

Análisis de coincidencias con R-Shiny

M. Escobar, L. Martínez-Uribe, F. Martínez y J.L. A. Berrocal

Universidad de Salamanca y Fundación Juan March

VII Jornadas de Usuarios de R - Comunidad R Hispano

Salamanca, 5 de Noviembre



Índice

1 Marco del modelo

- Definiciones
- Grados
- Adyacencias
- Gráficos

2 Implementación

- coin
- dichotomize
- igraph
- R-Shiny

3 Ejemplos

- Compositores
- Unamuno
- L'Oreal

4 Próximos pasos

Análisis de coincidencias

Definición

El análisis de coincidencias es un conjunto de técnicas cuyo objeto consiste en detectar y representar qué sucesos, objetos o sujetos tienden a aparecer al mismo tiempo en unos espacios delimitados.

- Estos N espacios delimitados (i) se denominan escenarios y pueden considerarse unidades de análisis (registros).
- En cada uno de estos escenarios (campos) un conjunto de J sucesos (x_{ij}) pueden estar presentes (1) o ausentes (0).
- Un conjunto de escenarios forman una matriz binaria de incidencias (\mathbf{X}) con dimensiones ($N \times J$).
- Estos escenarios pueden agruparse en H subconjuntos para poderlos comparar.

Material de análisis

Matriz de incidencias (Aparición o ausencia de 8 sucesos in 4 escenarios)

El material de análisis en el análisis de coincidencias es una matriz \mathbf{X} construida con i filas, que representan los escenarios, y j columnas, que representan los sucesos

$$\mathbf{X} = \begin{bmatrix} 1 & 1 & 1 & 0 & 0 & 0 & 0 & 0 \\ 1 & 1 & 1 & 1 & 1 & 0 & 0 & 1 \\ 0 & 1 & 1 & 1 & 1 & 1 & 1 & 0 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 0 \end{bmatrix}$$

Matriz de coincidencias

Definición

- A partir de la matriz de incidencias (\mathbf{X}), se puede obtener la matriz de coincidencias (\mathbf{F}) mediante la siguiente operación
 - donde cada elemento f_{jk} representa el número de escenarios en los que x_{ij} y x_{ik} tienen el valor de 1, lo que equivale a decir que coinciden.
- Los elementos diagonales de la matriz (f_{jj}) equivalen al número de x_{ij} en los N escenarios.

7 grados de coincidencias

Clasificación

Las coincidencias entre sucesos pueden graduarse del modo siguiente:

- Sin coincidencia (sucesos mutuamente excluyentes)
- Mera coincidencia (al menos coinciden en un escenario)
- Probable ($p(\mathbf{x}_j|\mathbf{x}_k) > 0.5$)
- Estadísticamente probable ($P(p(\mathbf{x}_j|\mathbf{x}_k) \leq 0.5) < c$)
- Condicional ($p(\mathbf{x}_j) < p(\mathbf{x}_j|\mathbf{x}_k)$)
- Estadísticamente condicional ($P(p(\mathbf{x}_j) - p(\mathbf{x}_j|\mathbf{x}_k) \leq 0) < c$)
- Total (siempre ocurren en los mismos escenarios)

Gráfico condicional de coincidencias

Grados de coincidencia (a).


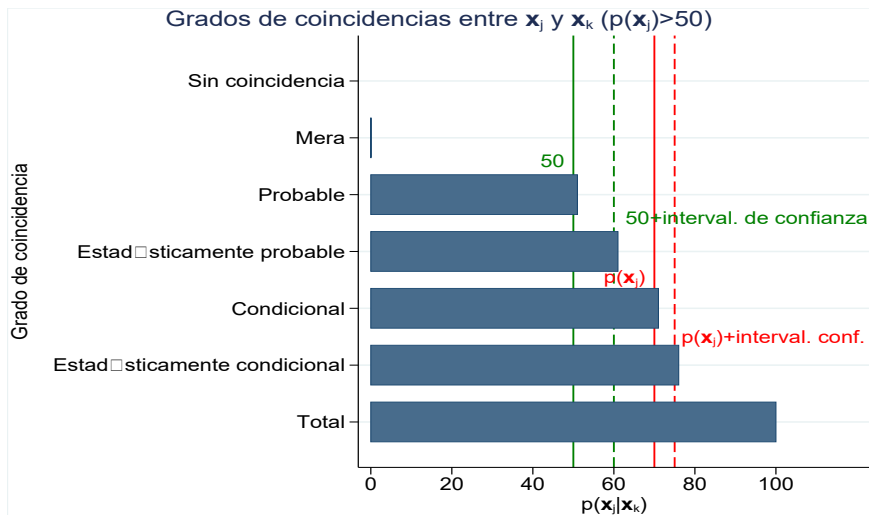


Gráfico condicional de coincidencias

Grados de coincidencia (b)



Dependencia estadística

Medición

- Se pueden emplear los residuos de Haberman (r_{jk}) para estimar la significación estadística de la coincidencia entre dos sucesos.

$$r_{jk} = \frac{f_{jk} - \frac{f_{jj}f_{kk}}{n}}{\sqrt{\frac{1-f_{jj}}{n} \frac{1-f_{kk}}{n}}}$$

Adyacencias

Definición operacional de sucesos adyacentes (coincidentes).

- Dos sucesos j y k pueden ser considerados adyacentes si siguen la siguiente norma:

$$A[j, k] = 1 \Leftrightarrow [P(r_{jk} \leq 0) < c] \wedge j \neq k$$

- Por tanto, se puede construir una $J \times J$ matriz \mathbf{A} con elementos igual a 1 en el caso en que r_{jk} sea significativo a un determinado nivel (c) e iguales a 0 en el resto de elementos incluidos los diagonales.
- A partir de \mathbf{A} puede calcularse la $J \times J$ matriz de distancias geodésicas (distancia mínima entre elementos conectados) \mathbf{D} y elaborar un grafo en el que los vértices o nodos sean los sucesos y los vínculos o aristas indiquen las coincidencias entre ellos.

Adyacencias (cont.)

Otras operacionalizaciones de adyacencias

- Por extensión, se pueden elaborar otras matrices de adyacencias con otros criterios:
 - Criterio de la mera adyacencia

$$A[j, k] = 1 \Leftrightarrow f_{jk} \geq 1$$

- Criterio de la adyacencia probable

$$A[j, k] = 1 \Leftrightarrow [P(r_{jk} \leq 0) < 0.5] \wedge j \neq k$$

Representaciones gráficas de las coincidencias

Tipos de gráficos

- Gráficos de barras
- Dendrograms
- Grafos
 - Geométricos
 - Circular
 - Estrella
 - Rejilla
 - Físicos
 - Fruchterman-Reingold
 - Kamada-Kawai
 - Estadísticos
 - mds (escalas multidimensionales)
 - pca (análisis de componentes principales)
 - ca (análisis de correspondencias)
 - biplot
- Comunidades
- Bloques recursivos

Índice

1 Marco del modelo

- Definiciones
- Grados
- Adyacencias
- Gráficos

2 Implementación

- coin
- dichotomize
- igraph
- R-Shiny

3 Ejemplos

- Compositores
- Unamuno
- L'Oreal

4 Próximos pasos

Implementación del análisis de coincidencias

Necesidades, requisitos, funciones y librerías

- El algoritmo de análisis coin se desarrolló inicialmente en Stata.
- Se consideró interesante hacerlo en otras plataformas de análisis estadístico como R.
- Necesidades y requisitos
 - Realizar cálculos estadísticos y matriciales.
 - Visualizaciones con gráficos.
 - Interfaz web interactiva capaz de mostrar e interactuar con diversos ejemplos.
- Funciones propias para los cálculos.
 - gcoin
 - dichotomize
- Librerías para visualizaciones e interacción web.
 - igraph
 - R-Shiny

Función `gcoin()`

Disponible en [github](#).

- Dos subfunciones importantes:
 - **Haberman**: cálculo de los residuos para estimar significación estadística.
 - **Adjacency**: genera la matriz de adyacencias.

Función dichotomize()

Preparación de la matriz

- Convierte datos con una columna de escenarios (Exposición) y otra de sucesos (Artistas) en una matriz de incidencias con tantas columnas como sucesos haya habido en el conjunto de escenarios.

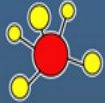
Exposición	Artistas	Título	Kandinsky, Wassily 1866–1944	Picasso, Pablo 1881–1973	Arp, Jean 1887–1966	Albers, Josef 1888–1975
1 Vladimir Lébedev (1891–1967)	Lébedev, Vladimir 1891–1967	V1 Vladimir Lébedev (1891–1967)	0	0	0	0
2 Pablo Palazuelo	Palazuelo, Pablo 1916–2007	V2 Pablo Palazuelo	0	0	0	0
3 The American Landscapes of Asher B. Durand (1796–...	Durand, Asher B. 1796–1886	V3 The American Landscapes of Asher B. Durand (1796–...	0	0	0	0
4 Andy Warhol	Warhol, Andy 1928–1987	V4 Andy Warhol	0	0	0	0
5 Georges Braque	Braque, Georges 1882–1963	V5 Georges Braque	0	0	0	0
6 Magritte	Magritte, René 1898–1967	V6 Magritte	0	0	0	0
7 Malevich	Malevich, Kazimir Severinovich 1878–1935	V7 Malevich	0	0	0	0
8 Mark Rothko	Rothko, Mark 1903–1970	V8 Mark Rothko	0	0	0	0
9 Max Ernst	Ernst, Max 1891–1976	V9 Max Ernst	0	0	0	0
10 Medio siglo de escultura (1900–1945)	Archipenko, Alexander 1887–1964;Arp, Jean 1887–1...	V10 Medio siglo de escultura (1900–1945)	0	1	1	0
11 Monet en Giverny	Monet, Claude 1840–1926	V11 Monet en Giverny	0	0	0	0
12 Rauschenberg	Rauschenberg, Robert 1925–2008	V12 Rauschenberg	0	0	0	0
13 Vieira da Silva	Vieira da Silva, Maria Helena 1908–1992	V13 Vieira da Silva	0	0	0	0
14 Zero, un movimiento europeo	Arman 1928–2005;Bury, Pol 1922–2005;Dorazio, Pie...	V14 Zero, un movimiento europeo	0	0	0	0
15 David Hockney	Hockney, David 1937–	V15 David Hockney	0	0	0	0
16 Edward Hopper	Hopper, Edward 1882–1967	V16 Edward Hopper	0	0	0	0

igraph

Paquete para el análisis de redes

Proporciona un conjunto de tipos de datos y funciones para:

- 1 Generación de gráficos simples de redes
- 2 Administración de grandes gráficos con miles de vértices y aristas
- 3 Visualización gráfica



igraph – The network analysis package

igraph is a collection of network analysis tools with the emphasis on **efficiency**, **portability** and ease of use. igraph is **open source** and free. igraph can be programmed in **R**, **Python** and **C/C++**.

Shiny

Entorno web para programas de R

- Permite crear aplicaciones web interactivas con R.
- Vincula entradas y salidas de manera automática y reactiva.
- Posee una extensa colección de widgets pre-construidos para elaborar aplicaciones fácilmente.



Índice

1 Marco del modelo

- Definiciones
- Grados
- Adyacencias
- Gráficos

2 Implementación

- coin
- dichotomize
- igraph
- R-Shiny

3 Ejemplos


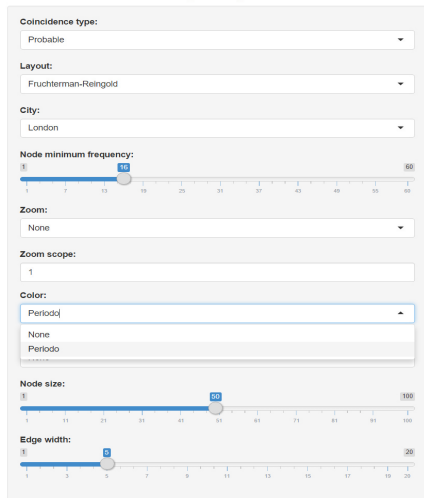
- Compositores
- Unamuno
- L'Oreal

4 Próximos pasos

Primer ejemplo de Shiny

Compositores en Londres ($n > 15$) (a): Color


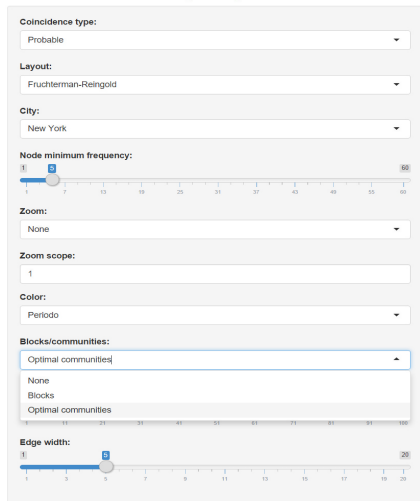
Coincidence Analysis (Bachtrack concerts reviewed 2009-2015)



Primer ejemplo de Shiny

Compositores en New York ($n > 4$) (b): Comunidades óptimas.

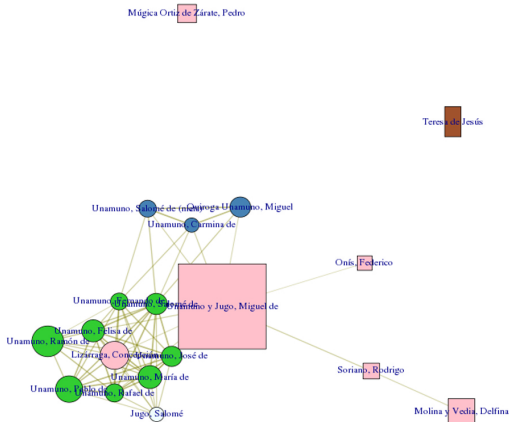
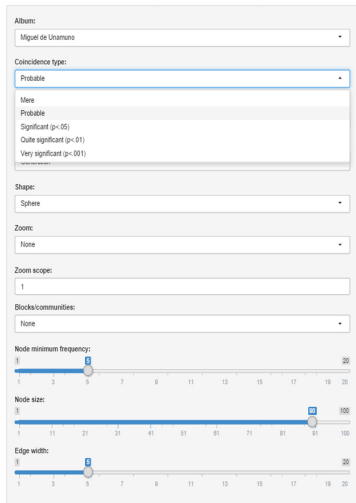
Coincidence Analysis (Bachtrack concerts reviewed 2009-2015)



Segundo ejemplo de Shiny

Unamuno (a): Tipo de coincidencias

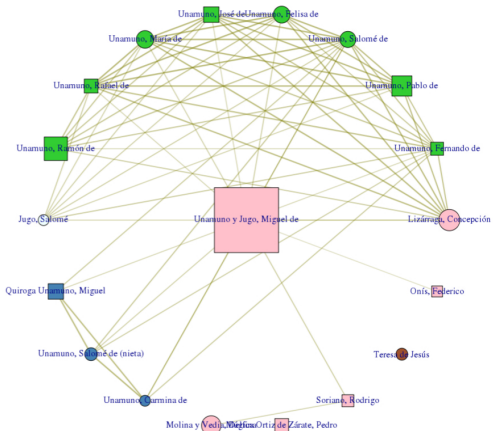
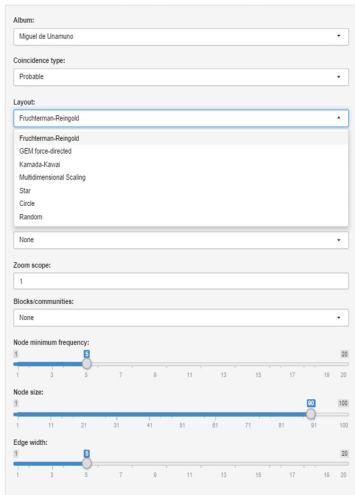
Coincidence Analysis (Foto Archives)



Segundo ejemplo de Shiny

Unamuno (c): Disposición estelar.

Coincidence Analysis (Foto Archives)



Índice

1 Marco del modelo

- Definiciones
- Grados
- Adyacencias
- Gráficos

2 Implementación

- coin
- dichotomize
- igraph
- R-Shiny

3 Ejemplos

- Compositores
- Unamuno
- L'Oreal

4 Próximos pasos

Próximos pasos

- Modelizar las coincidencias
 - Modelos log-lineales para estimar las frecuencias.
 - Modelos QAP y ERG para descubrir los determinantes de las coincidencias.
- Relacionar el análisis de coincidencias con otros modelos
 - Análisis comparado cualitativo.
 - Reglas de asociación.
 - Otros modelos de aprendizaje automático.
- Divulgación
 - Construcción y divulgación de un paquete para analizar coincidencias.
 - Mejorar la interactividad con Shiny.
 - Aplicar Shiny a otros problemas para divulgar los análisis estadísticos.

¡Muchísimas gracias!

modesto@usal.es
lmartinez@march.es
martinez@march.es
berrocal@usal.es

Código de gcoin.

```
gcoin<-function(Data, variables, Characteristics=NULL, color="",
                shape="",minimum=5, p=.5, Bonferroni=FALSE, size=30, lwidth=5)
  require(igraph)
  D <- subset(Data, select=variables)
  Q=data.matrix(D)
  Q<-Q[,colSums(Q)>=minimum]
  N<-Haberman(Q)
  ifelse(Bonferroni,b<-ncol(N)*(ncol(N)-1)/2,b<-1)
  A<-Adjacency(N, p, b, nrow(D))
  G<-graph.adjacency(A, weighted=T, mode="undirected")
  G<-simplify(G)
  if (is.data.frame(Characteristics))
    V(G)$shape<-as.character(Characteristics[V(G),shape])
    V(G)$label<-as.character(Characteristics[V(G),"label"])
    V(G)$color<-as.character(Characteristics[V(G),color])

  V(G)$size<-colSums(data.matrix(Q))/max(colSums(data.matrix(Q)))*size
  egam<-log(E(G)$weight+1)/max(log(E(G)$weight+1))
  E(G)$color <- rgb(0.5, 0.5, 0, egam)
  E(G)$width <- egam*lwidth
  plot(G)
  return(G)
```

Código de Haberman y Adjacency.

```
Haberman<-function (Q, minimum=5)
  L<-colSums(Q)
  M<-crossprod(Q)
  n=nrow(Q)
  E<-tcrossprod(L)/n
  N<-((M-E)/sqrt(E))/sqrt(tcrossprod(1-(L/n)))
  return(N)
```

```
Adjacency<- function (N, p, b, n)
  A<-N
  A[(1-pt(N,n))>=(p/b)]<-0
  diag(A)<-0
  return(A)
```