

# Pattern Classification

**All materials in these slides were taken from Pattern Classification (2nd ed) by R. O. Duda, P. E. Hart and D. G. Stork, John Wiley & Sons, 2000 with the permission of the authors and the publisher**

# Chapter 1

## Wprowadzenie do rozpoznawania obrazów (Sections 1.1-1.6)


- „Widzenie” maszynowe
- Pojęcia podstawowe:
  - rozpoznawanie, cechy, klasy, obszary decyzyjne, algorytm rozpoznawania
- Przykład
- System rozpoznawania obrazów
- Cykl projektowania
- Uczenie i adaptacja

# „Widzenie” maszynowe

- Typowe zadania rozpoznawania wykonywane przez urządzenia techniczne (maszyny):
  - Rozpoznawanie mowy
  - Rozpoznawanie osoby na podstawie odcisku palca
  - OCR (Optical Character Recognition) – rozpoznawanie znaków
  - Rozpoznawanie sekwencji DNA
- Inne przykłady:
  - EKG → stan serca
  - sygnały sensorów robota → decyzja
  - wyniki badań lekarskich → nazwa choroby

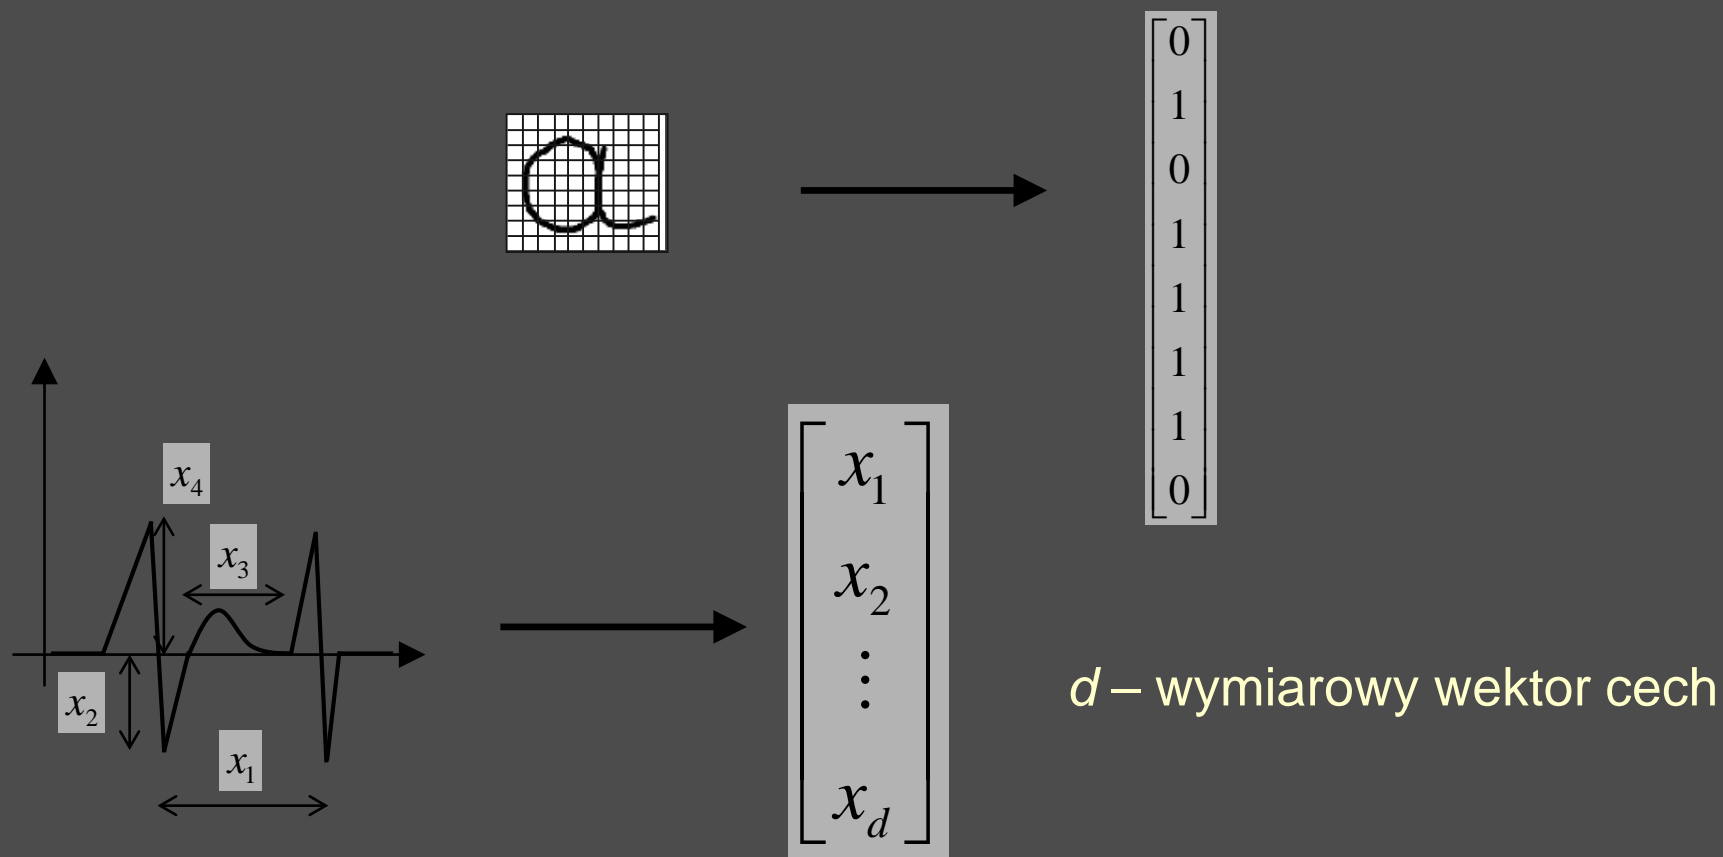
# Rozpoznawanie

- Rozpoznawanie to proces przyporządkowania obiektu do klasy



# Cechy

- Reprezentacja obiektu przy pomocy wektora cech



# Cechy

- liczba

$$x_s \in \mathcal{R}$$

- element ze zbioru

$$x_s \in \mathcal{X}^s = \{\text{man, woman}\}$$

$$x_s \in \{\text{kolor}_1, \text{kolor}_2, \dots, \text{kolor}_r\}$$

$$x_s \in \{s \tan_1, s \tan_2, \dots, s \tan_r\}$$

- szczególny przypadek

$$x_s \in \mathcal{X} = \{0,1\}$$

$$\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_s \end{bmatrix} \in \mathcal{X}$$

$\mathcal{X}$  – przestrzeń cech

# Klasy

- Obiekt należy do pewnej klasy

$a \in \{a, b, c, \dots, z\}$  – zbiór liter

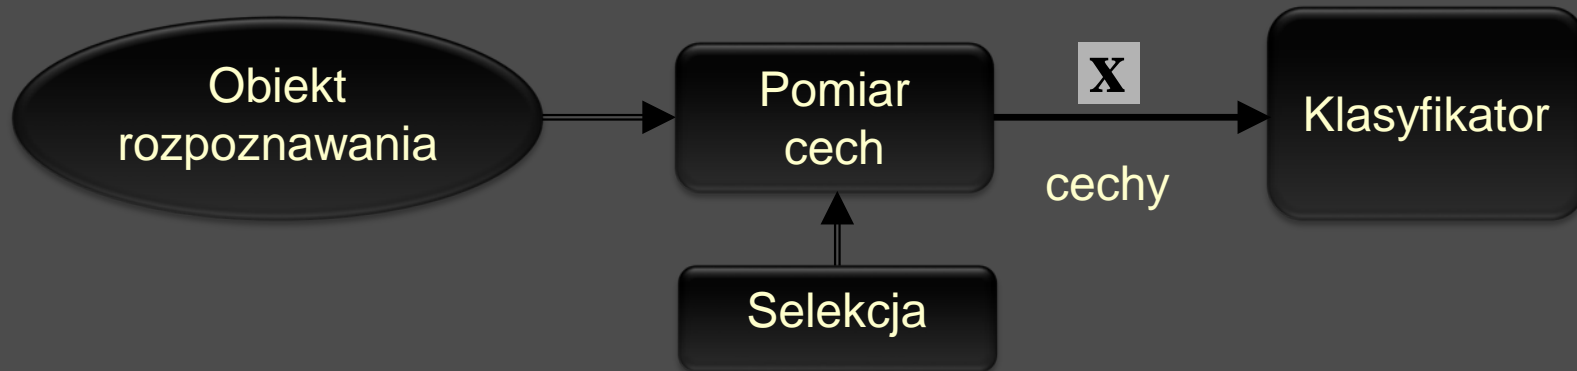
$\blacktriangle \in \{\blacksquare, \blacktriangle, \dots, \blacklozenge\}$  – zbiór wielokątów

choroba  $\in \{choroba_1, choroba_2, \dots, choroba_n\}$


⋮

$\{\omega_1, \omega_2, \dots, \omega_c\} = \mathcal{I}$  – zbiór klas

# Zadanie rozpoznawania



- Problem rozpoznawania: na podstawie wektora cech określić numer klasy




$$\alpha_i = \alpha(\mathbf{x})$$

$\alpha$  – algorytm rozpoznawania

$$\alpha: \mathcal{X} \rightarrow \mathcal{I}$$



# Obszary decyzyjne



- Obszar decyzyjny

$$\mathcal{R}_i = \{\mathbf{x} \in \mathcal{X}, \alpha(\mathbf{x}) = \alpha_i\} \quad \alpha_i \in \{1, 2, \dots, c\}$$

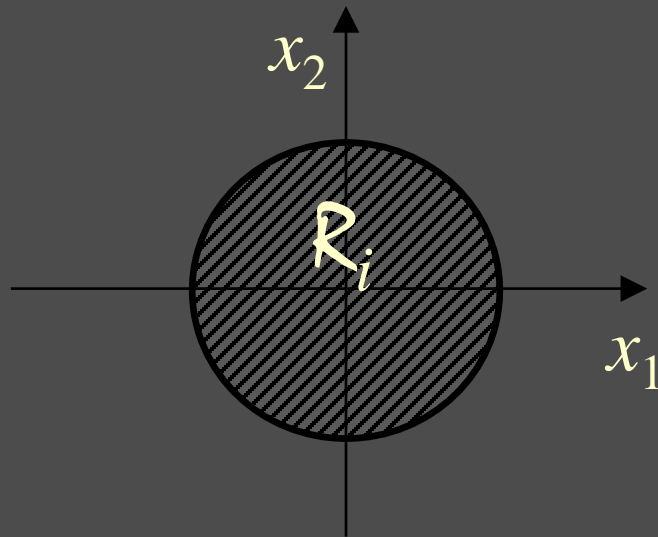
$$\mathcal{R}_i \cap \mathcal{R}_j = \begin{cases} \emptyset & \text{dla } i \neq j \\ \mathcal{R}_i & \text{dla } i = j \end{cases} \quad \bigcup_{i=1}^c \mathcal{R}_i = \mathcal{X}$$

# Obszary decyzyjne

$$\mathcal{R}_i = \{\mathbf{x} \in \mathcal{X}, F_i(\mathbf{x}, \mathbf{a})\}$$

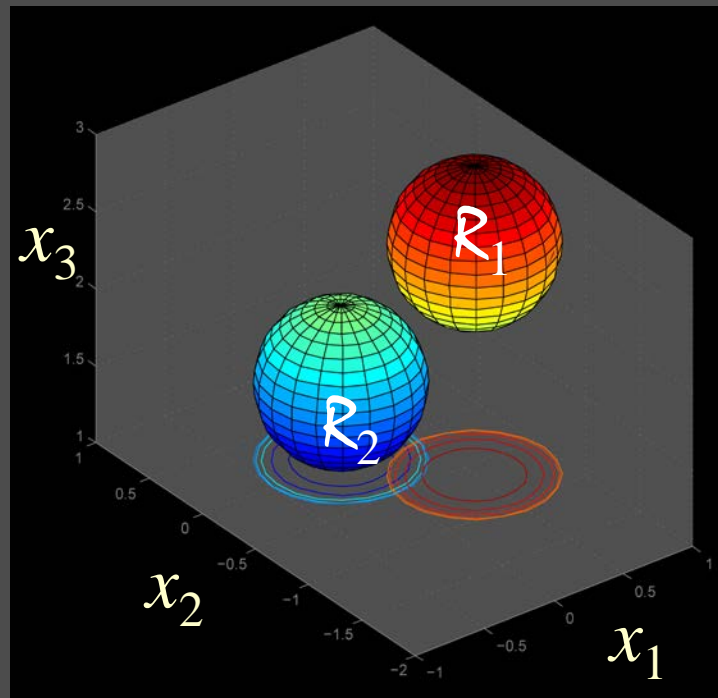
$F_i(\mathbf{x}, \mathbf{a})$  – zestaw prawdziwych zdań, np.

$$x_1^2 + x_2^2 \leq a^2$$



# Algorytm rozpoznawania

- Zadanie: wyznaczyć algorytm rozpoznawania.
- Mogą się pojawić różne problemy:
  - a) czy  $\mathbf{x}$  jednoznacznie opisuje klasy



# Algorytm rozpoznawania

b) nie znamy  $\alpha$

- znamy z dokładnością do parametrów


$$\mathcal{R}_i = \{\mathbf{x} \in \mathcal{X}, F(\mathbf{x}, \mathbf{a})\} \quad \text{np.} \quad x_1 < x_2$$

$$\mathcal{R}_i = \{\mathbf{x} \in \mathcal{X}, \phi(\mathbf{x}, \mathbf{a})\} \quad - \text{ przybliżenie}$$

c) ?

# Algorytm rozpoznawania

- Wyznaczyć algorytm, tj. nauczyć się rozpoznawać



- Ciąg uczący

$$\begin{cases} x_1 & x_2 & \cdots & x_M \\ \omega_1 & \omega_2 & \cdots & \omega_M \end{cases}$$

– ciąg  $M$  obrazów

– ciąg  $M$  poprawnych klasyfikacji

$x_m$

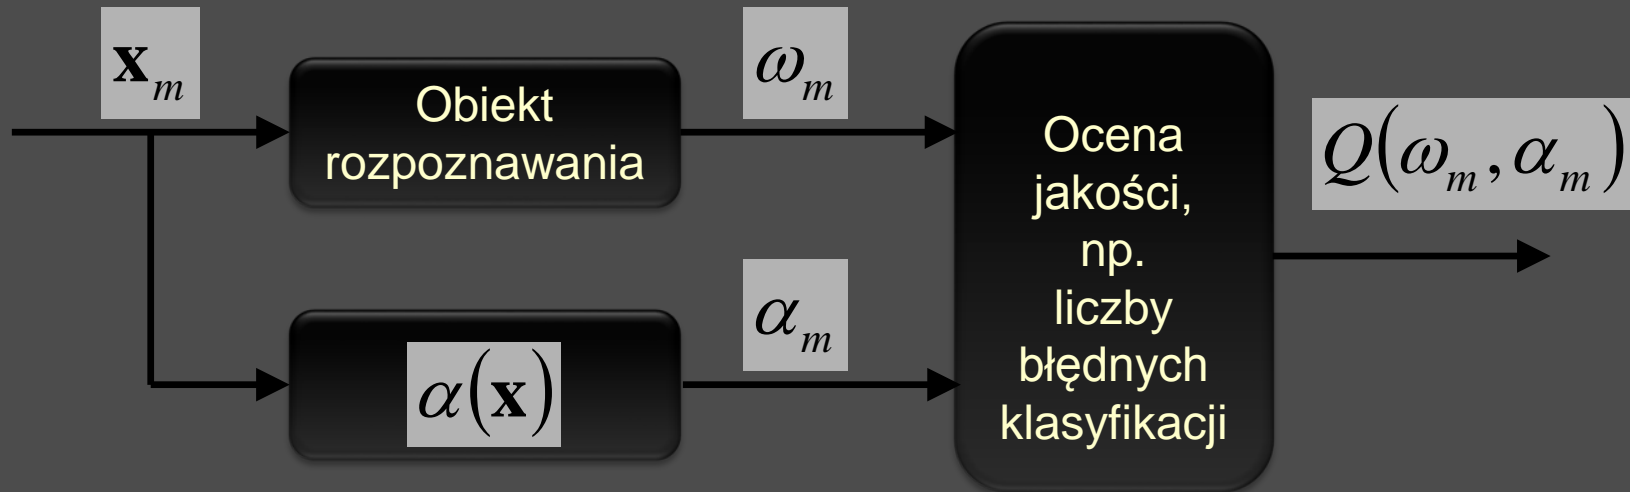
–  $m$ -ty obraz

$\omega_m$

–  $m$ -ta klasyfikacja

} nauczyciel


# Algorytm rozpoznawania



- Wybór optymalnego algorytmu rozpoznawania

# Przykład

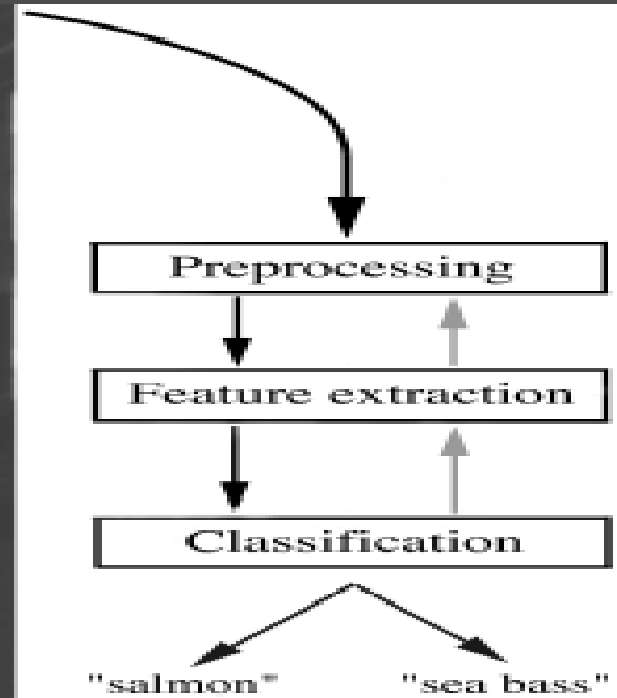
- “Sortowanie ryb na taśmociągu ze względu na gatunek, z wykorzystaniem czujników optycznych”




- Analiza problemu
  - Na podstawie zdjęć wykonanych z kamery należy dokonać ekstrakcji cech:
    - długość
    - jasność
    - szerokość
    - liczba i kształt płetw
    - położenie otworu gębowego, etc...
  - Zbiór wszystkich cech proponowanych do rozpoznawania



- Przetwarzanie wstępne
  - Operacja segmentacji ma na celu oddzielenie ryby od tła i od innych ryb
- Informacja o pojedynczej rybie jest przekazywana do modułu ekstrakcji cech, którego celem jest redukcja ilości danych poprzez wyznaczenie wybranych cech
- Zestaw wartości cech jest przekazywany do klasyfikatora

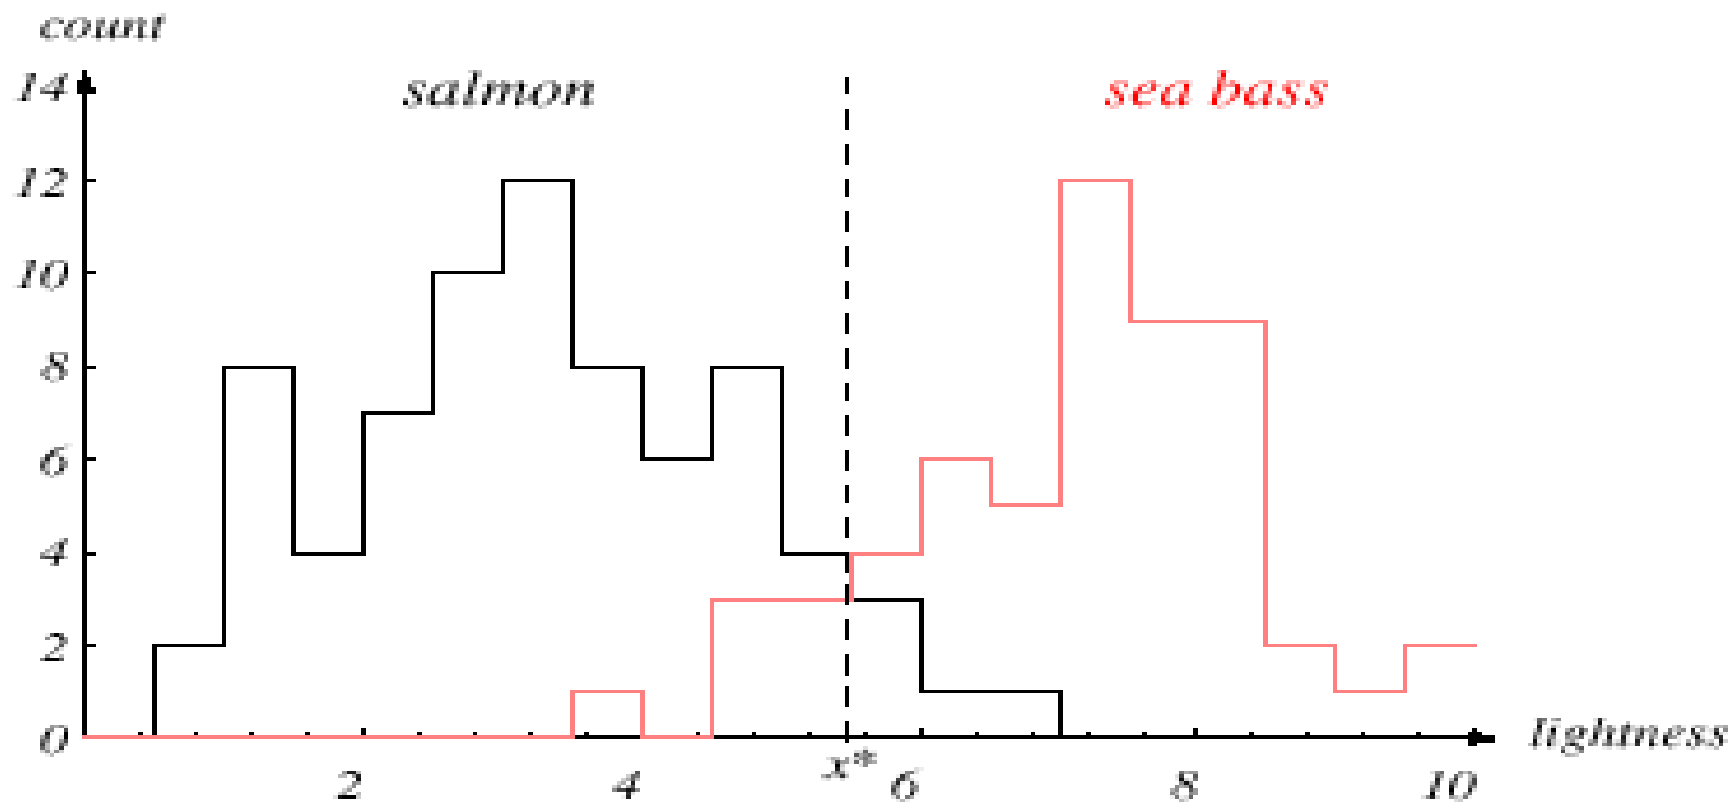


- Klasyfikacja
  - Wybierz długość ryby jako cechę najlepiej separującą klasy



Oprócz **długości ryby** warto wziąć pod uwagę inne cechy, ponieważ pojedyncza cecha – nawet najlepsza – daje niewielkie możliwości odseparowania obiektów różnych klas.

Przykładem dodatkowej cechy jest **jasność**.




- Próg rozpoznawania i koszt

- Wybór progu rozpoznawania zależy nie tylko od jakości klasyfikacji przy danej wartości progu ale również od kosztów ewentualnych błędów rozpoznawania jakie mogą zajść przy tej wartości progu

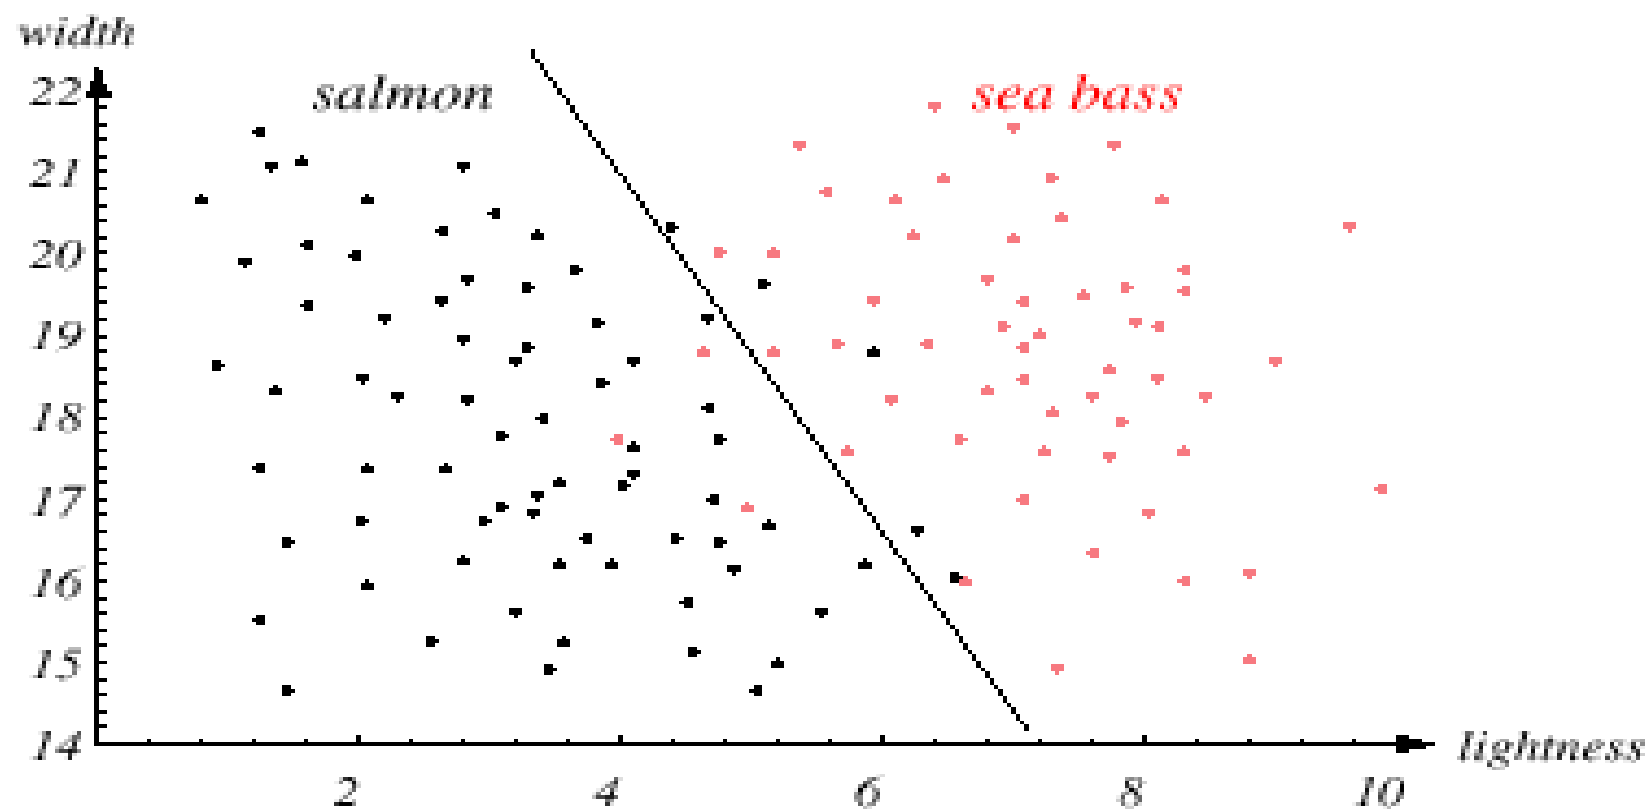


- Przykłady:                      zadanie podejmowania decyzji
  - modyfikacja progu w taki sposób, aby zmniejszyć liczbę okoni, które zakwalifikowano jako łososie
  - w diagnostyce: ze względu na asymetrię kosztów błędnych decyzji opłaca się zwiększyć liczbę zdrowych osób skierowanych na dodatkowe testy jeżeli pozwoli to jednocześnie zmniejszyć liczbę chorych „odesłanych do domu”


- Wektor cech: jasność i szerokość








- Możemy dodawać kolejne cechy, nieskorelowane z dotychczas mierzonymi, jeżeli nie są obciążone dużymi zakłóceniami.
- Najlepsza granica decyzyjna (zdeterminowana przez funkcję dyskryminującą) powinna odpowiadać najlepszej jakości rozpoznawania, jak na rysunku:



- Należy jednak brać pod uwagę, że głównym celem klasyfikatora jest rozpoznawanie nowych obiektów, których nie było w ciągu uczącym.

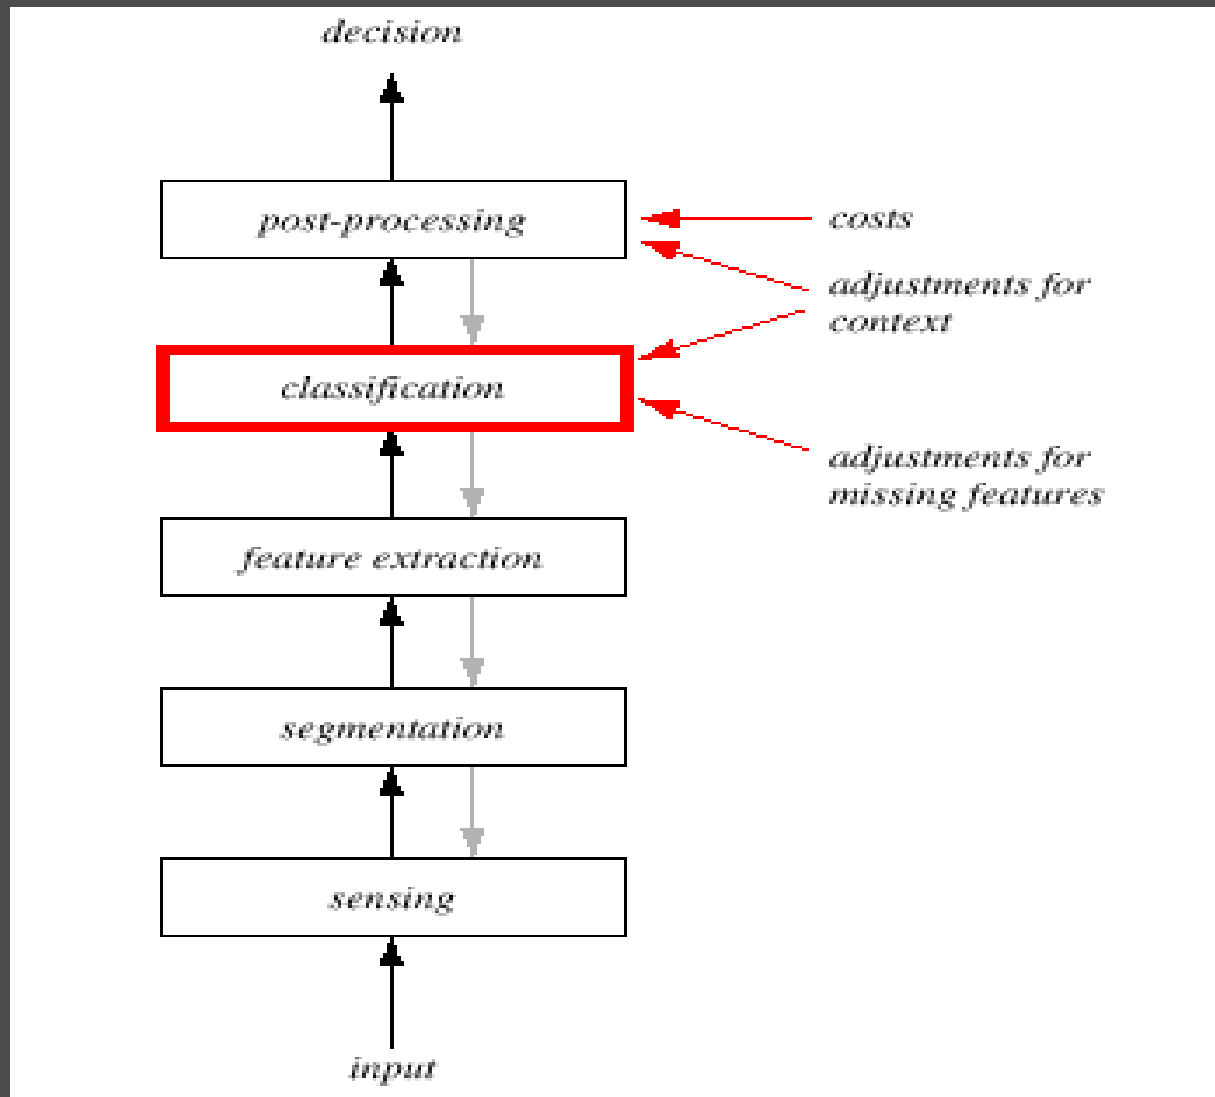


Problem generalizacji



# System rozpoznawania obrazów

- Pomiary
  - Odpowiedni czujnik (np. kamera, mikrofon)
  - Działanie systemu rozpoznawania zależy od szerokości pasma, rozdzielczości, czułości, zniekształceń wprowadzanych przez sam czujnik
- Segmentacja i grupowanie
  - Obrazy powinny być dobrze odseparowane a obszary ich występowania nie powinny się na siebie nakładać

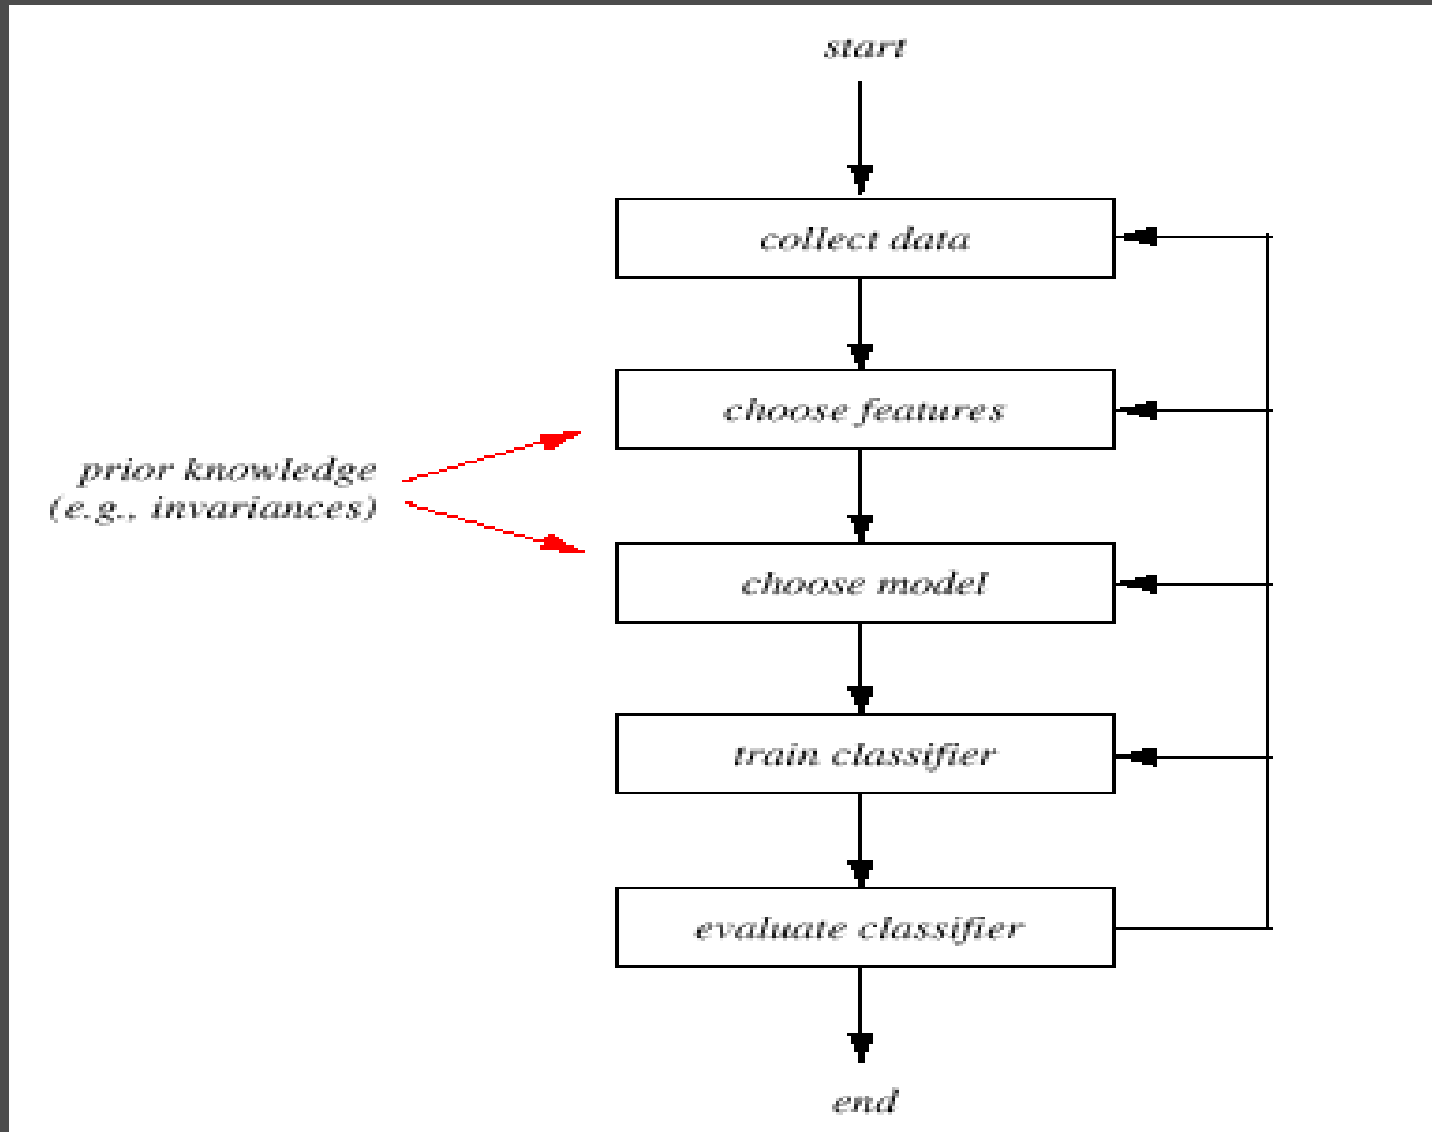


- Ekstrakcja cech
  - Cechy dyskryminujące
  - Cechy niezależne od translacji, obrotu i zmiany skali
- Klasyfikacja
  - Użycie wektora cech z wartościami wyznaczonymi w procesie ekstrakcji cech w celu przyporządkowania numeru klasy obrazowi obiektu
- Przetwarzanie końcowe
  - Poprawa jakości działania systemu rozpoznawania na podstawie **kontekstu**, np. w oparciu o koszty podjęcia decyzji (jakość klasyfikatora  $\neq$  jakość systemu rozpoznawania)



# Cykl projektowania

- Zebranie danych pomiarowych
- Wybór cech
- Wybór modelu
- Uczenie
- Ocena jakości systemu rozpoznawania
- Analiza złożoności obliczeniowej



- Zebranie danych pomiarowych
  - Jak stwierdzić, czy ciąg uczący zawiera wystarczającą liczbę reprezentatywnych przypadków obrazów dla celów uczenia i testowania systemu rozpoznawania?

- Wybór cech
- Wybór cech zależy od problemu. Ogólnie, cechy powinny być
  - łatwe do wyekstrahowania,
  - niezależne od nieistotnych transformacji (tj. takich, które nie zmieniają klasy obiektu),
  - niewrażliwe na zakłócenia.

- Wybór modelu
  - Należy ustalić matematyczną postać klasyfikatora, która określa związek między cechami i klasami. Jeżeli dla jednego modelu nie jesteśmy w stanie uzyskać satysfakcjonującej jakości rozpoznawania, należy rozważyć inny model (tj. inną postać klasyfikatora).

- Uczenie
  - Postać klasyfikatora na ogół zadana jest z pewną dokładnością (np. nieustalone wartości parametrów, liczba funkcji bazowych). Uczenie polega na ustaleniu dokładnej postaci klasyfikatora i wymaga użycia ciągu uczącego zawierającego dane pomiarowe w postaci par (wektor cech, numer klasy).

- Ocena jakości systemu rozpoznawania
  - Pomiar błędu klasyfikacji (lub innego wskaźnika) dla różnych zestawów cech

- Analiza złożoności obliczeniowej
  - Kompromis pomiędzy złożonością obliczeniową i jakością rozpoznawania.
  - Jak nakład obliczeń zależy od:
    - liczby cech,
    - liczby obrazów w ciągu uczącym,
    - liczby klas?



# Uczenie i adaptacja

- Uczenie z nauczycielem
  - Ciąg uczący zawiera informację o przynależności do klas dla wszystkich obiektów. Celem uczenia jest uzyskanie najlepszego klasyfikatora (w sensie określonym przez zadany wskaźnik jakości).
- Uczenie bez nauczyciela
  - Ciąg uczący zawiera tylko pomiary cech obiektów. Celem uczenia jest uzyskanie „naturalnego” podziału danych na klasy.