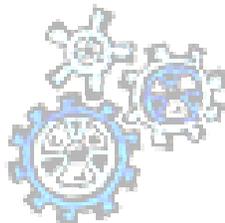
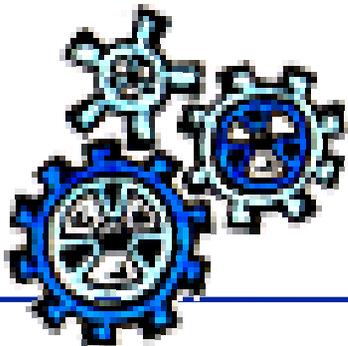


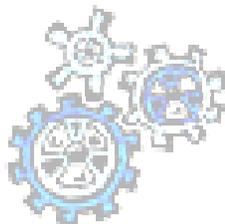
Strumenti per l'Analisi ed il Preprocessing dei dati

Francesco Folino



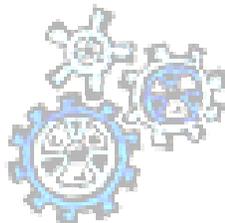
Obiettivo

- **Introdurre gli aspetti essenziali della fase di preparazione dei dati**
- **Acquisire padronanza di un processo tipicamente “artigianale”**
 - **La preparazione dei dati è speculare ad un obiettivo**
 - **La preparazione deve essere adeguata**



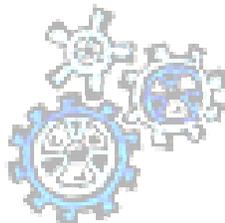
Tools

- **Si adopereranno a tale scopo due strumenti:**
 - **KnowledgeStudio (a scopo dimostrativo)**
 - **Weka (a scopo didattico)**



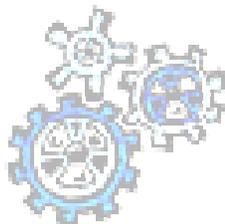
Data Set

- **Il Data Set utilizzato per la dimostrazione è FNBA:**
 - **First National Bank of Anywhere (FNBA)**
 - **Dati relativi a situazioni di credito**
 - **Obiettivo principale: campagna di marketing per attrarre nuovi acquirenti**
 - **La campagna è fatta per gruppi di affinità**
 - **Sulla base delle loro caratteristiche**



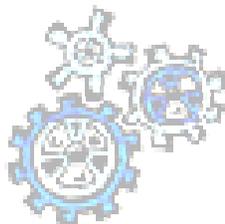
Il Data Preprocessing è un Processo...

- **Accesso ai Dati**
- **Esplorazione dei Dati**
 - **Sorgenti**
 - **Quantità**
 - **Qualità**
- **Ampliamento e arricchimento dei dati**
- **Applicazione di tecniche specifiche**



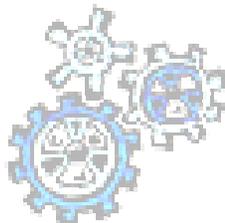
Il Data Preprocessing dipende (ma non sempre) dall'Obiettivo

- **Alcune operazioni sono necessarie**
 - **Studio dei dati**
 - **Pulizia dei dati**
 - **Campionamento**
- **Altre possono essere guidate dagli obiettivi**
 - **Trasformazioni**
 - **Selezioni**



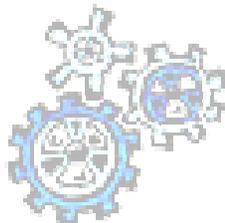
Problemi tipici

- **Troppi dati**
 - dati sbagliati, rumorosi
 - dati non rilevanti
 - dimensione intrattabile
 - mix di dati numerici/simbolici
- **Pochi dati**
 - attributi mancanti
 - valori mancanti
 - dimensione insufficiente



I° passo: Analisi dei Dati

- **Effettuare un'analisi quanto più approfondita sui dati al fine di valutarne al meglio caratteristiche ed eventuali anomalie**
- **A tal fine utilizzeremo:**
 - **Visualizzazione dei dati:**
 - **Distribuzioni**
 - **Diagrammi a barre**
 - **Scatters (o Dot Diagrams per un'analisi della dispersione)**
 - **Misure descrittive dei dati**
 - **Media**
 - **Varianza**
 - **Deviazione Standard**



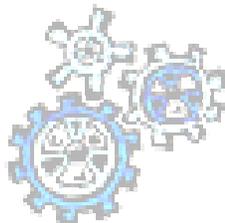
Possibili problemi riscontrabili nei dati

- **Sparsità**
 - Mancanza di valore associato ad una variabile
 - Un attributo è sparso se contiene molti valori nulli
- **Monotonicità**
 - Crescita continua dei valori di una variabile
 - Intervallo $[-\infty, \infty]$ (o simili)
 - Non ha senso considerare l'intero intervallo
- **Outliers**
 - Valori singoli o con frequenza estremamente bassa
 - Possono distorcere le informazioni sui dati
- **Dimensionalità**
 - Il numero di valori che una variabile può assumere può essere estremamente alto
 - Tipicamente riguarda valori categorici
- **Anacronismo**
 - Una variabile può essere contingente: abbiamo i valori in una sola porzione dei dati



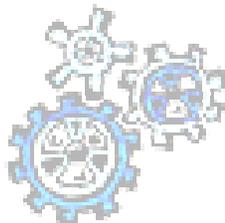
Analisi dei dati FNBA in Knowledge Studio

- **Obiettivo: analisi preventiva per la riduzione dei dati ad un data set di minore dimensione**
- **I dati devono essere “significativi” e non ridondanti**
- **L’analisi viene fatta sugli attributi e sulle istanze**



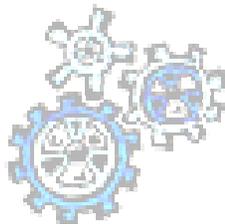
Analisi sugli attributi – Overview Report

- **Attributi molto sparsi. Osservando il report, gli attributi:**
 - **EQLIMIT, EQBAL, EQHIGHBAL, EQCURBAL, BCOPEN** presentano la maggior parte dei loro valori a **NULL**.
- **Presenza di molti attributi outliers:**
 - **CRITERIA, BCOPEN, OWN_HOME, BUYER, EST_INC** i cui valori sono singoli o comunque a bassissima frequenza



Analisi sugli attributi – DataSet chart

- **Permette di visualizzare, usando diversi tipi di grafici, le distribuzioni degli attributi.**
- **Consente di avere una conferma immediata sulle ipotesi fatte riguardo agli attributi sotto esame.**

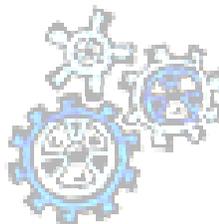


Analisi sugli attributi – Correlations

- Consente di identificare eventuali correlazioni tra attributi
- Ad esempio in FNBA gli attributi **MTCURBAL** e **MTHIGHBAL** sono tra loro negativamente correlati (hanno un coefficiente di correlazione pari a 0.98) e come tali non indipendenti. Il coefficiente di correlazione (Pearson) è:

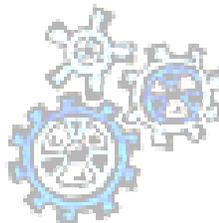
$$r_{xy} = \frac{Cov(x, y)}{s_x s_y}$$

- Uno tra loro (va scelto opportunamente) è ridondante e come tale può essere eliminato
- Passo importante ai fini della riduzione della dimensionalità degli attributi. Inoltre il modello di regressione può essere utile nella sostituzione di valori NULL



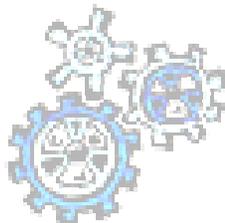
Analisi sugli attributi – Cross Tabs

- Consente di effettuare diversi tipi di grafici incrociando fra loro gli attributi da analizzare
- E' possibile così identificare, qualora esista, una linea di regressione
- La curva dovuta all'incrocio fra **MTCURBAL** e **MTHIGHBAL**, ad esempio, mostra abbastanza chiaramente il rapporto di dipendenza che esiste tra loro



Analisi sugli attributi – Segment Viewer

- **Consente di vedere come si distribuiscono gli attributi rispetto ad un fissato valore di un dato attributo.**
- **Può essere utile ad identificare anomalie nei dati: ad esempio attributi che perdono di significato quando altri assumono valori determinati**
- **Può essere utilizzato per identificare istanze poco significative e quindi passibili di eliminazione**



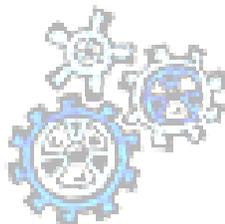
Analisi delle istanze

- Nel caso dell'FNBA Data Set esistono molte istanze poco significative dovute all'altissima presenza di valori NULL
- Ad esempio, se segmentiamo tutti gli attributi rispetto al valore NULL assunto dall'attributo **RLIMIT**, è possibile osservare che molti altri attributi (**CRITERIA**, **ROPEN**, **RBALNO**, **RBAL**, **LST_R_OPEN**) contemporaneamente hanno valore NULL.
- Si potrebbe così pensare di eliminare tutte le istanze in cui **RLIMIT** assume valore NULL



WEKA: il software

- E' un software scritto in Java e permette di fare analisi di Data Mining
- Usato molto in ambito accademico e di ricerca
- **Principali caratteristiche:**
 - **Contiene un insieme di tools per il data pre-processing e implementazioni di diversi algoritmi di DM**
 - **Ha un'interfaccia grafica che ne semplifica l'uso**
 - **Consente di effettuare confronti fra i vari algoritmi messi a disposizione**



Weka – Tipo di file

@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

Flat file in
ARFF format



Weka – Tipo di file

@relation heart-disease-simplified

numeric attribute

@attribute age numeric

@attribute sex { female, male}

nominal attribute

@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

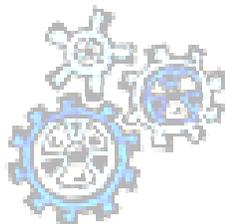
63,male,typ_angina,233,no,not_present

67,male,asympt,286,yes,present

67,male,asympt,229,yes,present

38,female,non_anginal,?,no,not_present

...



Weka – l'ambiente

Weka GUI Chooser

Waikato Environment for Knowledge Analysis

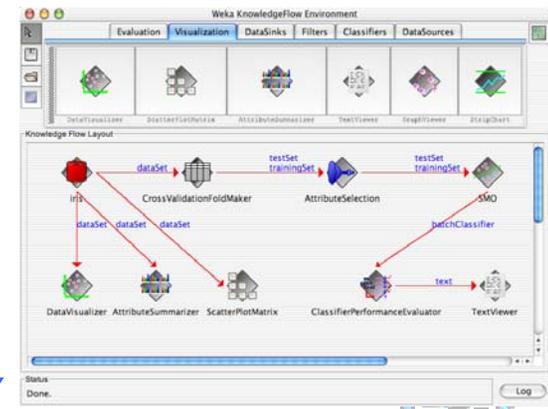
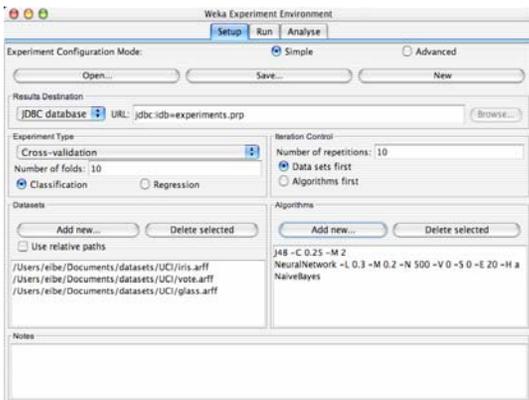
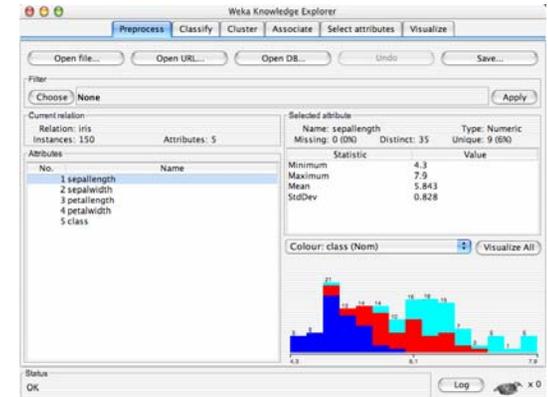
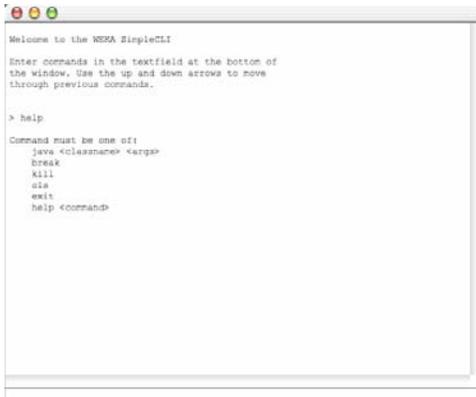
(c) 1999 – 2003
University of Waikato
New Zealand



GUI

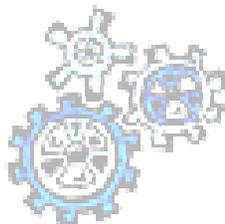
Simple CLI Explorer

Experimenter KnowledgeFlow



Weka - Explorer

- I dati possono essere importati da files in vari formati: ARFF, CSV, C4.5, binari
- I dati possono essere letti da un URL o da un database (usando JDBC)
- Gli strumenti di pre-processing in WEKA sono chiamati “filtri”
- WEKA contiene filtri per:
 - Discretizzazione, normalizzazione, selezione degli attributi, trasformazione di attributi...



Preprocess

Classify

Cluster

Associate

Select attributes

Visualize

Open file...

Open URL...

Open DB...

Undo

Save...

Filter

Choose **None**

Apply

Current relation

Relation: None

Instances: None

Attributes: None

Selected attribute

Name: None

Missing: None

Distinct: None

Type: None

Unique: None

Attributes

Empty list area for attributes.

Empty list area for selected attributes.

Visualize All

Status

Welcome to the Weka Knowledge Explorer

Log



x 0

Preprocess

Classify

Cluster

Associate

Select attributes

Visualize

Open file...

Open URL...

Open DB...

Undo

Save...

Filter

Choose None

Apply

Current relation

Relation: None
Instances: None

Attributes: None

Selected attribute

Name: None
Missing: None

Distinct: None

Type: None
Unique: None

Attributes



Visualize All

Status

Welcome to the Weka Knowledge Explorer

Log



Preprocess

Classify

Cluster

Associate

Select attributes

Visualize

Open file...

Open URL...

Open DB...

Undo

Save...

Filter

Choose None

Apply

Current relation

Relation: iris
Instances: 150

Attributes: 5

Selected attribute

Name: sepallength Type: Numeric
Missing: 0 (0%) Distinct: 35 Unique: 9 (6%)

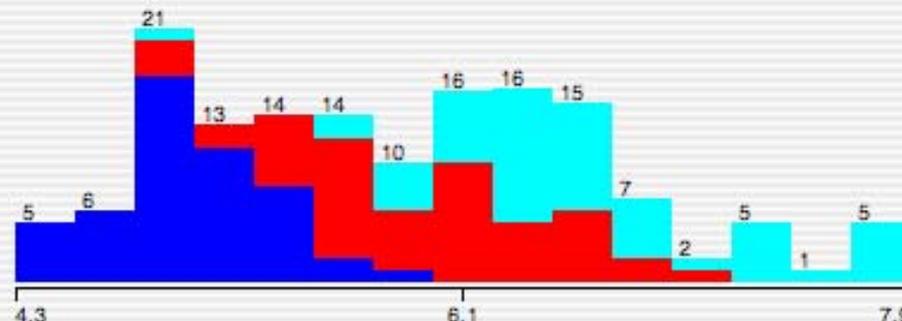
Attributes

No.	Name
1	sepallength
2	sepalwidth
3	petallength
4	petalwidth
5	class

Statistic	Value
Minimum	4.3
Maximum	7.9
Mean	5.843
StdDev	0.828

Colour: class (Nom)

Visualize All



Status

OK

Log



Preprocess

Classify

Cluster

Associate

Select attributes

Visualize

Open file...

Open URL...

Open DB...

Undo

Save...

Filter

Choose None

Apply

Current relation

Relation: iris
Instances: 150

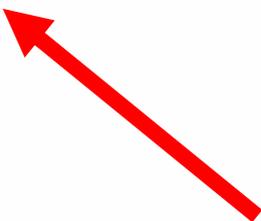
Attributes: 5

Selected attribute

Name: sepallength
Missing: 0 (0%)
Distinct: 35
Unique: 9 (6%)
Type: Numeric

Attributes

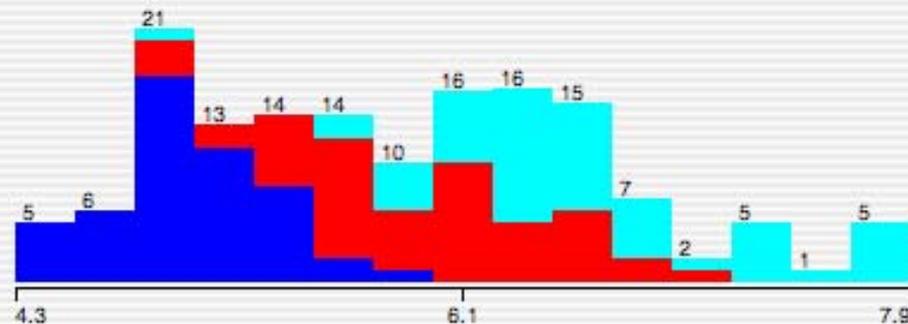
No.	Name
1	sepallength
2	sepalwidth
3	petallength
4	petalwidth
5	class



Statistic	Value
Minimum	4.3
Maximum	7.9
Mean	5.843
StdDev	0.828

Colour: class (Nom)

Visualize All



Status

OK

Log



Preprocess

Classify

Cluster

Associate

Select attributes

Visualize

Open file...

Open URL...

Open DB...

Undo

Save...

Filter

Choose None

Apply

Current relation

Relation: iris

Instances: 150

Attributes: 5

Selected attribute

Name: class

Missing: 0 (0%)

Distinct: 3

Type: Nominal

Unique: 0 (0%)

Attributes

No.	Name
1	sepalength
2	sepalwidth
3	petallength
4	petalwidth
5	class

Label	Count
Iris-setosa	50
Iris-versicolor	50
Iris-virginica	50

Colour: class (Nom)

Visualize All

50



50



50



Status

OK

Log

x 0

Preprocess

Classify

Cluster

Associate

Select attributes

Visualize

Open file...

Open URL...

Open DB...

Undo

Save...

Filter

Choose None

Apply

Current relation

Relation: iris
Instances: 150

Attributes: 5

Attributes

No.	Name
1	sepalength
2	sepalwidth
3	petallength
4	petalwidth
5	class

Selected attribute

Name: class
Missing: 0 (0%)

Distinct: 3

Type: Nominal
Unique: 0 (0%)

Label	Count
Iris-setosa	50
Iris-versicolor	50
Iris-virginica	50

Colour: class (Nom)

Visualize All

50



50



50


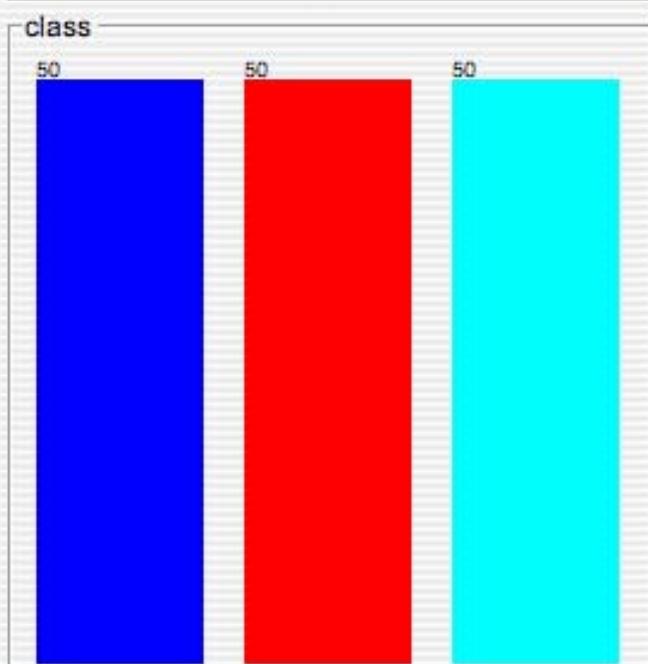
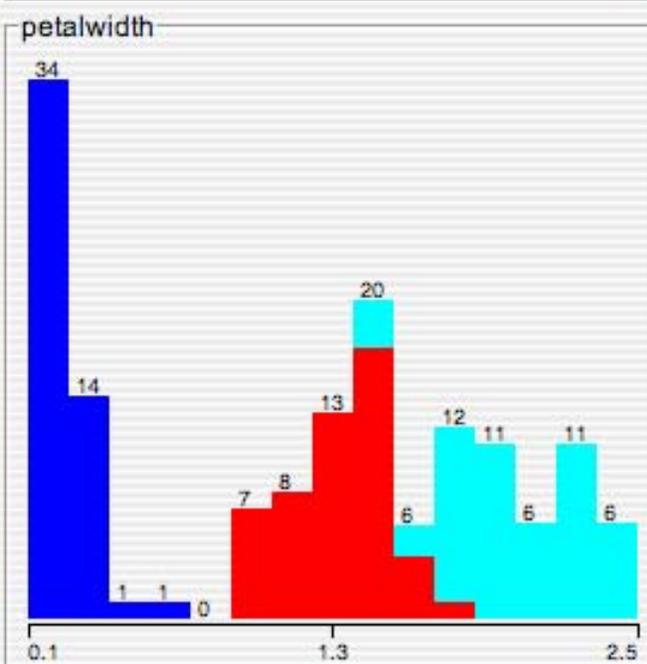
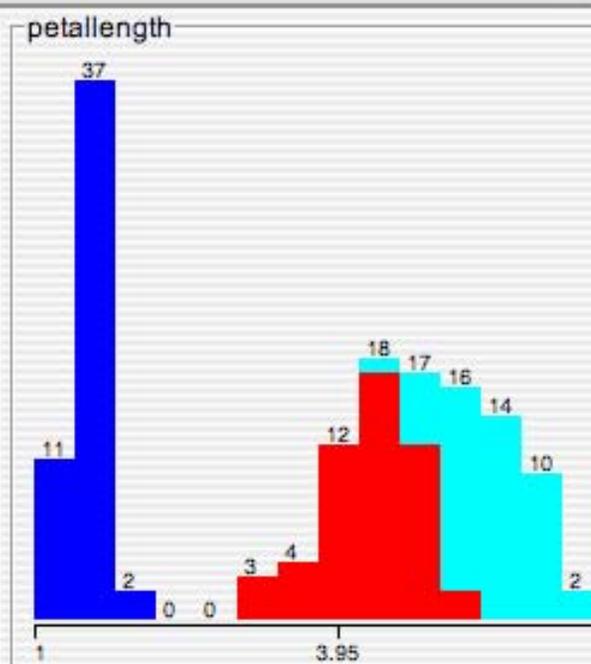
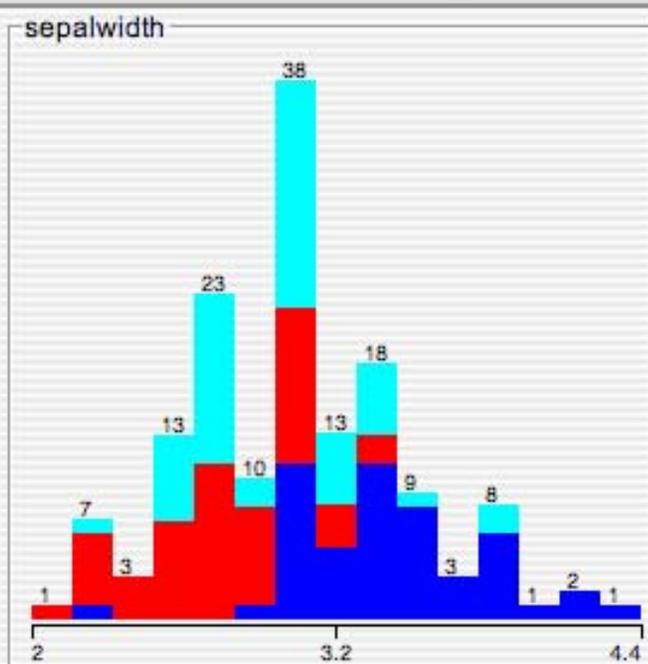
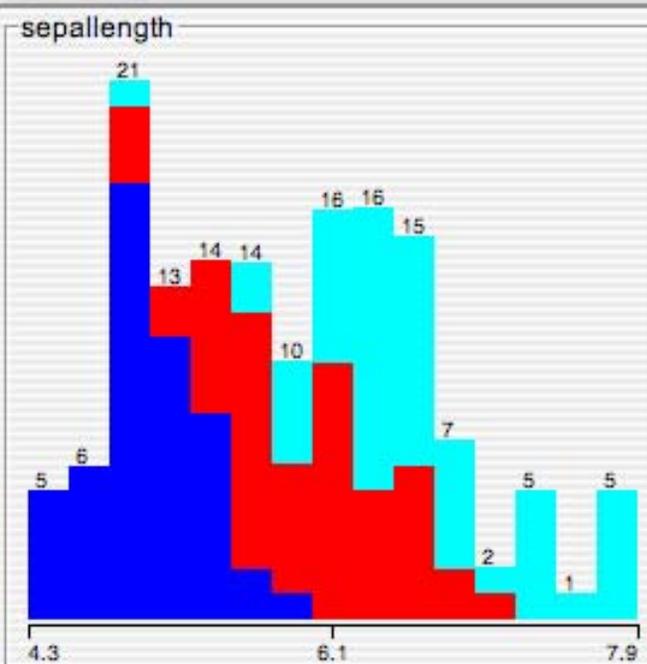


Status

OK

Log





Preprocess

Classify

Cluster

Associate

Select attributes

Visualize

Open file...

Open URL...

Open DB...

Undo

Save...

Filter

Choose None

Apply

Current relation

Relation: iris
Instances: 150

Attributes: 5

Selected attribute

Name: petallength
Missing: 0 (0%) Distinct: 43 Type: Numeric
Unique: 10 (7%)

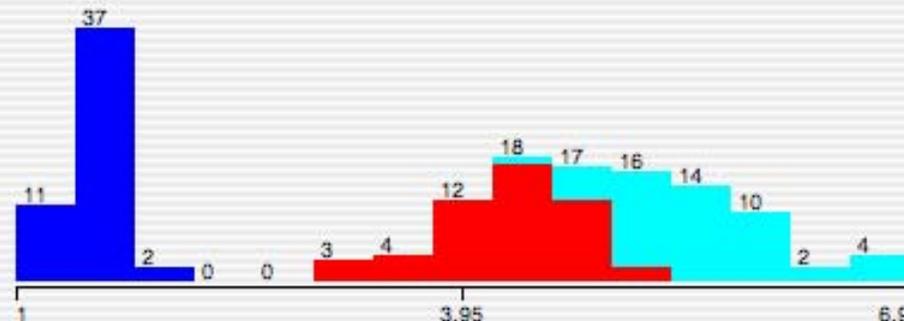
Attributes

No.	Name
1	sepalength
2	sepalwidth
3	petallength
4	petalwidth
5	class

Statistic	Value
Minimum	1
Maximum	6.9
Mean	3.759
StdDev	1.764

Colour: class (Nom)

Visualize All



Status

OK

Log



Preprocess

Classify

Cluster

Associate

Select attributes

Visualize

Open file...

Open URL...

Open DB...

Undo

Save...

Filter

Choose **None**

Apply

Current relation

Relation: iris
Instances: 150

Attributes: 5

Attributes

No.	Name
1	sepalength
2	sepalwidth
3	petallength
4	petalwidth
5	class

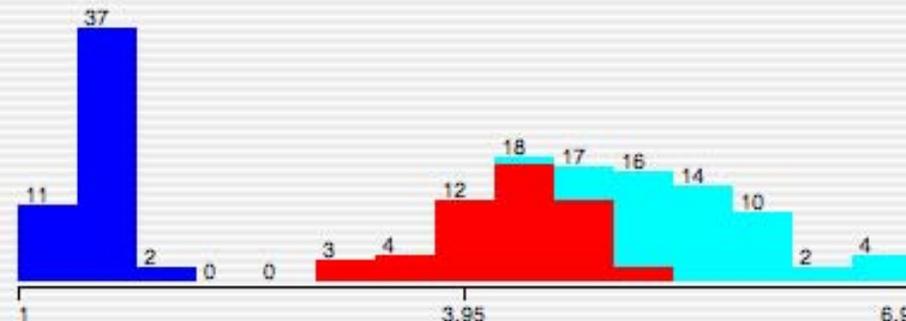
Selected attribute

Name: petallength Type: Numeric
Missing: 0 (0%) Distinct: 43 Unique: 10 (7%)

Statistic	Value
Minimum	1
Maximum	6.9
Mean	3.759
StdDev	1.764

Colour: class (Nom)

Visualize All



Status

OK

Log



Preprocess

Classify

Cluster

Associate

Select attributes

Visualize

Open file...

Open URL...

Open DB...

Undo

Save...

Filter

- weka
 - filters
 - unsupervised
 - attribute
 - instance

Apply

Selected attribute

Name: petallength

Type: Numeric

Missing: 0 (0%)

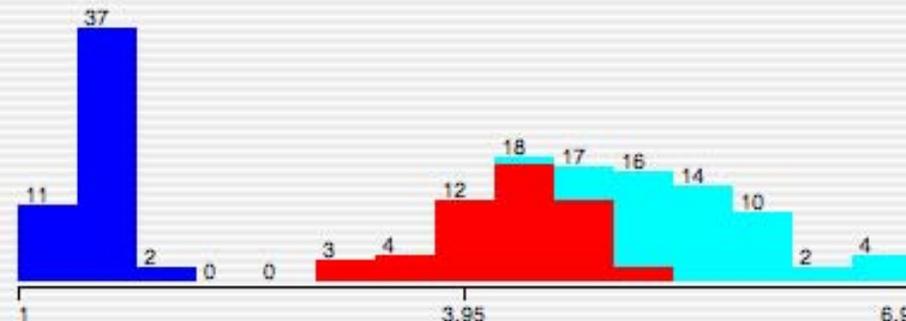
Distinct: 43

Unique: 10 (7%)

Statistic	Value
Minimum	1
Maximum	6.9
Mean	3.759
StdDev	1.764

Colour: class (Nom)

Visualize All



Status

OK

Log

x 0

Preprocess

Classify

Cluster

Associate

Select attributes

Visualize

Open file...

Open URL...

Open DB...

Undo

Save...

Filter

- weka
 - filters
 - unsupervised
 - attribute
 - instance

Apply

Selected attribute

Name: petallength

Type: Numeric

Missing: 0 (0%)

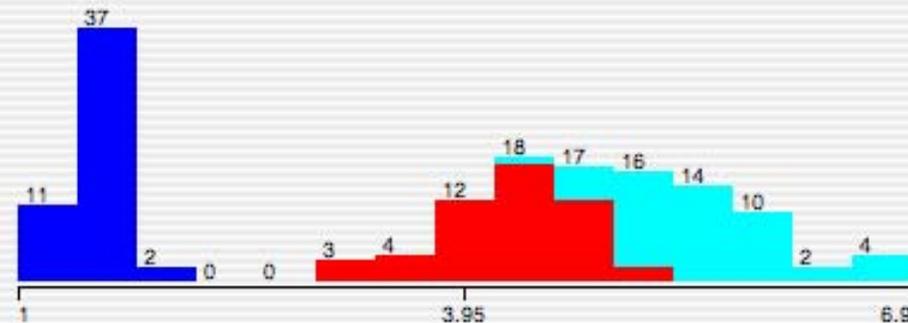
Distinct: 43

Unique: 10 (7%)

Statistic	Value
Minimum	1
Maximum	6.9
Mean	3.759
StdDev	1.764

Colour: class (Nom)

Visualize All



Status

OK

Log

x 0

Preprocess

Classify

Cluster

Associate

Select attributes

Visualize

Open file...

Open URL...

Open DB...

Undo

Save...

Filter

- weka
 - filters
 - unsupervised
 - attribute
 - Add
 - AddCluster
 - AddExpression
 - AddNoise
 - Copy
 - Discretize
 - FirstOrder
 - MakeIndicator
 - MergeTwoValues
 - NominalToBinary
 - Normalize
 - NumericToBinary
 - NumericTransform
 - Obfuscate
 - PKIDiscretize
 - Remove
 - RemoveType

Apply

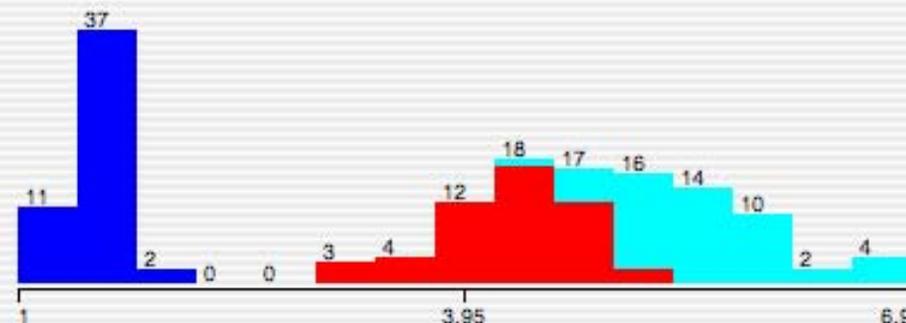
Selected attribute

Name: petallength Type: Numeric
 Missing: 0 (0%) Distinct: 43 Unique: 10 (7%)

Statistic	Value
Minimum	1
Maximum	6.9
Mean	3.759
StdDev	1.764

Colour: class (Nom)

Visualize All



Status

OK

Log



Preprocess

Classify

Cluster

Associate

Select attributes

Visualize

Open file...

Open URL...

Open DB...

Undo

Save...

Filter

Choose

Discretize -B 10 -R first-last

Apply

Current relation

Relation: iris

Instances: 150

Attributes: 5

Selected attribute

Name: petallength

Type: Numeric

Missing: 0 (0%)

Distinct: 43

Unique: 10 (7%)

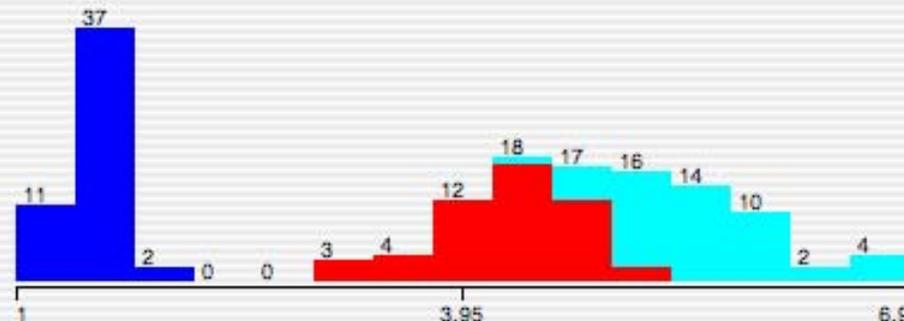
Attributes

No.	Name
1	sepalength
2	sepalwidth
3	petallength
4	petalwidth
5	class

Statistic	Value
Minimum	1
Maximum	6.9
Mean	3.759
StdDev	1.764

Colour: class (Nom)

Visualize All



Status

OK

Log



Preprocess

Classify

Cluster

Associate

Select attributes

Visualize

Open file...

Open URL...

Open DB...

Undo

Save...

Filter

Choose **Discretize -B 10 -R first-last**

Apply

Current relation

Relation: iris
Instances: 150

Attributes: 5

Attributes

No.	Name
1	sepalength
2	sepalwidth
3	petallength
4	petalwidth
5	class

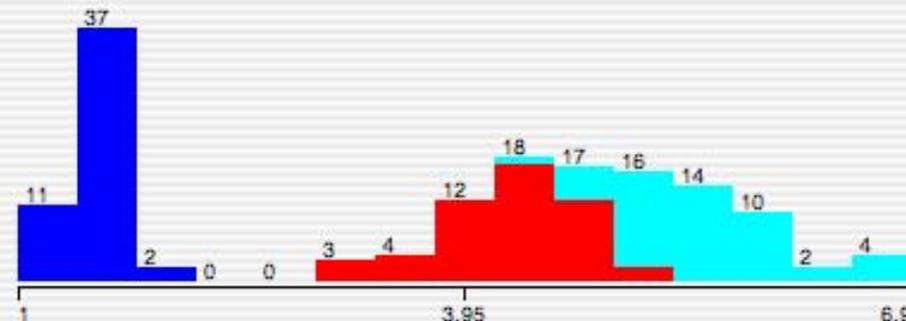
Selected attribute

Name: petallength
Missing: 0 (0%)
Distinct: 43
Unique: 10 (7%)

Statistic	Value
Minimum	1
Maximum	6.9
Mean	3.759
StdDev	1.764

Colour: class (Nom)

Visualize All



Status

OK

Log



Preprocess

Classify

Cluster

Associate

Select attributes

Visualize

Open file...

Open URL...

Open DB...

Undo

Save...

Filter

Choose Discretize -B 10 -R first-last

Current relation

Relation: iris
Instances: 150

Attributes:

Attributes

No.	Name
1	sepalength
2	sepalwidth
3	petallength
4	petalwidth
5	class

weka.gui.GenericObjectEditor

weka.filters.unsupervised.attribute.Discretize

About

An instance filter that discretizes a range of numeric attributes in the dataset into nominal attributes.

More

: Numeric
: 10 (7%)

attributeIndices first-last

bins 10

findNumBins False

invertSelection False

makeBinary False

useEqualFrequency False

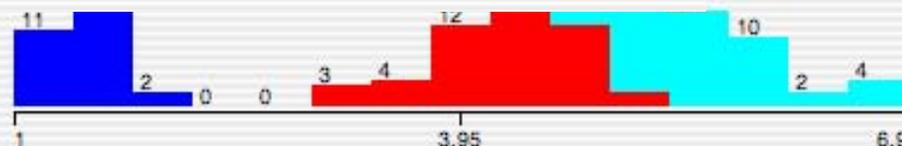
Visualize All

Open...

Save...

OK

Cancel



Status

OK

Log



x 0

Preprocess

Classify

Cluster

Associate

Select attributes

Visualize

Open file...

Open URL...

Open DB...

Undo

Save...

Filter

Choose **Discretize -B 10 -R first-last**

Current relation

Relation: iris

Instances: 150

Attributes:

Attributes

No.	Name
1	sepalength
2	sepalwidth
3	petallength
4	petalwidth
5	class

weka.gui.GenericObjectEditor

weka.filters.unsupervised.attribute.Discretize

About

An instance filter that discretizes a range of numeric attributes in the dataset into nominal attributes.

More

: Numeric
: 10 (7%)

attributeIndices first-last

bins 10

findNumBins False

invertSelection False

makeBinary False

useEqualFrequency False

Visualize All

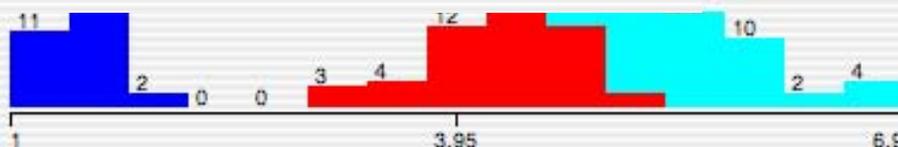


Open...

Save...

OK

Cancel



Status

OK

Log



Preprocess

Classify

Cluster

Associate

Select attributes

Visualize

Open file...

Open URL...

Open DB...

Undo

Save...

Filter

Choose **Discretize -B 10 -R first-last**

Current relation

Relation: iris
Instances: 150

Attributes:

Attributes

No.	Name
1	sepalength
2	sepalwidth
3	petallength
4	petalwidth
5	class

weka.gui.GenericObjectEditor

weka.filters.unsupervised.attribute.Discretize

Apply

About

An instance filter that discretizes a range of numeric attributes in the dataset into nominal attributes.

More

: Numeric
: 10 (7%)

e

attributeIndices first-last

bins 10

findNumBins False

invertSelection False

makeBinary False

useEqualFrequency True

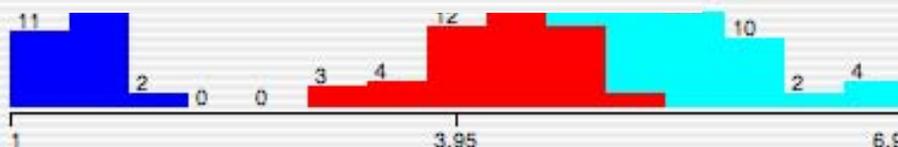
Visualize All

Open...

Save...

OK

Cancel



Status

OK

Log



Preprocess

Classify

Cluster

Associate

Select attributes

Visualize

Open file...

Open URL...

Open DB...

Undo

Save...

Filter

Choose **Discretize -B 10 -R first-last**

Current relation

Relation: iris

Instances: 150

Attributes:

Attributes

No.	Name
1	sepalength
2	sepalwidth
3	petallength
4	petalwidth
5	class

weka.gui.GenericObjectEditor

weka.filters.unsupervised.attribute.Discretize

Apply

About

An instance filter that discretizes a range of numeric attributes in the dataset into nominal attributes.

More

: Numeric
: 10 (7%)

attributeIndices first-last

bins 10

findNumBins False

invertSelection False

makeBinary False

useEqualFrequency True

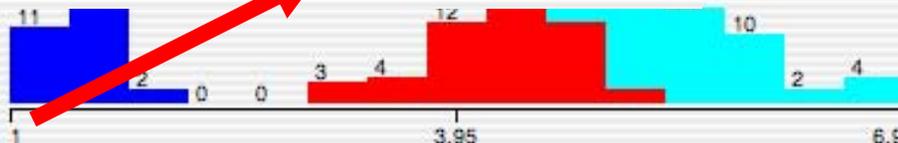
Visualize All

Open...

Save...

OK

Cancel



Status

OK

Log



Preprocess

Classify

Cluster

Associate

Select attributes

Visualize

Open file...

Open URL...

Open DB...

Undo

Save...

Filter

Choose

Discretize -F -B 10 -R first-last

Apply

Current relation

Relation: iris

Instances: 150

Attributes: 5

Attributes

No.	Name
1	sepalength
2	sepalwidth
3	petallength
4	petalwidth
5	class

Selected attribute

Name: petallength

Type: Numeric

Missing: 0 (0%)

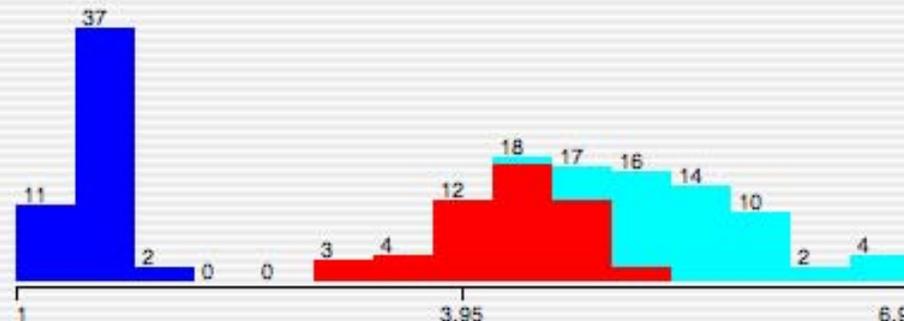
Distinct: 43

Unique: 10 (7%)

Statistic	Value
Minimum	1
Maximum	6.9
Mean	3.759
StdDev	1.764

Colour: class (Nom)

Visualize All



Status

OK

Log



Preprocess

Classify

Cluster

Associate

Select attributes

Visualize

Open file...

Open URL...

Open DB...

Undo

Save...

Filter

Choose **Discretize -F -B 10 -R first-last**

Apply

Current relation

Relation: iris
Instances: 150

Attributes: 5

Attributes

No.	Name
1	sepalength
2	sepalwidth
3	petallength
4	petalwidth
5	class

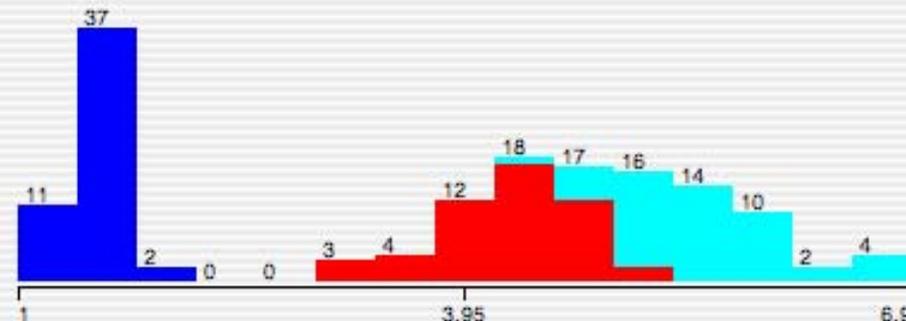
Selected attribute

Name: petallength Type: Numeric
Missing: 0 (0%) Distinct: 43 Unique: 10 (7%)

Statistic	Value
Minimum	1
Maximum	6.9
Mean	3.759
StdDev	1.764

Colour: class (Nom)

Visualize All



Status

OK

Log



Preprocess

Classify

Cluster

Associate

Select attributes

Visualize

Open file...

Open URL...

Open DB...

Undo

Save...

Filter

Choose

Discretize -F -B 10 -R first-last

Apply

Current relation

Relation: iris-weka.filters.unsupervised.attribute.Disc...

Instances: 150

Attributes: 5

Attributes

No.	Name
1	sepalength
2	sepalwidth
3	petallength
4	petalwidth
5	class

Selected attribute

Name: petallength

Type: Nominal

Missing: 0 (0%)

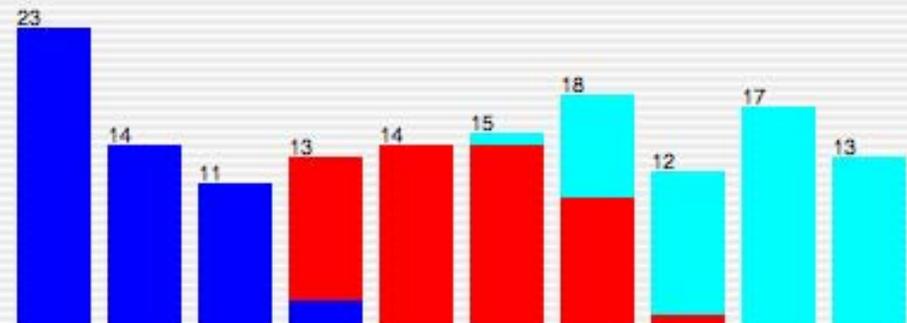
Distinct: 10

Unique: 0 (0%)

Label	Count
'(-inf-1.45]'	23
'(1.45-1.55]'	14
'(1.55-1.8]'	11
'(1.8-3.95]'	13
'(3.95-4.35]'	14
'(4.35-4.65]'	15
'(4.65-5.05]'	18

Colour: class (Nom)

Visualize All



Status


OK

Log

x 0

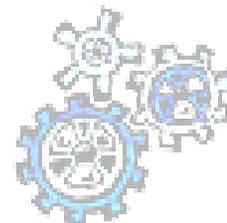
Trattamento dei dati in Weka

- **L'analisi esplorativa dei dati fatta in Knowledge Studio può essere interamente replicata in Weka usando i tools Preprocess e Visualize nel pannello Explorer.**
- **Affrontiamo perciò come trattare i problemi evidenziati nell'analisi usando:**
 - **Sostituzione dei valori NULL**
 - **Eliminazione di attributi**
 - **Generazione di nuove variabili**
 - **Normalizzazione**
 - **Discretizzazione**
 - **....**



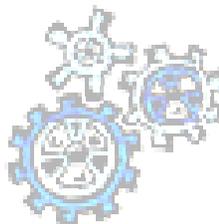
Trattamento dei dati in Weka

- **Sostituzione dei valori NULL:**
 - Utilizzando media/mediana/moda
 - Predicendo i valori mancanti utilizzando la distribuzione dei valori non nulli
 - Segmentando i dati (tramite le distribuzioni di altre variabili) e utilizzando misure statistiche (media/moda/mediana) di ogni segmento
 - Costruendo un modello di regressione
- **In Weka i valori nulli vengono sostituiti con le medie e le mode calcolate sui dati di training (*ReplaceMissingValues* filter)**



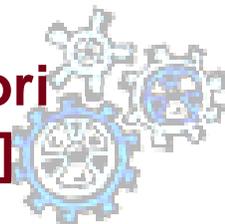
Trattamento dei dati in Weka

- **Eliminazione degli attributi necessaria allorchè:**
 - **Ci siano moltissimi valori NULL**
 - **Ci siano pochissimi valori distinti**
 - **Esista una correlazione con altri attributi**
- **In Weka tale funzione è svolta dal filtro *Remove* che cancella uno specificato set di attributi dal Data Set di partenza**



Trattamento dei dati in Weka

- **La Normalizzazione è utile qualora ci siano:**
 - **Errori nei dati**
 - **Dati incompleti**
 - **Forte asimmetria nei dati**
 - **diversi raggruppamenti esprimono comportamenti differenti**
 - **Molti picchi**
 - **residui larghi e sistematici nella definizione di un modello**
- **La modifica della forma dei dati può alleviare questi problemi**
- **In Weka tale funzione è svolta dal filtro *Normalize*. I valori risultanti da questo passo sono valori compresi tra $[0,1]$**



Normalizzazioni

- **min-max normalization**

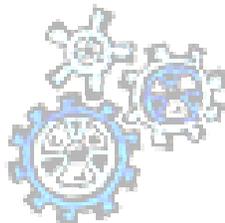
$$v' = \frac{v - \min_A}{\max_A - \min_A} (\text{new_max}_A - \text{new_min}_A) + \text{new_min}_A$$

- **z-score normalization**

$$v' = \frac{v - \text{mean}_A}{\text{stand_dev}_A}$$

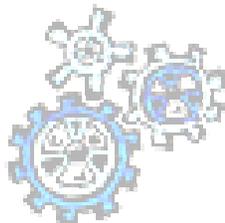
- **normalization tramite decimal scaling**

$$v' = \frac{v}{10^j} \quad \text{dove } j \text{ è il più piccolo intero tale che } \text{Max}(|v'|) < 1$$



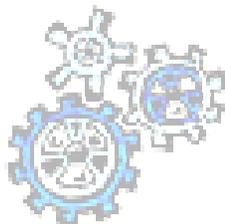
Trattamento dei dati in Weka

- **Discretizzare perché?**
 - I dati originali possono avere valori continui estremamente sparsi
 - I dati discretizzati possono essere più semplici da interpretare
 - Le distribuzioni dei dati discretizzate possono avere una forma “Normale”
- **Esistono due modalità di discretizzazione:**
 - Supervisionata
 - Non supervisionata



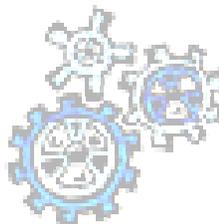
Trattamento dei dati in Weka

- **Discretizzazione non supervisionata:**
 - Discretizza senza un preciso criterio (GAIN, ENTROPIA...)
 - Il numero di classi è noto a priori
 - Natural binning
 - intervalli di identica ampiezza
 - Equal Frequency binning
 - intervalli di identica frequenza
 - Statistical binning
 - Utilizzando informazioni statistiche
 - media e varianza
 - Quartili



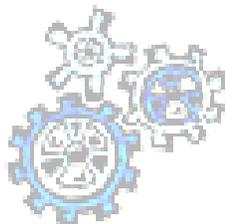
Trattamento dei dati in Weka

- **Discretizzazione supervisionata:**
 - La discretizzazione ha un obiettivo quantificabile (entropia, guadagno)
 - Il numero di classi non è noto a priori
- I dati discretizzati possono essere ancora estremamente sparsi. In tal caso:
 - Eliminazione della variabile in oggetto



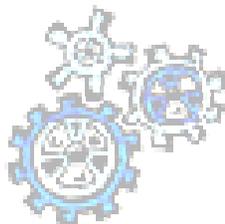
Trattamento dei dati in Weka

- **Discretizzazione supervisionata in Weka:**
 - Un filtro che discretizza un range di attributi numerici in attributi nominali. La discretizzazione utilizzata è quella di Fayyad & Irani
- **Discretizzazione non supervisionata in Weka:**
 - La discretizzazione è sia natural che frequency binning.



Trattamento dei dati in Weka

- La dimensione del Data Set è un problema importante nel Data Mining.
- In Weka è possibile ottenere un sottoinsieme del Data Set originale utilizzando il filtro *Resample*.
- Il Data Set ridotto è ottenuto attraverso una scelta random sulle sue istanze.
- E' importante valutare che il Data Set così generato non snaturi il Data Set di origine.
- A tal fine è possibile osservare la “forma” delle distribuzioni degli attributi del sottoinsieme rispetto a quelle del Data Set originale



Espandibilità di Weka

- **Weka è un ambiente scritto in Java e completamente estendibile.**
- **E' possibile scrivervi i propri metodi di filtering, clustering o classificazione e poterli utilizzare nell'ambiente.**
- **Per far ciò occorre conoscere la struttura del codice di Weka.**
- **A fine didattico è stato scritto un filtro *NullHandle* che va a cancellare le istanze nelle quali i valori NULL superano una percentuale fissata**

