

INDICE

Introduzione

Capitolo I

La cluster analysis: cenni teorici.

Capitolo II

Costruzione del data set

2.1 Identificazione delle variabili di classificazione.

2.2 Selezione della tecnica di raggruppamento delle entità.

2.3 Identificazione del numero di gruppi entro i quali ripartire le entità.

Capitolo III

La cluster Analysis con l'utilizzo di SPSS

3.1 Metodo delle K-Means

3.2 Metodo Gerarchico

Conclusioni

Bibliografia

Introduzione

Nell'elaborato viene focalizzata l'attenzione sull'analisi di raggruppamento o denominata anche:

“CLUSTER ANALYSIS” .

Operativamente, in ambito economico-aziendale la cluster analysis viene utilizzata per individuare possibili raggruppamenti fra gli individui della popolazione, sostituendo le singole unità con opportuni “tipi”.

Questi gruppi sono costruiti in modo da essere massimamente omogenei al loro interno e massimamente eterogenei fra loro. Dal contrasto tra questi due criteri, si origina l'articolazione finale dei gruppi.

Le variabili considerate sono i consumi medi/giornalieri dei principali prodotti alimentari, in sedici Paesi Europei.

I dati verranno elaborati mediante il software statistico SPSS.

Per poter effettuare una cluster analysis occorre un data set da cui partire, quello che ho utilizzato è stato costruito considerando le statistiche di consumo cronico degli alimenti, pubblicate dall'Autorità Europea per la sicurezza alimentare (EFSA).

Dopo aver opportunamente sintetizzato i dati, è stato possibile effettuare l'analisi e valutare i risultati.

Scopo di questo elaborato è quello di mostrare in senso pratico la suddivisione della popolazione in gruppi considerando vari metodi statistici, e confrontarli .

La parte teorica sarà solo brevemente accennata.

Capitolo I

La cluster Analysis : cenni teorici.

La cluster analysis consiste in un insieme di tecniche statistiche atte ad individuare gruppi di unità tra loro simili rispetto ad un insieme di variabili prese in considerazione e secondo uno specifico criterio. L'obiettivo che si pone è sostanzialmente quello di riunire unità tra loro eterogenee in più sottoinsiemi tendenzialmente omogenei e mutuamente esaustivi.

La cluster analysis consente allora di pervenire ai seguenti risultati ¹:

- ridurre i dati in forma grafica semplice (immediatamente percepibile) e parsimoniosa;
- generare ipotesi di ricerca;
- identificare tipi: la ricerca tipologica mira all'individuazione di gruppi di unità con caratteristiche distintive che, nell'insieme, facciano percepire la fisionomia del sistema osservato;
- costruire sintesi di classificazione automatica;
- stratificare popolazioni da sottoporre a campionamento;
- attribuire alle entità valori noti con accuratezza solo per la classe.
- Questa proprietà può portare a trovare dati validi con cui: sostituire dati mancanti, trovare una modalità con cui confrontare una risposta elusiva, infine, stimare la probabilità che si verifichi un certo evento in campioni di numerosità esigua.

¹ Fabbris L. (1997), **8**: 303-304

Capitolo II

Costruzione del data set

2.1 Identificazione delle variabili di classificazione.

Il data set dell'analisi contiene informazioni sul consumo medio giornaliero dei principali alimenti in 16 Paesi Europei.

Ho ottenuto questi dati applicando la proprietà associativa della media aritmetica² alle varie classi di età

in cui il consumo di ogni singolo prodotto era suddiviso.

Dopo un'analisi esplorativa iniziale le variabili considerate sono: cereali e prodotti a base di cereali, verdure e prodotti vegetali, radici e tuberi, frutta e prodotti ortofrutticoli, carne e derivati, pesce e frutti di mare, latte, uova e ovo prodotti, zucchero e pasticceria, grassi animali, vegetali e oli, infine i prodotti surgelati.

I dati sono stati rilevati da varie agenzie di sondaggi nei seguenti paesi: Belgio, Bulgaria, Cipro, Danimarca, Finlandia, Francia, Germania, Irlanda, Italia, Lettonia, Paesi Bassi, UK, Repubblica Ceca, Spagna, Svezia e Ungheria.

² In base alla quale: suddividendo in due o più gruppi i valori della variabile, la media aritmetica della variabile è uguale alla media aritmetica delle medie parziali dei diversi gruppi ponderate con il numero di elementi di ciascuno.

$$\bar{x} = \frac{\bar{x}_A \cdot n_A + \bar{x}_B \cdot n_B}{n_A + n_B}$$

Il data set ottenuto è il seguente:

Id	paese	cereali	Verdure	Tuberi	frutta	carne	pesce	latte	uova	zucchero	grassi	Prodotti Surgel.
BE	Belgio	206.27	105.89	99.88	124.11	102.59	21.00	214.13	7.42	23.23	28.61	113.17
BU	Bulgaria	87.50	75.84	34.45	54.58	46.28	3.23	191.43	8.03	11.93	13.34	13.06
CI	Cipro	161.00	103.70	68.00	95.50	72.50	18.50	228.70	2.30	12.60	6.00	139.20
DA	Danimarca	212.32	152.87	105.44	146.84	127.78	17.27	406.17	15.67	35.84	31.03	.0
FI	Finlandia	123.38	103.58	83.57	133.16	102.34	20.21	476.96	12.50	26.60	28.63	5.89
FR	Francia	224.02	131.72	66.26	121.21	126.49	27.27	228.62	14.50	29.46	24.44	.50
GE	-Germania	228.16	109.37	61.96	167.44	107.66	16.69	185.03	6.82	21.28	23.26	73.56
IR	Irlanda	218.30	150.70	252.50	90.80	169.10	21.30	302.50	11.90	31.60	34.70	29.70
IT	Italia	248.20	222.38	50.21	190.96	109.55	44.64	197.32	20.81	19.55	38.50	12.04
LE	Lettonia	218.76	76.24	123.31	109.97	120.83	13.79	144.38	8.16	22.84	13.70	256.96
PB	Paesi Bassi	171.11	63.64	70.51	104.73	75.47	6.32	393.97	5.17	36.02	20.90	56.79
UK	Regno Unito	213.50	128.00	111.80	94.90	107.30	26.90	259.60	17.80	23.80	16.60	3.30
RC	Repubblica Ceca	263.53	118.43	94.06	139.01	167.34	15.77	202.32	18.98	29.31	39.74	16.88
SP	Spagna	207.81	141.16	61.34	144.92	157.07	57.42	425.09	13.65	14.14	30.80	39.66
SV	Svezia	217.80	43.17	101.82	111.60	74.25	19.67	425.94	6.25	22.33	12.96	171.96
UN	Ungheria	238.87	156.03	108.17	186.18	178.68	8.09	262.43	25.49	29.83	44.90	4.88

2.2 Selezione della tecnica di raggruppamento delle entità.

Le tecniche (o criteri o algoritmi) di analisi dei gruppi sono numerose.

Ho scelto due tecniche per la cluster analysis: K-means Cluster e Hierarchical Cluster.

I due metodi cercano entrambi gruppi di oggetti tali che all'interno dello stesso gruppo (cluster) gli oggetti siano "simili" tra loro, e oggetti appartenenti a gruppi diversi siano "differenti" tra loro.

Lo scopo è minimizzare la distanza all'interno dei cluster e massimizzare la distanza tra cluster.

Metodo K-means cluster: gli oggetti sono divisi in sottoinsiemi disgiunti, tali che ciascun oggetto appartiene ad uno ed un solo cluster.

Ogni cluster è associato con un centroide³; ogni oggetto viene associato al cluster il cui centroide risulta più vicino.

Hierarchical Cluster: consiste in un insieme di cluster gerarchici organizzati tramite un “albero gerarchico” (dendrogramma).

L’algoritmo si basa su una matrice di distanze tra gli oggetti.

2.3 Identificazione del numero di gruppi entro i quali ripartire le entità.

Nell’analisi non gerarchica con il metodo delle k-medie il numero dei cluster deve essere specificato inizialmente.

Ho considerato i seguenti casi: 3 e 4.

L’analisi gerarchica non necessita di specificare a priori il numero di cluster; il numero di cluster può essere ottenuto spezzando il dendrogramma a diverse altezze.

³ Si dice centroide il punto d’incontro delle medie di una distribuzione multivariata.

Capitolo III

La cluster Analysis con l'utilizzo di SPSS

3.1) Metodo delle K-Means

Dopo aver costruito il data set, ho selezionato le variabili da considerare nell'analisi e scelto come "label cases by" la variabile nominale id (o paese).

Numero di cluster: 3

Analisi dell'output.

Comincio dalla tabella 1 che presenta il riassunto dell'analisi.

In particolare, ci sono 3 cluster, a cui appartengono rispettivamente 6, 9 oggetti e viene individuato un cluster con un solo oggetto.

Tabella 1:

Numero di casi in ogni cluster

Cluster	1	6.000
	2	9.000
	3	1.000
Validi		16.000
Mancanti		.000

La tabella 2: Cluster di appartenenza ci dice a quale cluster appartiene ciascun oggetto.

Tabella 2: Cluster di appartenenza

Numero di caso	ID	Cluster	Distanza
1	BE	2	79.431
2	BU	2	177.295
3	CI	2	126.294
4	DA	1	76.273
5	FI	1	114.445
6	FR	2	50.655
7	GE	2	67.852
8	IR	1	191.555
9	IT	2	130.806
10	LE	3	.000
11	PB	1	83.322
12	RU	2	76.342
13	RC	2	87.510
14	SP	1	88.579
15	SV	1	150.132
16	UN	2	118.630

Al primo cluster appartengono: Danimarca, Finlandia, Irlanda, Paesi Bassi, Spagna e Svezia.

Al secondo appartengono: Belgio, Bulgaria, Cipro, Francia,. Germania, Italia, Regno Unito, Repubblica Ceca e Ungheria.

Infine, al terzo cluster troviamo la Lettonia.

L'ultima colonna rappresenta la distanza dal punto al centroide del cluster di riferimento, dove la metrica utilizzata da SPSS è la metrica euclidea⁴.

⁴In formula: $d_{hk} = \left\{ \sum_{v=1}^p w_v (x_{hv} - x_{kv})^2 \right\}^{1/2}$

Ora ci domandiamo se possiamo dare un'interpretazione ai gruppi ottenuti.

Cosa hanno in comune i Paesi che appartengono allo stesso gruppo?

Comincio col vedere quali siano i centroidi finali.

Tabella 3: Centri dei cluster finali

	Cluster		
	1	2	3
grano	191.79	207.89	218.76
verdure	109.19	127.93	76.24
tuberi	112.53	77.20	123.31
frutta	122.01	130.43	109.97
carne	117.67	113.15	120.83
pesce	23.70	20.23	13.79
latte	405.11	218.84	144.38
uova	10.86	13.57	8.16
zucchero	27.75	22.33	22.84
grassi	26.50	26.15	13.70
surgelati	50.67	41.84	256.96

Sapendo che i “final cluster centers” di un gruppo sono costituiti dalle medie di ogni variabile all'interno del gruppo e, ci aiutano a capire le caratteristiche degli oggetti appartenenti a ciascun gruppo.

Quali sono i paesi appartenenti al cluster 1?

Al gruppo 1 appartengono i paesi con un alto consumo di pesce, latte, zucchero, grassi e un consumo medio alto di tuberi.

Un basso consumo di grano. Paesi con una dieta tendenzialmente calorica .

Al gruppo 2 appartengono i paesi con un alto consumo di verdure, frutta, uova

Un medio alto consumo di grano, carne, pesce, grassi. un basso consumo di tuberi, prodotti surgelati e zucchero.

I paesi con un regime alimentare variato e completo.

Infine, al gruppo 3 appartiene il paese con un alto consumo di grano, tuberi, carne, e surgelati.

Un basso consumo di verdure, frutta, pesce, uova, grassi.

Quindi una dieta che a differenza del primo gruppo è sempre calorica ma, più proteica.

tabella 4:

Distanze tra i centri dei cluster finali

Cluster	1	2	3
1		191.758	336.024
2	191.758		239.666
3	336.024	239.666	

Analizzando la tabella 4 notiamo la distanza euclidea tra i centroidi dei gruppi finali e sappiamo che maggiore è la distanza, maggiore sarà la dissomiglianza tra i tre gruppi.

I tre gruppi sembrano distanti tra loro; in particolare la distanza maggiore si osserva tra il primo e il terzo, mentre il primo e il secondo sembrano più vicini.

Quali variabili hanno influenzato la determinazione dei cluster?

Per rispondere osserviamo la tabella 5⁵ che indica quali variabili hanno maggiormente contribuito all'individuazione dei cluster.

⁵Ricordiamo che la procedura ANOVA di SPSS richiede che i gruppi siano bilanciati e in questo caso non lo sono, quindi i risultati ottenuti dalla tabella hanno un'interpretazione solo descrittiva.

Tabella 5: ANOVA

	Cluster		Errore		F	Sig.
	Media quadrati	dei df	Media quadrati	dei df		
grano	607.462	2	2326.388	13	.261	.774
verdure	1547.725	2	1927.980	13	.803	.469
tuberi	2726.278	2	2379.146	13	1.146	.348
frutta	264.681	2	1478.670	13	.179	.838
carne	52.827	2	1686.332	13	.031	.969
pesce	50.354	2	205.917	13	.245	.787
latte	72851.036	2	1773.578	13	41.076	.000
uova	22.046	2	43.995	13	.501	.617
zucchero	54.225	2	56.541	13	.959	.409
grassi	74.567	2	130.223	13	.573	.578
surgelati	21125.695	2	3258.090	13	6.484	.011

Latte e Sargelati risultano le due variabili significativamente associate ai cluster individuati, a seguire Tuberi e Verdure.

Uova, Pesce, Carne e Zucchero risultano invece le meno influenti nella divisione in gruppi così ottenuta.

Numero di cluster:4

Inizio col valutare la tabella 6 che indica 4 cluster a cui appartengono rispettivamente 1, 4, 5 e 6 oggetti.

Tabella 6:**Numero di casi in ogni cluster**

Cluster	1	1.000
	2	4.000
	3	5.000
	4	6.000
Validi		16.000
Mancanti		.000

Anche in questo caso osserviamo la tabella 7 “cluster di appartenenza” per vedere a quale cluster appartiene ciascun oggetto.

Tabella 7: Cluster di appartenenza

Numero di caso	ID	Cluster	Distanza
1	BE	2	64.382
2	BU	2	135.524
3	CI	2	64.538
4	DA	3	90.256
5	FI	3	95.428
6	FR	4	60.694
7	GE	2	88.845
8	IR	4	162.391
9	IT	4	125.896
10	LE	1	.000
11	PB	3	69.598
12	RU	4	68.624
13	RC	4	68.109
14	SP	3	83.111
15	SV	3	141.070
16	UN	4	68.166

Al primo cluster appartiene la Lettonia.

Al secondo appartengono: Belgio, Bulgaria, Cipro e Germania.

Al terzo troviamo: Danimarca, Finlandia, Paesi Bassi, Spagna e Svezia.

Infine, al quarto appartengono: Francia, Irlanda, Italia, Regno Unito, Repubblica Ceca e Ungheria.

Tabella 8: Centri dei cluster finali

	Cluster			
	1	2	3	4
grano	218.76	170.73	186.48	234.40
verdure	76.24	98.70	100.88	151.21
tuberi	123.31	66.07	84.54	113.83
frutta	109.97	110.41	128.25	137.18
carne	120.83	82.26	107.38	143.08
pesce	13.79	14.86	24.18	24.00
latte	144.38	204.82	425.63	242.13
uova	8.16	6.14	10.65	18.25
zucchero	22.84	17.26	26.99	27.26
grassi	13.70	17.80	24.86	33.15
surgelati	256.96	84.75	54.86	11.22

Al gruppo 1 appartengono i paesi con un basso consumo di verdure, pesce, grassi e latte.

Un alto consumo di tuberi e prodotti surgelati. Un medio alto consumo di grano e carne.

Al gruppo 2 appartengono i paesi con basso consumo di grano, tuberi, carne, e uova.

Al gruppo 3 appartengono i paesi con alto consumo di pesce, latte.

Medio alto consumo di grano, zucchero e grassi.

Infine al gruppo 4 appartengono paesi con alto consumo in quasi tutte le categorie alimentari, ad esclusione dei prodotti surgelati.

Quindi un'alimentazione varia.

Tabella 9: Distanze tra i centri dei cluster finali

Cluster	1	2	3	4
1		202.334	351.948	278.817
2	202.334		226.809	144.472
3	351.948	226.809		206.742
4	278.817	144.472	206.742	

Analizzando la tabella 9 notiamo che il secondo e il quarto gruppo presentano una distanza euclidea tra i centroidi minore, mentre il primo e il terzo gruppo presentano la distanza maggiore.

Tabella 10: ANOVA

	Cluster		Errore		F	Sig.
	Media dei quadrati	df	Media dei quadrati	df		
grano	3896.855	3	1647.284	12	2.366	.122
verdure	3771.442	3	1403.739	12	2.687	.094
tuberi	2259.893	3	2466.815	12	.916	.462
frutta	668.095	3	1478.982	12	.452	.721
carne	3113.510	3	1057.286	12	2.945	.076
pesce	102.360	3	205.879	12	.497	.691
latte	51792.464	3	1115.099	12	46.447	.000
uova	131.503	3	18.460	12	7.124	.005
zucchero	96.270	3	46.223	12	2.083	.156
grassi	243.032	3	92.745	12	2.620	.099
surgelati	18540.825	3	2415.340	12	7.676	.004

Anche in questo caso visualizzando la tabella 10 notiamo che Latte e Surgelati sono le due variabili più significative per i cluster individuati; mentre lo Zucchero risulta il meno influente.

3.2) Metodo Gerarchico

Utilizzando lo stesso data set ho individuato la presenza di possibili cluster mediante SPSS ma, scegliendo l'approccio Hierarchical Cluster⁶.

Le tecniche di analisi gerarchica si distinguono in:

- agglomerative, se procedono a una successione di fusioni delle n unità, a partire dalla situazione di base nella quale ognuna costituisce un gruppo a sé stante e fino allo stadio n-1 nel quale si forma un gruppo che le comprende tutte;
- divisive, o scissorie, quando l'insieme delle n unità, in n-1 passi, si ripartisce in gruppi che sono, a ogni passo dell'analisi, sottoinsiemi di un gruppo formato allo stadio di analisi precedente, e che termina con la situazione in cui ogni gruppo è composto da un'unità.

⁶ Ho selezionato le variabili considerate nell'analisi e ho assegnato la variabile nominale Id(o paese) come "Label Cases by" .

Il software SPSS procede con il primo metodo.

Il risultato dell'analisi è dato dal dendrogramma e dalla tabella "programma di agglomerazione".

Il dendrogramma rappresenta una sintesi grafica del risultato ottenuto dall'analisi del cluster gerarchico, mentre la tabella 11 rappresenta una sintesi numerica.

Tabella 11: Programma di agglomerazione

Stadio	Cluster accorpatis		Coefficienti	Stadio di formazione del cluster		Stadio successivo
	Cluster 1	Cluster 2		Cluster 1	Cluster 2	
1	6	12	4331.001	0	0	5
2	1	7	6299.526	0	0	6
3	4	14	6981.792	0	0	8
4	13	16	8460.043	0	0	5
5	6	13	11542.919	1	4	9
6	1	3	11972.142	2	0	10
7	5	11	15447.482	0	0	8
8	4	5	18421.521	3	7	11
9	6	9	20576.891	5	0	10
10	1	6	25989.598	6	9	12
11	4	15	37102.277	8	0	14
12	1	2	48554.131	10	0	13
13	1	8	55092.652	12	0	14
14	1	4	65450.388	13	11	15
15	1	10	92859.917	14	0	0

Osservando la tabella 11 vediamo che al primo livello i casi 6 e 12 (corrispondenti a Francia e Regno Unito) sono raggruppati, in quanto hanno la distanza minima.

Il nuovo cluster così creato riappare al 5 stadio.

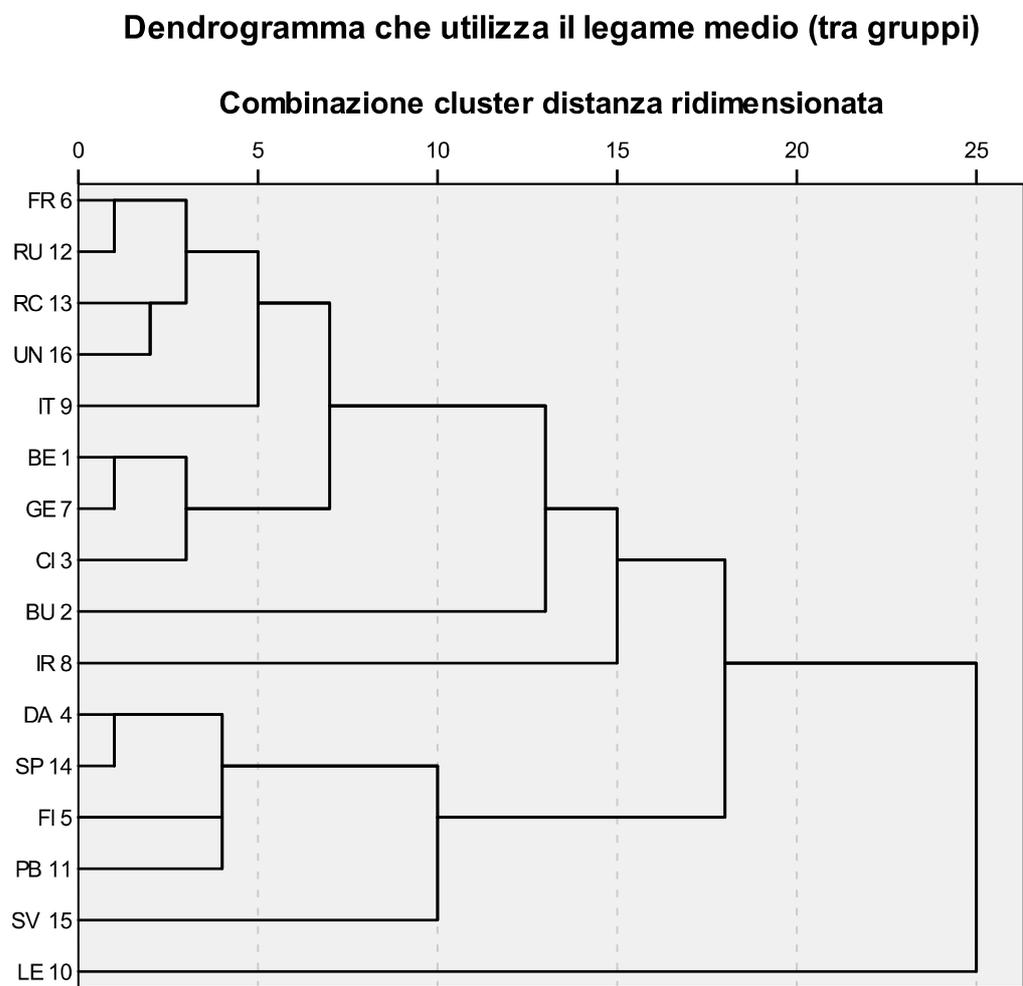
In corrispondenza della riga dello stadio 5, vediamo che i cluster 6 e 13 vengono raggruppati e notiamo anche che il cluster 13 è stato creato al quarto stadio ed è l'unione degli oggetti 13 e 16 (corrispondenti a Repubblica Ceca e Ungheria.), mentre il cluster 6 è il gruppo creato al primo livello di agglomerazione.

Quando le osservazioni sono tante, la lettura della precedente tabella può essere complicata e si preferisce la rappresentazione grafica data dal dendrogramma.

È importante non sottovalutare l'informazione data nella quarta colonna che fornisce la distanza tra gli oggetti.

Per poter considerare tutte le osservazioni in un modo più facile e immediato considero il dendrogramma della figura 1.

figura 1.



Nell'asse verticale di sinistra leggiamo gli oggetti presenti nell'analisi, l'asse orizzontale mostra la distanza tra i cluster quando sono uniti.

L'albero fornisce vari livelli di aggregazione: la scelta del livello a cui "tagliare" l'albero deve rappresentare un giusto compromesso tra numero di gruppi e omogeneità degli stessi.

Se tagliamo lo schema gerarchico prima del valore 20, troviamo tre gruppi. In uno appartiene la

Lettonia; in un secondo gruppo appartengono: Danimarca, Spagna, Finlandia, Paesi Bassi, Svezia.

Nel terzo gruppo troviamo: Francia, UK, Repubblica Ceca, Ungheria, Italia, Belgio, Germania, Cipro, Bulgaria e Irlanda.

Se decidessimo di tagliare prima del valore 15, notiamo che si forma un ulteriore gruppo formato dall'Irlanda.

Il problema principale dei metodi di classificazione gerarchica consiste nel definire il criterio di raggruppamento di due oggetti, cosa che equivale a definire una distanza tra oggetti.

Tutti gli algoritmi di classificazione gerarchica si sviluppano in modo tale da ricercare ad ogni tappa le due classi più vicine, le si riunisce e si continua fino a che non si abbia una sola classe.

Con il programma SPSS possiamo scegliere il metodo agglomerativo e il tipo di distanza da utilizzare.

Il metodo utilizzato di default da SPSS è "between-groups linkage"⁷.

La distanza che ho utilizzato per il precedente dendrogramma è "Squared Euclidean distance"⁸

È possibile anche scegliere il tipo di standardizzazione delle variabili.

Il dendrogramma riportato nella figura.2 è stato ottenuto scegliendo la standardizzazione tramite la devianza standard.

Si ottengono risultati differenti, in particolare notiamo che se replichiamo i tagli precedenti.

Nel primo caso abbiamo quattro gruppi. Uno formato da Irlanda, Ungheria e Repubblica Ceca.

$$D(X, Y) = \frac{1}{N_X \times N_Y} \sum_{i=1}^{N_X} \sum_{j=1}^{N_Y} d(x_i, y_j);$$

⁷ in formula: $x_i \in X, y_i \in Y,$

⁸ in formula: $d(p, q) = (p_1 - q_1)^2 + (p_2 - q_2)^2 + \dots + (p_i - q_i)^2 + \dots + (p_n - q_n)^2.$

Un secondo gruppo formato da Italia e Spagna.

Un terzo gruppo formato da Bulgaria e Cipro.

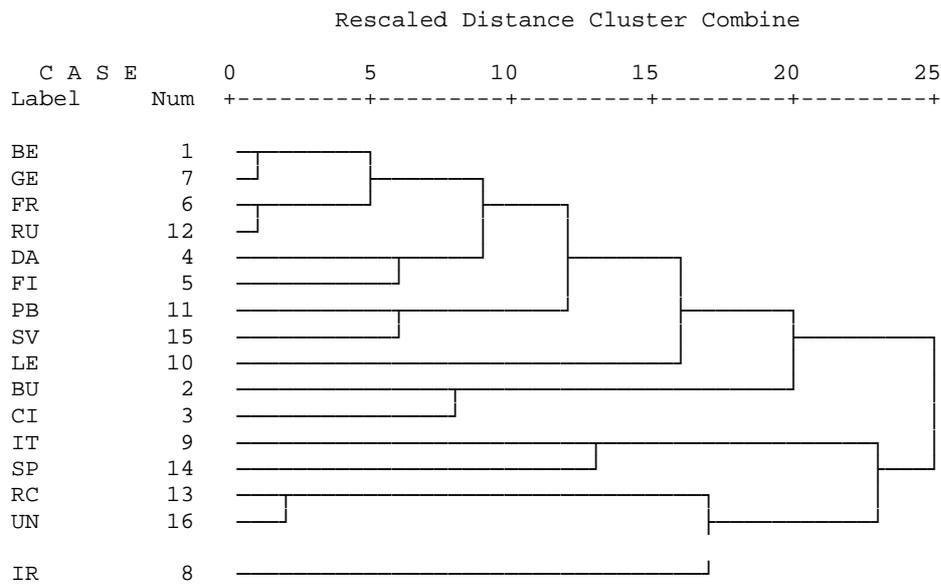
Infine, un gruppo formato da Belgio, Germania, Francia, UK, Danimarca, Finlandia, Paesi Bassi, Svezia e Lettonia.

Se invece consideriamo il taglio prima del valore 15 abbiamo ben 6 gruppi.

Il primo formato da: Belgio, Germania, Francia, UK, Danimarca, Finlandia, Paesi Bassi e Svezia.

Il secondo formato dalla Lettonia; il terzo da Bulgaria e Cipro; il quarto da Italia e Spagna; il quinto da Repubblica Ceca e Ungheria. Infine, l'ultimo contenente solo l'Irlanda.

Figura 2: Dendrogram using Average Linkage (Between Groups)



Conclusioni

Dopo aver applicato i due metodi nei vari casi è possibile trarre delle conclusioni.

Si evince come con il metodo delle k-medie in entrambi i casi sia quando si è scelto di fissare il numero di cluster a 3, e sia nel caso in cui si è scelto di fissarlo a 4, ho riscontrato un gruppo formato solo dallo stato della Lettonia.

Inoltre si nota anche come il primo gruppo del primo caso coincida con il terzo gruppo del secondo caso, ad esclusione dell'Irlanda.

Quindi Danimarca, Finlandia, Paesi Bassi, Spagna e Svezia, li ritroviamo accorpati in un unico cluster, possiamo dedurre che presentano un consumo alimentare simile.

Può risultare anomalo come il consumo alimentare degli spagnoli sia associato a quello dei paesi Scandinavi ma, ovviamente questo risultato è frutto di determinati dati e quindi può variare se viene effettuata una diversa indagine.

Con il metodo gerarchico in entrambi i casi troviamo un gruppo formato solo dalla Lettonia e uno solo dall'Irlanda.

Quindi pur considerando le variabili in maniera differente questi due gruppi restano costanti.

Per decidere sulla strategia da adottare, si deve tener conto dell'obiettivo analitico.

In generale le tecniche non gerarchiche sono più informative di quelle gerarchiche perché danno risultati anche intermedi e vari indici per la misura della qualità del risultato.

I metodi gerarchici risentono di più della presenza di errori di misura e di altre fonti di variabilità spuria presenti nelle misure di prossimità, e sono scombinati dalla presenza di dati anomali⁹.

I metodi gerarchici risentono di più della presenza di errori di misura e di altre fonti di variabilità spuria presenti nelle misure di prossimità, e sono scombinati dalla presenza di dati anomali.

Per grandi linee, si può dire che, se si cercano gruppi di unità statistiche caratterizzate da alta omogeneità interne (nel senso di strettezza dei legami tra entità appartenenti a un gruppo), le tecniche gerarchiche sono meno efficaci delle tecniche non gerarchiche.

⁹ Fabbris L. (1997, 8.3.1)

Bibliografia:

FABBRIS L. (1997) Statistica multivariata: analisi esplorativa dei dati, McGraw-Hill, Milano.

Sitografia:

<http://www.spss.it>

Software SPSS.

<http://www.efsa.europa.eu/it/datexfoodcdb/datexfooddb.htm>

Statistiche di consumo cronico degli alimenti (per Paese, indagine e classe di età) reported in grams/day.