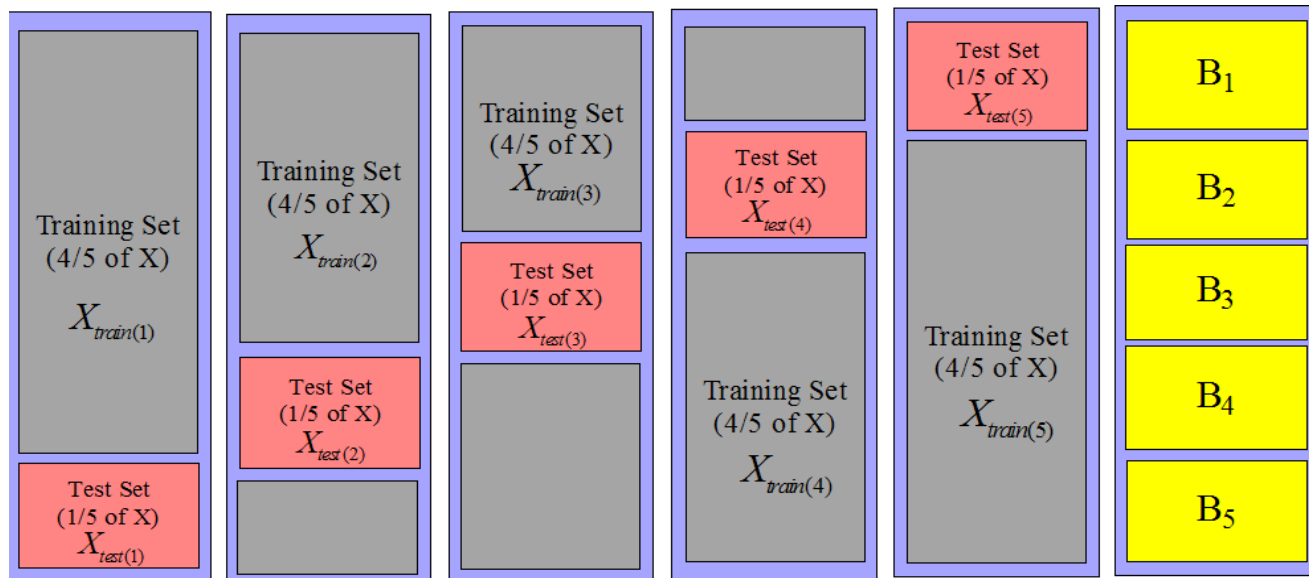


# Test krzyżowy

- Podziel zbiór danych  $X$  na  $N$  równych niezależnych części  $R(i)$ ,  $i=1..N$  (losowanie bez zwracania)
- For  $i=1:N$ 
  - Ucz model na zbiorze  $X / R(i)$
  - Testuj model na  $R(i)$

Dwa typy testu krzyżowego:

- normalny – losowo podział zbioru danych
- Stratyfikowany – losowy podział ale zapewniający stały rozkład punktów w poszczególnych klasach



# Jeden pozostaw

---

- Test jeden pozostaw (ang. Leave one out) jest szczególną wersją testu krzyżowego, gdzie zawsze tylko 1 wektor pozostawiany jest do testowania, a proces uczenia odbywa się  $M$  razy, gdzie  $M$  – liczba wektorów w zbiorze uczącym
- Zalety – test nie obciążony
- Wady – duża złożoność obliczeniowa (znane są różne uproszczenia testu LOO)

# Bootstrap (by Efron)

---

Mając zbiór  $X$  o  $M$  wektorach

- Ze zbioru danych  $X$  wylosuj ze zwracaniem  $M$  wektorów aby powstał zbiór  $R_j$
- Naucz model  $H_j$  na zbiorze  $R_j$  i wyznacz błąd modelu na tym zbiorze  $RE_j$
- Wyznacz błąd  $XE_j$  modelu  $H_j$  na całym zbiorze danych  $X$
- Wyznacz optyimizm  $opt_j = XE_j - Re_j$
- Powtórz kroki 1:4  $J$  krotnie
- Wyznacz średni optyimizm  $\underline{opt}$
- Wyznacz błąd na zbiorze uczącym  $E$  (trening modelu i jego testowanie odbywa się na zbiorze  $X$ )
- Na tej podstawie estymatę błędu generalizacji ( $e$ )  
wynosi  
$$e = E + \underline{opt}$$