Eksploracja danych
Laboratorium 5

Regresja logistyczna

Regresja logistyczna

- Regresja logistyczna jest metodą klasyfikacji (patrz **wykład 4**)
  - Oczekiwane jest, że atrybut wyjściowy jest etykietą klasy (a nie liczbą)
  - Atrybuty wejściowe muszą być numeryczne
- Podczas zajęć będziemy przetwarzali plik zawierający rzeczywiste dane obejmujące:
  - ocenę i datę zaliczenia z języka C (co najmniej 3.0)
  - ocenę pierwszego zaliczenia z języka C++
  - ocenę z I terminu egzaminu (można przystąpić bez zaliczenia)

- Interesuje nas wpływ ocen z zaliczeń na wynik egzaminu w pierwszym terminie (przekształcony do problemu klasyfikacji binarnej):
  - nie zdał (2.0)
  - zdał (3.0-5.0)

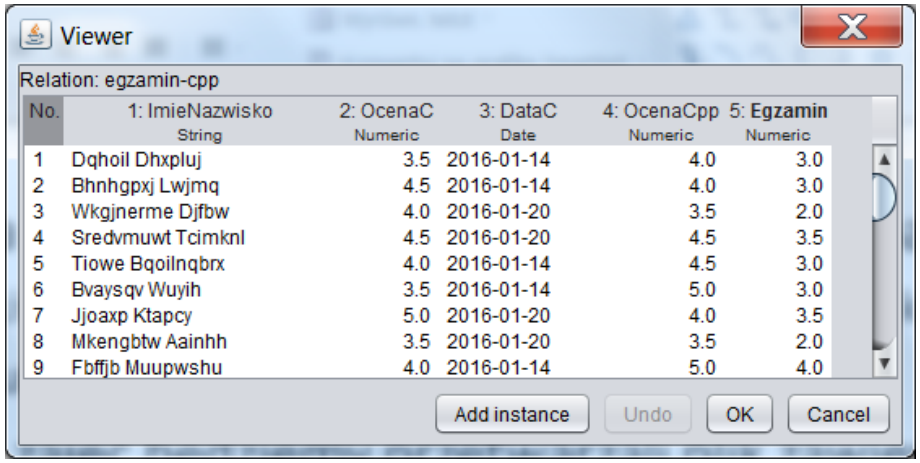

5.1 Przygotowanie danych

- Pobierz pliki
  - egzamin-cpp.csv
  - egzamin-cpp-train.csv
  - egzamin-cpp-test.csv

  Dwa ostatnie powstały z podziału egzamin-cpp na dwa
- Przekształć je do postaci ARFF

Najlepiej w tym celu użyć polecenia w konsoli:

```
java -cp …\weka.jar weka.core.converters.CSVLoader [opcje]
egzamin-cpp-train.csv > egzamin-cpp-train.arff
```

Opcje dostępne na stronie:

http://weka.sourceforge.net/doc.dev/weka/core/converters/CSVLoader.html

Należy

- wskazać separator
- podać, który atrybut jest typu String
- który atrybut jest datą i jaki jest jej format (-format ”yyyy-mm-dd”)
- dla pliku egzamin-cpp-test.csv użyj opcji –N 5, aby wskazać, że ostatni atrybut jest nominalny (są tam puste wartości)

5.2 Konwersja danych

- Konwersja stosuje się do egzamin-cpp.arff i egzamin-cpp-train.arff.
- Jest ona kilkuetapowa i można ją przeprowadzić w :
  - Weka Explorer wybierając kolejno stosowne filtry i klikając Apply. Na wszelki wypadek należy zapisywać pliki pośrednie.
  - Można też skonstruować knowledge flow (**zalecane**, bo łatwiej poprawić błędy i zastosować do dwóch plików).
- Etap 1: NumericToNominal

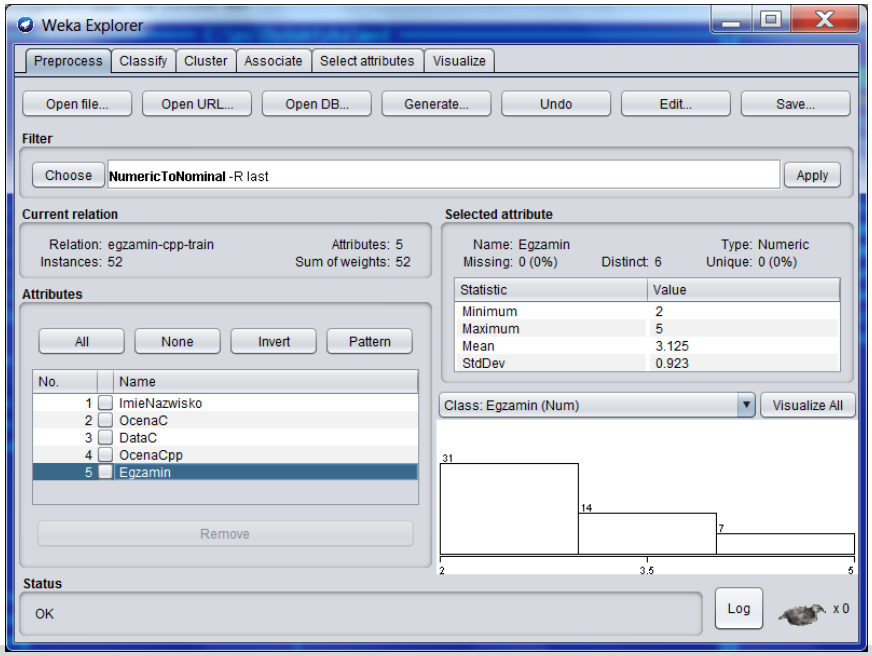

Użyj Apply i zapisz

Konwersja danych

- Etap 2: RenameNominalValues 2-> nie_zdal

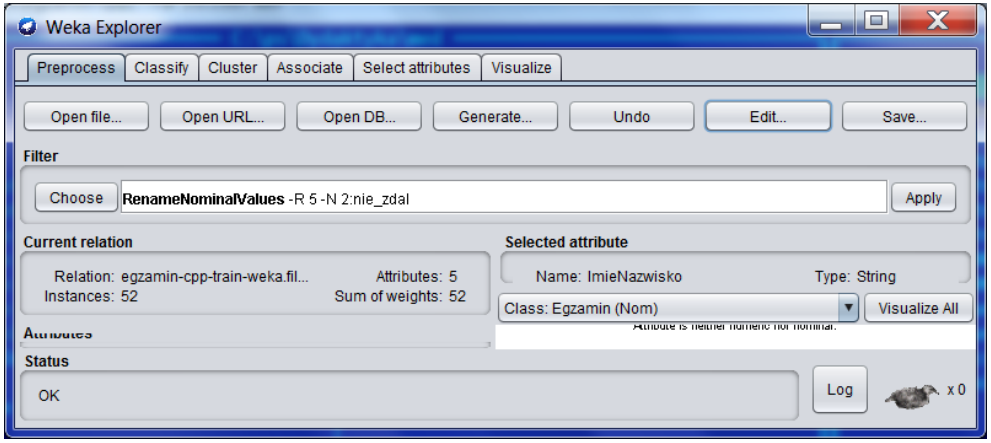

- Etap 3: MergeManyValues {3,3.5,4,4.5,5}-> zdal

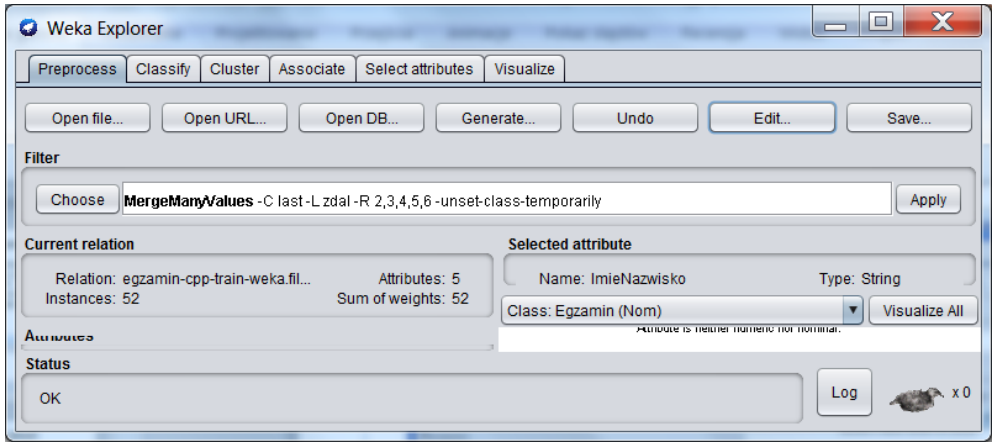

Znikający przecinek?: wprowadź {2,3,4,5,6} a potem usuń {}

Jako alternatywa: workflow KW1

- Opcje dokładnie te same

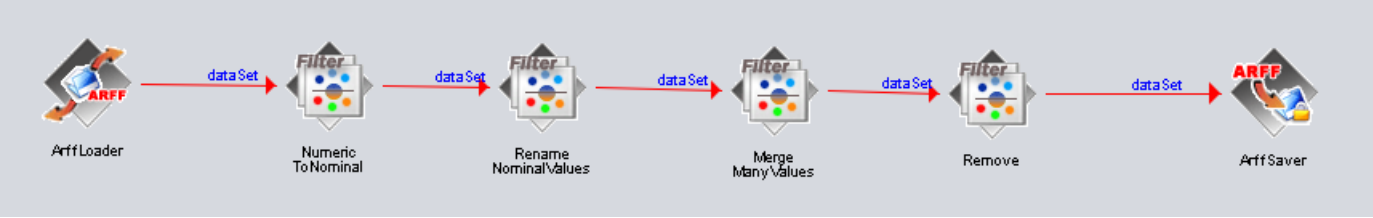

- Załóżmy, że w ArffSaver ustawiony jest prefiks „preprocessed”:
  Pliki wyjściowe będą miały nazwy typu:
  - preprocessed-egzamin-cpp-[].arff
  - preprocessed-egzamin-cpp-train[].arff

5.3 Klasyfikator

- Otwórz plik preprocessed-**egzamin-cpp**- […].arff
- Wybierz w zakładce Classify regresję logistyczną i uruchom
- Jak zinterpretujesz wyniki? Patrz **wykład 4**

1. Podaj wzór na hiperpłaszczyznę separującą dane
2. Podaj o ile wzrost/spadek ocen wpływa na szanse zdania/niezdania egzaminu
3. Jak wpływa na egzamin zmiana daty wpisu zaliczenia?
4. Zinterpretuj wyniki klasyfikacji.
5. Porównaj wyniki testów z użyciem zbioru uczącego i walidacji krzyżowej

[https://weka.wikispaces.com/Primer]
The *True Positive (TP)* rate is the proportion of examples which were classified as class *x*, among all examples which truly have class *x*, i.e., how much of the class was captured correctly. It is equivalent to *Recall*. In the confusion matrix, this is the diagonal element divided by the sum over the relevant row.

The *False Positive (FP)* rate is the proportion of examples which were classified as class *x*, but belong to a different class, among all examples which are not of class *x*. [**Element poza przekątną podzielony przez wiersz. FP i TP sumują się po przekątnych….]**

The *Precision* is the proportion of the examples which truly have class *x* among all those which were classified as class *x*.

The *F-Measure* is simply 2*Precision*Recall/(Precision+Recall), a combined measure for precision and recall.

Regresja

Szansa

5.4 Porównaj jawnie wyniki klasyfikacji

- W Weka Explorer otwórz przetworzony plik preprocessed-**egzamin-cpp**- […].arff
- W Preprocess wybierz filtr AddClassification
- Jako classifier wybierz Logistic ze standardowymi opcjami
- Zwróć uwagę na opcje filtra:

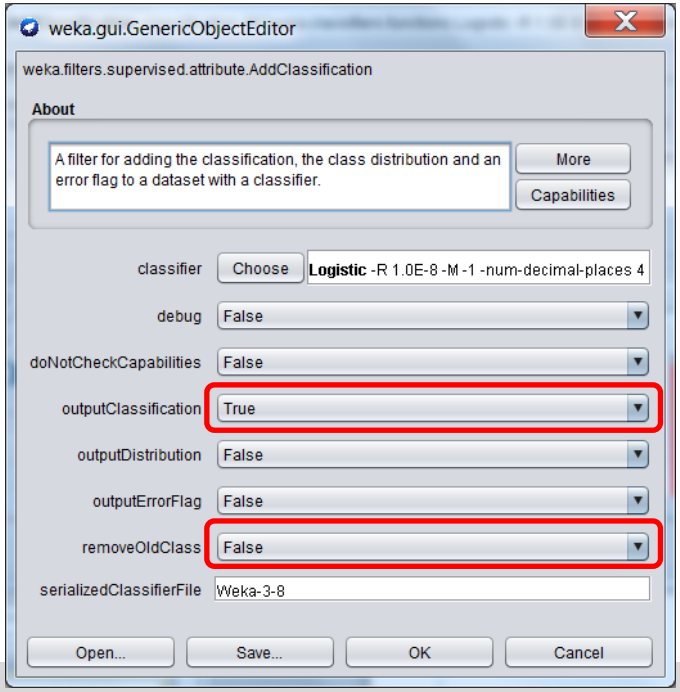

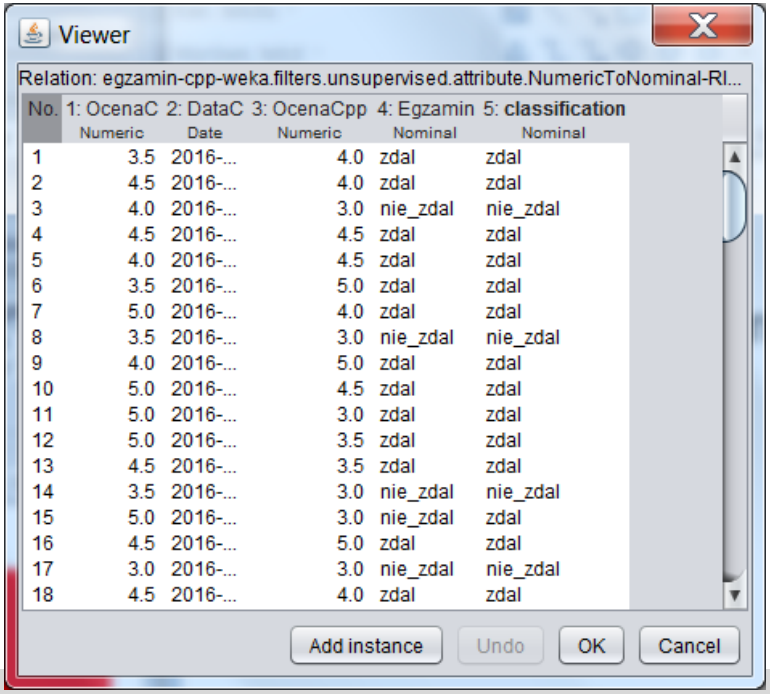

5.5 Klasyfikacja w Knowledge Flow

- Zbudowany zostanie model regresji logistycznej na podstawie **preprocessed-egzamin-cpp-train**[…].arff
- Model zostanie zapisany
- W drugim procesie model zostanie załadowany i zastosowany do **egzamin-cpp-test**.arff

Klasyfikacja w Knowledge Flow

- Zbuduj następujący workflow KW2

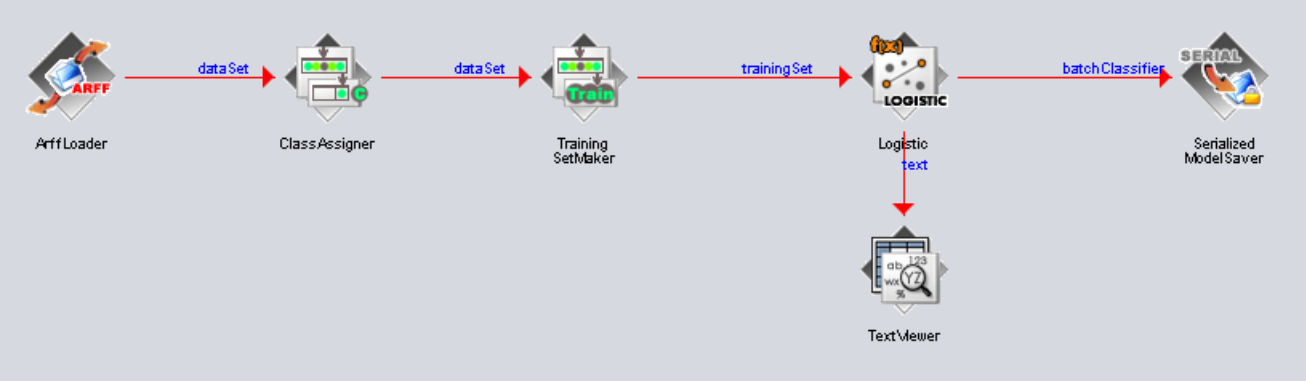

1. Załaduj plik **preprocessed-egzamin-cpp-train**[…].arff
2. Jako klasę wyjściową wybierz Egzamin
3. TrainingSetMaker i Logistic – opcje standardowe
4. Zapisz model dodając prefiks, np. **egzamin-cpp**

Model to zbudowany klasyfikator, w tym przypadku wagi dla równania $w^T[ocenaC, dataC, ocenaCpp] = 0$

Przetwarzamy plik testowy

- Zbuduj następujący workflow KW3

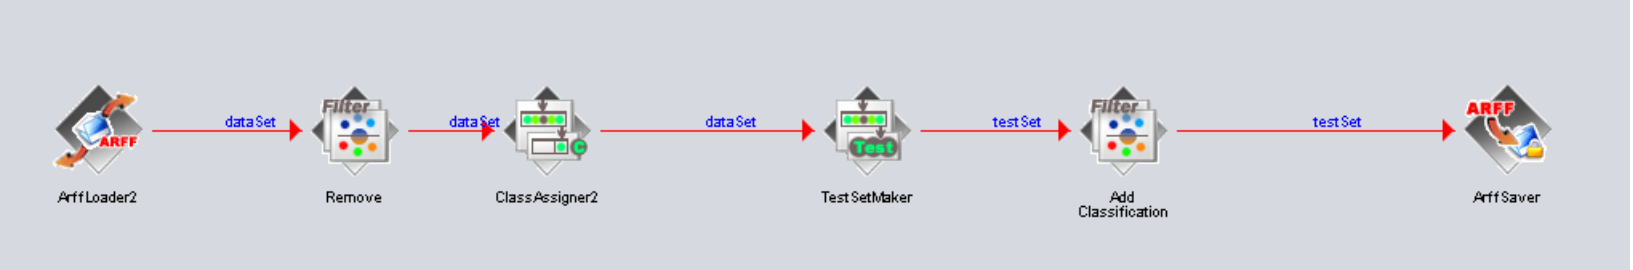

1. Załaduj plik **egzamin-cpp-test**.arff
2. Usuń pierwszy atrybut
3. Jako atrybut klasy wybierz Egzamin
4. Skonfiguruj AddClassification (**patrz następna strona**)
5. Wybierz nazwę pliku wyjściowego dla ArffSaver
6. Uruchom i obejrzyj wyniki

Konfiguracja AddClassification

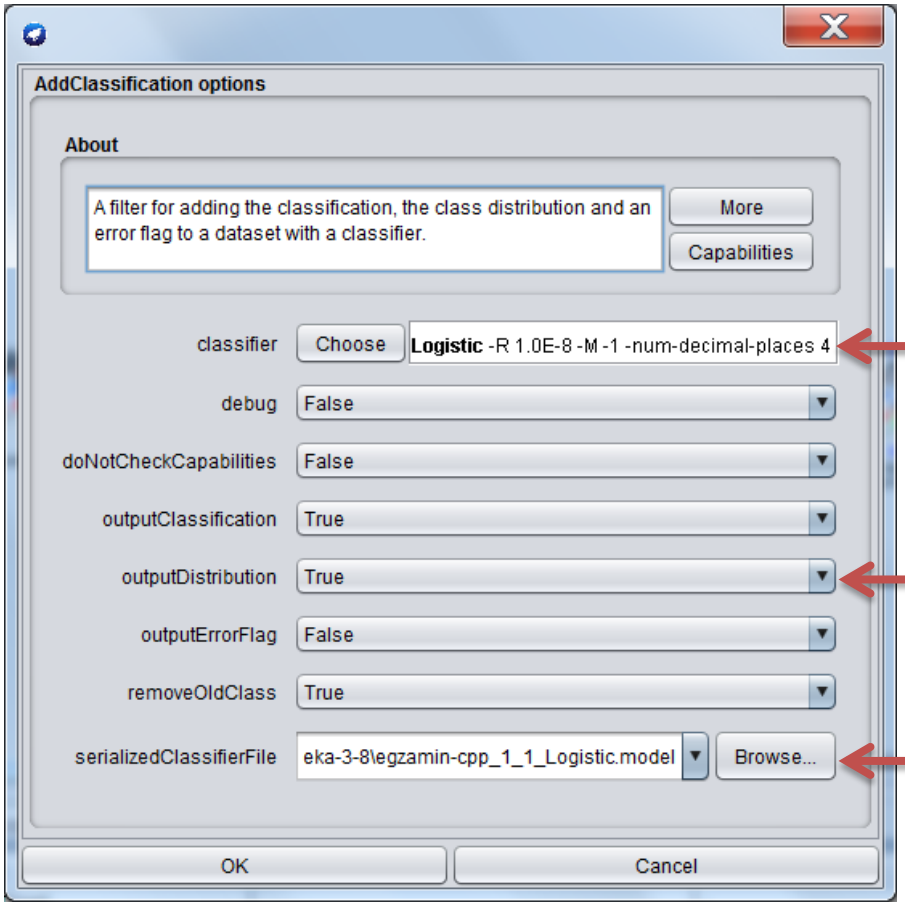

Wybierz Logistic, ale jeśli załadowany jest model to raczej nie ma znaczenia

Dodane zostaną prawdopodobieństwa nie_zdal/zdal

Wyberz wcześniej zapisany model

Jeżeli w trakcie wykonania pojawiły się błędy (wyjątki) typu „unary class”:
W pliku arff zamień @attribute Egzamin {*unknown*} na
@attribute Egzamin {nie_zdal,zdal}

Testy wszystkich wartości

Tak naprawdę różnych wariacji ocen wejściowych jest niewiele. Można sprawdzić je **wszystkie**.

Pobierz plik **grid.arff** Jest to wygenerowany plik z wszystkimi kombinacjami ocen (w tym 2.0 dla pierwszego zaliczenia z C++)

5.6 Test modelu na podstawie zbioru egzamin-cpp-train

- Skonfiguruj workflow KW3 tak, aby czytać z grid.arff
- Uruchom i sprawdź wyniki (nie są szczególnie wyraziste, praktycznie wszyscy zdają).
- Oceń wyznaczone przez klasyfikator prawdopodobieństwa

5.7 Test modelu na podstawie zbioru egzamin-cpp

- Skonfiguruj workflow KW2 tak, aby model był jednak generowany na podstawie **preprocessed-egzamin-cpp[].arff** (lepsze pokrycie)
- Uruchom KW3 (skonfigurowany wcześniej do odczytu grid.arff) i porównaj wyniki
- Zestaw wyniki w postaci tabelki (OcenaC, OcenaCpp,wynik egzaminu, pojedyncza [większa] wartość prawdopodobieństwa)