Il software Weka

Prof. Matteo Golfarelli
Alma Mater Studiorum - Università di Bologna

Weka

- Un software per il Data Mining/Machine learningscritto in Java e distribuito sotto la GNU Public License)
  - ✓ Waikato Environment for Knowledge Analysis
- Utilizzato in ambito scientifico, didattico e applicativo
- Include:
  - ✓ Un insieme di tool per il pre-processing, algoritmi di apprendimento e metodi di valutazione
  - ✓ Interfaccia grafica
  - ✓ Un ambiente per comparare i risultati degli algoritmi di apprendimento

Weka

Experimenter
Ambiente per la comparazione dei risultati su più algoritmi di mining o su più data set

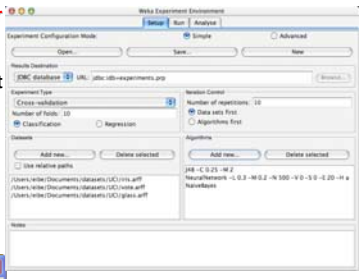

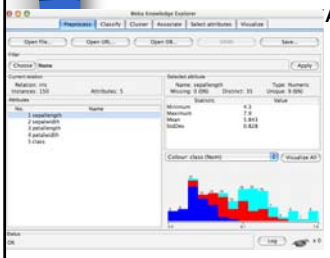

Explorer
Pre-processing e creazione di modelli di learning

SimpleCLI
Interfaccia testuale

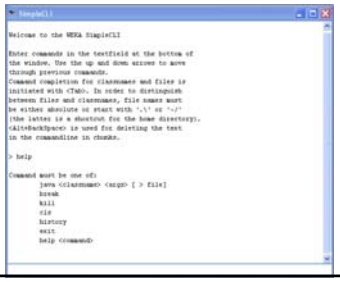

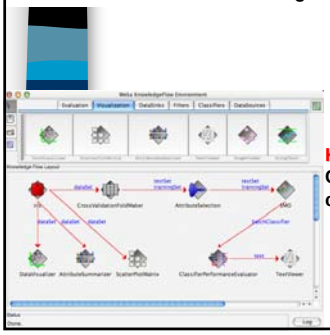

KnowledgeFlow
Creazione di flussi complessi di funzioni Weka

Gestione dei dati

- Il principale tipo di dati con cui opera WEKA è l'Attribute – Relation file (ARFF file)
  - ✓ I file descrivono la relazione, gli attributi e i valori che questi possono contenere, i dati

```
@relation heart-disease-simplified

@attribute age numeric
@attribute sex { female, male}
@attribute chest_pain_type { typ_angina, asympt, non_anginal, atyp_angina}
@attribute cholesterol numeric
@attribute exercise_induced_angina { no, yes}
@attribute class { present, not_present}

@data
63,male,typ_angina,233,no,not_present
67,male,asympt,286,yes,present
67,male,asympt,229,yes,present
38,female,non_anginal,?,no,not_present
...
```

Gestione dei dati

- I classificatori costruiti (addestrati) possono essere salvati su file denominati modelli
  - ✓ Il salvataggio e il caricamento del modello si avviano con un right click del mouse sulla result list
- E quindi possibile ricaricare un modello e rieseguirlo su un nuovo data set
  - ✓ Il data set deve essere caricato utilizzando la voce “Test options→Supplied test set”

Il pre-processing

- Il pre-processing si realizza mediante filtri:
  - ✓ Discretizzazione
  - ✓ Normalizzazione
  - ✓ Resampling
  - ✓ Selezione di attributi
  - ✓ Trasformazione di attributi
- Il tab pre-processing consente inoltre funzionalità di visualizzazione delle distribuzione dei dati rispetto all’attributo di classificazione o altro attributo

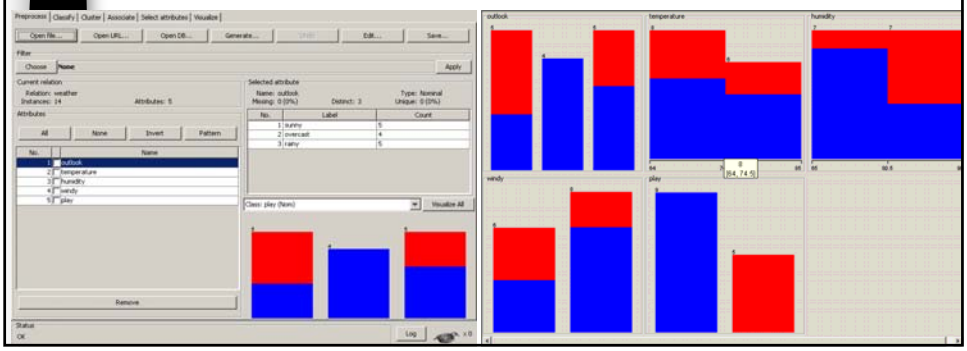

Il pre-processing

- Il pre-processing si realizza mediante filtri:
  - ✓ Discretizzazione
    - Discretize (unsupervised): An instance filter that discretizes a range of numeric attributes in the dataset into nominal attributes.
  - ✓ Normalizzazione
    - Normalize : normalizes all numeric values in the given dataset (apart from the class attribute, if set). The resulting values are by default in [0,1] for the data used to compute the normalization intervals. But with the scale and translation parameters one can change that, e.g., with scale = 2.0 and translation = -1.0 you get values in the range [-1,+1].
    - Standardize: standardizes all numeric attributes in the given dataset to have zero mean and unit variance (apart from the class attribute, if set).

Il pre-processing

- Il pre-processing si realizza mediante filtri:
  - ✓ Resampling
    - Resample: produces a random subsample of a dataset using either sampling with replacement or without replacement.
  - ✓ Trasformazione di attributi e valori
    - NominalToBinary: converts all nominal attributes into binary numeric attributes.
    - AddNoise: An instance filter that changes a percentage of a given attributes values. The attribute must be nominal. Missing value can be treated as value itself.
  - ✓ Gestione valori mancanti
    - ReplaceMissingValues: replaces all missing values for nominal and numeric attributes in a dataset with the modes and means from the training data.

Il pre-processing

- Selezione di attributi: consente di identificare il subset di attributi che contenga la massima quantità di informazione
  - ✓ CfsSubsetEval: evaluates the worth of a subset of attributes by considering the individual predictive ability of each feature along with the degree of redundancy between them
  - ✓ ClassifierSubsetEval: evaluates attribute subsets on training data (or a seperate hold out testing set). Uses a classifier to estimate the 'merit' of a set of attributes.
- Lo spazio di ricerca (possibili subset degli attributi) può essere elevato è necessario definire un metodo di ricerca
  - ✓ Bestfirst
  - ✓ ExhaustiveSearch
  - ✓ GreedyStepWise
  - ✓ RandomSearch
  - ✓ …….

Visualizzazione

- Permette di visualizzare in un piano cartesiano le istanze del data set in funzione dei valori assunti da coppie di attributi
  - ✓ Il valore della classe è indicato tramite una diversa colorazione
- Dopo avere eseguito la classificazione è possibile utilizzare lo stesso tipo di visualizzazione per analizzare le istanze classificate in modo non corretto (rappresentate tramite rettangoli)
  - ✓ La visualizzazione si attiva con il tasto destro del mouse, selezionando la riga del log di esecuzione dell'algoritmo di learning
- Le tuple vere e proprie possono essere visualizzate
  - ✓ Dalla Weka GUI Choser
    - Tools→ArffViewer
  - ✓ Da Weka Explorer
    - Pulsante Edit

Classificazione

- Il tab di classificazione permette di:
  - ✓ Selezionare il tipo di algoritmo di classificazione e settarne i parametri
  - ✓ Definire le modalità per valutare la bontà del risultato
  - ✓ Visualizzare il risultato della classificazione
- Tra i molti classificatori a disposizione utilizzeremo:
  - ✓ Alberi decisionali (tree)
    - J48: implementazione dell'algoritmo C4.5
      - Unpruned (TRUE/FALSE) esegue o meno il post pruning
      - Confidence factor: valori piccoli accentuano l'effetto del post pruning
      - minNumObj : numero minimo di elementi in una foglia
    - Decision Stump: crea un albero decisionale a un livello
  - ✓ Classificatori basati su regole (rules)
    - Jrip: implementazione dell'algoritmo RIPPER
      - usePruning(TRUE/FALSE) esegue o meno il pruning
      - minNo: numero minimo di ementi coperti da una regola

Classificazione

- Il tab di classificazione permette di:
  - ✓ Selezionare il tipo di algoritmo di classificazione e settarne i parametri
  - ✓ Definire le modalità per valutare la bontà del risultato
  - ✓ Visualizzare il risultato della classificazione
- Tra i molti classificatori a disposizione utilizzeremo:
  - ✓ Classificatori istance based (lazy)
    - IBK: implementazione dell'algoritmo k-mediani
      - KNN: valore di k
      - nearestNeighbourSearchAlgorithm: tecnica utilizzata per la ricerca dell'NN
  - ✓ Classificatori Bayesiani (bayes)
    - Naive Bayes: implementazione dell'omonimo algoritmo

Classificazione

- Tra i molti classificatori a disposizione utilizzeremo:
  - ✓ Multi-classificatori (meta): utilizzano classificatori semplici per creare classificatori più complessi e potenti
    - Bagging
    - AdaBoost
    - RandomCommittee: il classificatore calcola la media dei risultati di più alberi decisionali ognuno dei quali utilizza un sottoinsieme random di attributi
    - CostSensitiveClassifier: rende cost sensitive il classificatore selezionato
- Test options: definiscono le modalità per verificare l'errore di classificazione:
  - ✓ Use training set
  - ✓ Supplied test set
  - ✓ Cross validation
  - ✓ Percentage split
- Attivando il flag More Options→Cost-Sensitive evaluation è inoltre possibile effettuare una **valutazione** dipendente dal peso degli errori

Analisi della classificazione

```
=== Classifier model (full training set) ===

J48 pruned tree
------------------

wage-increase-first-year <= 2.5: bad (15.27/2.27)
wage-increase-first-year > 2.5
|   statutory-holidays <= 10: bad (10.77/4.77)
|   statutory-holidays > 10: good (30.96/1.0)

Number of Leaves  :     3

Size of the tree :      5


Time taken to build model: 0 seconds

=== Evaluation on training set ===
=== Summary ===

Correctly Classified Instances          50               87.7193 %
Incorrectly Classified Instances         7               12.2807 %
Kappa statistic                          0.745
Mean absolute error                      0.195
Root mean squared error                  0.304
Relative absolute error                 42.6664 %
Root relative squared error             63.6959 %
Total Number of Instances               57

=== Detailed Accuracy By Class ===

               TP Rate   FP Rate   Precision   Recall  F-Measure   ROC Area  Class
                 0.95      0.162      0.76      0.95      0.844      0.918    bad
                 0.838     0.05       0.969     0.838     0.899      0.918    good
Weighted Avg.    0.877     0.089      0.896     0.877     0.88       0.918

=== Confusion Matrix ===

  a  b   <-- classified as
 19  1 |  a = bad
  6 31 |  b = good
```

Struttura dell'albero/regole con indicazione del numero di istanze del training set classificate correttamente e non. Le frazioni riguardano istanze con valori mancanti

Statistiche riassuntive

Statistiche dettagliate per classe

Matrice di confusione