

# Visualizing Statistics

Pedro Valero Mora-valerop@uv.es

*Metodología de las CC del Comp-Universitat de València*

*Abril 2010*



VNIVERSITAT ID VALÈNCIA

# Índice

<b>Introducción y Ejemplos</b>	<b>4</b>	Ejemplo: Cepillado, ligado y líneas	31
Introducción	5		
Ejemplo: Ciudades para jubilación	9		
Ejemplo: Identificando clusters visualmente	10		
<b>Historia y Software</b>	<b>11</b>	<b>Gráficos básicos</b>	<b>35</b>
Historia	12	Gráficos de presentación v. gráficos de análisis	36
A modo de resumen	15	Matrices de diagramas de dispersión	42
<b>ViSta</b>	<b>16</b>	Spinplots y Tourplots	43
¿Por qué ViSta?	17	Boxplot, Diamond plot, Parallel coordinates	44
Historia	18		
Características	20		
Tipo de datos	22		
<b>Interacción con gráficos</b>	<b>24</b>	<b>Spreadplots</b>	<b>46</b>
Ejemplo: Jobs	25	Manejando muchas ventanas	47
Etiquetas	27	Spreadplot para 2 variables numéricas	49
Ligado	28	Spreadplot para 3 variables numéricas	50
Enfocar y Excluir	29	Analisis de varianza	51
Cambiar Colores y Símbolos	30	Spreadplot para modelos loglineales	52
		Notas finales	53
<b>Datos categóricos</b>	<b>54</b>		
		Visualización de datos categóricos multivariados	55
		Spinogramas y Mosaic plots	57
		Ejemplo: Datos de Berkeley	59
		Spreadplot para Berkeley	60
		Ejemplo: Felicidad en función del Género/Raza	61

Modelos loglineales	62	Componentes Principales y Biplots	92
Ejemplo: Modelos loglineales para Berkeley	64	Ejemplo: Crímenes en Estados en USA	93
Ejemplo: Modelos loglineales para Felicidad	65	Ejemplo: Proteínas	97
Ejemplo: Modelo Logit para Sexo	68	Cluster jerárquico	98
<b>Datos numéricos univariados</b>	<b>70</b>	Ejemplo: Horas de trabajo, Precios y Sueldos en ciudades	
Histogramas	71	100	
Ejemplo: Old Faithful	72	<b>Datos perdidos</b>	<b>101</b>
Ejemplo: Bigmac	75	El desafío de los datos perdidos multivariados	102
<b>Datos numéricos bivariados</b>	<b>76</b>	Visualización de Patrones de Perdidos	103
Matrices de diagramas de dispersión	77	Ejemplo: Mundo95	104
Ejemplo: Proteínas en Europa 1970	78	Imputando los datos	106
<b>Datos numéricos trivariados</b>	<b>80</b>	Ejemplo: World95	107
Spinplots	81	Ejemplo: Titanic	110
Ejemplo: Componentes Principales en Jobs	82	<b>Escalamiento multidimensional</b>	<b>111</b>
Regresión	84	Recuperando posiciones a partir de distancias	112
Observando regularidades	85	Ejemplo: Distancias entre ciudades	113
<b>Datos numéricos multivariados</b>	<b>86</b>	Ejemplo: Explorando la posición de los colores	114
Técnicas	87	<b>Apéndices</b>	<b>115</b>
Tours	88	Importando datos	116
Ejemplo: Crimes	91	Guardar gráficos en formato vectorial	117

# *Introducción y Ejemplos*

# Introducción

*"Exploratory data analysis is an attitude, a flexibility, and a reliance on display, NOT a bundle of techniques, and should be so taught."*

John W. Tukey, We need both exploratory and confirmatory,  
The American Statistician, 34(1), (Feb., 1980), pp. 23-25.

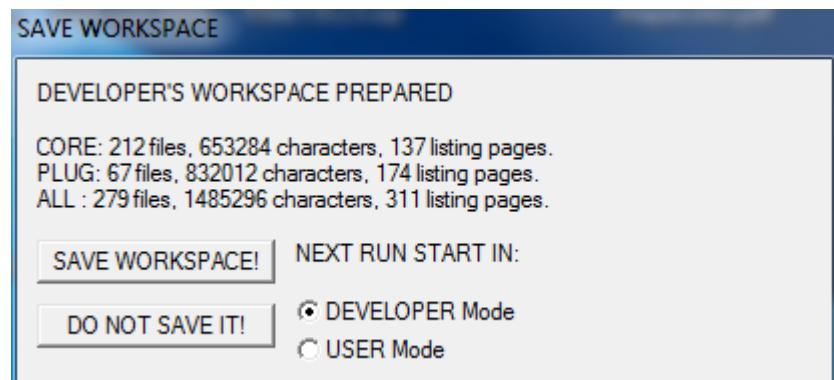
- No obstante, cuando utilizamos software estadístico estándar a menudo nos encontramos con un conjunto de técnicas y métodos ya prediseñados
  - Hay poca flexibilidad
  - No están basados en gráficos

- Determinados sistemas estadísticos no obstante permiten un buen grado de flexibilidad: Análisis de datos interactivos
  - R permite un grado de flexibilidad que otros sistemas a menudo no tienen
- ¿Y cuándo se trata de gráficos?
  - El desafío es que los gráficos se conviertan en el análisis, no en la parte final de éste
- Instalemos ViSta y veamos un ejemplo

# Instalación de ViSta

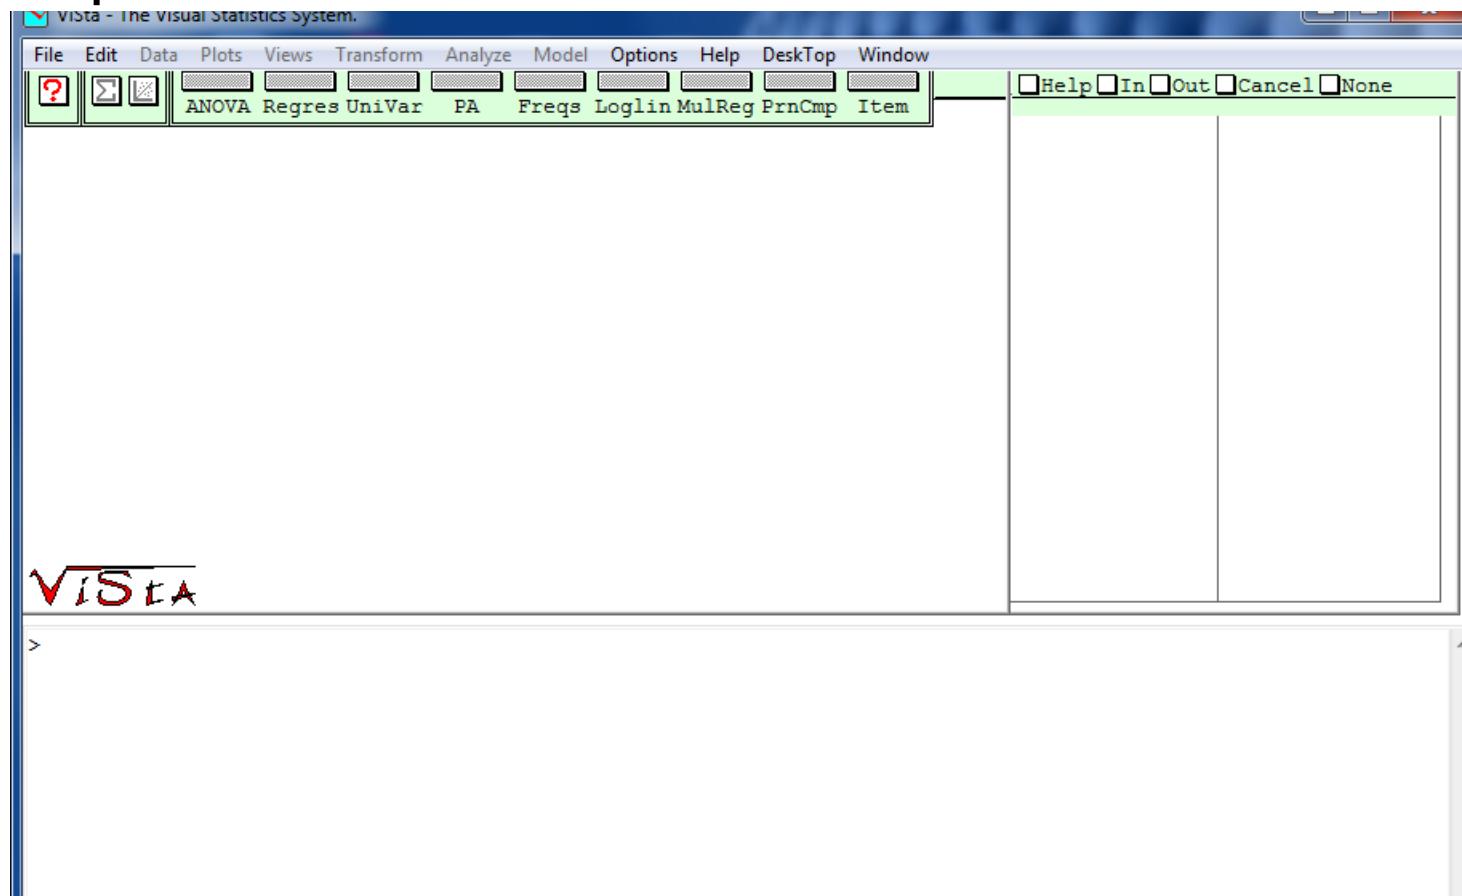
1. Descargar ViSta de <http://www.uv.es/visualstats/Book/> e ir a la sección de descargas
2. Descargar en [www.uv.es/visualstats/Book](http://www.uv.es/visualstats/Book) (el lugar original [www.visualstats.org](http://www.visualstats.org) y similares no están actualizados)
3. Descomprimir en donde se quiera utilizar (es un archivo .zip)

4. Poner en marcha ViSta.exe
- Se pondrá en marcha el proceso de carga de archivos y directorios
- Aparecerá el siguiente cuadro de diálogo.



5. Hacer click en SAVE WORKSPACE

## 6. Volver a poner en marcha ViSta.exe



## 7. Ir al menú File>Open Data

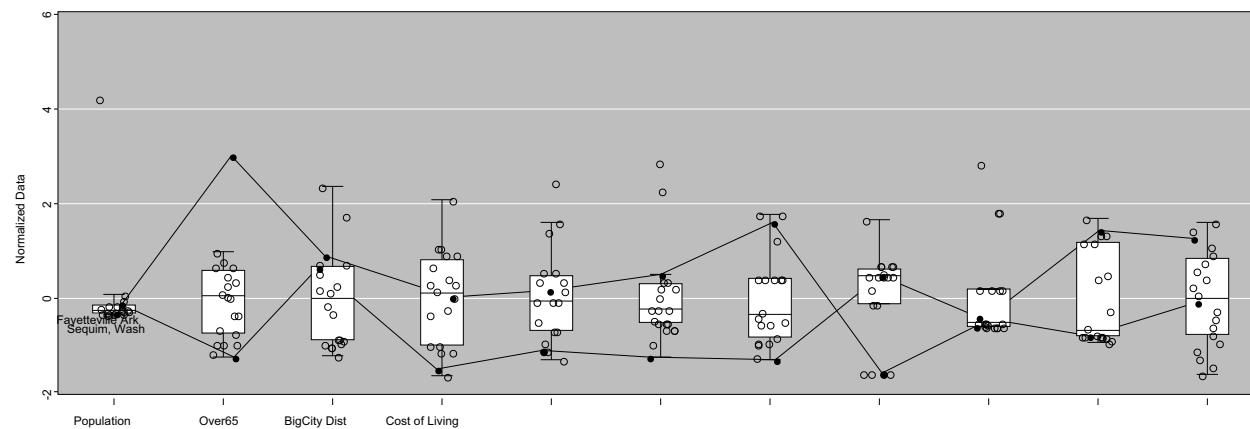
En el cuadro de diálogo hacer data>regress>retire.vdf

Esto nos dará unos datos para empezar

# Ejemplo: Ciudades para jubilación

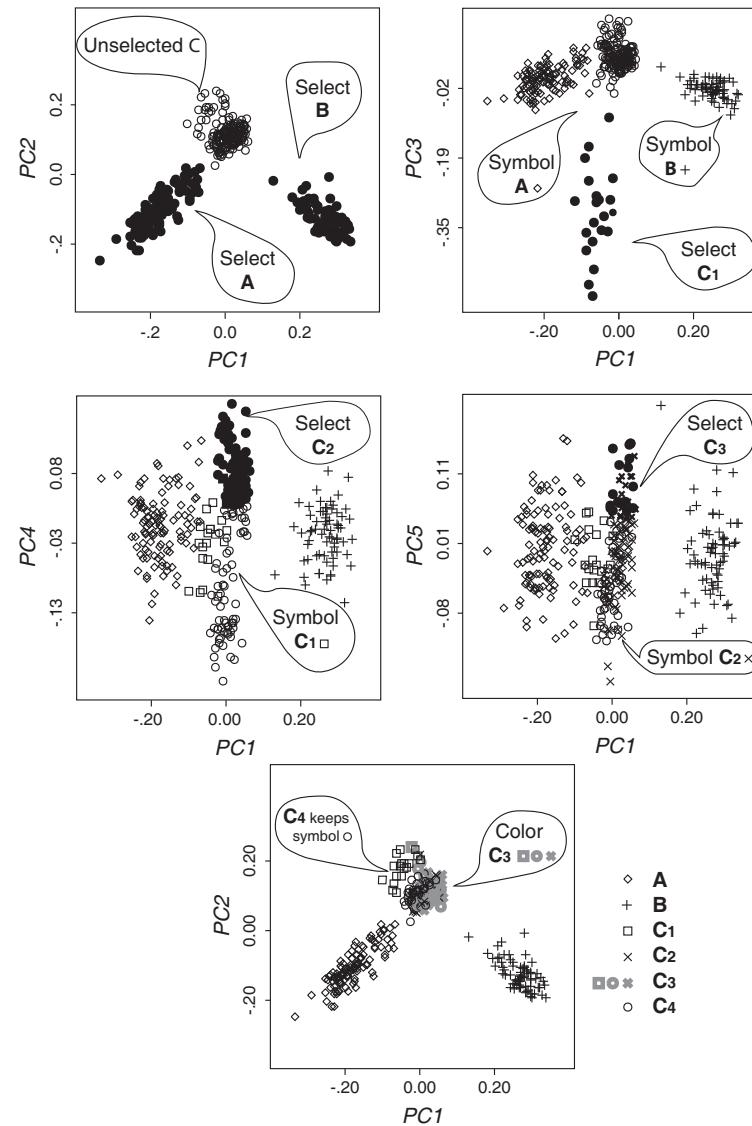
- Seleccionar **Boxplots** en el menú **Plot**

Obtendremos un gráfico de este tipo



- Preguntas que podemos explorar
  - ¿En qué difieren la ciudad más joven y la más anciana?
  - ¿Cuál es la mejor ciudad globalmente?

# Ejemplo: Identificando clusters visualmente



# *Historia y Software*

# Historia

- La idea de los gráficos dinámicos puede decirse que empezó con [PRIM9](#)  
No obstante, se utilizaba hardware especial sólo disponible en ciertos lugares
- Buena parte de los desarrollos iniciales acabaron en el libro ["Dynamic Graphics for Statistics"](#)
- Hasta la aparición de los ordenadores Macintosh, no fue posible llevar este tipo de análisis a todo el mundo. Un par de aplicaciones que marcaron el camino a seguir fueron:

[MacSpin](#)

[Statview](#)

# Software (más o menos actual)

Comerciales:

[DataDesk](#)

[JMP](#)

[Tableau](#)

[Spotfire](#)

No comerciales

[ViSta](#)

Arc

[XGobi, GGobi y RGobi](#)

[Manet y Mondrian](#)

[iPlots](#)

En la nube

[Google Chart Explorer](#) (no muy interactivo)

[Gapminder](#)

[Google public data explorer](#)

[TrendCompass](#)

# LispStat

- LispStat fue un lenguaje de programación estadístico (similar a R) desarrollado en los años 90 por Luke Tierney.

ViSta está desarrollado prácticamente del todo en LispStat

- En su momento ofrecía la posibilidad de experimentar con gráficos estadísticos interactivos y dinámicos a un nivel que no había sido posible previamente

Algunos creen que esa facilidad no ha sido igualada todavía

- La gente que desarrollaba software para Lisp-Stat se centraba a menudo en gráficos sofisticados, dinámicos Los resultados de texto parecían secundarios
- Lisp-Stat está actualmente moribundo pero parece que hay algunos esfuerzos por revivirlo

[Lisp-Stat: Past, Present and Future](#)

[Back to the Future](#)

[CommonLispStat](#)

[Incanter](#)

# A modo de resumen

- La cantidad de recursos disponibles es muy grande actualmente
- No obstante, las ideas básicas son las mismas prácticamente desde hace 20 ó 30 años
  - Aunque esas ideas aplicadas tienen muchas posibilidades
- Software comercial versus software no comercial
  - El comercial ofrece técnicas más probadas, más simples pero no necesariamente las mejores
  - El no comercial ofrece técnicas más avanzadas pero el esfuerzo necesario para utilizarlo es a menudo mayor (aunque R parece ser capaz de cambiar el escenario de una manera radical)

*ViSta*

# ¿Por qué ViSta?

- ViSta incorpora buena parte de las técnicas interactivas que se han propuesto desde los años 80
- El código es abierto y realizar modificaciones es sencillo
- Integra técnicas estadísticas y gráficos en un mismo entorno

Varios de los sistemas que hemos visto necesitan dos lenguajes: Por ejemplo, R y C o R y Java,

- Es una manera sencilla de familiarizarse con las técnicas
  - ViSta no es perfecto pero tiene muchas cosas interesantes
  - No obstante, hay que tener en cuenta que este curso está centrado en los *conceptos*: No tenemos la capacidad de una empresa comercial

# Historia

- Desarrollado por Forrest W. Young
  - 15 años de desarrollo! Desde el año 1991
  - Fundamentalmente usando XLispStat
  - Muchas características, algunas de ellas posteriormente eliminadas
- Desde el año 1998 me incorporo al proyecto haciendo cosas de
  - Datos “missing”
  - Modelos loglineales
  - Regresión múltiple (sin terminar)
  - Adaptaciones de MDS, Cluster, Mapas
  - Multitud de corrección de bugs, detalles, etc.

- Rubén Ledesma también ha incorporado un buen número de características
  - Adaptación del módulo de análisis de homogeneidad
  - Software para Psicometría
  - Bootstrap
  - etc.
- En 2006 publicamos el libro "["Visual Statistics: Seeing your data with dynamic interactive graphics"](#)"
- Michael Friendly incluye ViSta y LispStat en su selección de [importantes momentos en la historia de los gráficos estadísticos](#)

# Características

- **Gratis**
- **Gráficos múltiples, interactivos, dinámicos**
- **Funciona en Windows (versiones anteriores funcionaban en Mac y Unix)**
- **Workmap (una representación de los pasos realizados)**
- **Spreadplots (varios gráficos simultáneamente)**
- **GuideMaps (desconectado en la versión actual)**
- **Hoja de datos (muy sencilla pero permite ver los datos)**
- **Tipo de datos (lo veremos ampliado en la siguiente sección)**
- **Ayuda**

- **Ampliable**
- **Gráficos en formato vectorial**
- **¿Ya he dicho gratuito?**
- **El proyecto está abierto a cualquiera con interés en desarrollar nuevas cosas, así como cualquier otra tarea!!**

**Si teneis datos que podamos analizar, estamos interesados!!**

# Tipo de datos

- Una característica de ViSta es que atribuye un tipo a los conjuntos de datos a partir de las características de las variables que hay en él:
  - Sólo variables numéricas: Numérico  
Si tiene algún valor perdido: Missing (se usa nil)
  - Una variable numérica y una o varias categóricas: Clasificación
  - Sólo variables categóricas  
Sin agrupar: Datos categóricos  
Agrupadas y con una variable denominada Freq o Frequency: Frequency classification  
Cruce de dos variables categóricas: Frequency Table
  - Datos de similaridades/disimilaridades: Datos relacionales

- ViSta limita los análisis a los tipos de datos y lo hace sobre la marcha (a partir de lo seleccionado).

A menudo lleva a que los gráficos/análisis se seleccionen automáticamente

A veces, no obstante, producen más problemas que los que solucionan!

*Interacción con  
gráficos*

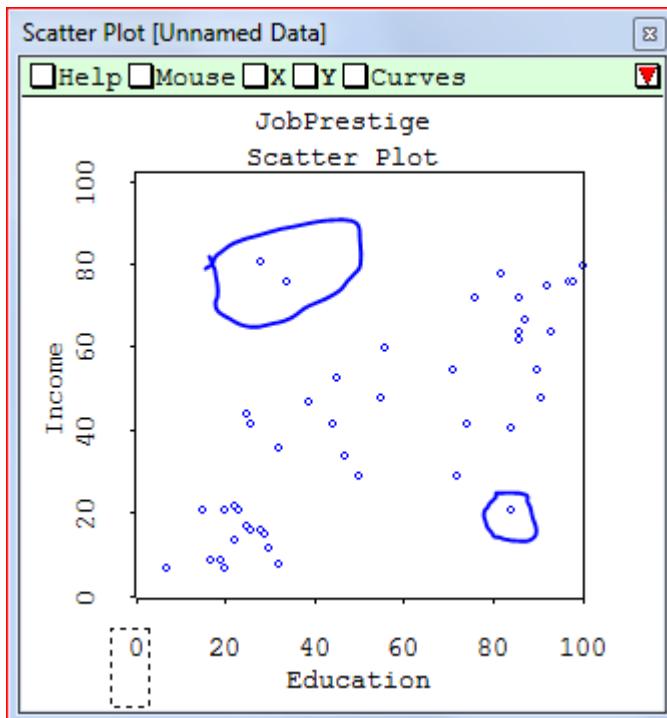
# Ejemplo: Jobs

- Este ejemplo está en data/regress/jobs.vdf

Las variables de Income, Prestige y Salary están escaladas a 100

# Activación de elementos

- En el gráfico de Income versus Education podemos ver tres puntos que no parecen ir con el resto



- Cepillado: Pasar el ratón para ver los nombres
- Selección: Cambiar el modo del ratón para ver los nombres
- Selección múltiple: Utilizando Ctrl seleccionar varios puntos
- Selección de area: Arrastrar

# Etiquetas

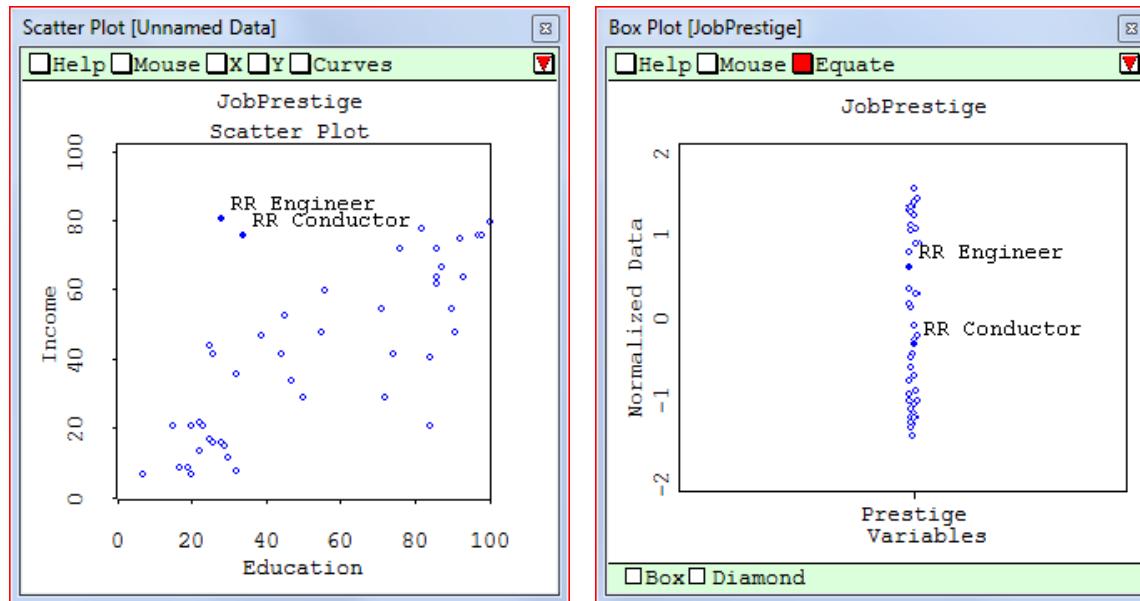
- Etiquetar los casos es una de las necesidades más básicas en muchos análisis
  - No obstante, poner las etiquetas automáticamente es muy difícil
  - Por ello, que las etiquetas se muestren interactivamente es de gran utilidad
  - Esto es sobre todo importante en gráficos densos, en los que se necesita explorar partes en detalle
- En ViSta, al seleccionar se muestra la etiqueta del punto

Se puede desconectar la opción de mostrar etiquetas y verlas en la lista de etiquetas del archivo de datos

# Ligado

El ligado es una de las estrategias más potentes. Las acciones sobre un gráfico se propagan a los otros gráficos

En el ejemplo de Jobs podemos conectar el diagrama de dispersión a un diagrama de puntos



# Enfocar y Excluir

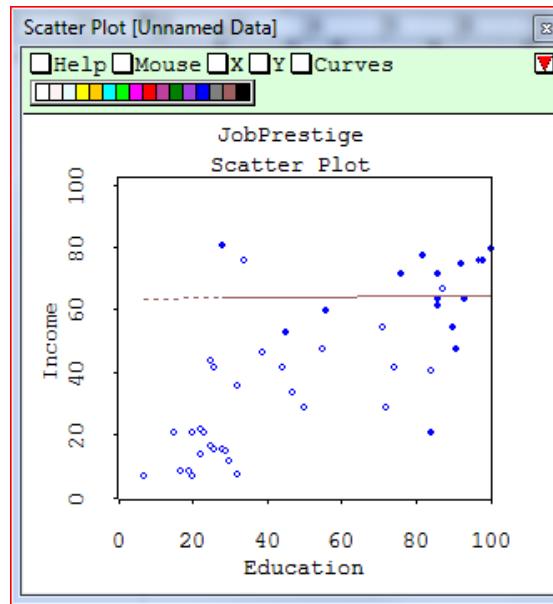
- En el ejemplo de Jobs hay un par de puntos que parecen no ir con el resto.
- En el menú contextual se pueden excluir esos puntos
  - **Remove Selection** excluye los puntos seleccionados.  
Las escalas se ajustan automáticamente a los puntos que quedan
  - **Focus** se centra en los puntos seleccionados
  - **Show all** muestra todos los puntos de nuevo
- Esas características están ligadas así que los otros gráficos ven reflejados los cambios

# Cambiar Colores y Símbolos

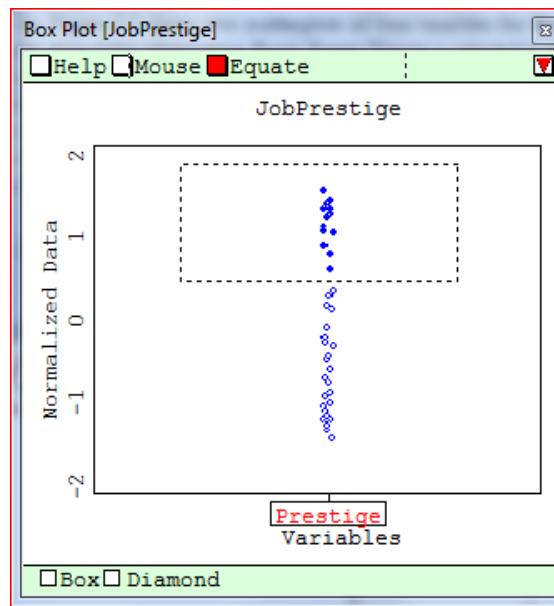
- Usando **Color Pallet** y **Symbol Pallet** aparece una paleta de colores
  - Haciendo click sobre el color, los puntos seleccionados cambian de color
- Esas características están ligadas así que se ven reflejados los cambios de un gráfico en los otros

# Ejemplo: Cepillado, ligado y líneas

- En el gráfico elegir Curves y seleccionar Regression Lines selected



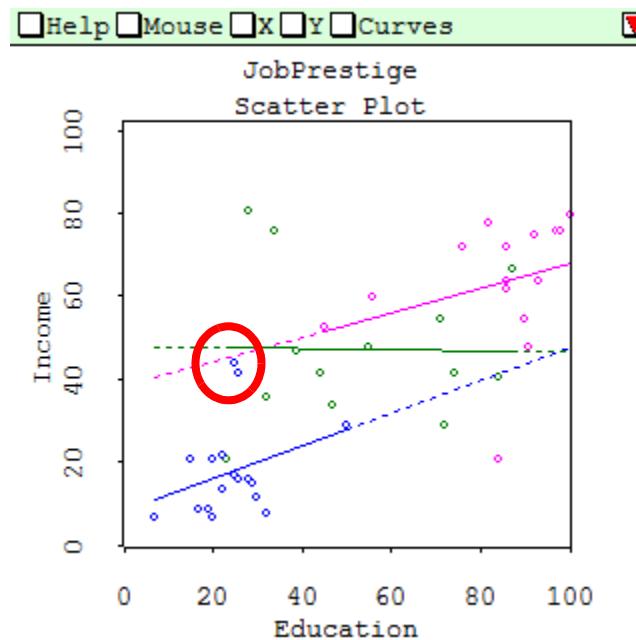
- En el gráfico de puntos, hacer el cepillo más grande y cepillar de arriba abajo



La línea de regresión irá cambiando, ajustándose a los puntos seleccionados

- ¿Qué podemos aprender de este ejercicio?
  - Para los niveles medios de prestigio, no parece que la Educación tenga efectos sobre los ingresos
  - Podemos hacer tres grupos con el Prestigio y cambiar el color
  - Luego, en Curves, podemos pedir Regresión por color

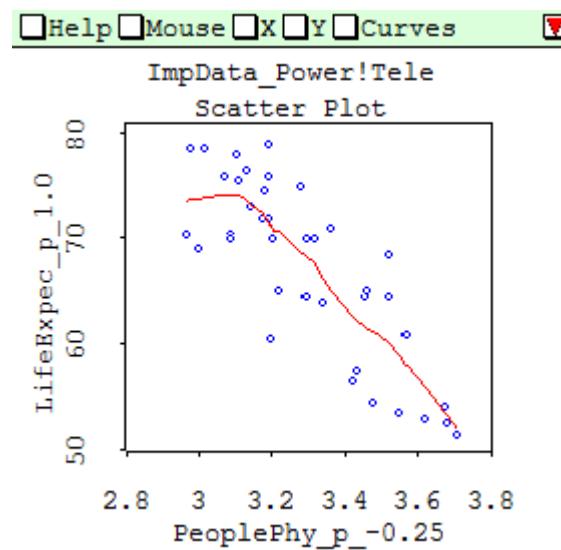
- ¿Y los valores extremos?
  - Podemos probar a quitarlos y ver que pasa
  - Cuando quitamos dos puntos influyentes en los valores medios de prestigio vemos que la relación entre educación en ingresos es la misma para todos los grupos de prestigio
  - Al hacerlo descubrimos nuevos valores destacados en el grupo con baja educación: Plumber y Tram Motorman



# Ejemplo: Transformación, Imputación y Visualización

1. Abrir el ejemplo Tele.vdf en data/regress
2. Usar las transformaciones BoxCox para linearizar  
¿Corea del Norte?
3. Imputar los valores perdidos
4. Visualizar la relación entre número de médicos per capita y esperanza de vida  
Lowess aporta algo interesante  
Usando un gráfico de puntos para

número de televisiones per capita puede explorarse la influencia de la economía



# *Gráficos básicos*

# Gráficos de presentación v. gráficos de análisis

- **Gráficos de presentación**

Los gráficos de presentación intentan dar una idea final completa de un resultado

Son una ilustración

A menudo empleamos bastante tiempo en ajustar cada detalle

No es posible ir más allá o quizás sí?

- El considerado mejor ejemplo de gráfico es el de [Minard](#)

Pero se puede ver que incluso el mejor de todos podría ser mejorado

- **Gráficos de análisis**

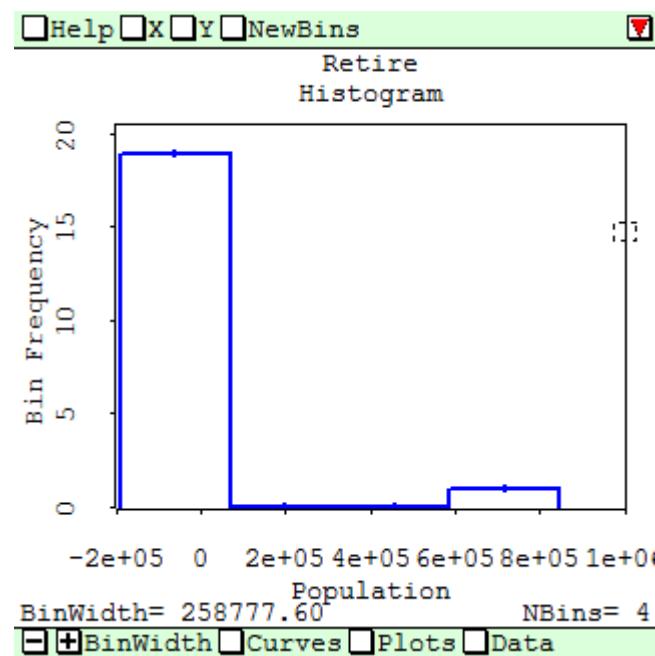
Permiten ir más allá de lo representado

Jugar con aspectos importantes

Añadir elementos, quitarlos. El artículo de [Weisberg](#) da ejemplos.

# Histogramas

- Cuatro comandos (pero tres son iguales!)

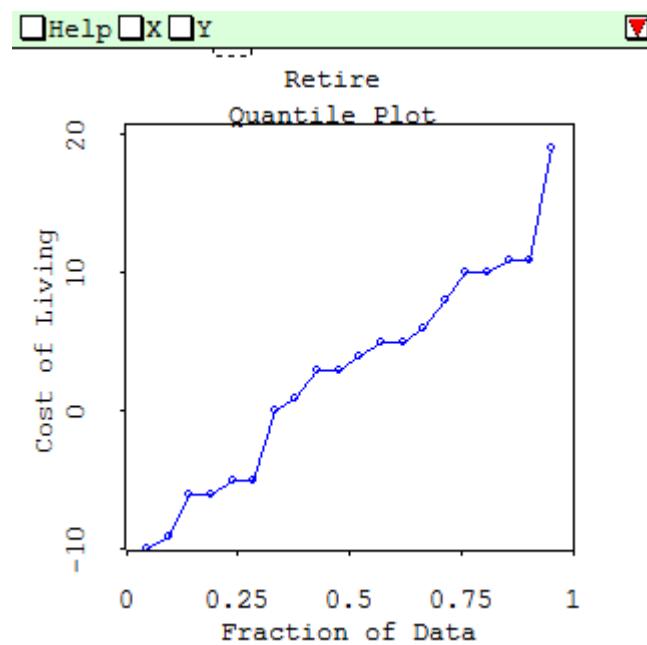


- Botón X, cambiar de variable
- Botón Y, pasar a probabilidades

- Binwidth: permite cambiar y explorar el efecto que tiene cambiar el tamaño de las barras
- Curves: Añade curvas de estimación de la densidad, controladas por una barra de desplazamiento
- Plots: Cambia de tipo de gráfico

# Plot acumulativo

- Gráficos de cuantiles



Gráfica los valores de la variable frente al cuantil

Para datos simétricos, la línea central se aproximará a la diagonal

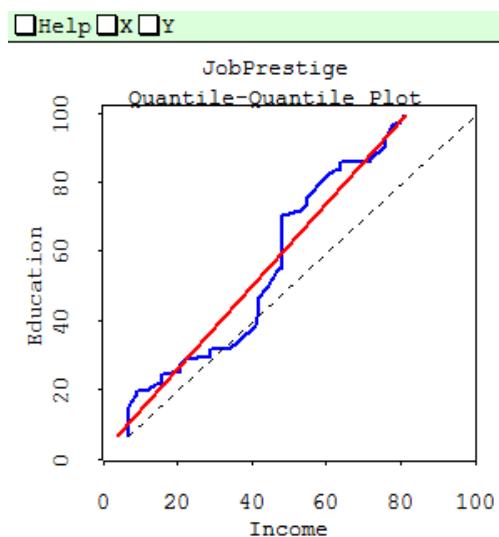
Para datos asimétricos positivos, la línea irá por debajo de la diagonal

Lo contrario para datos positivos negativos

- Haciendo click en X cambia a un gráfico de probabilidad normal  
Si la distribución es normal, los valores seguirán la diagonal

# Comparación de dos variables

- Este gráfico permite comparar las distribuciones de dos variables



- El gráfico representa los cuantiles de una variable frente a los cuantiles de la otra variable

- La línea azul indica si las dos variables tienen distribuciones con la misma forma
- La línea roja representa dos variables con la misma forma pero con centro y amplitud iguales a las variables observadas
- La línea de puntos representa dos variables semejantes

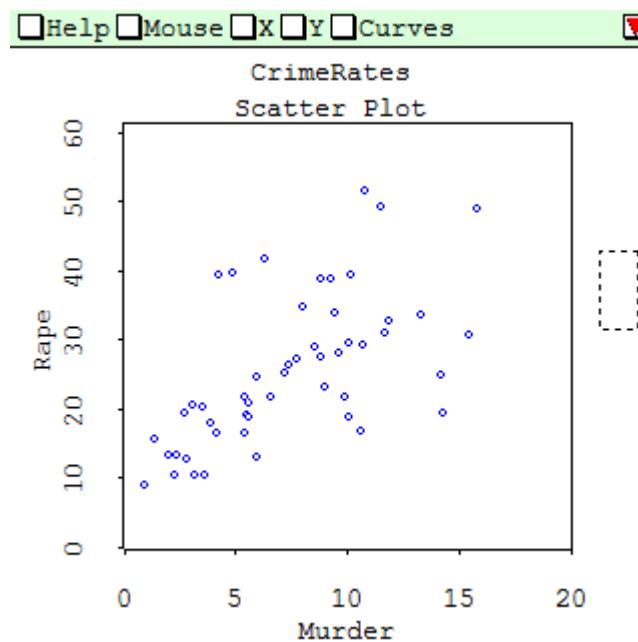
- Interpretación
  - Línea azul igual a línea de punto: igual forma, centro y amplitud
  - Línea azul igual a roja pero no a línea de puntos: igual forma

# Gráfico de Puntos

- Muy similar al gráfico de líneas (creo que lo desconectaré en el futuro)

# Diagrama de dispersión

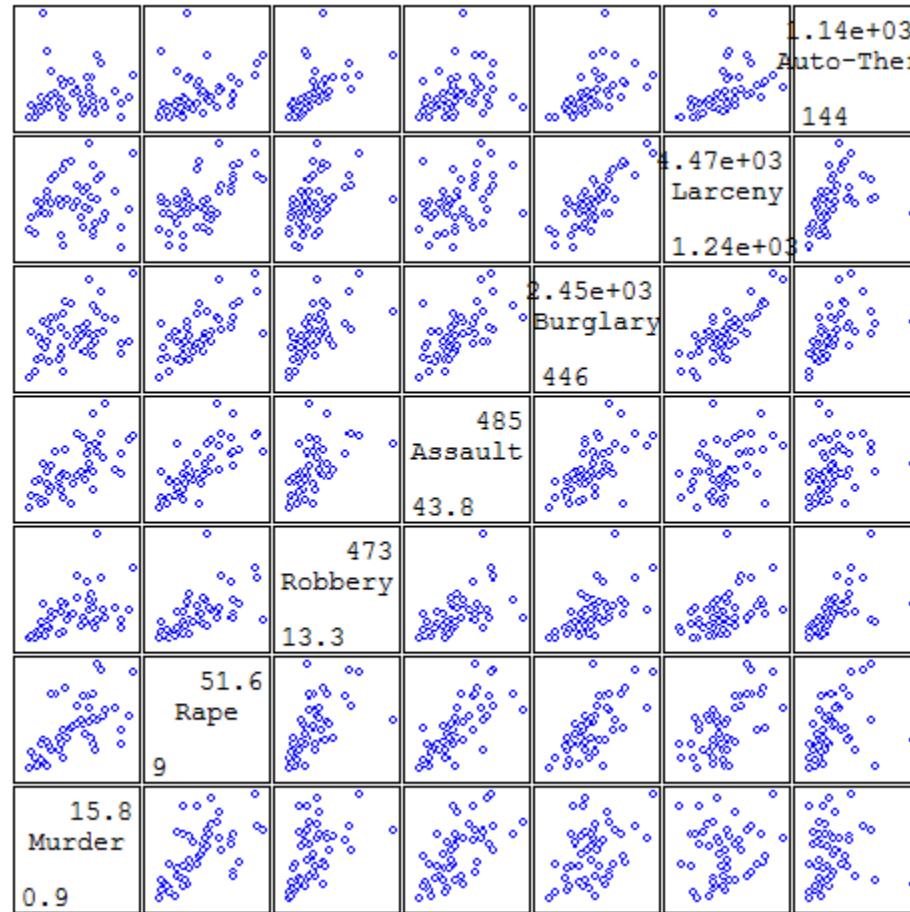
- Los botones X e Y sirven para cambiar las variables que se incluyen
- El botón Curves sirve para añadir una variedad de líneas



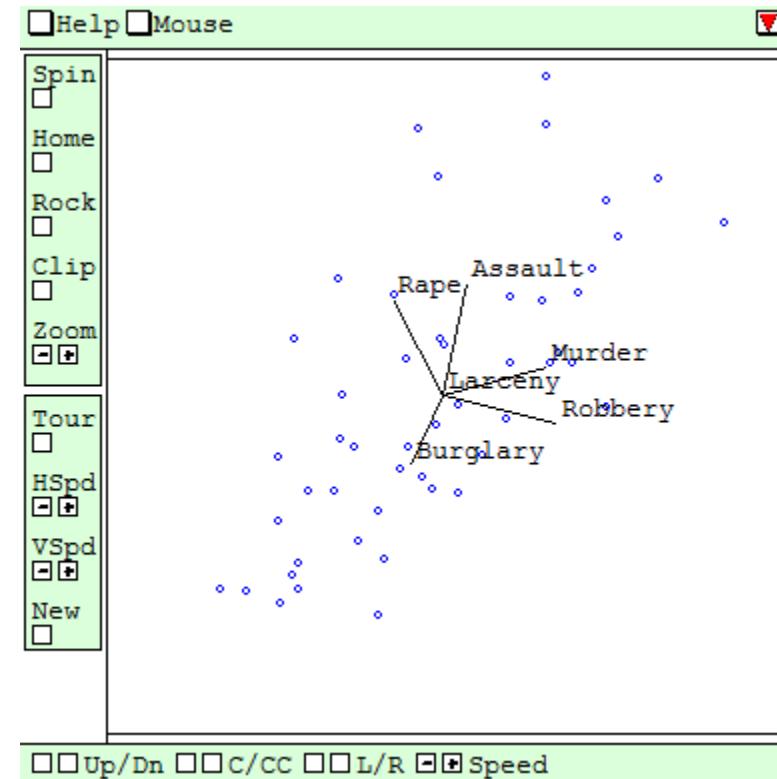
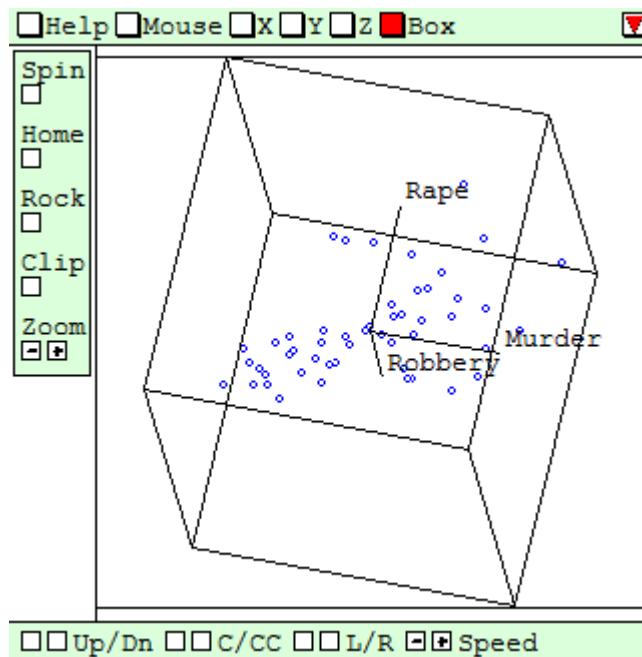
- Las líneas disponibles son:
  - Eje Principal
  - Líneas de regresión
  - Línea monotona
  - Normal and Quantile contours
  - [Lowess](#): regresión local
    - El slider controla la proporción de casos que es utilizada
  - Kernel smoother: otra forma de regresión local
    - El slider controla la anchura de la función kernel

# Matrices de diagramas de dispersión

- Muestra los diagramas de dispersión para varias variables simultáneamente

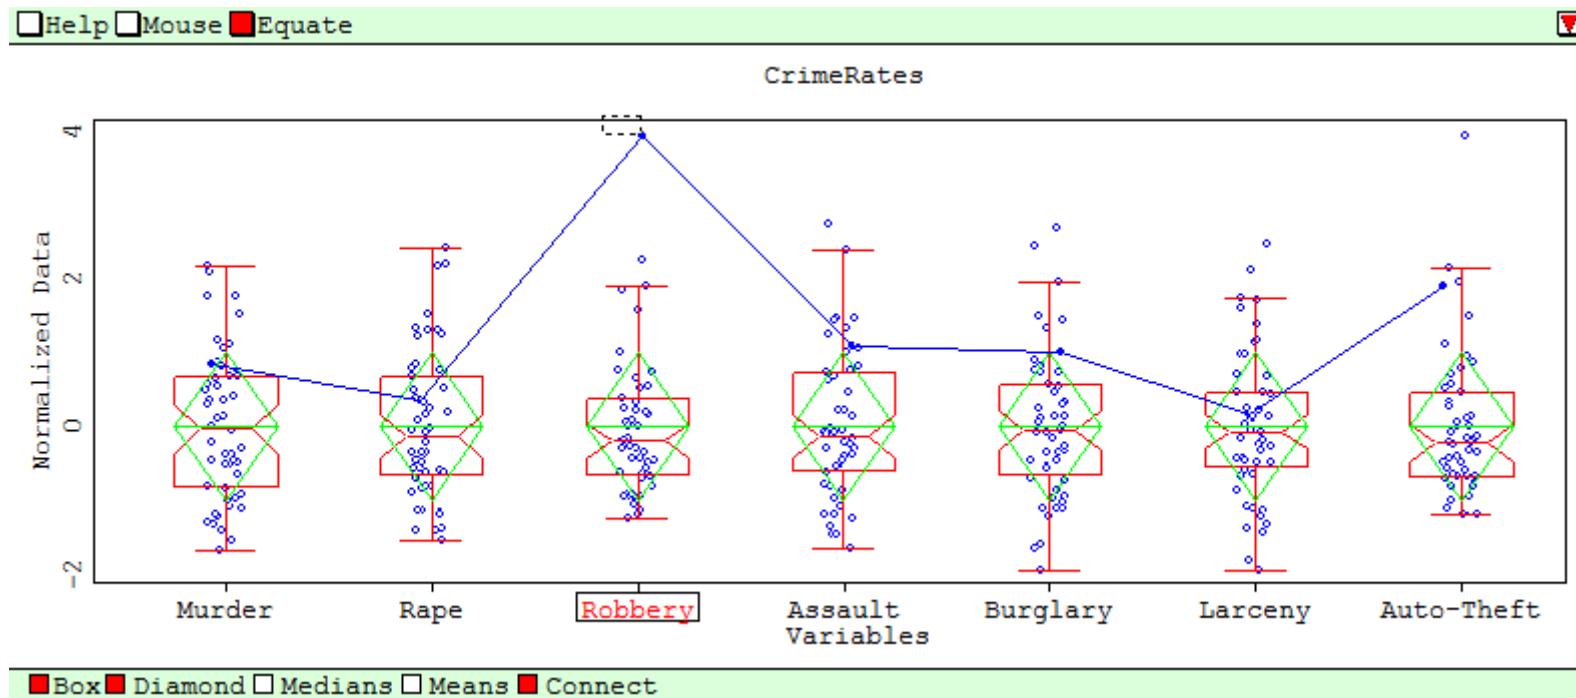


# Spinplots y Tourplots



# Boxplot, Diamond plot, Parallel coordinates

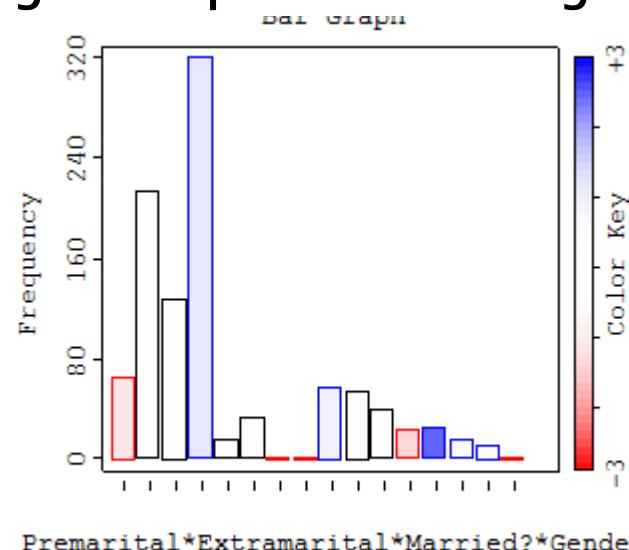
- Son variantes del mismo gráfico



- Los diamantes son las medias. Los casos están conectados.
- El botón Equate estandariza o no las variables. Se pueden añadir líneas para medianas, medias.

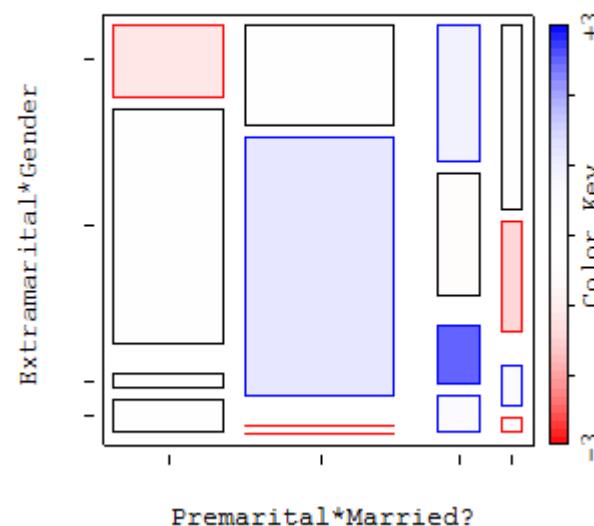
# Gráficos de mosaico y diagramas de barras

- Son gráficos para datos categóricos



No están ligados (tendría que hacerlo esto)

No tienen la posibilidad de cambiar de variables (por eso es mejor utilizarlos desde la visualización para datos de frecuencias)



# *Spreadplots*

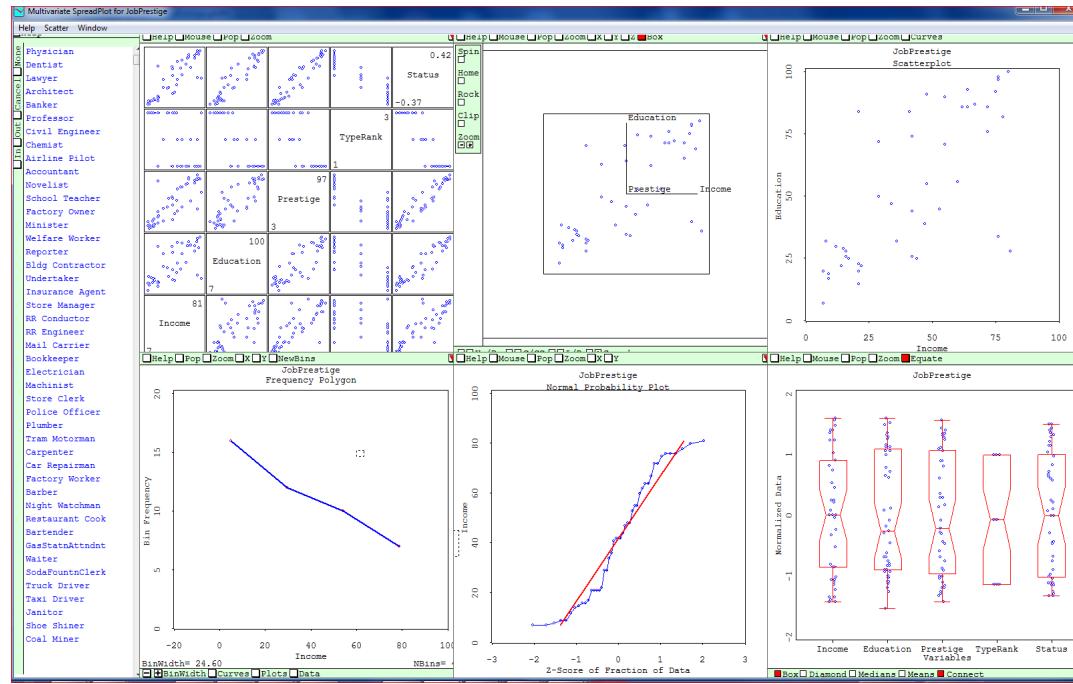
# Manejando muchas ventanas

- A veces tenemos ideas que usan muchas ventanas/gráficos

Además, la interacción entre ellas puede ser sofisticada

Si tenemos una combinación de ventanas interesante podemos querer guardarla para no tener que repetir el proceso cada vez

- Una solución son los spreadplots

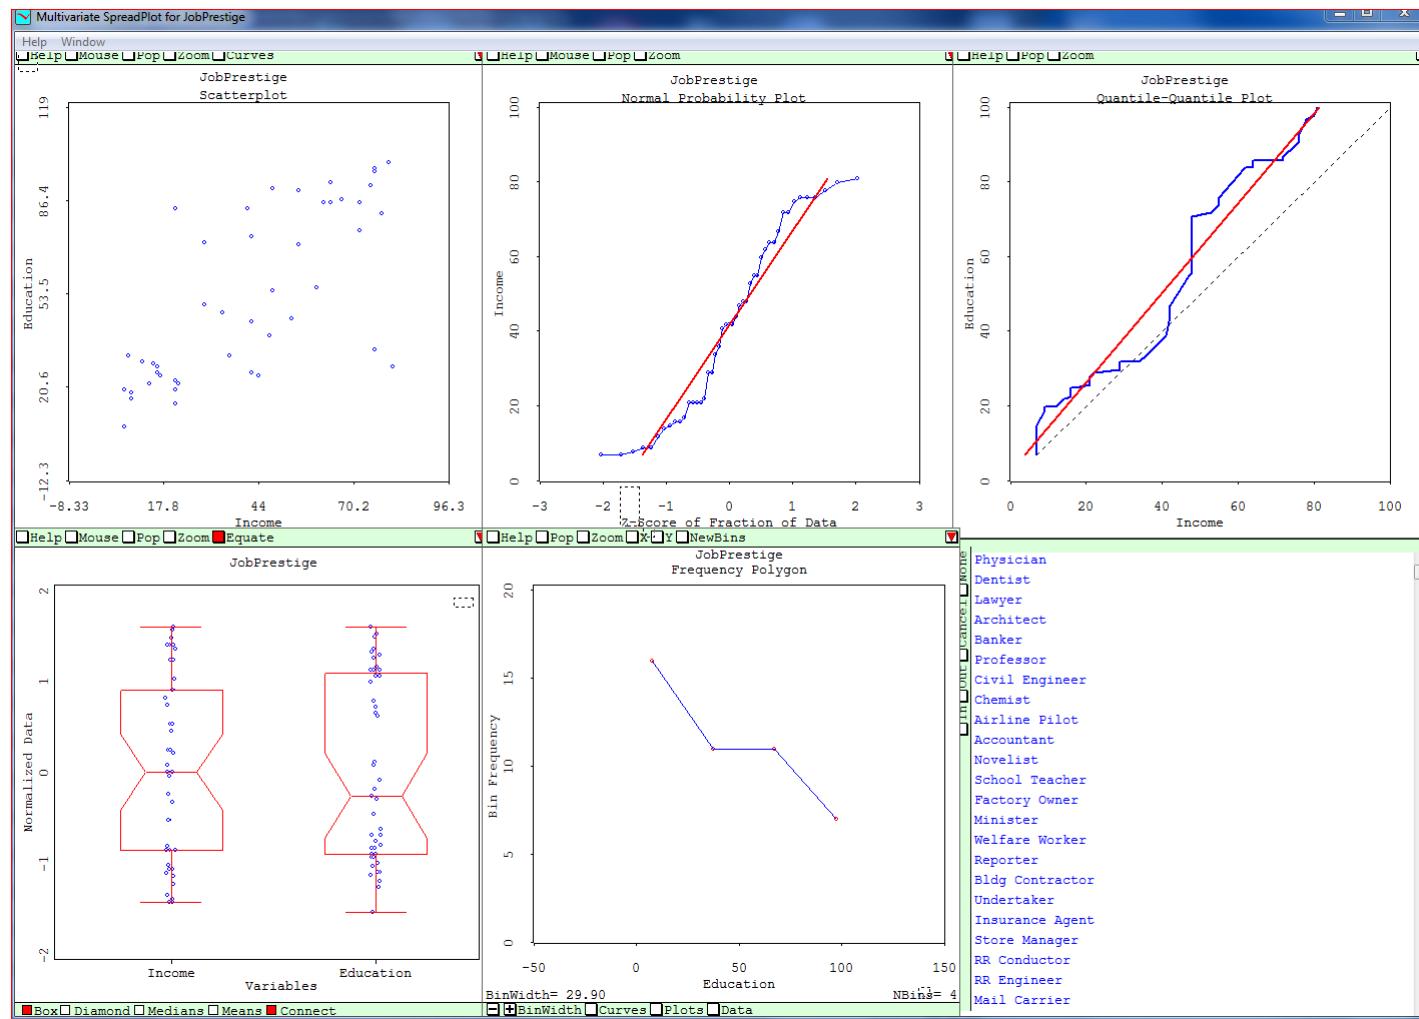


Producen una combinación de gráficos ajustada a un problema concreto

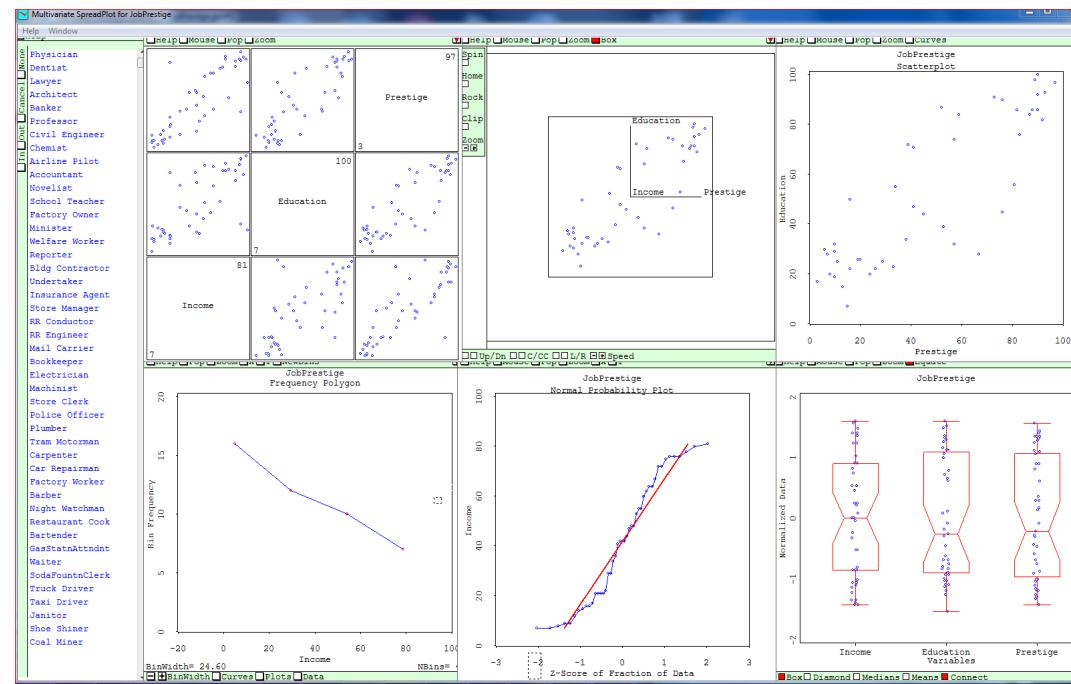
Las ventanas funcionan conjuntamente (se abren, se cierran, etc.)

Son programables

# Spreadplot para 2 variables numéricas

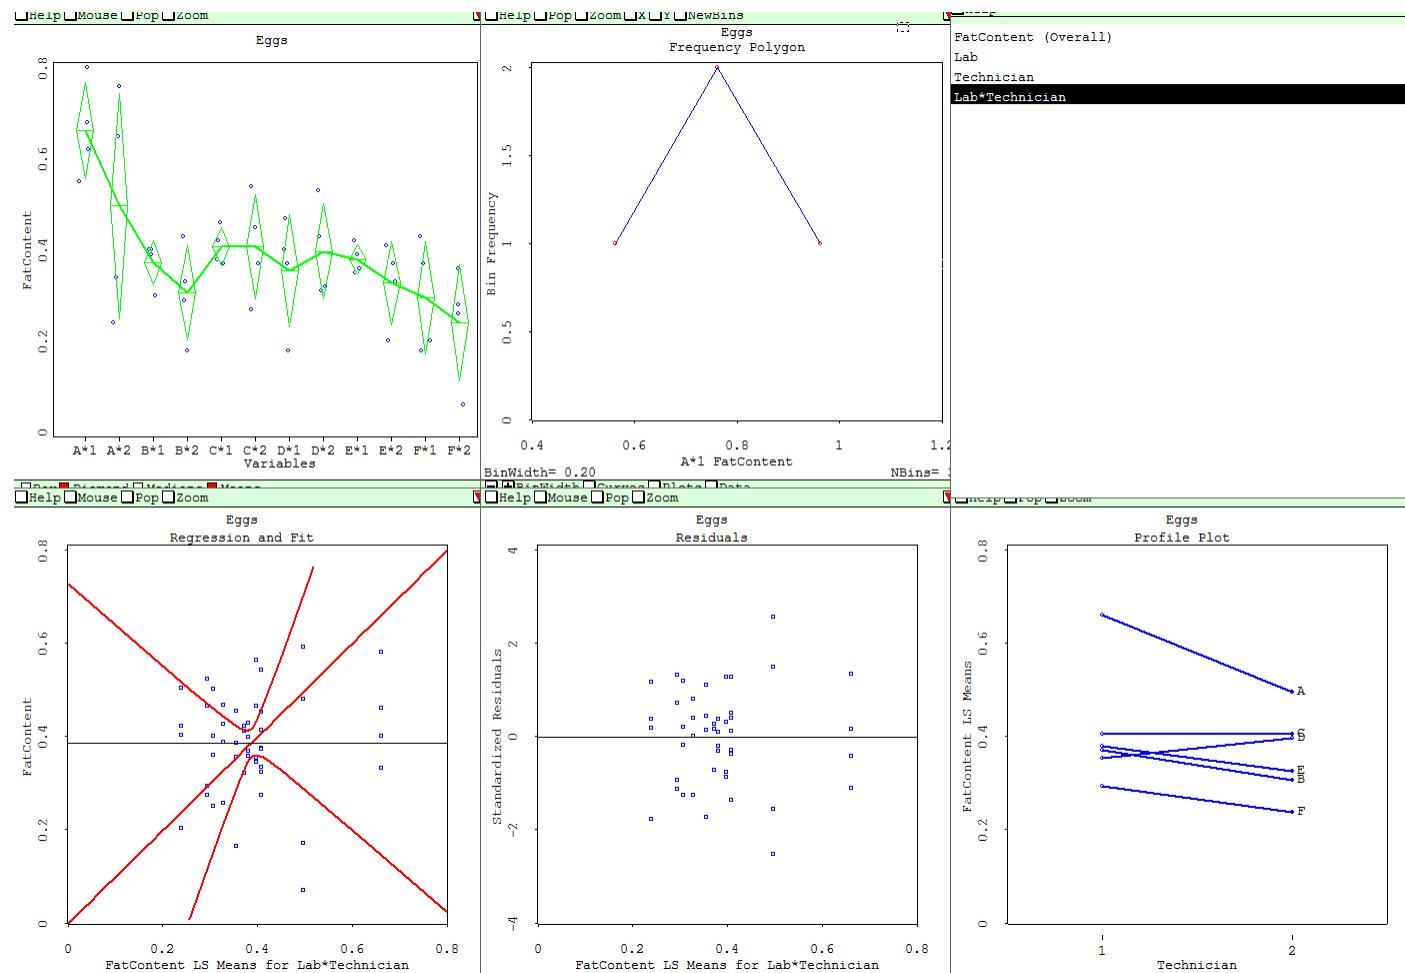


# Spreadplot para 3 variables numéricas

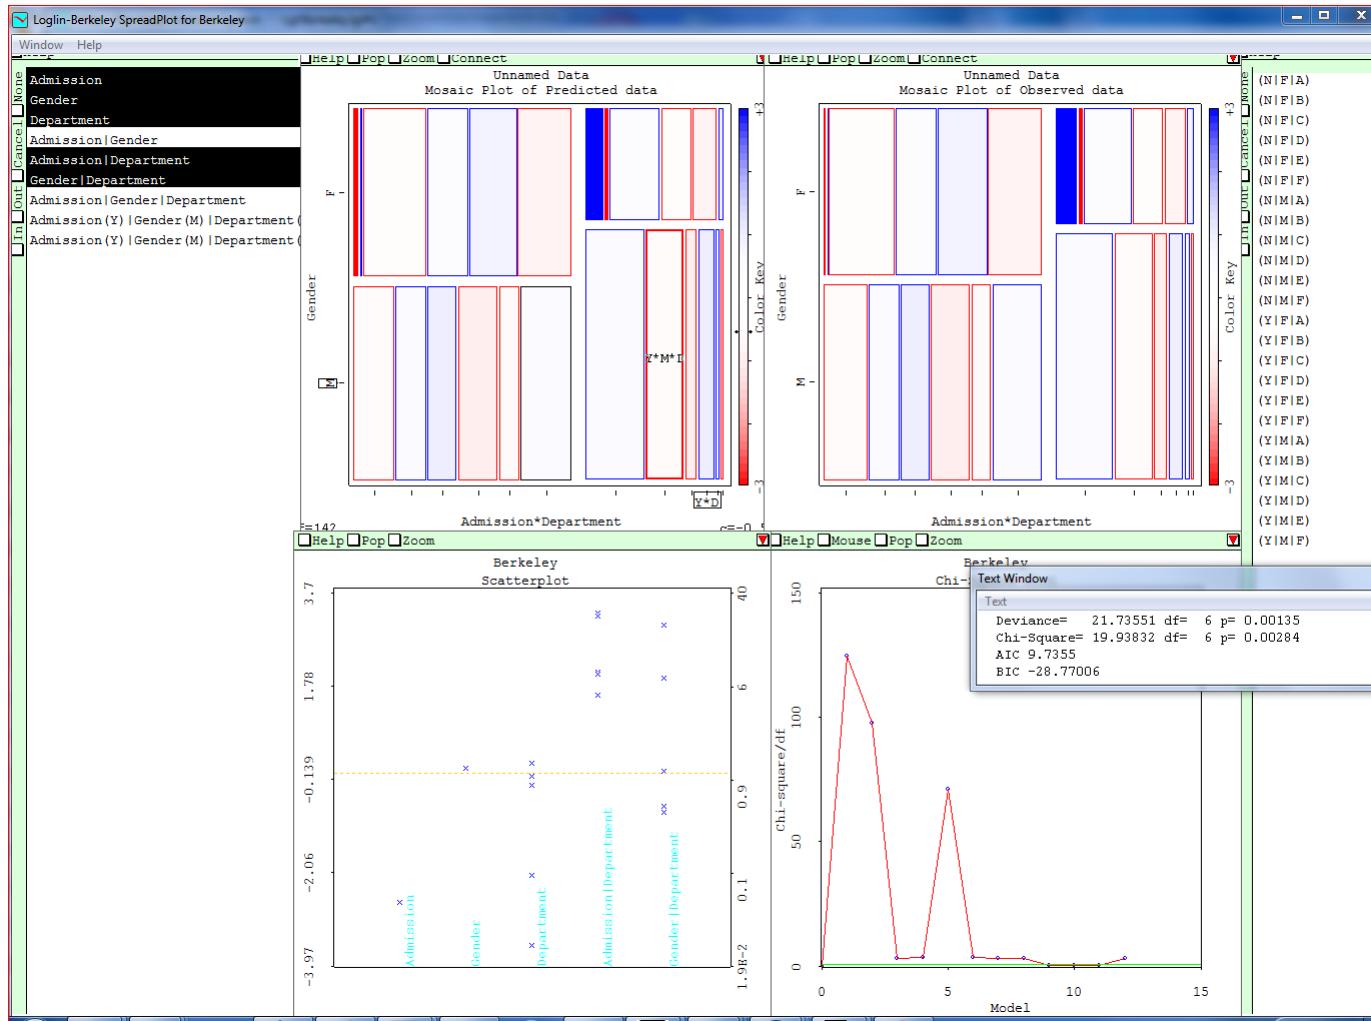


Fijarse que la matriz de diagramas de dispersión sirve de control para el resto de gráficos

# Análisis de varianza



# Spreadplot para modelos loglineales



# Notas finales

- La idea de los spreadplots es muy poderosa

En JMP y en DataDesk hay conceptos muy parecidos

Varios programas comerciales también los utilizan (Spotfire, TrendCompass)

Dashboards es un concepto muy similar que parece estar de moda

# *Datos categóricos*

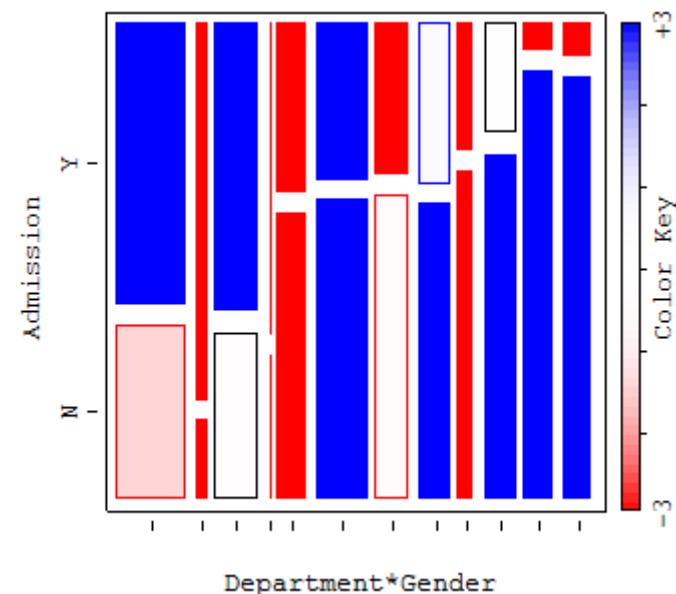
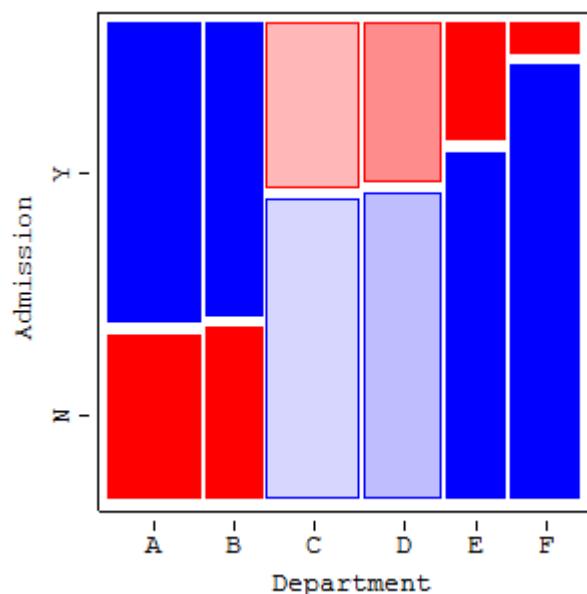
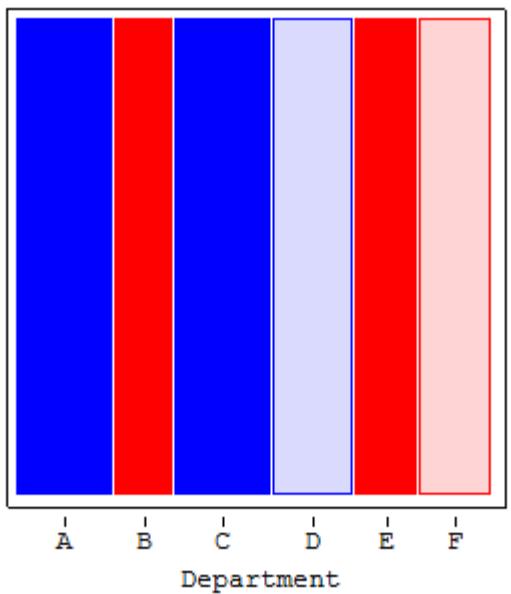
# Visualización de datos categóricos multivariados

- El desarrollo de las técnicas de visualización se han basado sobre todo en datos cuantitativos
  - Los datos categóricos han tenido un desarrollo más lento: ver [Friendly, 2000](#)
  - Las extensiones dinámicas han sido exploradas todavía más recientemente  
[Manet](#) fue el primer programa en explorar este tema sistemáticamente
- Los plots de mosaico han generado mucho interés por su capacidad de representar muchas variables categóricas simultáneamente

En principio, el número de variables que se pueden incluir es ilimitado

No obstante, ViSta está limitado a cuatro

- Un ejemplo de plot de mosaico



- Se trata de los mismos datos con tres variables

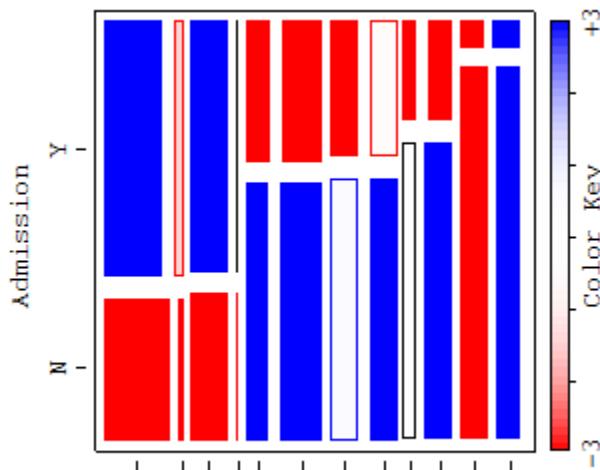
Cada vez que se añade una variable, el gráfico se subdivide

Cada celda es proporcional a la frecuencia condicional de las categorías a las que corresponde

El color de las celdas es el residual standarizado respecto de un modelo. En este caso se trata del modelo de efectos simples (azul +, rojo -)

# Spinogramas y Mosaic plots

- Originalmente ViSta hacía Mosaic plots, pero lo he cambiado (trabajo en progreso)



La diferencia sólo se nota cuando hay más de dos variables

- Los Spinogramas son más apropiados cuando tienes una variable dependiente y la situas en el eje Y

Es decir son más apropiados para modelos logit

- Los plots de Mosaico son más acordes con la situación en la que no se distingue entre variables dependientes/independientes

Más apropiados para modelos loglineales

# Ejemplo: Datos de Berkeley

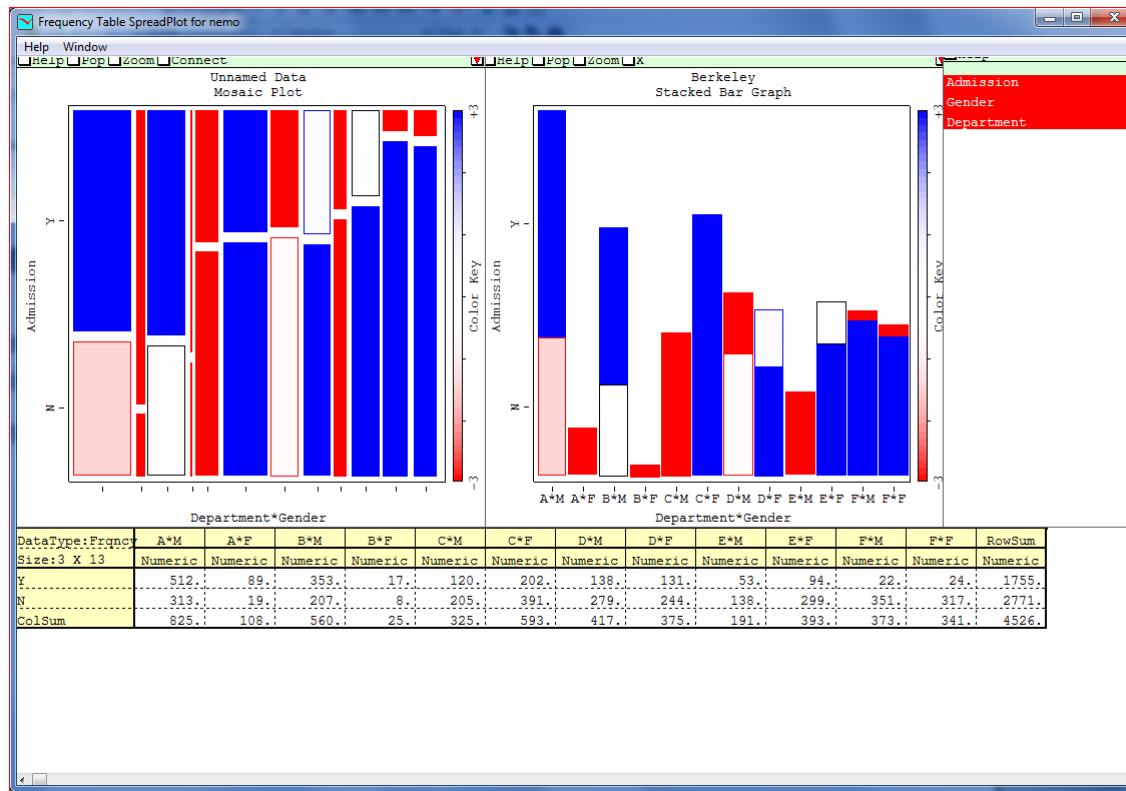
- Los datos de Berkeley analizan la discriminación por género por departamento

Hay 6 departamentos divididos por género y por aceptado/rechazado

Berkeley Admissions Dataset				
Department	Gender			
	Male		Female	
	Admission			
	Yes	No	Yes	No
A	512	313	89	19
B	353	207	17	8
C	120	205	202	391
D	138	279	131	244
E	53	138	94	299
F	22	351	24	317

- Está en data/loglinear

# Spreadplot para Berkeley



- Eligiendo las variables que están en la derecha, el gráfico de mosaico cambia  
El orden en la selección de variables transmite mensajes diferentes

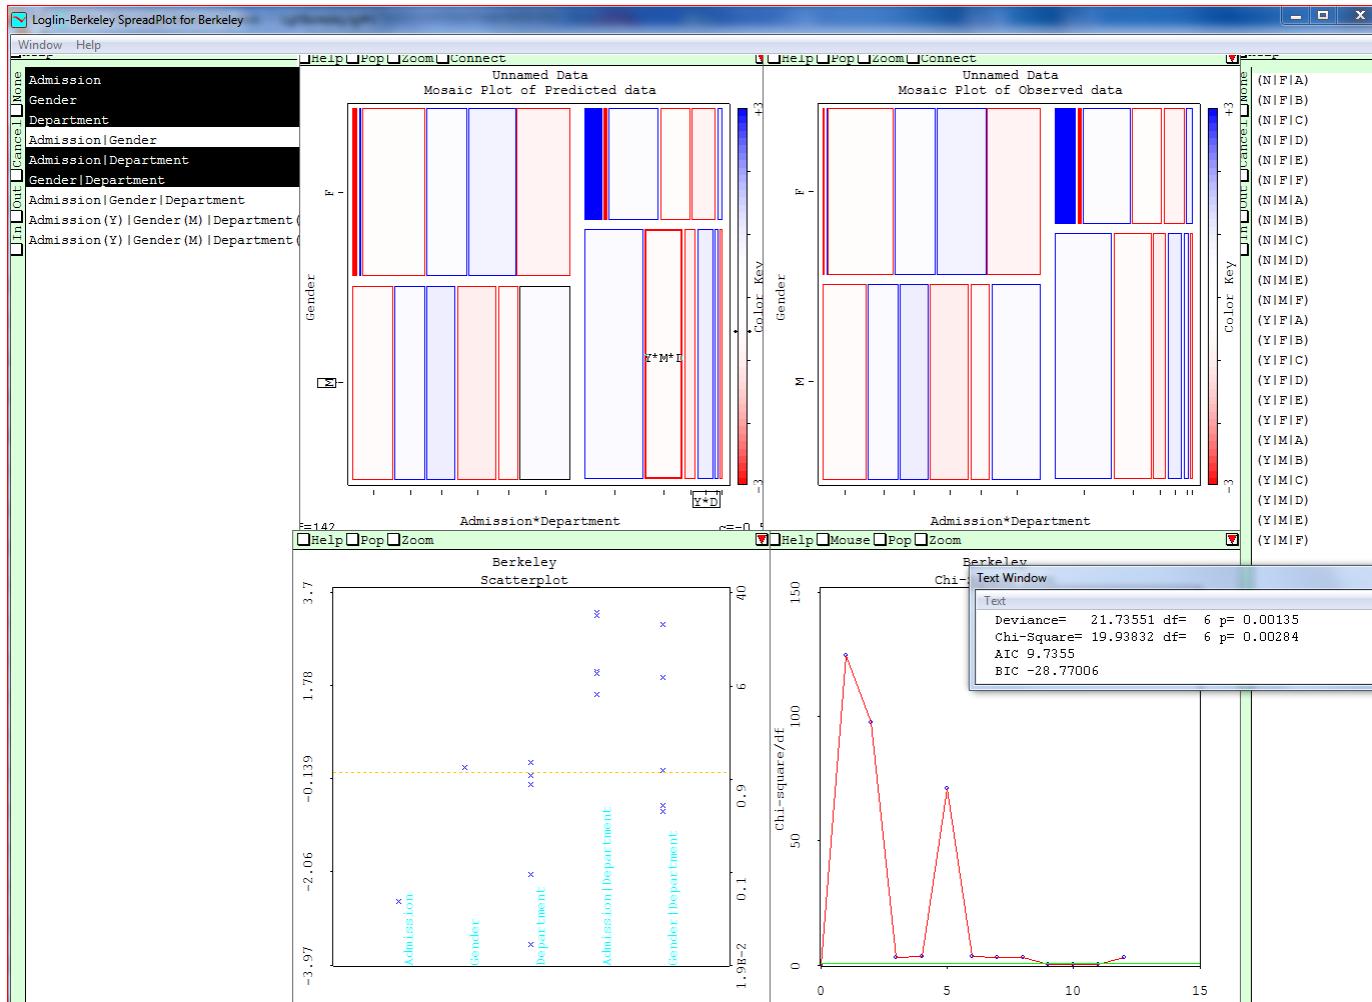
# Ejemplo: Felicidad en función del Género/Raza

- En este ejemplo examinamos el efecto del Género y la Raza sobre la felicidad
- Este archivo se encuentra en data/loglinear/happiness.vdf  
(no happinessfreqs.vdf)

Seleccionar sólo Happy, Gender y Race

# Modelos loglineales

- Este es el spreadplot para modelos loglineales que vimos antes



A la izquierda están las combinaciones de variables para formar modelos  
Funciona jerarquicamente (variables anidadas se añaden automáticamente)  
Los valores de ajuste se van registrando en el gráfico de modelos  
Podemos retroceder para examinar modelos antiguos  
Se comparan modelos automáticamente simplemente seleccionando dos (se comprueba que estén anidados)  
Hay una ventana de parámetros que indica qué elementos son responsables del ajuste  
También puede funcionar no jerarquicamente  
Etc., etc.

# Ejemplo: Modelos loglineales para Berkeley

- Un modelo no saturado no ajusta.

No obstante, un modelo sin la interacción de 3 orden muestra claramente que la anomalía está solo en el departamento A

- Esto lleva a un modelo no jerárquico que incluye interacción entre Género y Admisión sólo para el departamento A

Este modelo ajusta muy bien y se interpreta del siguiente modo: No existe discriminación generalizada pero sí en el departamento A (aunque es a favor de las mujeres, no en contra)

# Ejemplo: Modelos loglineales para Felicidad

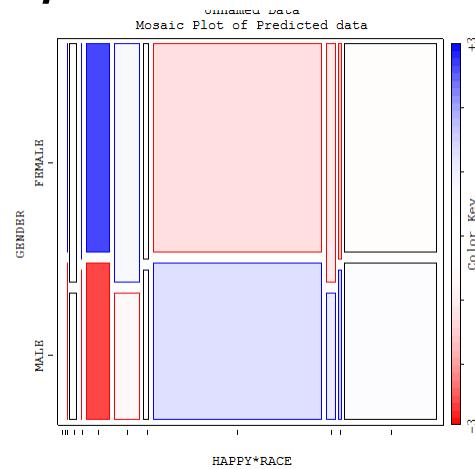
- En este modelo, resulta interesante cambiar las categorías de referencias puestas por defecto
- Si introducimos todas las interacciones de segundo orden el modelo ajusta
- No obstante, si examinamos los parámetros veremos que ninguno de segundo orden es significativo

¿Cómo interpretamos entonces los resultados?

Si cambiamos las categorías de referencia es posible poner una diferente y entonces los parámetros son más fácilmente interpretables

En concreto, podemos usar not very happy como categoría de referencia en la variable Happy. Eso muestra que la felicidad parece ser cosa de hombres!

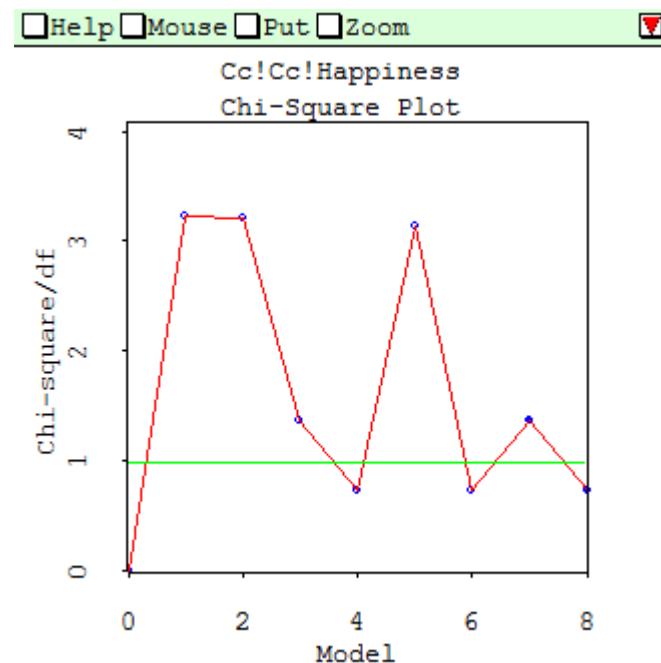
- Por otro lado, si quitamos la interacción entre Felicidad y Género llama la atención en el gráfico de mosaico la diferencia entre las mujeres y los hombres de raza blanca que declaran no ser muy felices



Un modelo con ese término ajustado individualmente ajusta muy bien

# Comparación de modelos

- En el ejemplo de felicidad es posible ver que un modelo que no incluya la interacción entre Happy y Gender ajusta casi bien (Deviance 13.4 con 9 g.l;  $p=0.14402$ )
- Sin embargo, si se incluye este término el ajuste es bueno (Deviance 4.875 con 6 g.l.;  $p=0.55994$ )
- Resulta interesante comparar estos dos modelos. Esto se puede hacer seleccionando los dos modelos en la ventana de historia

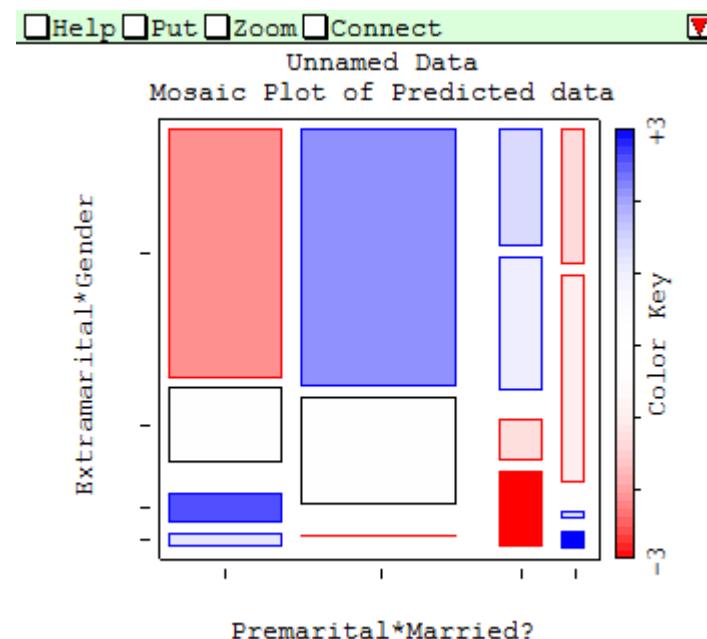


# Ejemplo: Modelo Logit para Sexo

- Este ejemplo está en Freq/Sex.vdf
- Después de empezar con el modelo loglinear y tener el spreadplot a la vista se escribe en el listeners
  - (send current-model :dependent variable 2)
    - Esto hace que se incluyan automáticamente todos los términos que no incluyan la variable Married?

# Interpretación de parámetros

- La interpretación de parámetros en análisis loglineal es un tanto complicada
  - No hay que interpretar términos que están anidados dentro de otros de nivel superior
  - El coeficiente es una tasa que depende de las categorías de referencia
  - La ventana de parámetros ofrece información sobre el coeficiente, su significación y su cálculo
- Otra forma de interpretar es desconectar el término y examinar el gráfico de mosaico



*Datos numéricos*

*univariados*

# Histogramas

- Los histogramas son una de las representaciones gráficas más básicas

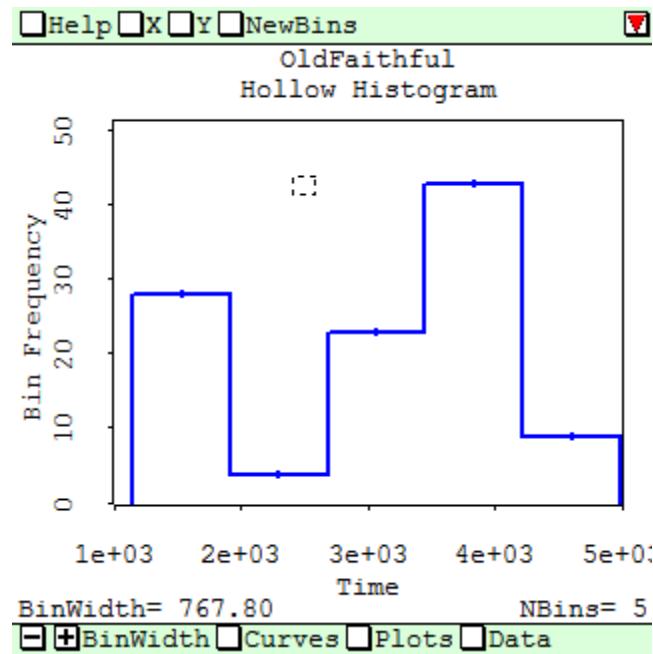
No obstante, los histogramas son problemáticos en dos aspectos

- El número de barras: Diferente número de barras produce diferentes histogramas
- El punto de origen: Diferentes puntos de origen produce diferentes histogramas

# Ejemplo: Old Faithful

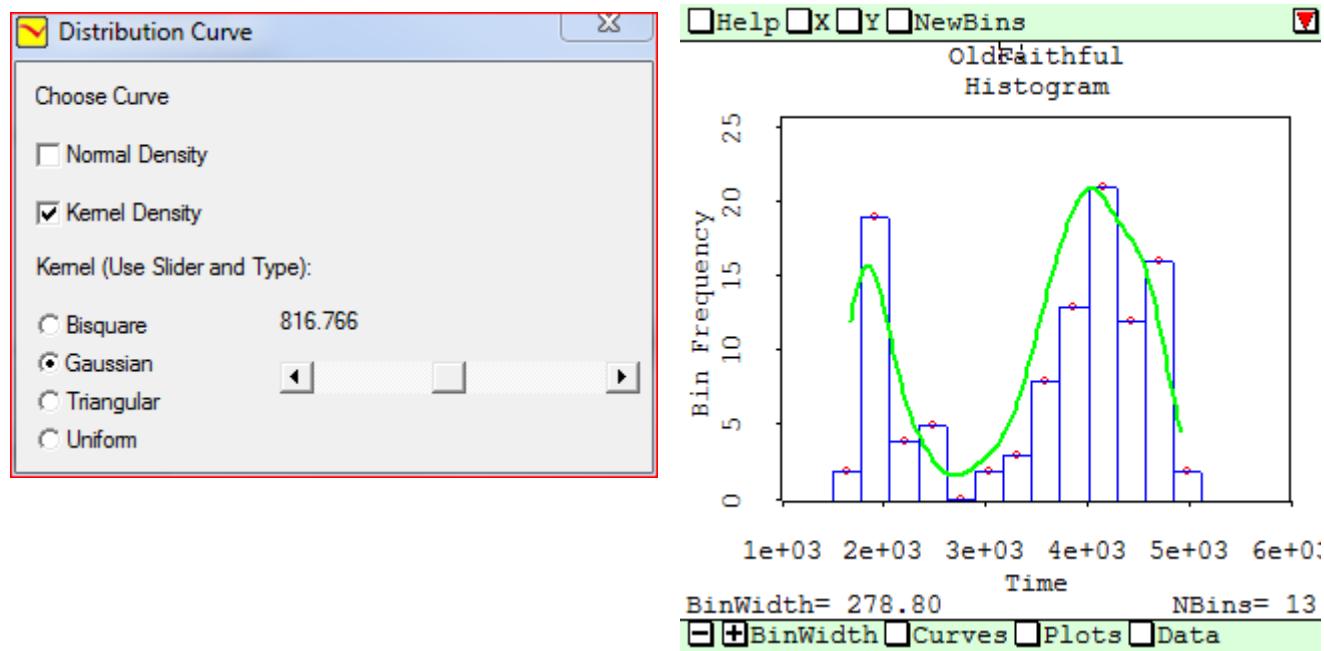
- Estos datos están en Data/general/oldfaith.vdf

El comando Hollow Histogram produce el siguiente histograma

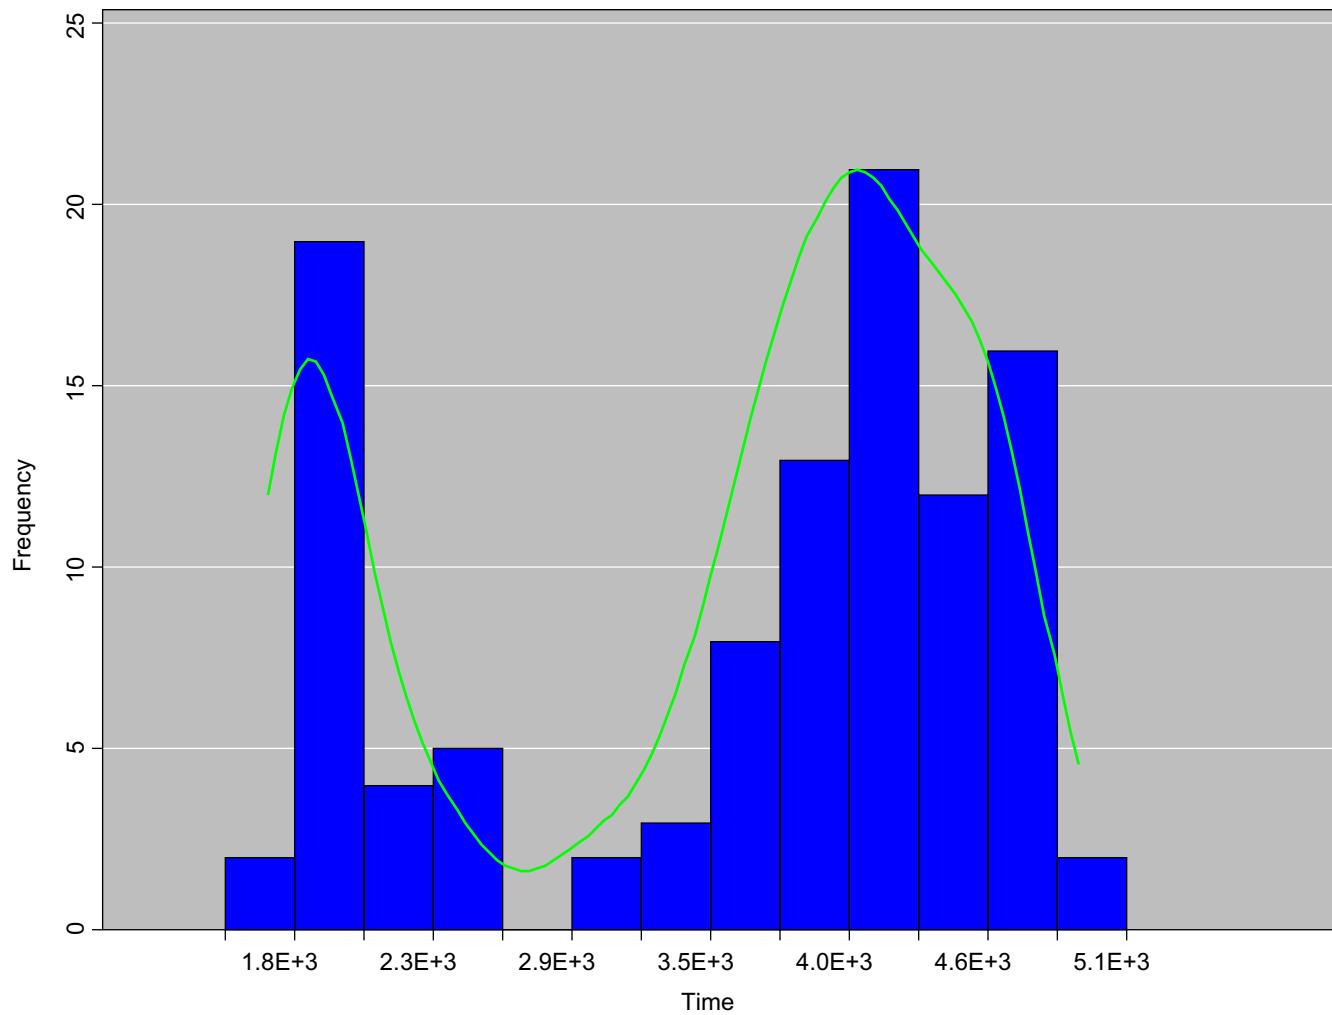


Usando Plots y BinWidth se puede jugar para ver el efecto

- En curvas podemos añadir una curva y con el slider controlar como de suave es el ajuste



- Del resultado podemos crear una figura apta para publicación



# Ejemplo: Bigmac

- En data/regress/bigmac.vdf hay un archivo de datos con precios, salarios y otras variables de capitales del mundo

Si se exploran una por una se puede encontrar que algunas de ellas son unimodales aunque asimétricas y otras son más bien bimodales e incluso trimodales

*Datos numéricos*

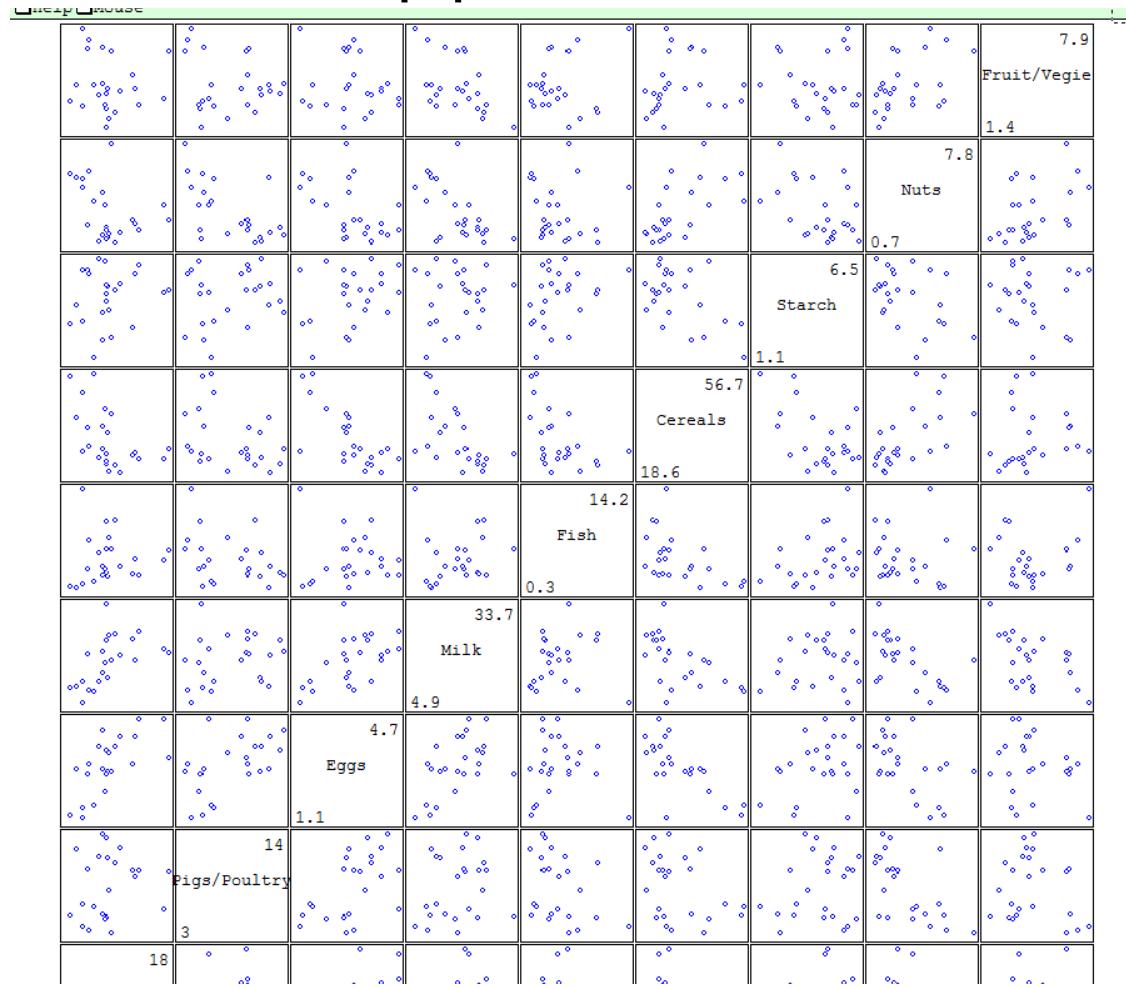
*bivariados*

# Matrices de diagramas de dispersión

- Permiten mostrar todos los diagramas de dispersión simultáneamente
- Es posible identificar valores destacados, relaciones curvilineas, etc.

# Ejemplo: Proteínas en Europa 1970

- Este archivo está en data/corresp/protein.vdf



Sólo utilizaremos las variables de proteinas (Meat hasta Fruit/Vegie)

- ¿Qué países destacan?
- ¿Hay valores extremos?
- Preguntas
  - ¿Qué país consume más dieta mediterranea?
  - ¿Qué país consume peor dieta en total?

*Datos numéricos*

*trivariados*

# Spinplots

- Los gráficos Spinplots permiten visualizar tres dimensiones

Al rotar suavemente, la ilusión de espacio es más fuerte que al estar parados

Cuando se detecta una perspectiva interesante se puede parar

- Algunas rotaciones interesantes

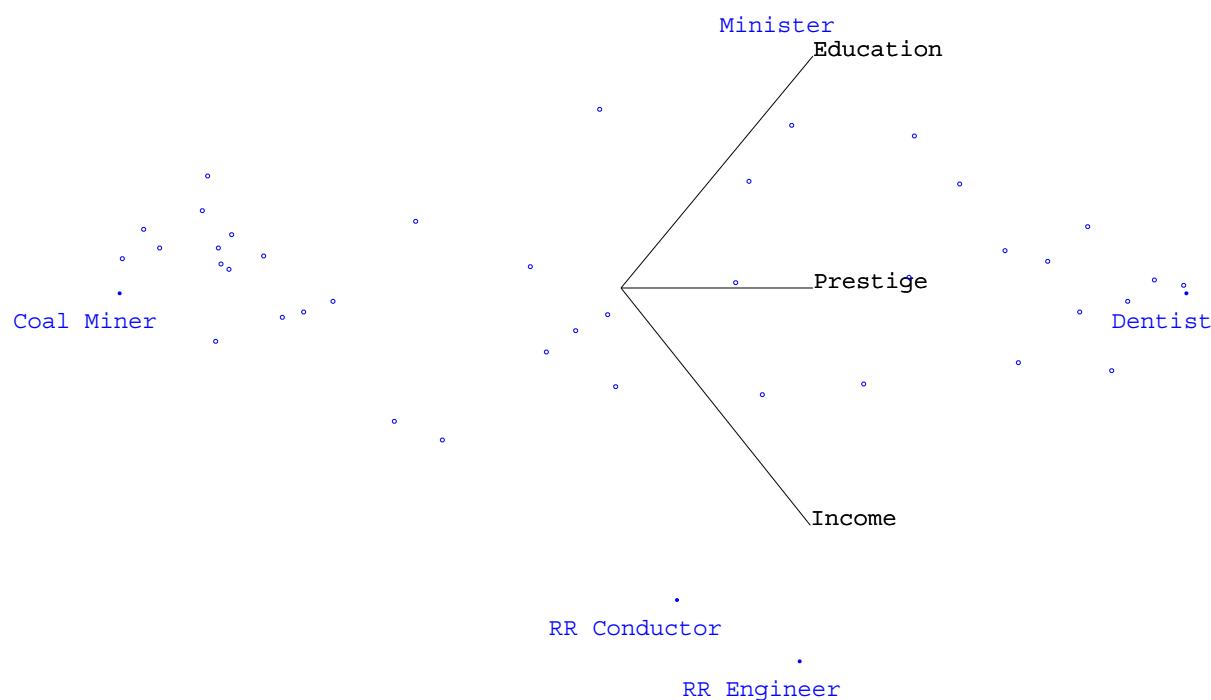
Componentes principales: Rotar para abarcar el máximo de varianza

Regresión: Usando este gráfico es posible estudiar dos predictores

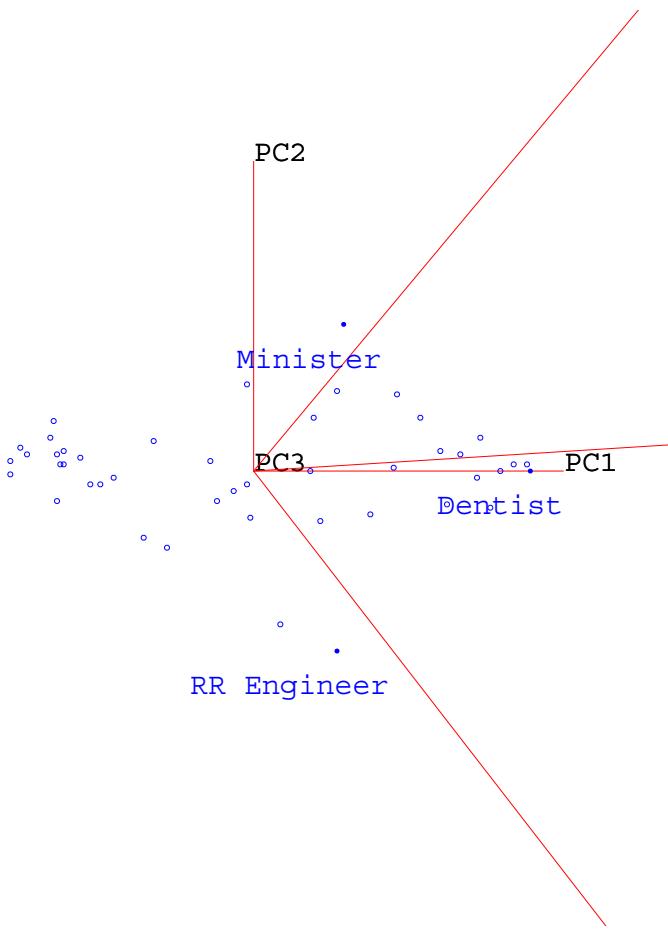
Observar regularidades en las observaciones, valores extraños, etc.

# Ejemplo: Componentes Principales en Jobs

- Rotando el Spinplot para Income, Prestige y Education obtenemos esto

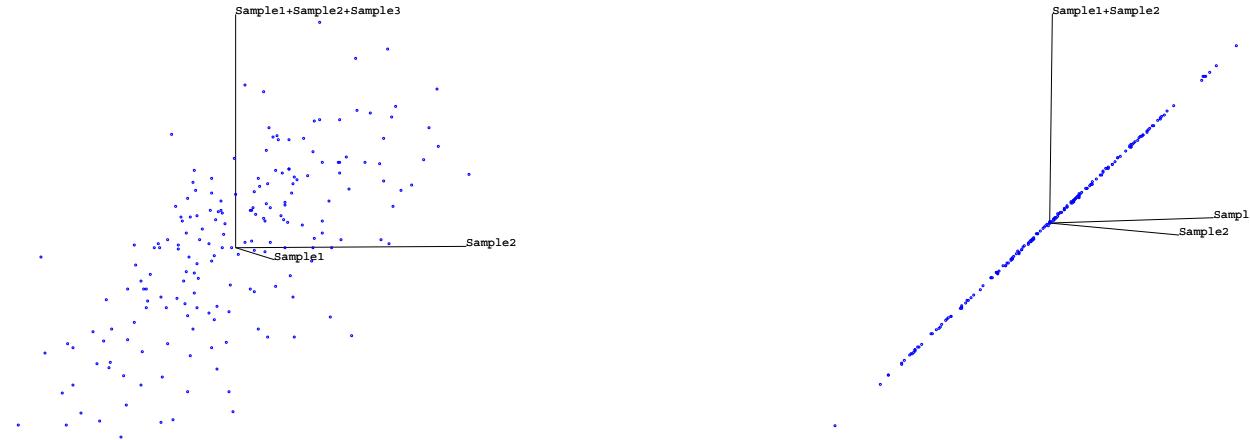


- Haciendo el análisis utilizando el programa de Principal Components de ViSta obtenemos esto



# Regresión

- Usando rotaciones pueden estudiarse la relación de dos variables con una tercera.



Aquí se visualizan dos variables normales aleatorias y la suma de ambas

# Observando regularidades

- En mi página web hay una animación sobre [Randu](#), el generador de números aleatorios que no eran tan aleatorios

Hay una demostración en ViSta que puede obtenerse usando el comando File>Load Edit y buscando el archivo data/general/Randu.vaf

Eso produce una demostración de que en una dimensión o en dos dimensiones el generador no parece problemático pero en tres sí

*Datos numéricos*

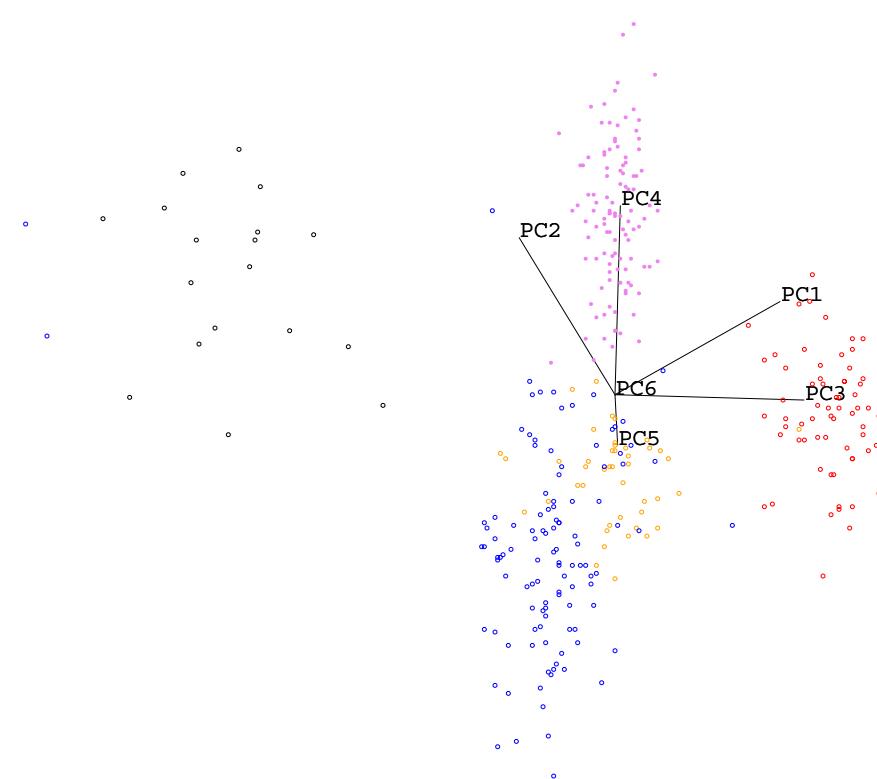
*multivariados*

# Técnicas

- Grand tours
- Componentes Principales, Biplots y Análisis Factorial
- Cluster jerarquico

# Tours

- Un tour es un gráfico en movimiento diseñado para estudiar la distribución conjunta de datos multivariados



- Los tours son creados haciendo una secuencia de proyecciones en dos dimensiones de datos multidimensionales

Esto puede servir para encontrar relaciones que implican muchas variables

La idea es buscar proyecciones que sean interesantes a partir de la visualización de muchas de ellas en una especie de película o animación

Cook and Swayne (2007) y el software que lo acompaña es probablemente la mejor referencia

- Los métodos de búsqueda que hay son:
  - Grand Tours: Los espacios visualizados son elegidos aleatoriamente
  - Projection Pursuit Tour: Las búsquedas están guiadas por un algoritmo que sugiere proyecciones interesantes
  - Busqueda manual: El usuario elige la proyección y permite explorar un espacio cercano a una proyección que parece interesante

- Muchas de las proyecciones obtenidas en los Tours están muy relacionadas con técnicas tradicionales que son vistas de modo numérico:
  - Los biplots hechos a partir de componentes principales
  - Análisis discriminante está conectada con la proyección que mejor separa las medias de los grupos
  - El análisis de correlación canónica y la regresión múltiple multivariada también producen proyecciones interesantes

# Ejemplo: Crimes

- El Tour plot en ViSta utiliza como índice a maximizar uno derivado de los componentes principales
- Utilizando el archivo de datos de crime que está en data/princomp y el orbiting plot podemos ver un tour

Un ejemplo de las cosas que podemos fijarnos es en puntos que se desplazan de una manera diferente a los demás

Hawai es uno de esos puntos

Para interpretar ese punto podemos hacer un diagrama de cajas paralelo y seleccionar Hawai

Podemos ver que Hawai es especial porque los niveles de Asalto son bajos pero los de otros crímenes no

# Componentes Principales y Biplots

- Los componentes principales son proyecciones que muestran donde los datos están más extendidos (mayor varianza)

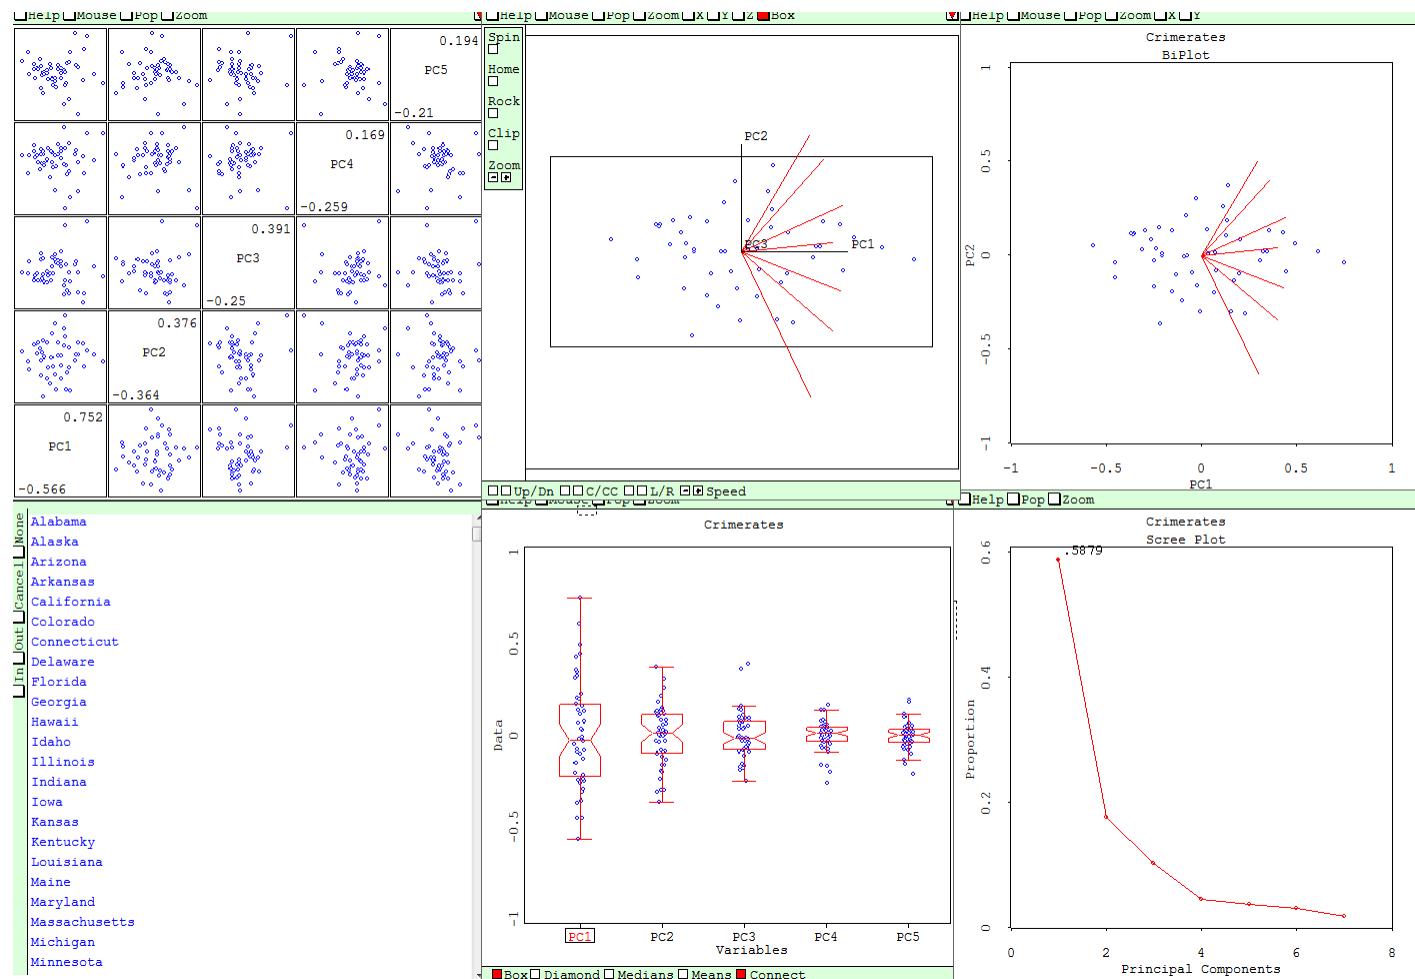
Las proyecciones sucesivas son ortogonales entre sí y buscan donde los residuales respecto de las dimensiones previas están más extendidos

- En ViSta, podemos visualizar los resultados de un análisis de componentes principales en un spreadplot que incluye un biplot

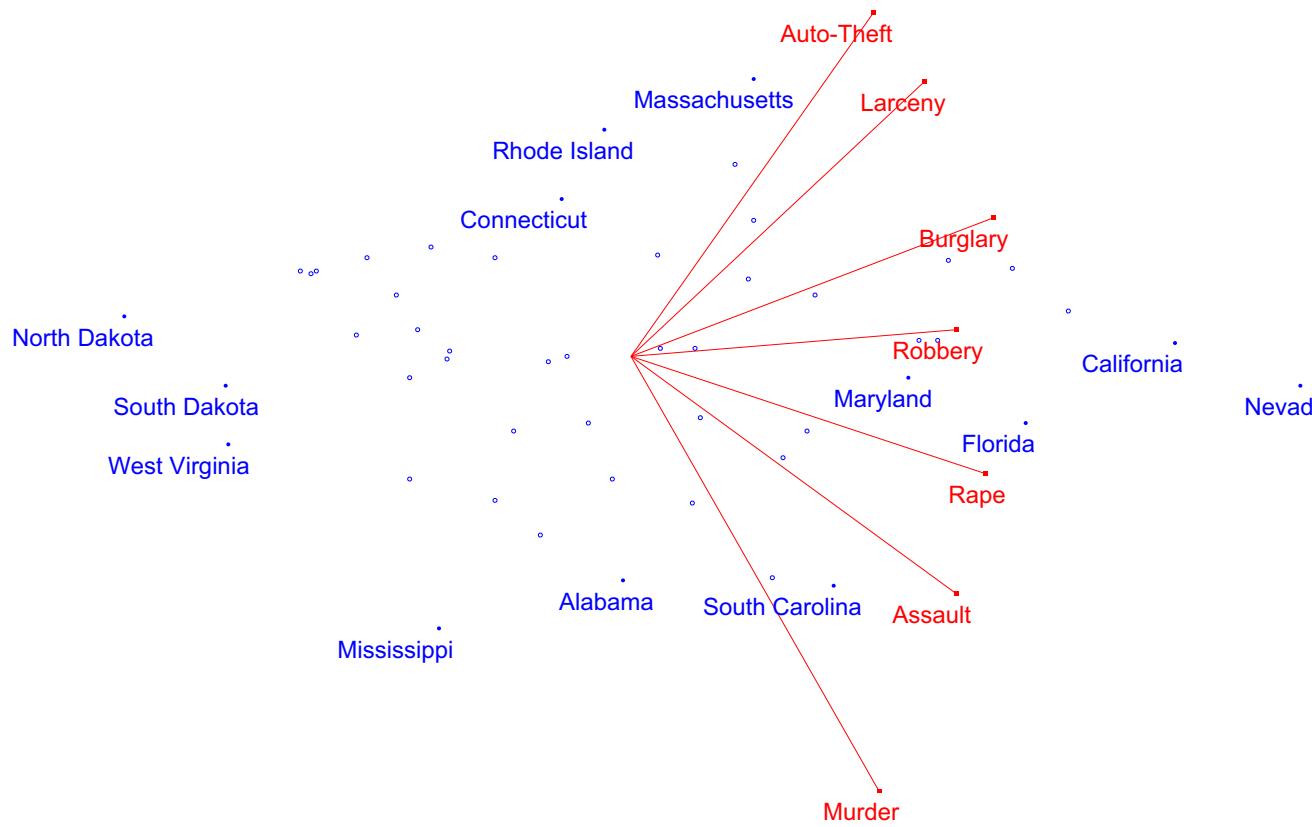
El análisis puede basarse en *correlaciones* (cuando la varianza de las variables está en diferentes escalas) o *covarianzas* (la varianza de las variables está en la misma escala)

# Ejemplo: Crímenes en Estados en USA

- Spreadplot



- **Biplot**

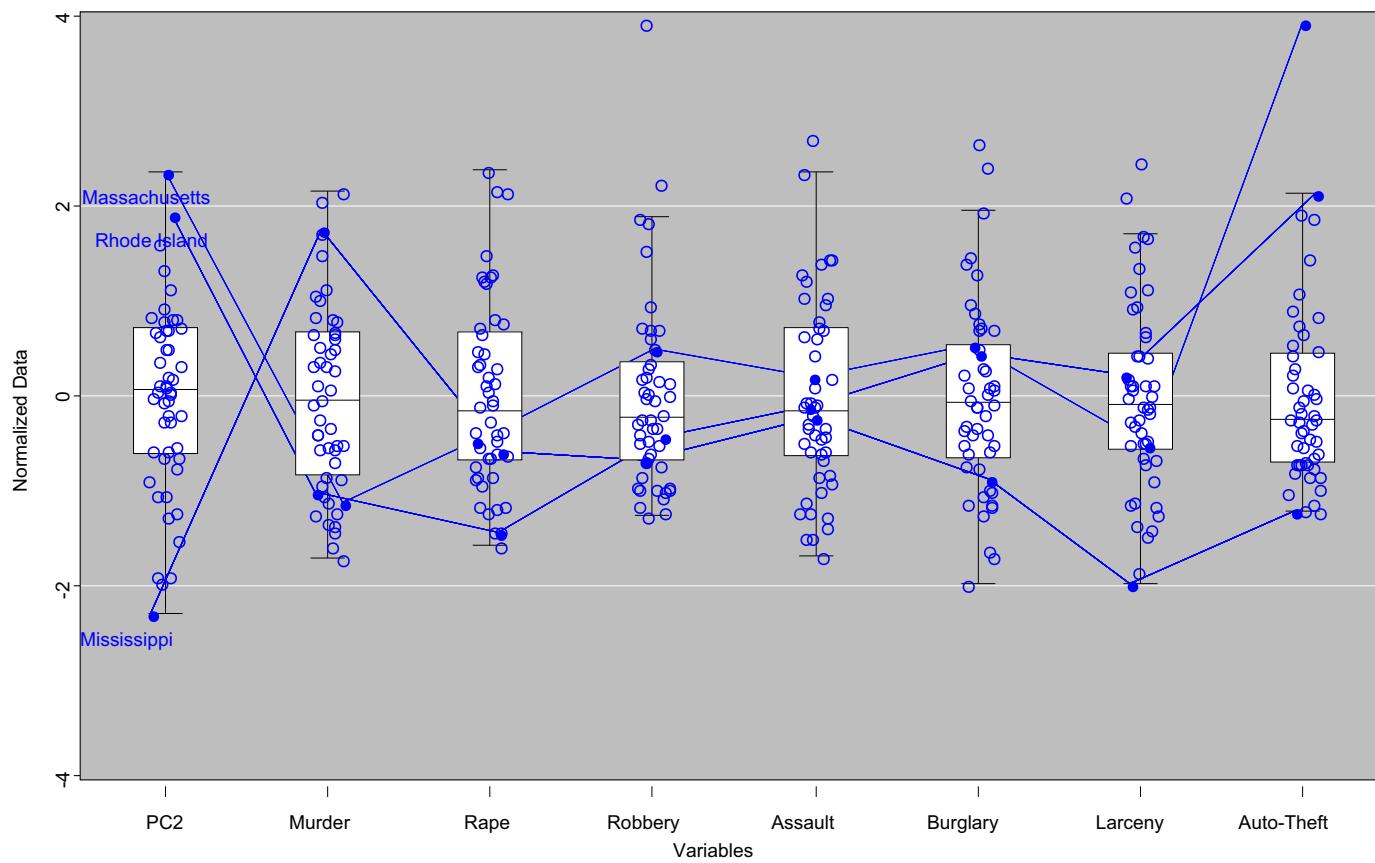


Este es un biplot del primer y el segundo componente principal

Podemos valorar relaciones entre variables y posiciones individuales

- En un Biplot vemos
  - Eigenvalores, proporción de varianza explicada por cada componente y acumulada
  - Eigenvectores: Proyecciones de los vectores de las variables sobre los componentes principales
  - Puntuaciones en los componentes: Es la matriz de puntuaciones en los componentes por la raíz cuadrada de los eigenvalores. La proyección sobre el PC nos da idea de como una observación está explicada por ese PC

- Interpretación



El PC1 está relacionado con volumen, pero el PC2 distingue perfiles de estados (crímenes contra las personas v. crímenes contra la propiedad).

En esta trasparencia se pueden ver un par de casos característicos

# Ejemplo: Proteínas

- Este ejemplo está en data/corresp/protein.vdf.
- Un análisis de componentes principales nos muestra una gran cantidad de detalles de interés

Alimentos que se suelen ir acompañados

Países que destacan en esos alimentos

Valores extremos, etc.

# Cluster jerárquico

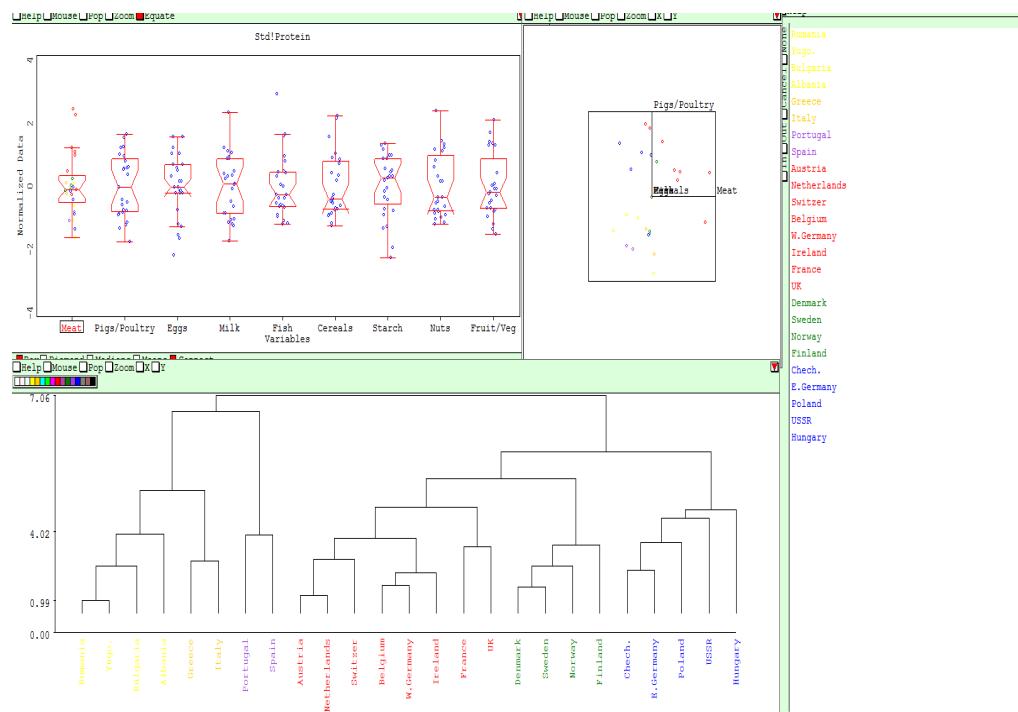
- Podemos analizar los datos de proteínas utilizando dendogramas calculados utilizando el módulo de Cluster jerárquico

Antes de empezar el análisis, pasaremos los variables a puntuaciones z

En la figura siguiente hemos usado distancias euclidianas y linkage completo

Al estar conectado el dendograma con los otros gráficos es posible explorar el significado de los grupos más fácilmente

- Spreadplot para cluster jerárquico



Este ejemplo usa linkage completo y es necesario estandarizar los valores antes  
 El resultado muestra fundamentalmente 4 grupos de países que pueden ser subdivididos posteriormente

Los grupos identificados por colores se pueden grabar como un archivo de datos para hacer análisis posteriores (no cerrar el spreadplot, sólo minimizar)

# Ejemplo: Horas de trabajo, Precios y Sueldos en ciudades

- Los datos están data/cluster/Cities.vdf
- Los datos tienen un par de valores perdidos que se puede utilizar mediante Impute Missing Data en el menú de Data
- A partir del análisis cluster con linkage completo se puede dividir los datos en 6 grupos de ciudades

Explorando los grupos se pueden ver las características que tienen y las diferencias  
También se pueden detectar algunas anomalías

*Datos perdidos*

# El desafío de los datos perdidos multivariados

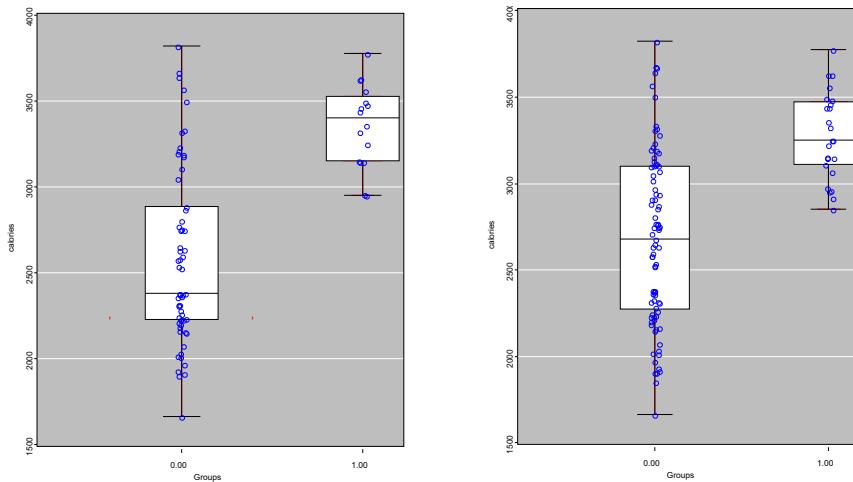
- Cuando hay datos perdidos, los gráficos se encuentran con muchos problemas
  - Diferentes gráficos univariados pueden tener diferentes casos
  - A medida que intentamos representar más variables, el número de casos completos puede disminuir mucho
- Con gráficos ligados, los gráficos pueden ser muy confusos
  - Datos que se iluminan en unos gráficos pero no en otros
  - Conexiones que no son posibles
- MANET tiene gráficos adaptados a esta situación
- En ViSta hay dos aproximaciones a visualizar datos con valores perdidos:
  - Patrones de datos perdidos y valores
  - Visualización después de hacer imputaciones de datos

# Visualización de Patrones de Perdidos

- En principio, una visualización interesante es tratar los valores perdidos/observados como una variable de grupo y comparar los valores en las otras

No obstante, la variable partida también puede tener valores perdidos por lo que siempre existe la duda acerca de si nos estamos perdiendo algo

En los dos gráficos anteriores, se ha clasificado en perdido/observado la variable Litfemale y se visualiza Calorías. En la derecha se han imputado valores (encuentra las diferencias)



# Ejemplo: Mundo95

- Usaremos como ejemplo el archivo de World95 que está en data/missing  
ViSta tiene un spreadplot que está especializado en examinar datos que tienen valores faltantes
- Ese spreadplot está enfocado a ver los *patrones de datos faltantes*  
Los datos faltantes en una variable a menudo no vienen solos  
Hay varias variables que coinciden en tener los mismos valores faltantes  
Conocer su asociación puede ser de gran interés para entender los problemas que hay en ellos

- El spreadplot para valores faltantes tiene este aspecto

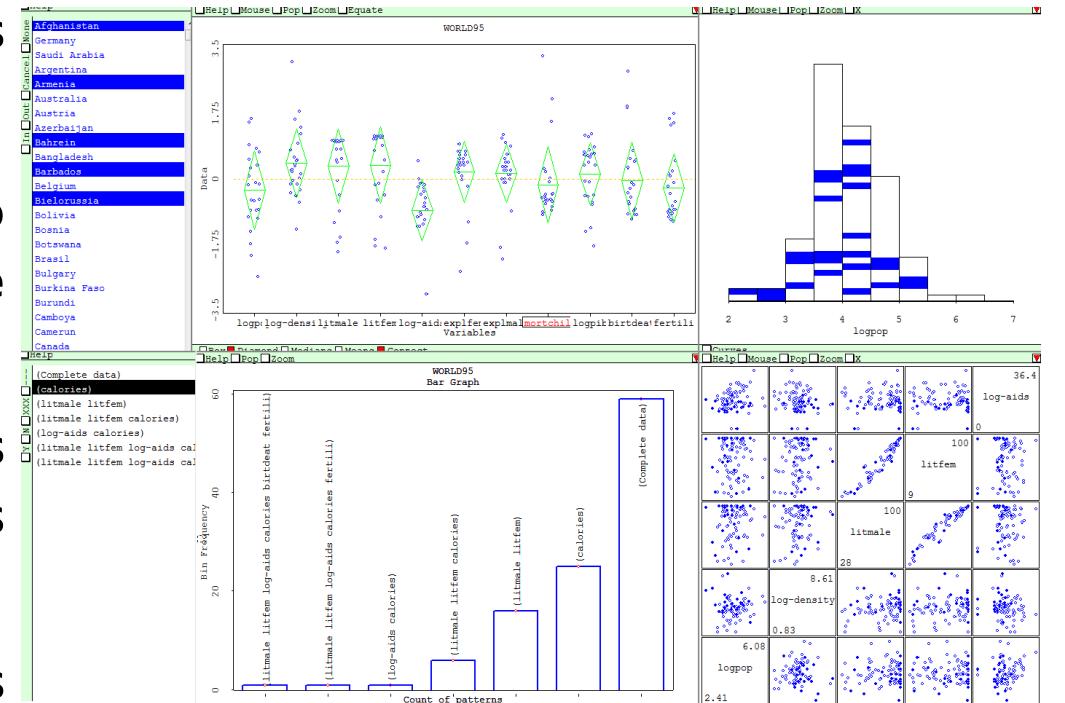
Hay que entender que cada gráfico intenta mostrar el máximo de información disponible en cada caso

El gráfico de puntos paralelos muestra todos los valores observados para el patrón de datos seleccionado

El histograma muestra todos los datos observados de la variable mostrada, y cuando se selecciona el patrón se ilumina mostrando los valores observados

La matriz de diagramas de dispersión muestra todos los valores observados en las variables mostradas en él en ese momento

- En este ejemplo, es fácil ver que el patrón Litmale Litfemale está asociado con valores concretos de las variables



# Imputando los datos

- Imputar datos con valores razonables tiene muchas ventajas desde el punto de vista de la visualización

Los gráficos vuelven a ser completos

Se puede tener una idea de qué valores estaban perdidos

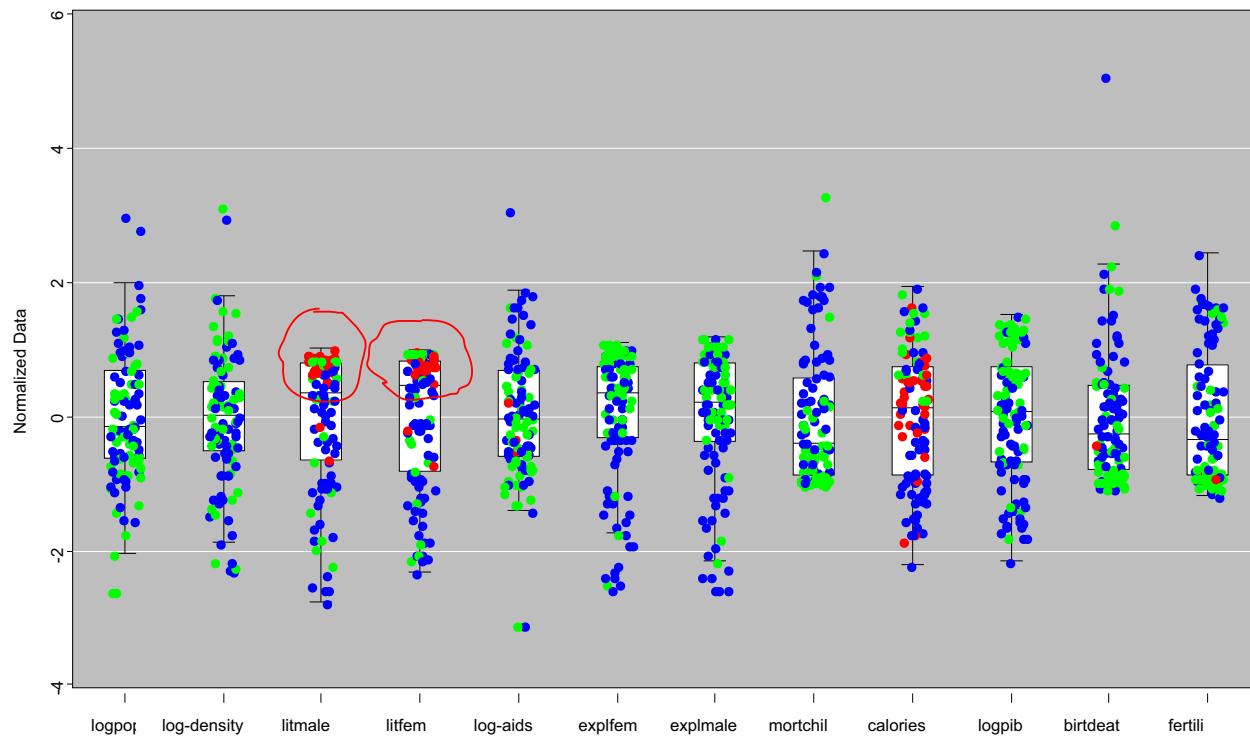
- También tiene sus inconvenientes

Técnicamente, imputar valores razonables puede ser costoso

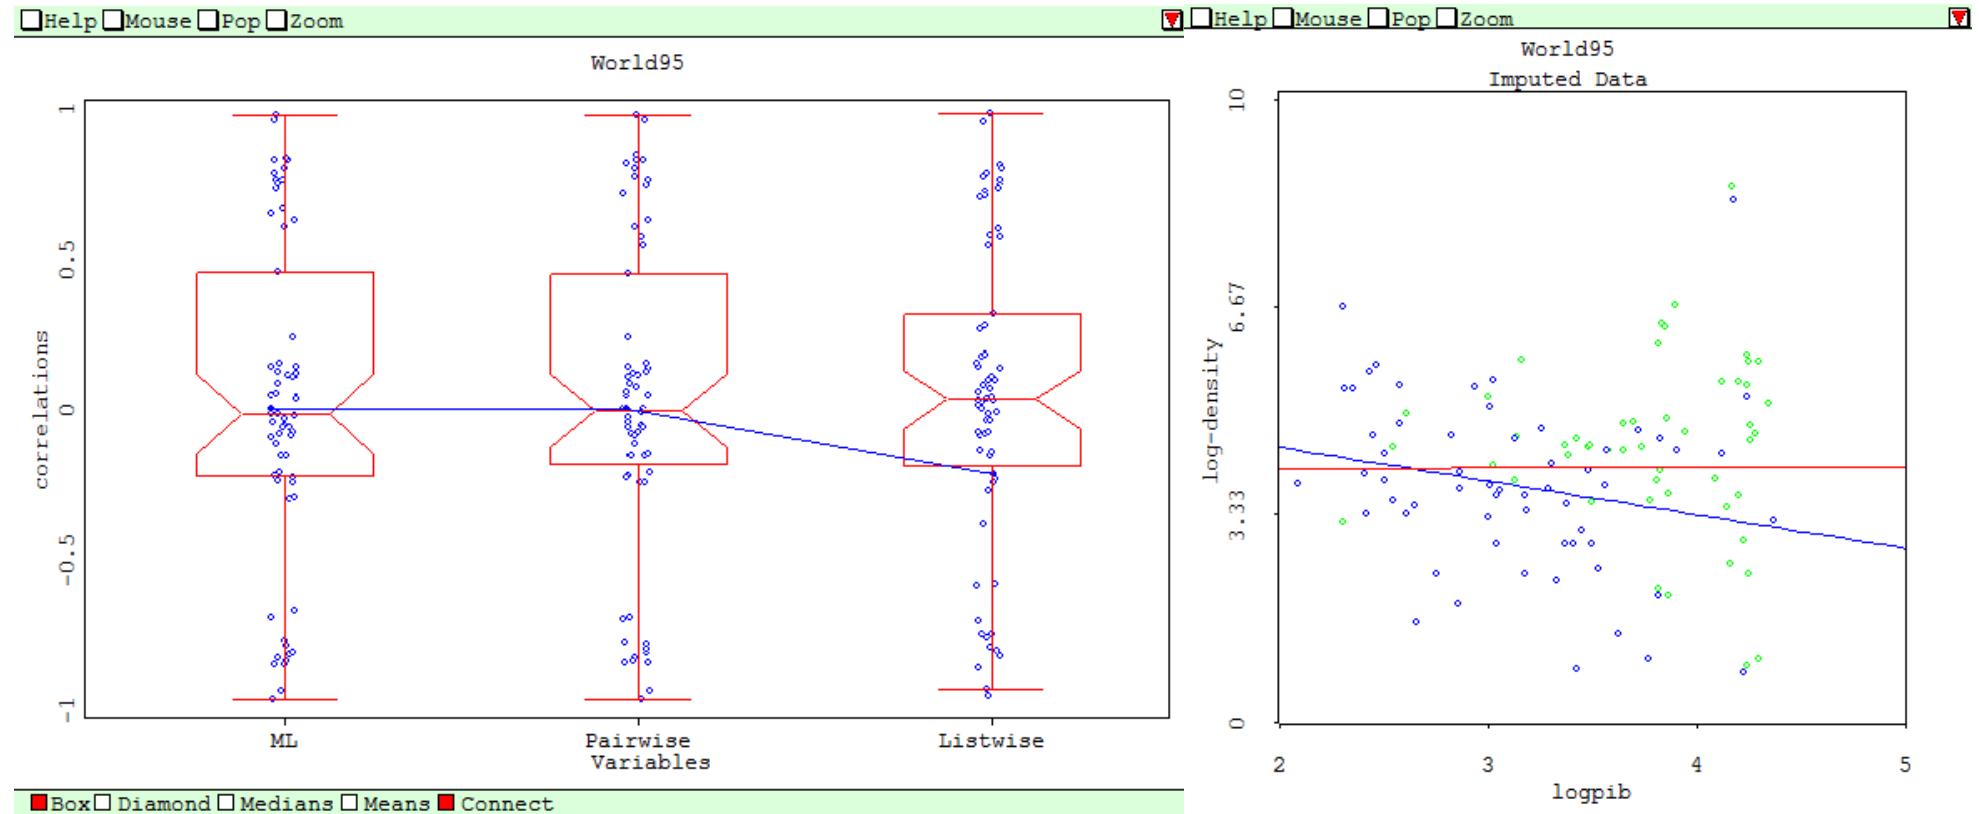
- Seleccionar el método
- Cumplir los supuestos (si se utiliza un método basado en predicciones lineales)
- El coste computacional puede ser excesivo

# Ejemplo: World95

- El comando **Impute Missing Data** en el menú **Data** usa el algoritmo EM basado en mínimos cuadrados para estimar medias y correlaciones entre las variables. A partir de ese resultado se puede hacer imputación simple y visualizar



- Otro aspecto interesante es examinar si hay variaciones en las correlaciones



Grandes diferencias entre las correlaciones nos alertan de lugares en los que los datos perdidos han causado mayores estragos

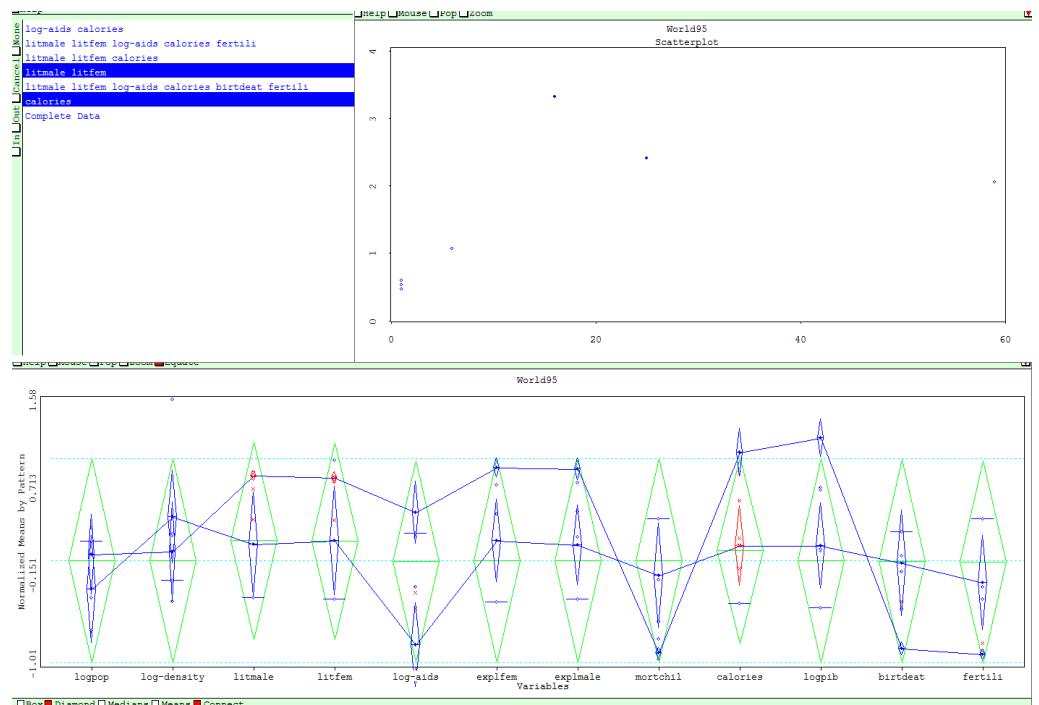
Un ejemplo muy llamativo es el de data/missing/marijuana.vdf

- El boxplot de puntos se puede simplificar para mostrar solamente la información por patrones

- El gráfico de arriba derecha está basado en el test de MCAR de Little

Ese test compara las diferencias entre las medias observadas y las medias estimadas por max. verosimilitud por patrón y las suma

El gráfico de arriba muestra las diferencias por patrón de datos perdidos y sirven de indicador de como los valores perdidos en un patrón están asociados con los valores observados en otras variables, y, al imputar, las medias estimadas son diferentes de las observadas



# Ejemplo: Titanic

- Este ejemplo está en data/missing/titanic2.vdf

En estos datos se muestran datos acerca de la supervivencia del titanic

La variable Edad falta en muchos de los datos

Una visualización muestra que Edad está asociado con no viajar en primera o segunda clase

Imputar los datos y hacer el gráfico de patrones (send current-model :visualize-patterns) muestra este resultado bastante claramente

*Escalamiento  
multidimensional*

# Recuperando posiciones a partir de distancias

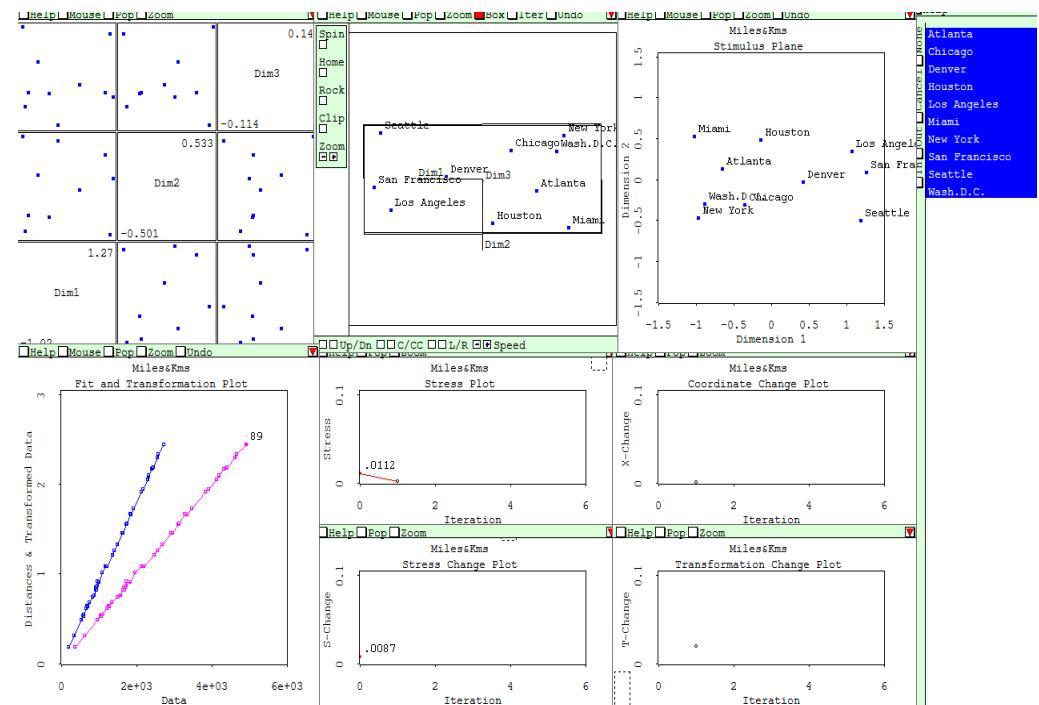
- ViSta tiene dos módulos sobre escalamiento multidimensional:
  - MDS promediado métrico es apropiado para distancias métricas e ignora cuando hay varias matrices de distancias (las promedia)
  - Multidimensional scaling: Admite distancias ordinales entre los objetos así como puede utilizar diferentes matrices siempre y cuando sean simétricas (hay programas que sí lo aceptan)  
Este módulo además ajusta distancias y no distancias al cuadrado (como hacían algunos programas más antiguos)

# Ejemplo: Distancias entre ciudades

- Se trata de las distancias en kilómetros y en millas entre ciudades en USA

Son dos matrices simétricas y equivalentes (transformación lineal)

- El gráfico de transformaciones muestra que la transformación de las distancias originales es lineal y semejante
- El mapa no obstante aparece girado, usando el Spin plot se puede poner de la manera correcta



# Ejemplo: Explorando la posición de los colores

- Se trata de juicios acerca de la similaridad de unos colores
- Utilizando el comando de **Metric Averaged MDS...** se aplica este método
  - A continuación se puede aplicar un número de iteraciones
  - Se pueden mover puntos para comprobar su efecto sobre el stress

# *Apéndices*

# Importando datos

- ViSta importa datos de texto

Variables separadas por tabuladores

Casos separados por retornos de carro

La primera columna puede ser de etiquetas

Valores perdidos se identifican con nil

ViSta puede importar también datos agrupados y datos de similaridades

Usar puntos para decimales. No usar separadores de miles

- En la carpeta Data/Import hay una serie de ejemplos que pueden ser imitados en caso de que haya problemas

Leer también el documento Import\_wisdom.txt

# Guardar gráficos en formato vectorial

- ViSta no es un buen programa para crear gráficos para presentación pero a veces crear los gráficos en otros programas sería costoso así que es interesante hacerlo en ViSta
  - Muchos gráficos tienen un comando de **Save Plot as...** en el menú de la derecha (marcado con un triángulo)
  - Ese menú abre un cuadro de diálogo. Se pone un nombre y el archivo se guarda en formato .pdf y dibujado vectorialmente  
El resultado es una interpretación del gráfico, no es una versión literal en todos los aspectos
- Si se desea, se pueden manipular estos gráficos utilizando un programa de dibujo vectorial:
  - Inkscape parece que funciona bien pero Draw de OpenOffice hace un desastre
  - El programa PDF Reader (no Acrobat) permite guardar como WMF para Word

- **Ejemplos de gráficos**

## Apartado de figuras de la página sobre el libro