

# Elementy sztucznej inteligencji

Sprawozdanie nr 1

## Klasyfikator Bayesa 1 i 2 wymiarowy

Maciej Ciupa

maciek.ciupa@gmail.com

### 1 Treść zadania

Należy napisać program, który dla wybranej ilości (w zadaniu domyślnie dwóch) próbek zaklasyfikuje dane do odpowiednich klas, wcześniej estymując te dane i wyświetlając je na wykresach. Każdą z danych potrzebnych do klasyfikacji wg metody Bayesa można zmienić w programie.

### 2 Selekcja informacji

„Obserwacja przedmiotów, stanów różnego rodzaju obiektów i zjawisk wiąże się często z przeprowadzeniem ich klasyfikacji. Jest to dzielenie na grupy, do których zalicza się przedmioty, stany obiektów lub zjawiska różniące się wprawdzie, ale mające cechy wspólne.” ([1] str. 7)

Zbiór obserwowanych przedmiotów, stanów, zaliczanych do jednej grupy (ze względu na rozpatrywaną cechę) nazywamy **klasą**. Każdy element klasy – **obiektem**.

„Abstrahując od konkretnej treści rozpoznawanego obiektu będziemy przyjmować, że można go zawsze opisać za pomocą pewnego **zbioru cech**. Przez pojęcie cech należy rozumieć nie same obiekty, lecz istotne i reprezentatywne charakterystyki lub ich odwzorowanie w postaci liczb, formuł, symboli itd.

Przypuśćmy, że w wyniku badania obiektu można z każdą z analizowanych jego  $N$  cech związać wartość liczbową. Wobec tego, formalnym opisem obiektu może być zbiór  $N$  liczb (...)” ([1] str. 8) tzw. wektor cech

$$\bar{x} = (x_1, x_2, \dots, x_N)$$

Systemy, które dzielą obiekty (dane im odpowiadające) na klasy nazywane są **klasyfikatorami**. Jednym z nich jest klasyfikator Bayesa wykorzystujący twierdzenie o prawdopodobieństwie zupełnym.

### 3 Teoretyczne podstawy klasyfikatora Bayesa

Klasyfikator ten wykorzystując

- macierz strat  $\Lambda \equiv \{\lambda_{ij}\}$ , gdzie  $\lambda_{ij}$  oznacza stratę wynikłą z przypisania obiektu klasy  $i$ -tej do klasy  $j$ -tej
- prawdopodobieństwa *a priori*  $P(A_i)$  wystąpienia  $i$ -tej klasy
- rozkłady prawdopodobieństwa  $P(\bar{x} | A_i)$  wystąpienia obiektu  $\bar{x}$  w  $i$ -tej klasie.

przyporządkowuje obiekt  $\bar{x}$  do pewnej klasy  $A_k, k \in [N]$ , dla której ryzyko jest najmniejsze tj.:

$$\bar{x} \in A_k \Leftrightarrow k = \min\{i : R_i(\bar{x}) \wedge i = 1, 2, \dots, N\}$$

gdzie:

$$R_i(\bar{x}) = \sum_{k=1}^N \lambda_{ki} P(A_k | \bar{x}), \quad P(A_k | \bar{x}) = \frac{P(A_k)P(\bar{x} | A_k)}{\sum_{i=1}^N P(A_i)P(\bar{x} | A_i)}$$

**Błąd klasyfikacji**

$$r = \frac{\text{ilosc\_blednie\_zaklasyfikowanych}}{\text{ilosc\_wszystkich\_obiektów}}$$

**Funkcja graniczna dla dwóch klas**

$$R_1 = R_2$$

$$(\lambda_{11} - \lambda_{12})P(A_1 | x) = (\lambda_{22} - \lambda_{21})P(A_2 | x)$$

$$\frac{P(A_1) \cdot P(x | A_1)}{P(A_2) \cdot P(x | A_2)} = \frac{(\lambda_{22} - \lambda_{21})}{(\lambda_{11} - \lambda_{12})}$$

a) przypadek jedno-wymiarowy  $\bar{x} \equiv x$

gdzie  $X \sim N(\mu_k, \sigma_k)$ ,  $P(x | A_k) = \frac{1}{\sqrt{2\pi}\sigma_k} \exp\left(-\frac{(x - \mu_k)^2}{2 \cdot \sigma_k^2}\right)$ ,  $P(A_k) = p_k$

$$Ax^2 + Bx + C = 0$$

$$A = \frac{(\sigma_1^2 - \sigma_2^2)}{\sigma_1^2 \cdot \sigma_2^2}, \quad B = -2 \frac{(\sigma_1^2 \mu_2 - \sigma_2^2 \mu_1)}{\sigma_1^2 \cdot \sigma_2^2}, \quad C = \frac{2}{\sigma_1^2 \cdot \sigma_2^2} \left( \ln \left( \frac{-p_1(\lambda_{1,1} - \lambda_{1,2})\sigma_2}{p_2(\lambda_{2,1} - \lambda_{2,2})\sigma_1} \right) \sigma_1^2 \sigma_2^2 + \sigma_1^2 \mu_2^2 - \sigma_2^2 \mu_1^2 \right)$$

czyli:

$$x_{1,2} = \frac{-b \pm \sqrt{b^2 - 4ac}}{2a}$$

b) przypadek dwu-wymiarowy

gdzie  $(x_1, x_2) = X \sim N(\bar{\mu}_k, \Sigma_k)$ ,  $P(\bar{x} | A_k) = \frac{1}{2\pi \sqrt{\det(\Sigma_k)}} \exp\left(-\frac{1}{2}(\bar{x} - \bar{\mu}_k) \Sigma_k^{-1} (\bar{x} - \bar{\mu}_k)^T\right)$ ,  $P(A_k) = p_k$

$$Ax_1^2 + Bx_2^2 + Cx_1 + Dx_2 + Ex_1x_2 + F - G = 0$$

$$\Sigma_k \equiv \{\sigma_{k,i,j}\}, \quad \bar{\mu}_k \equiv (\mu_{k,1}, \mu_{k,2})$$

$$A = \sigma_{1,1,1} - \sigma_{2,1,1}$$

$$B = \sigma_{1,2,2} - \sigma_{2,2,2}$$

$$C = -2\sigma_{1,1,1}\mu_{1,1} - \mu_{1,2}(\sigma_{1,1,2} + \sigma_{1,2,1}) + \sigma_{2,1,1}\mu_{2,1} + \mu_{2,2}(\sigma_{2,1,2} + \sigma_{2,2,1})$$

$$D = -\mu_{1,1}(\sigma_{1,1,2} + \sigma_{1,2,1}) - 2\sigma_{1,2,2}\mu_{1,2} + \mu_{2,1}(\sigma_{2,1,2} + \sigma_{2,2,1}) + 2\sigma_{2,2,2}\mu_{2,2}$$

$$E = \sigma_{1,1,2} + \sigma_{1,2,1} - \sigma_{2,1,2} - \sigma_{2,2,1}$$

$$F = \sigma_{1,1,1}\mu_{1,1}^2 + \mu_{1,1}\mu_{1,2}(\sigma_{1,1,2} + \sigma_{1,2,1}) + \sigma_{1,2,2}\mu_{1,2}^2 - \sigma_{2,1,1}\mu_{2,1}^2 - \mu_{2,2}(\mu_{2,1}(\sigma_{2,1,2} + \sigma_{2,2,1}) + \sigma_{2,2,2}\mu_{2,2})$$

$$G = 2 \ln \left( \frac{p_1 \sqrt{\det(\Sigma_2)} (\lambda_{1,1} - \lambda_{1,2})}{p_2 \sqrt{\det(\Sigma_1)} (\lambda_{2,2} - \lambda_{2,1})} \right)$$

## 4 Klasyfikator 1-wymiarowy

Do sprawozdania załączony jest program *Bayes1W* napisany w środowisku Matlab, który dla

- zewnętrznego zbioru klas (menu *Plik ► Import danych z pliku ...*), liczba klas dowolna (teoretycznie, powyżej 8 mała czytelność)
- prawdopodobieństwa a priori wystąpienia każdej z klas (pole *Spis prawdopodobieństw*)
- parametrów rozkładów prawdopodobieństwa wystąpienia obiektów w danych klasach (pole *Spis parametrów rozkładów*)
- macierzy strat (pole *Macierz strat*)

generuje funkcje ryzyka dla każdego z obiektów i klasyfikuje je do tej klasy, dla którego ryzyko jest najmniejsze. Oblicza przedziały wystąpienia dla każdej z klas, w przypadku dwóch klas generuje funkcje graniczną i po logarytmowaniu kwadratową. Wyznacza również ilość poprawnie/błędnie zaklasyfikowanych obiektów tj. błąd klasyfikacji.

Program uruchamiamy z linii poleceń, przy ustawionym aktualnym katalogu roboczym na ten, w którym znajdują się pliki programu:

- *Bayes1W.m* - główny program
- *Bayes1W.fig* - graficzne okno
- *getParams.m* - funkcja zwracająca wektor średniej *mi* i odchylenie standardowe (macierz kowariancji) *sigma* 10% danych wybieranych losowo z zadanej próbki *Data*  

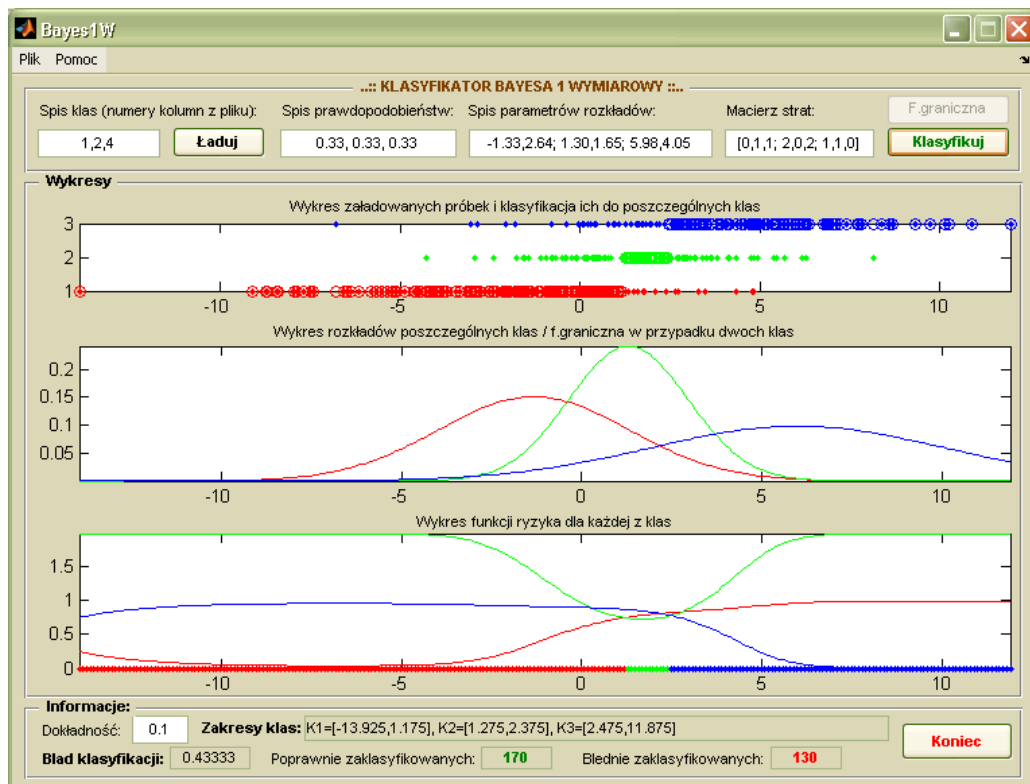
```
function [mi, sigma] = getParams(DATA)
```
- *fnorm1W.m* - funkcja zwracająca wartość gęstości rozkładu normalnego jednowymiarowego przy zadanych parametrach  $N(\mu, \sigma)$   

```
function Y = fnorm(X, MI, SIGMA)
```

### Algorytm klasyfikacji

1. Program pobiera dane z pliku i za pomocą funkcji *getParams()* określa parametry potrzebne do wyznaczenia rozkładu prawdopodobieństwa wystąpienia obiektu danej klasy.
2. Następnie korzystając z macierzy strat i prawdopodobieństwa całkowitego obliczane są funkcje ryzyka przypisania każdego z obiektów do każdej z klas.

3. Poszukiwana jest funkcja, dla której dla danego elementu wartość jest najmniejsza – do tej klasy obiekt zostaje zaklasyfikowany.




(rys. 1)

## 5 Analiza danych 1-wymiarowych

### 5.1 Domyślna klasyfikacja

*Dane wejściowe:*

Plik *dane.txt*, kolumny 1, 2, 3 (rys.2)



(rys. 2)

*Estymacja danych (z 10% przypadkowo wybranych danych):*

Próbka  $A_1$ :  $\mu = -1.45$ ,  $\sigma = 2.18$


Próbka  $A_2$ :  $\mu = 1.25$ ,  $\sigma = 1.39$

Próbka  $A_3$ :  $\mu = -4.21$ ,  $\sigma = 3.17$


Macierz strat  $\Lambda = \begin{bmatrix} 0 & 1 & 1 \\ 1 & 0 & 1 \\ 1 & 1 & 0 \end{bmatrix}$

Prawdopodobieństwa a priori:  $P(A_i) = 1/3$  dla  $i = 1,2,3$

Wykres rozkładów  $X_{A_i} \sim N(\mu, \sigma)$  dla  $i = 1, 2, 3$




Wykres funkcji ryzyka dla każdej z klas:




Czyli wybieramy te klasy, dla których wartość funkcji jest najmniejsza.

Wykres klasyfikacji obiektów:



Program obliczył przedziały z dokładnością  $\varepsilon = 0.1$

Czyli wynik klasyfikacji przedstawia się następująco:



Błąd klasyfikacji:  $r = 0.38667$

Ilość poprawnie zaklasyfikowanych: 184

Ilość błędnie zaklasyfikowanych: 116

Błąd jest „spory”, w następnym punkcie dokonamy zmian różnych parametrów i przyjrzymy się zmianie błędu klasyfikacji w szczególności.

## 5.2 Wpływ zmian parametrów na klasyfikację

### 5.2.1 Zmiana prawdopodobieństwa a priori

Dane początkowe:  $P(A_1) = 0.33$ ,  $P(A_2) = 0.33$ ,  $P(A_3) = 0.33$   
 $r = 0.38667$


Dane końcowe:  $P(A_1) = 0.24$ ,  $P(A_2) = 0.38$ ,  $P(A_3) = 0.38$   
 $r = 0.37667$

Choć generalnie zmiany tych parametrów powiększają błąd klasyfikacji.

## 5.2.2 Zmiana parametrów rozkładów

Dane początkowe:  $A_1: \mu = -1.45, \sigma = 2.18$ ,  $A_2: \mu = 1.25, \sigma = 1.39$ ,  $A_3: \mu = -4.21, \sigma = 3.17$   
 $r = 0.38667$

Dane końcowe:  $A_1: \mu = -1.05, \sigma = 2.0$ ,  $A_2: \mu = 1.25, \sigma = 1.39$ ,  $A_3: \mu = -4.21, \sigma = 1.7$   
 $r = 0.36667$



Bledszym kolorem zostały oznaczone poprzednie rozkłady.

I tu również, zmiana na inne parametry powiększa błąd klasyfikacji.

## 5.2.3 Zmiana macierzy strat

Macierz zerojedynkowa (domyślna) dla tych danych znów okazują się praktycznie najbardziej optymalna. Dla innych ustawień powiększamy tylko błąd klasyfikacji.

## 6 Klasyfikator 2-wymiarowy

Do sprawozdania załączony jest również klasyfikator 2-wymiarowy *Bayes2W* napisany w środowisku Matlab 7.2.0, który umożliwia

- Załadowanie dwóch klas z plików tekstowych odpowiedniego formatu (załączone do treści zadania - pliki *dom\*.txt*), oznaczone odpowiednio [Próbka 1](#) i [Próbka 2](#) wraz z parametrami rozkładu normalnego opisującego owe dane.
- Ręczną zmianę parametrów rozkładów lub estymację 10% losowo wybranych danych
- Ręczną zmianę innych parametrów potrzebnych do klasyfikacji Bayesa, tj. macierzy strat i prawdopodobieństwa a priori
- Zaklasyfikowanie każdego z obiektów do jednej z dwóch klas
- Wygenerowanie funkcji granicznej dzielącej przestrzeń  $R^2$  na dwa (w szczególności brak podziału, gdy minimalne ryzyko dla całej dziedziny jest przypisane jednej klasie) podzbiory klasyfikujące jej elementy do odpowiedniej klasy
- Obliczenie błędu klasyfikacji

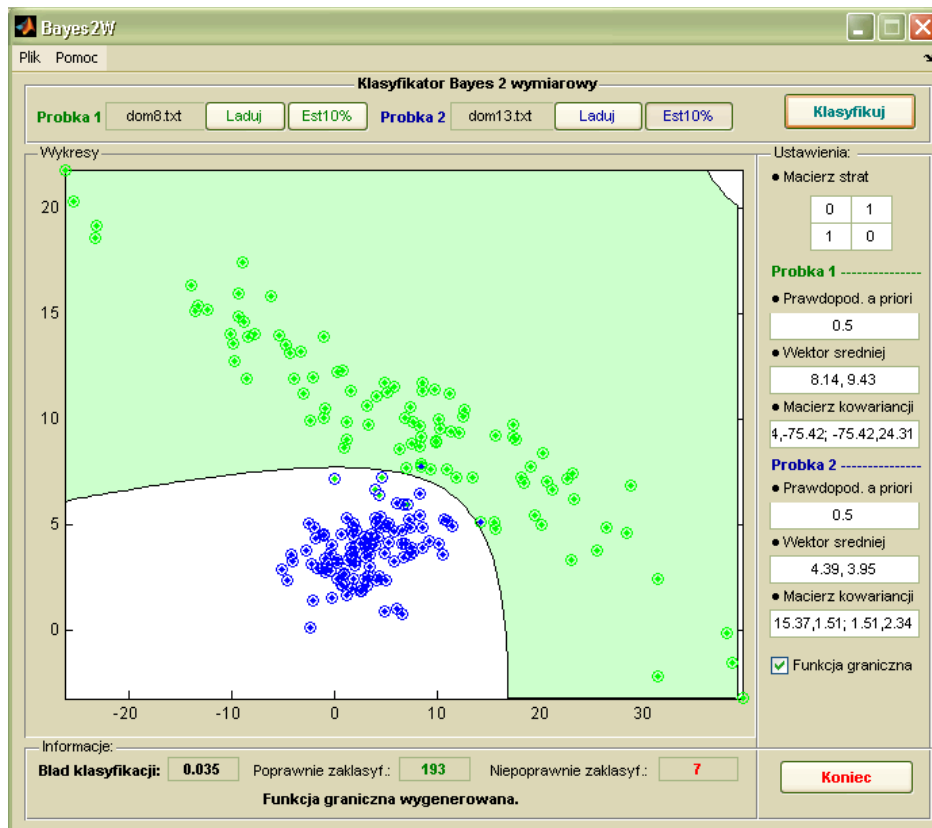
Program uruchamiamy z linii poleceń, przy ustawionym aktualnym katalogu roboczym na ten, w którym znajdują się pliki programu:

- *Bayes2W.m* – główny program
- *Bayes2W.fig* – graficzne okno
  
- *getParams.m* – funkcja zwracająca wektor średniej  $\mu$  i odchylenie standardowe (macierz kowariancji)  $\sigma$  10% danych wybieranych losowo z zadanej próbki *Data*

```
function [mi, sigma] = getParams(DATA)
```

- *fnorm2W.m* – funkcja zwracająca wartość gęstości rozkładu normalnego dwuwymiarowego przy zadanych parametrach  $N(\mu, \Sigma)$   
`function Y = fnorm2W(X, Mi, invCov, detCov)`  
gdzie *invCov* to odwrócona macierz kowariancji a *detCov* to wyznacznik macierzy kowariancji (aby przy każdym wywołaniu nie obliczał jej ponownie)

Algorytm klasyfikacji jest analogiczny do tego w jednowymiarowym przypadku, z tym że funkcja graniczna jest funkcją dwóch zmiennych.



## 7 Analiza danych dwu-wymiarowych

Dla przykładu weźmy próbki:

Próbka 1 - dom1.txt

Probka 2 - dom13.txt

Domyślne dane rozkładów (pobrane z pliku) wynoszą odpowiednio:

$$\text{Próbka 1: } \bar{\mu} = (5.3, 5.12), \Sigma = \begin{bmatrix} 0.8 & 0.4 \\ 0.4 & 1.29 \end{bmatrix}$$

$$\text{Probka 2: } \bar{\mu} = (5.19, 5.07), \Sigma = \begin{bmatrix} 0.24 & 0.36 \\ 0.36 & 1.18 \end{bmatrix}$$

Bład klasyfikacji:  $r = 0.22$

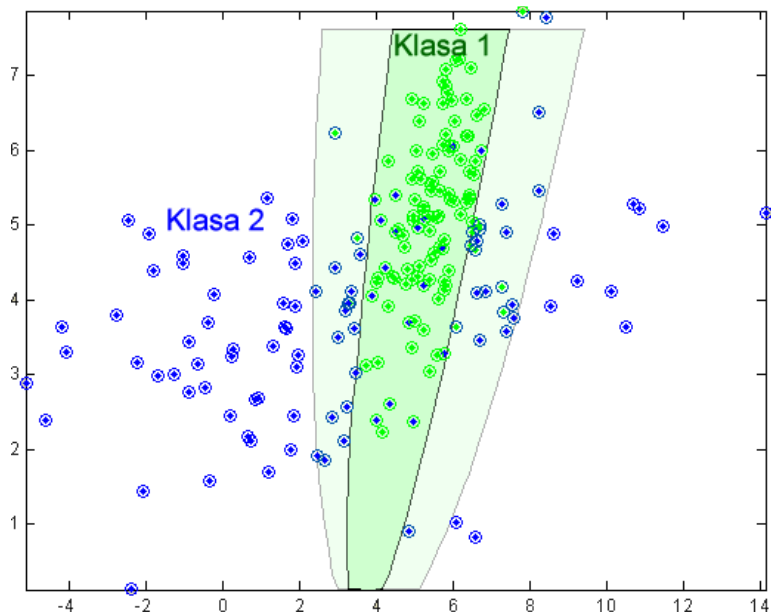
Dane uzyskane po estymacji 10% danych (wybranych przypadkowo) dla klasy 1:

Próbka 1:  $\bar{\mu} = (5.19, 5.07)$ ,  $\Sigma = \begin{bmatrix} 0.24 & 0.36 \\ 0.36 & 1.18 \end{bmatrix}$

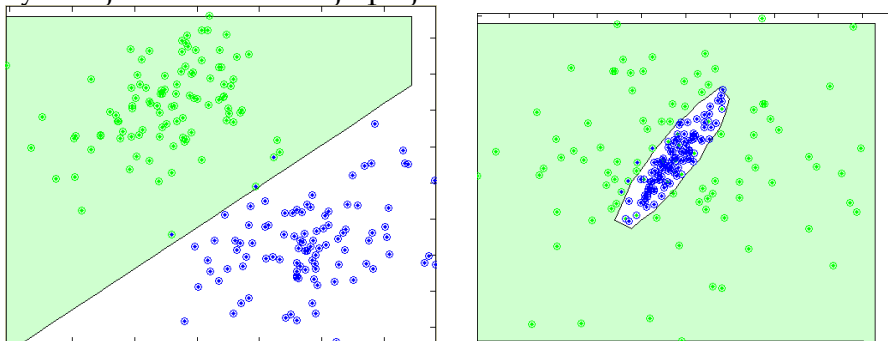
Próbka 2:  $\mu = (2.62, 3.61)$ ,  $\Sigma = \begin{bmatrix} 14.2 & 1.84 \\ 1.84 & 1.58 \end{bmatrix}$

Błąd klasyfikacji:  $r = 0.145$


Czyli modyfikacja parametrów może polepszyć wynik klasyfikacji. Wszystko zależy od rozmieszczenia klas względem siebie.



Dla klas zlokalizowanych w różnych obszarach lub dla danych o różnym współczynniku skupienia, klasyfikacja radzi sobie najlepiej.



Natomiast dla danych przenikających się o podobnym współczynniku skupienia błąd klasyfikacji rośnie (w drugim przypadku dochodzi nawet do 0.5)



## 8 Literatura

- [1] Metody Selekcji informacji, Wojciech Sobczak, Witold Malina, WN-T W-wa 1978
- [2] Klasyfikator Bayesa, materiały do laboratoriów ESI, mgr J. Rafałko,  
<http://jrafalko.webpark.pl/kbi.doc>