

Dzień 3 - Analiza dyskryminacyjna

Spis treści

Analiza dyskryminacyjna

1

Analiza dyskryminacyjna

Wersja pdf

Analiza dyskryminacyjna (ang. discriminant analysis) – jej zadaniem jest rozstrzyganie, które zmienne niezależne (predyktory) w najlepszy sposób dzielą dany zbiór przypadków na występujące w naturalny sposób grupy, opisane jakościową zmienną zależną.

W metodzie tej możemy wyróżnić dwa główne etapy:

- etap uczenia / budowy modelu – w którym znajdujemy reguły klasyfikacyjne w oparciu o tak zwany zbiór uczący (próbę statystyczną)
- etap klasyfikacji / wykorzystania modelu – w którym dokonujemy klasyfikacji zasadniczego zbioru obiektów, których przynależność jest nam nieznana, w oparciu o znalezione charakterystyki klas.

Zostanie opisany model liniowy (użyjemy liniowej kombinacji predyktorów aby przewidzieć klasę obserwacji).

Załadujmy potrzebne biblioteki:

```
library(tidyverse)
library(caret)
```

Załadujmy ponownie ramkę `iris` i podzielimy ją na tzw. część treningową (uczącą) i testową.

```
data("iris")

set.seed(123)
training.samples <- createDataPartition(iris$Species, p = 0.8, list = FALSE)
train.data <- iris[training.samples, ]
test.data <- iris[-training.samples, ]
```

Wykonajmy normalizację danych:

```
preproc.param <- preProcess(train.data, method = c("center", "scale"))
train.transformed <- predict(preproc.param, train.data)
head(train.transformed)

##   Sepal.Length Sepal.Width Petal.Length Petal.Width Species
## 1    -0.8344991   1.15462417   -1.328132   -1.311924 setosa
## 2    -1.0673826  -0.07152539   -1.328132   -1.311924 setosa
## 3    -1.3002661   0.41893443   -1.384789   -1.311924 setosa
## 4    -1.4167078   0.17370452   -1.271475   -1.311924 setosa
## 7    -1.4167078   0.90939426   -1.328132   -1.180732 setosa
## 8    -0.9509409   0.90939426   -1.271475   -1.311924 setosa

test.transformed <- predict(preproc.param, test.data)
head(test.transformed)

##   Sepal.Length Sepal.Width Petal.Length Petal.Width Species
## 5    -0.9509409   1.3998541    -1.328132   -1.311924 setosa
## 6    -0.4851739   2.1355438    -1.158162   -1.049539 setosa
```

```

## 10 -1.0673826 0.1737045 -1.271475 -1.443117 setosa
## 12 -1.1838243 0.9093943 -1.214819 -1.311924 setosa
## 16 -0.1358487 3.3616934 -1.271475 -1.049539 setosa
## 17 -0.4851739 2.1355438 -1.384789 -1.049539 setosa

```

Algorytm liniowy na starcie szuka kierunków, które “maksymalizują” oddzielenie klas/grup. Następnie kierunki są zastosowane na danych testowych. Kierunki (zwane liniowymi dyskryminatorami) są liniową kombinacją predyktorów.

```
library(MASS)
```

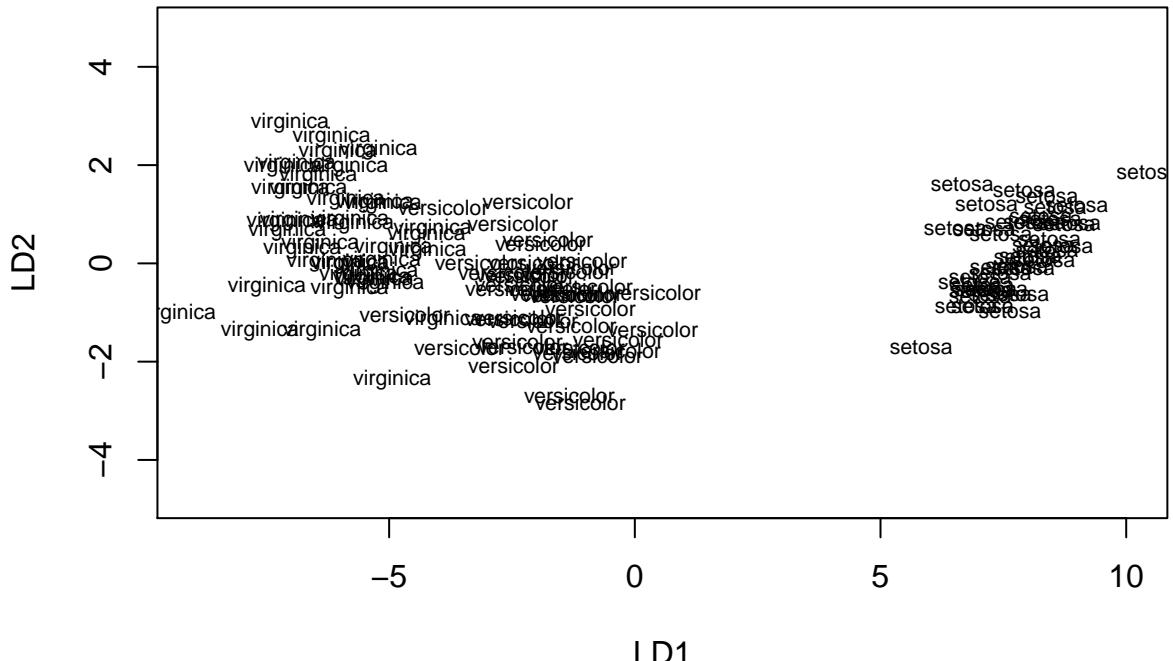
```

model <- lda(Species ~ ., data = train.transformed)
predictions <- predict(model, test.transformed)
mean(predictions$class == test.transformed$Species)

## [1] 1
model

## Call:
## lda(Species ~ ., data = train.transformed)
##
## Prior probabilities of groups:
##   setosa versicolor virginica
## 0.3333333 0.3333333 0.3333333
##
## Group means:
##           Sepal.Length Sepal.Width Petal.Length Petal.Width
## setosa      -1.0120728   0.7867793  -1.2927218  -1.2496079
## versicolor   0.1174121  -0.6478157   0.2724253   0.1541511
## virginica    0.8946607  -0.1389636   1.0202965   1.0954568
##
## Coefficients of linear discriminants:
##             LD1        LD2
## Sepal.Length 0.9108023  0.03183011
## Sepal.Width  0.6477657  0.89852536
## Petal.Length -4.0816032 -2.22724052
## Petal.Width  -2.3128276  2.65441936
##
## Proportion of trace:
##   LD1     LD2
## 0.9905 0.0095
plot(model)

```



```

predictions <- predict(model,test.transformed)
names(predictions)

## [1] "class"      "posterior"   "x"

head(predictions$class, 6)

## [1] setosa setosa setosa setosa setosa setosa
## Levels: setosa versicolor virginica

head(predictions$posterior, 6)

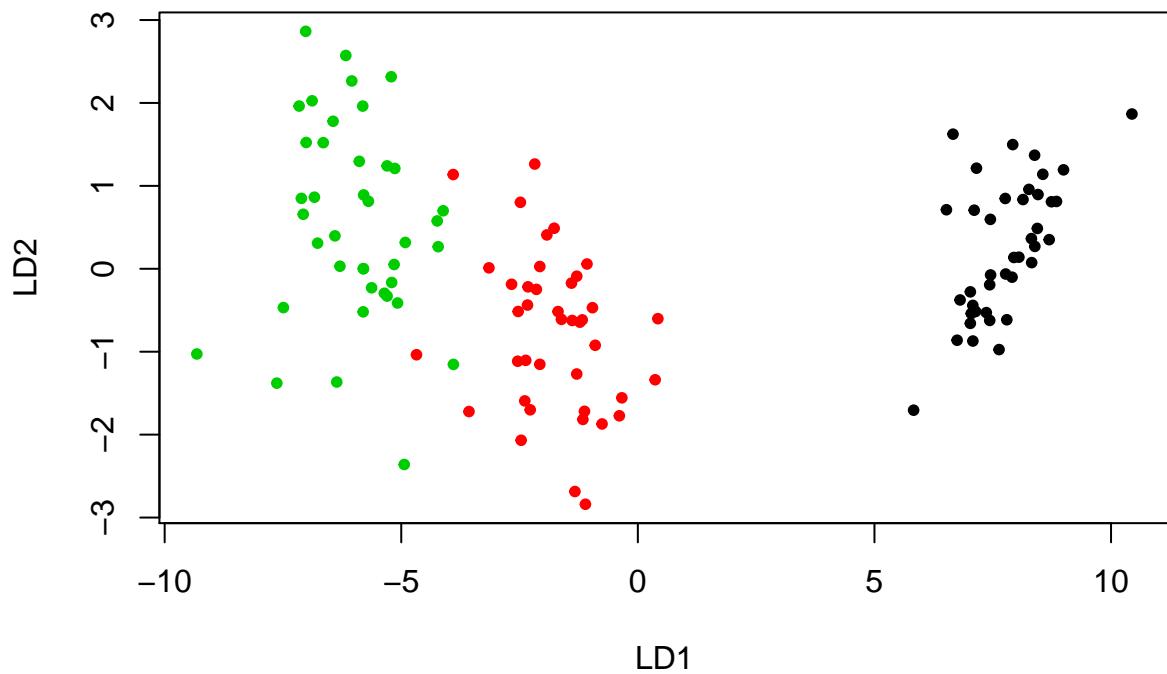
##      setosa    versicolor    virginica
## 5  1 5.718110e-24 5.016023e-46
## 6  1 9.459855e-23 1.638348e-43
## 10 1 7.615603e-20 2.693591e-41
## 12 1 1.495465e-19 3.345580e-40
## 16 1 7.132457e-30 1.009441e-52
## 17 1 8.379340e-27 5.833391e-49

head(predictions$x, 3)

##          LD1         LD2
## 5  8.495822  0.7032086
## 6  8.095995  1.6969837
## 10 7.667684 -0.8766525

lda.data <- cbind(train.transformed, predict(model)$x)
plot(predict(model)$x, pch=20, col=train.transformed$Species)

```



```
plot(predictions$x, pch=20, col=predictions$class)
```

