



UNIVERSITÀ  
DEGLI STUDI  
DI TERAMO



# Big Data Analytics

## Riconoscere strutture in KNIME Tutorial

Prof.ssa Romina Eramo

Università degli Studi di Teramo

Dipartimento di Scienze della Comunicazione

[reramo@unite.it](mailto:reramo@unite.it)

# Tutorial: creare gruppi di consumatori

---

- » Applicare algoritmi di **clustering** per:
  - creare **gruppi omogenei** di consumatori
  - supportare **strategie di comunicazione differenziate**
  - trasformare l'analisi dei dati in **azioni di business**
- » Il tutorial copre sia:
  - la **definizione** dei cluster
  - sia la **preparazione e interpretazione** del dataset

# Contesto

---

## » Il caso

- negozio online di articoli da regalo e gadget (Londra)
- forte crescita del business
- nascita di un primo nucleo di **CRM (Customer Relationship Management)**

## » Esigenza

- creare **strategie di comunicazione personalizzate**
- aumentare **loyalty e fatturato**

# Problema analitico

---

» Il negozio ha:

- oltre 4.000 clienti attivi
- storico delle **transazioni**
- poche informazioni anagrafiche

» Serve:

- ridurre la complessità
- passare da transazioni a **profili cliente**

# Variabili descrittive del cliente

---

» Per caratterizzare i clienti scegliamo 4 indicatori:

- **Frequenza**

- » numero di atti d'acquisto

- » indicatore di lealtà

- **Dimensione del carrello**

- » numero medio di unità per acquisto

- **Prezzo medio**

- » indica preferenza per prodotti economici o premium

- **Numero di articoli diversi**

- » misura varietà vs focalizzazione degli acquisti

# Dataset di partenza

---

## » File Ecommerce-Clean.csv

- versione ripulita delle transazioni \*
- una riga per **articolo/fattura**


## » Colonne principali:

- InvoiceNo
- CustomerID
- StockCode
- Quantity
- UnitPrice
- Value

\* Vedi slide successiva per dettagli dataset

# Dataset di partenza

- » Il dataset si può ottenere in 2 modi diversi:
  - Esportare i dati ottenuti (uniti e manipolati) nel tutorial Ecommerce (lezione 5) e filtrare le colonne necessarie



- Scaricare il dataset disponibile qui  
<https://www.kaggle.com/datasets/aliessamali/ecommerce> e calcolare/aggiungere il campo Value

# Dal dato transazionale al dato cliente

---

## » Problema:

- il dataset contiene più di 500.000 righe
- ma serve una tabella con una riga per cliente

## » Soluzione:

- **aggregare** le transazioni
- calcolare le variabili descrittive per cliente

# Strategia di aggregazione

---

» Per le prime tre variabili:

- aggregazione per fattura

 **GroupBy**  
Gruppi: InvoiceNo e CustomerID  
Aggregazione: Quantity (per somma) e Value (per somma)

- calcolare il Prezzo medio per unità


 **Math Formula**  
Espressione:  $\$Sum(Value) / \$Sum(Quantity)$   
Append column: Price

- poi aggregazione per cliente

 **GroupBy**  
Gruppi: CustomerID  
Aggregazione: Sum(Quantity) e Price per media (Mean), mentre il numero delle fatture generate sarà ottenuto con il conteggio (Count) di una qualsiasi colonna, ad esempio InvoiceNo

# Strategia di aggregazione


- » Per la quarta variabile dobbiamo creare un percorso alternativo nel nostro workflow:
  - aggregazione diretta per cliente per contare gli articoli che ogni cliente acquista almeno una volta



Gruppi: CustomerID  
Aggregazione: StockCode (usando Unique Count)


- Combiniamo le tabelle ottenute

Joiner



Criteri: CustomerID e CustomerID


- Rinominiamo le colonne




## Column Renamer

Column	New name
Customer_ID	CustomerID
.00 Mean(Sum(Quantity))	Dimensione carrello
.00 Mean(Price)	Prezzo medio
123 Unique count(StockCode)	Prodotti diversi
123 Count(Invoice)	Frequenza

# Porzione del workflow che si occupa di ottenere i quattro indicatori di preferenze di acquisto per cliente





# Normalizer

---

» Il nodo **Normalizer** consente di:

- normalizzare i valori numerici di una tabella
- ridurre le differenze di scala tra le colonne
- preparare i dati per algoritmi basati sulla distanza (es. clustering)

» **Cosa fa il Normalizer**

- considera **ogni colonna numerica** selezionata come un **insieme indipendente**
- applica una trasformazione ai valori
- produce una versione normalizzata della tabella

**⚠️ Possono essere normalizzate solo colonne numeriche.**

# Configurazione del nodo

---

» Per configurare il Normalizer è necessario:

- selezionare le **colonne numeriche** da normalizzare
- scegliere il **metodo di normalizzazione**
  1. Min–Max Normalization
  2. Metodo Z-Score
  3. Metodo Decimal Scaling
- (se necessario) impostare i parametri del metodo scelto

## 1. Min–Max Normalization

- comprime i valori in un **intervallo definito**
  - intervallo predefinito: **[0, 1]**
  - personalizzabile tramite i campi **Min** e **Max**
-  È il metodo più usato nel clustering.

# Configurazione del nodo

---

## 2. Z-Score Normalization

- standardizzazione statistica
- assume una distribuzione approssimativamente normale
- media = 0, varianza = 1

» Il valore normalizzato indica:

- la distanza dalla media
- in unità di deviazione standard

» Utile per:

- individuare **outlier**
- analisi statistiche

## 3. Decimal Scaling

- divide i valori per una potenza di 10 (10, 100, 1000, ...)
- la potenza è scelta automaticamente
- obiettivo: riportare i valori nel range  $[-1, 1]$

» Esempio:

- valori tra -25 e 170
- divisione per 1000
- range normalizzato:  $[-0.025, 0.170]$

## Normalizer

X

### Number columns

Manual   Wildcard   Regex   Type

Q Search

Aa

#### Excludes

No columns in this list.

#### Includes

- .00 Dimensione carrello
- .00 Prezzo medio
- 123 Frequenza
- 123 Prodotti diversi

Any unknown column

>  
»  
<  
«

### Normalization method

Min-max   Z-score   Decimal scaling

#### Minimum

0

^  
▼

#### Maximum

1

^  
▼

# Output del Normalizer

---

- » Il nodo produce **due output**:
  - **Tabella normalizzata**
    - » le colonne selezionate sono sostituite dai valori normalizzati
  - **Modello di normalizzazione**
    - » descrive formalmente le trasformazioni applicate
    - » serve per la **denormalizzazione**

# Denormalizer

---

- » È utile per **interpretare correttamente i risultati del clustering**.
  - inverte il processo di normalizzazione
  - riporta i valori nel **range originale**
  - applica in senso inverso i passi del **Normalizer**
- » Caratteristiche principali:
  - non richiede **configurazione**
  - richiede in input:
    - » la tabella normalizzata
    - » il **modello di normalizzazione**
  - restituisce in output:
    - » la tabella con valori **denormalizzati**

# Scelta dell'algoritmo di clustering

---

## » Il momento chiave: clustering dei clienti

- A questo punto del workflow, i dati sono puliti, le variabili sono aggregate per cliente, le colonne sono normalizzate
- Siamo pronti a  **creare gruppi omogenei di clienti**

## » In KNIME sono disponibili diversi nodi di clustering:

- k-means
- Hierarchical Clustering

## » Nel nostro caso scegliamo k-means perché:

- non serve una struttura gerarchica
- il numero di clienti è elevato
- vogliamo cluster **operativi e gestibili**

# Il parametro k

---

» Il parametro chiave di k-means è:

**$k$  = numero di cluster**

- La scelta di  $k$  non è solo tecnica, deve essere compatibile con l'uso pratico dei risultati

» **Vincolo di business sulla scelta di  $k$**

- Confrontandoci con il team CRM: il team è ridotto, la gestione delle campagne è impegnativa, non possono essere gestiti troppi gruppi
- Conclusione:  **massimo 5 cluster gestibili**

» **Intervallo per  $k$**

- Dalla discussione emerge che:
  - »  $k$  deve essere **almeno 2**
  - »  $k$  non deve superare **5**
- Definiamo quindi:
  - »  $k \in [2, 5]$
- Questo intervallo guida le nostre sperimentazioni

# K-means


---

- » Il nodo **k-Means** implementa l'algoritmo di clustering k-means
  - raggruppa righe simili
  - assegna ogni riga a un **cluster**
  - lavora su **colonne** numeriche
- » **Parametri principali del k-Means**
  - **Number of clusters (k)**  
→ numero di gruppi da creare
  - **Max. number of iterations**  
→ limite massimo di iterazioni  
(il valore predefinito 99 è in genere sufficiente)
  - **Colonne numeriche da includere**  
→ variabili su cui calcolare le distanze

# K-means

- » Nel clustering:
  - si usano solo colonne numeriche
  - colonne identificative (es. *CustomerID*) sono escluse

- » Le variabili incluse determinano:
  - la distanza tra i punti
  - la forma dei cluster



# Output del nodo k-Means

---

- » Il nodo k-Means produce **tre output**:
  - **Tabella etichettata**
    - » nuova colonna **Cluster**
    - » valori: cluster\_0, cluster\_1, ...
  - **Tabella dei centroidi**
    - » una riga per cluster
    - » valori medi delle colonne
    - » descrizione sintetica dei cluster
  - **Modello di clustering**
    - » regole di assegnazione ai cluster
    - » utilizzabile per nuovi dati tramite **Cluster Assigner**


# Flusso operativo

---

## » Normalizzazione e k-Means

-  Il nodo k-Means **non normalizza automaticamente** i dati.
- Buona pratica: precedere sempre k-Means con il **Normalizer** e garantire che tutte le variabili abbiano lo stesso peso

## » Workflow consigliato:



## » Analisi e interpretazione dei cluster

- La **normalizzazione** serve per il calcolo,
- la **denormalizzazione** per l'interpretazione.

# Denormalizzazione dei risultati

---

- » Dopo il clustering: i valori sono ancora normalizzati e non sono immediatamente interpretabili
- » Con il nodo **Denormalizer**:
  - si riporta la tabella ai valori originali
  - si facilitano le analisi descrittive dei cluster
- » Una volta denormalizzati i dati:
  - è possibile confrontare i cluster
  - valutare differenze tra centroidi
  - decidere il **valore definitivo di k**
- » L'interpretazione guida la scelta finale.

# Visualizzare i cluster

---

- » Quando il numero di variabili è contenuto (5–6):
  - la **visualizzazione grafica** è il metodo più efficace
  - aiuta a capire cosa distingue i cluster
- » Due visualizzazioni molto usate:
  - Scatter Matrix
  - Box Plot

# Scatter Matrix

---

## » Il nodo Scatter Matrix:

- genera una matrice di **scatter plot**
- ogni grafico rappresenta una coppia di variabili
- le variabili compaiono sia come righe sia come colonne

» È una visualizzazione combinata e compatta.

» All'interno della matrice:

- i grafici sulla diagonale mostrano la **distribuzione di una singola variabile**
- gli altri grafici mostrano la relazione tra **due variabili diverse**

» Serve per individuare:


- correlazioni
- separazioni tra cluster
- pattern strutturali


# Scatter Matrix e clustering

---

- » Colorando i punti in base al cluster:
  - possiamo vedere come i gruppi si distribuiscono
  - capire se i cluster sono realmente distinti
  - interpretare il significato dei gruppi
- » La scatter matrix può essere sufficiente, in molti casi, per spiegare il clustering.
- » **Esempio di interpretazione** (vedi slide successiva):
  - **cluster verde**: immobili costosi, centrali e piccoli
  - **cluster blu**: immobili periferici, economici e grandi
  - **cluster rosso**: soluzioni intermedie
- » I cluster risultano interpretabili grazie alla distribuzione nei grafici.

# Scatterix matrix prodotta per visualizzare dimensione, prezzo e distanza al centro di 16 immobili

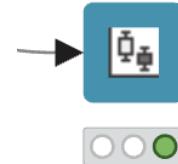




# Colorare i punti: Color Manager

---

- » Per colorare i punti nei grafici in base al cluster:
  - si utilizza il nodo **Color Manager**
  - disponibile in **Views → Property**
- » Il nodo:
  - associa colori ai valori di una colonna (es. cluster)
  - supporta anche gradienti per colonne numeriche



# Box Plot

» Il **Box Plot** è una visualizzazione sintetica che:

- descrive la distribuzione di una variabile numerica
- evidenzia valori centrali e dispersione
- mostra la presenza di **outlier**

» È molto efficace per confronti tra gruppi.

» I nodo **Conditional Box Plot**:

- genera un box plot per ogni valore di una variabile nominale
- permette di confrontare la stessa variabile numerica tra cluster diversi

» Se la variabile nominale è il cluster:

👉 possiamo confrontare i cluster “in parallelo”.

# Come leggere un Box Plot

---

## » Elementi principali:

- Mediana (Q2): valore centrale della distribuzione
- Quartile inferiore (Q1): 25% dei valori più bassi
- Quartile superiore (Q3): 25% dei valori più alti
- IQR (Q3 – Q1): ampiezza della parte centrale dei dati

» La scatola rappresenta il 50% centrale dei valori.

## » Outlier nel Box Plot

- I “baffi” indicano il range accettabile
- I punti oltre i baffi sono **outlier**
- In KNIME:
  - » cerchi → *mild outlier*
  - » “X” → *extreme outlier*
- Gli outlier non sono errori, ma informazioni utili.

# Box Plot e clustering

---

## » Confrontando i box plot dei cluster:

- osserviamo se le distribuzioni si sovrappongono
- valutiamo se i cluster sono davvero distinti
- individuiamo gruppi troppo piccoli o anomali

 È un controllo qualitativo molto importante.

## » Problema dei cluster sbilanciati

- Nel caso analizzato:
  - » un cluster contiene ~85% degli elementi
  - » altri cluster contengono pochissimi clienti
- Questo risultato:
  - » è poco utile
  - » non rappresenta gruppi significativi
  - » indica la presenza di **punti eccezionali**

# Interpretazione dei cluster sbilanciati

---

» Quando pochi punti formano cluster a sé:

- significa che sono **molto distanti** dagli altri
- rappresentano casi estremi
- distorcono il clustering




Questi casi vanno **gestiti separatamente**.

» **Trattamento degli outlier**

- Strategia adottata:

- » identificare gli outlier con la **distanza interquartile (IQR)**
- » eliminare o gestire i punti troppo estremi
- » ripetere il clustering su dati più omogenei



# Numeric Outliers

---

## » Il nodo Numeric Outliers:

- identifica outlier basandosi su Q1, Q3 e IQR
- usa un moltiplicatore (default 1.5)
- permette di:
  - » rimuovere outlier
  - » sostituire i valori anomali

## » Dopo la rimozione:

- i cluster risultano più bilanciati
- diminuisce il numero di cluster “vuoti”
- la normalizzazione funziona meglio

## » Ma attenzione:

- rimuovere troppi punti può far perdere informazione

# Scelta del moltiplicatore IQR

---

- » valore predefinito: 1.5
- » aumentarlo (es. 3.0):
  - mantiene i mild outlier
  - rimuove solo gli extreme outlier
- » Buona pratica:
  - iterare
  - controllare dimensione dei cluster
  - evitare di rimuovere >10% dei dati

Outlier Settings

Group Settings

Flow Variables

Job Manager Selection

Memory Policy

## Outlier Selection

 Manual Selection Wildcard/Regex Selection

Exclude



No columns in this list

Include



- Dimensione carrello
- Prezzo medio
- Frequenza
- Prodotti diversi

 Enforce exclusion Enforce inclusion

## General Settings

Interquartile range multiplier (k) 

## Quartile calculation

 Use heuristic (memory friendly) Full data estimate using   Update domain

## Outlier Treatment

Apply to

All outliers

Treatment option

Replace outlier values

Replacement strategy

Closest permitted value

# Ritorno alle visualizzazioni

---

» Dopo il trattamento degli outlier:

- Scatter Matrix
- Conditional Box Plot

» vengono riutilizzati per:

- interpretare i cluster finali
- verificare separazione e coerenza

## Confronto tra soluzioni con k diverso

» Testando  $k = 2, 3, 4, 5$ :

- 2–3 cluster  $\rightarrow$  troppo generici
- 5 cluster  $\rightarrow$  frammentazione inutile
- **4 cluster**  $\rightarrow$  miglior compromesso

» La scelta di  $k$  è guidata dall'interpretabilità.

# Configurazione Box Plot

Box Plot

**Data**

Dimension columns

- Manual
- Wildcard
- Regex
- Type

Search

Excludes

- Prezzo medio
- Frequenza
- Prodotti diversi

Includes

- Dimensione car...

Condition column

- Cluster

**Plot**

Title

Box Plot - Dimensione Carrello

Value axis limits

- Automatic
- Domain bounds
- Manual

Dimension axis label

Dimension

Value axis label

Value

Display legend

**Interactivity**

- Enable image download
- Show tooltip
- Enable animation

**Image Generation**


- Generate image

Image type (SVG, PNG)

- SVG
- PNG

- » Creare i box plot condizionali per cluster
- » Includere in parallelo le 4 variabili descrittive
  - Dimensione carrello
  - Prezzo medio
  - Frequaneza d'acquisto
  - Prodotti diversi
- » Otteniamo 4 diversi diagrammi

Box plot per cluster delle quattro variabili descrittive. Quando le scatole non si sovrappongono in altezza c'è una chiara differenza tra cluster.



# Configurazione Scatter Matrix

Scatter Plot Matrix X

**Data**

Dimensions

Manual   Wildcard   Regex   Type


Search Aa

Excludes   Includes

<input type="checkbox"/> CustomerID	<input type="checkbox"/> Dimensione carr...
<input type="checkbox"/> Frequenza	<input type="checkbox"/> Prezzo medio
<input type="checkbox"/> Customer_ID (Ri...)	>
<input type="checkbox"/> Prodotti diversi	»
<input type="checkbox"/> Cluster	<
<<	
Any unknown column	

- » Configurare includendo coppie di variabili descrittive in parallelo
- » Otteniamo 16 diversi diagrammi

Scatterix matrix con la distribuzione dei cluster per ogni coppia di variabili descrittive. I colori dei cluster sono gli stessi della figura con I box plot



# Ritorno alle visualizzazioni

---

» Dopo il trattamento degli outlier:

- Scatter Matrix
- Conditional Box Plot

» vengono riutilizzati per:

- interpretare i cluster finali
- verificare separazione e coerenza

## Confronto tra soluzioni con k diverso

» Testando  $k = 2, 3, 4, 5$ :

- 2–3 cluster → troppo generici
- 5 cluster → frammentazione inutile
- **4 cluster** → miglior compromesso

» La scelta di  $k$  è guidata dall'interpretabilità.

# Descrizione finale dei cluster

---

## » Esempio di profili ottenuti:

- **Cluster 0 (blu)**

- » Clienti frequenti, molti prodotti diversi → da coinvolgere spesso

- **Cluster 1 (arancione)**

- » Clienti occasionali → da riattivare con promozioni mirate

- **Cluster 2 (verde)**

- » Carrelli molto grandi → rivenditori / grossisti

- **Cluster 3 (rosso)**

- » Pochi prodotti ma costosi → clienti premium

# Dal clustering all’azione CRM

---

- » I cluster permettono di:
  - differenziare messaggi
  - personalizzare le offerte
  - semplificare il lavoro del team CRM
- » Il valore nasce dall’unione di:
  - analisi automatica
  - interpretazione umana

# Workflow finale

