

# I. Métodos Estadísticos y Construcción de Modelos

---

DR. FRANCISCO RABADÁN PÉREZ  
ESTADÍSTICA SUPERIOR

# Índice

---



[pacorabadan.com](http://pacorabadan.com)

1. Definición AMV
2. Objetivos AMV.
3. Estructura
4. Software (Data Mining y lenguajes)
5. Conceptos previos:
  1. Valor teórico
  2. Principios de Validez y Fiabilidad.
  3. Error de medida
  4. Significación vs. Potencia
  5. P-valor
6. Selección de la técnica AMV (Hair)

# I.1. El análisis de datos multivariante

---

AMV es necesario para describir/comprender una realidad compleja.

**Definición amplia:** Todos los métodos estadísticos que analizan simultáneamente varias variables para cada individuo u objeto de investigación (Hair,p.5)

**Definición estricta:** las variables deben ser aleatorias y estar interrelacionadas de tal forma que sus diferentes efectos no puedan ser interpretados separadamente con algún sentido (Hair, p.5)

# I.1. El análisis de datos multivariante

## Objetivos AMV

Resumir

Identidad

Clasificar

Relaciones

AMV: estudio estadístico de multitud de variables medidas en elementos de una población con los siguientes **objetivos** (Peña, p.2):

- **Resumir datos** mediante un pequeño conjunto de nuevas variables (Parsimonia).
- **Identidad**: Encontrar grupos homogéneos, si existen.
- **Clasificar** nuevas observaciones (inferencia)
- **“Causalidad”-interacción**: Relacionar conjuntos de variables

# I.1. El análisis de datos multivariante

## Objetivos AMV

Se busca simplificar la descripción con pocas variables indicadoras.

Resumir

Ventajas:

- Representación gráfica
- Comparar conjuntos de datos
- Comparar en distintos instantes de tiempo.
- Mejorar nuestro conocimiento/comprensión de la realidad.

Identidad

Clasificar

relaciones

# I.1. El análisis de datos multivariante

## Objetivos AMV

Resumir

Identidad

Clasificar

Causalidad

## Fases en el examen de datos

1. Análisis gráfico
2. Identificación y evaluación de **valores perdidos** (*missing values*).
3. Identificación y tratamiento de los **valores atípicos** (*outliers*).
4. Verificar si se cumplen las **hipótesis exigidas** por la técnica multivariante.
5. **Comprensión preliminar** primera descripción de los datos y del comportamiento de las variables observadas.

# I.1. El análisis de datos multivariante

## Objetivos AMV

Resumir

Identidad

Clasificar

Relaciones

- Tipos de variables resumen:
  - **Variables latentes:** explican el comportamiento de un conjunto de variables observadas.
  - **De pertenencia:** asignan un caso a un grupo.
  - **Proxy:** Variable observada que representa a un conjunto de variables con un comportamiento similar.
  - **Índices:** Construidas “a priori” sobre una conjunto de variables para comparar / explicar su evolución.

# I.1. El análisis de datos multivariante

## Objetivos AMV

Resumir

Identidad

Clasificar

Relaciones

- **Identidad** : Esperamos que existan individuos/casos lo suficientemente parecidos como para formar grupos con características homogéneas que a su vez se diferencien del resto.
- Construiremos tipologías.

# I.1. El análisis de datos multivariante

## Objetivos AMV

Resumir

Identidad

Clasificar

Relaciones

Cuando aumenta el espacio muestral y queremos juzgar a que grupos pre-existentes pertenecen los nuevos casos.

Ejemplo: riesgo de cobro con nuevos clientes, perfiles de comportamiento, nichos de mercado,...

# I.1. El análisis de datos multivariante

## Objetivos AMV

Resumir

Identidad

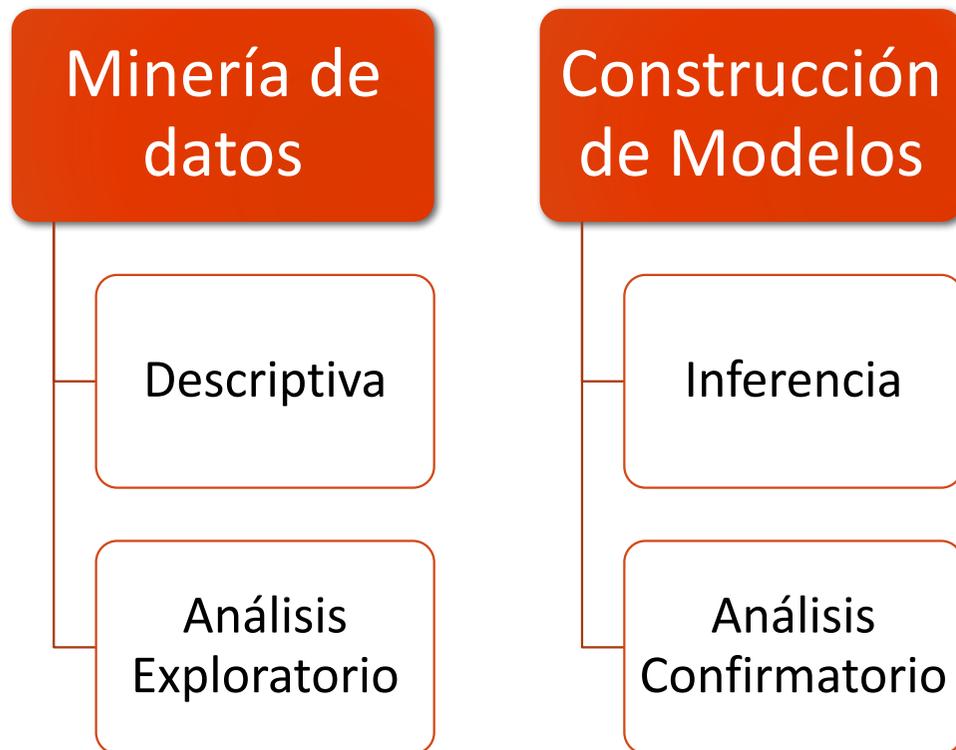
Clasificar

Relaciones

Relacionar conjuntos de variables.

- Ej: capacidades intelectuales vs. resultados profesionales.
- Objetivo: descubrir nuevas dimensiones (latentes) en la relación de grupos de variables.
- También podemos comparar el mismo grupo de variables en distintos momentos del tiempo.

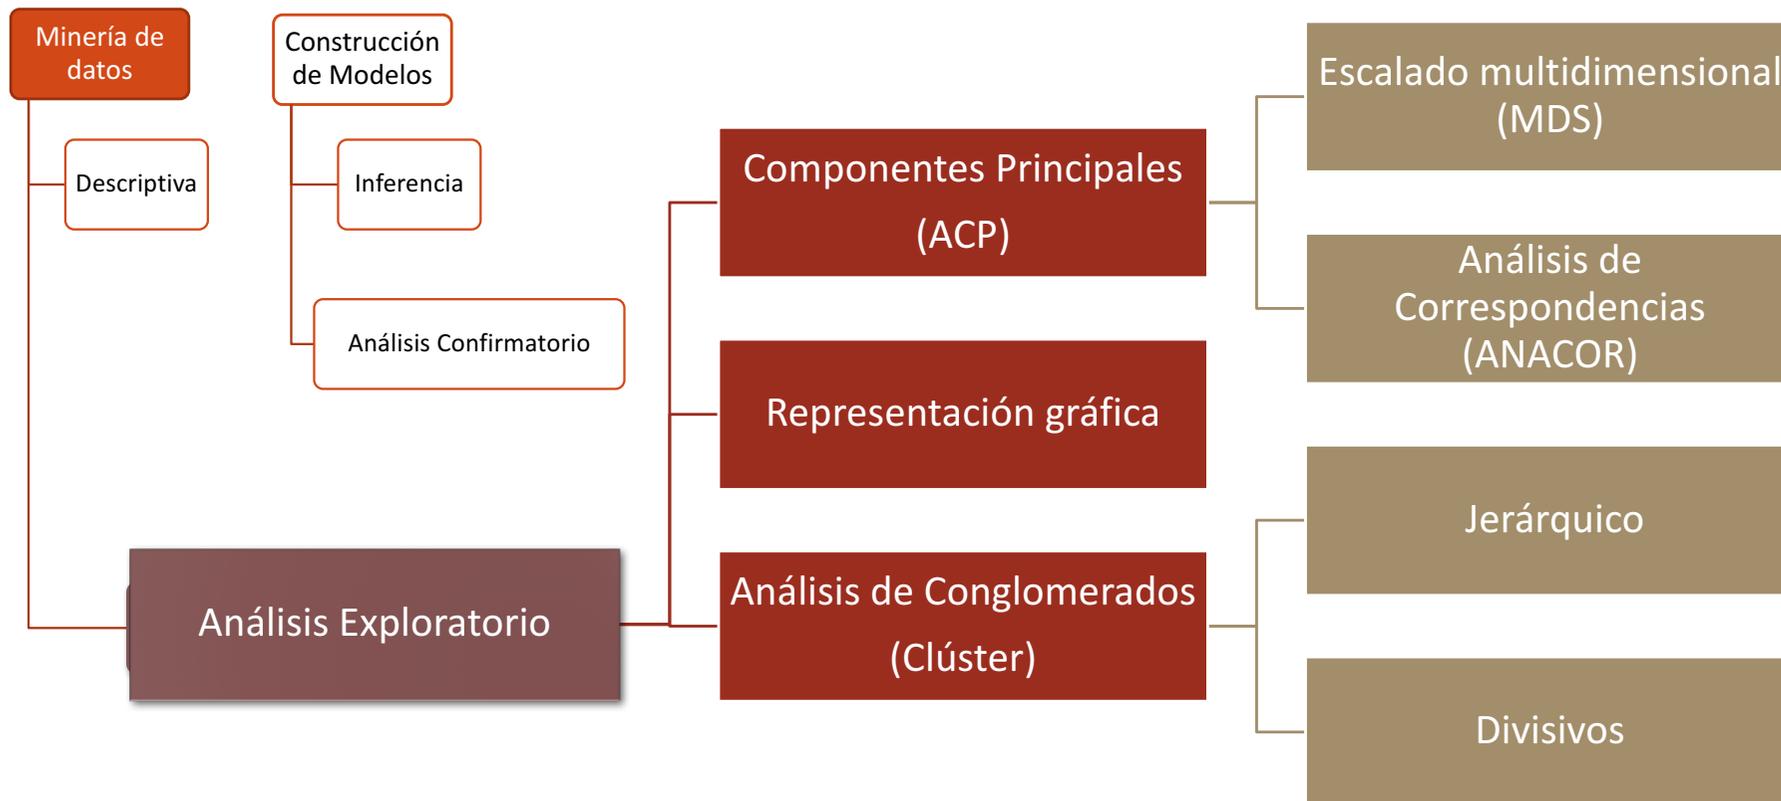
## I.2. Estructura



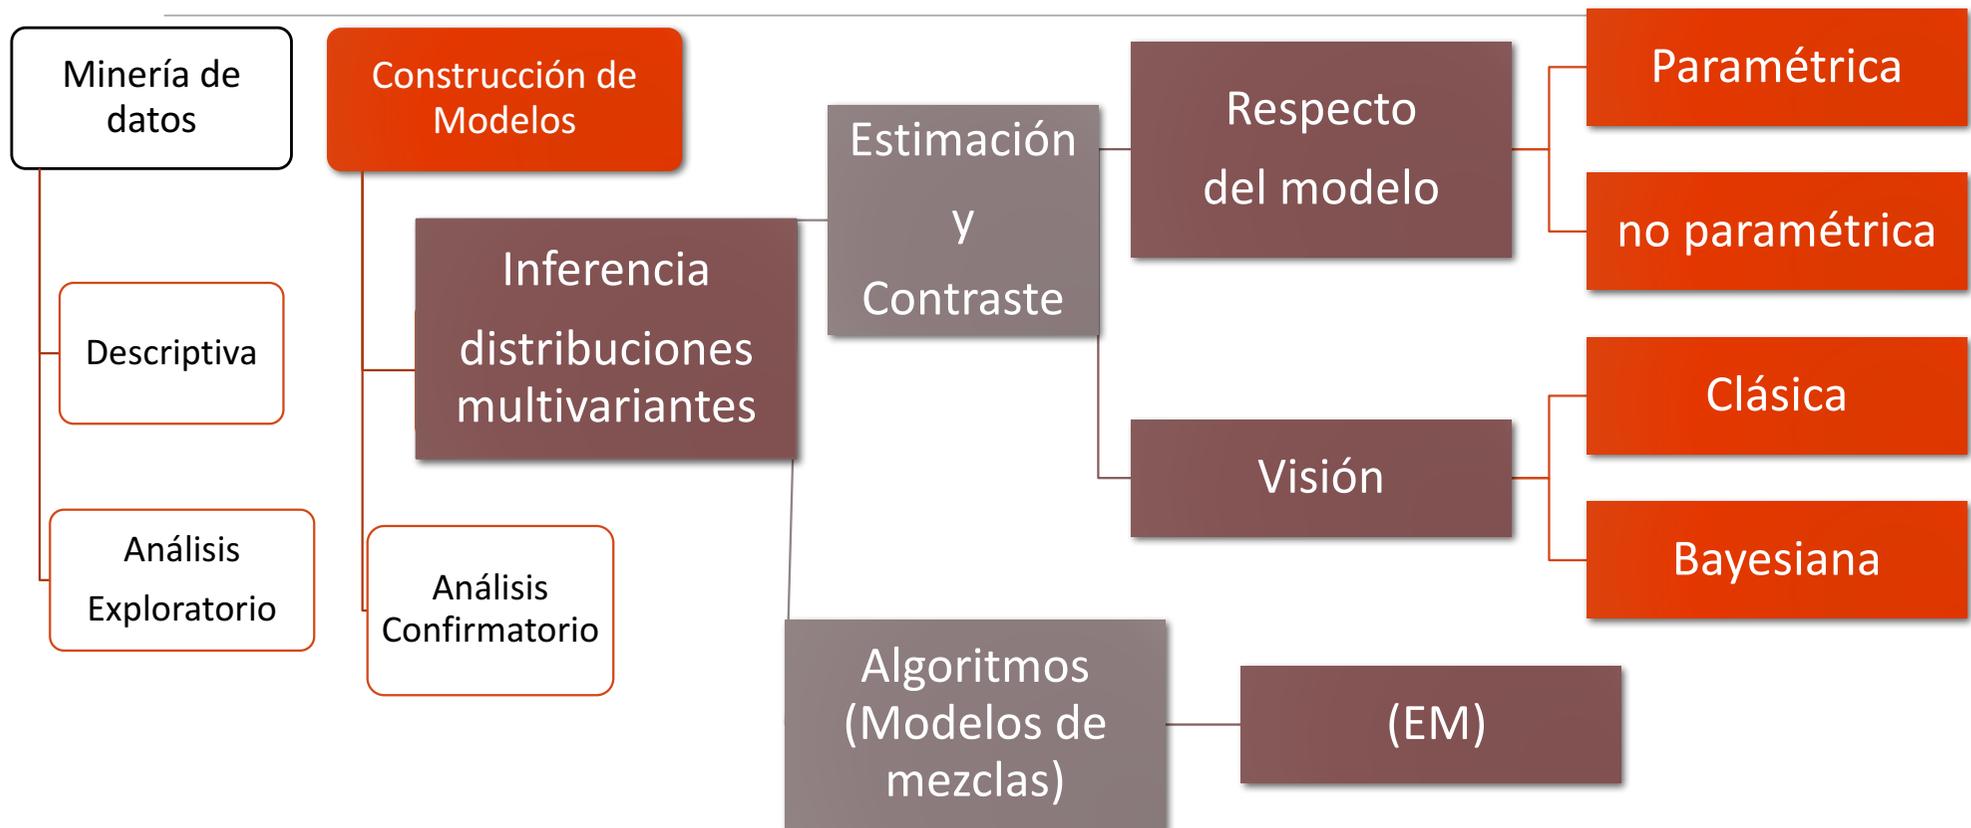
De la tabla multidimensional al algebra matricial:

- proyección ortogonal/oblicua,
- MCO,
- MCP...

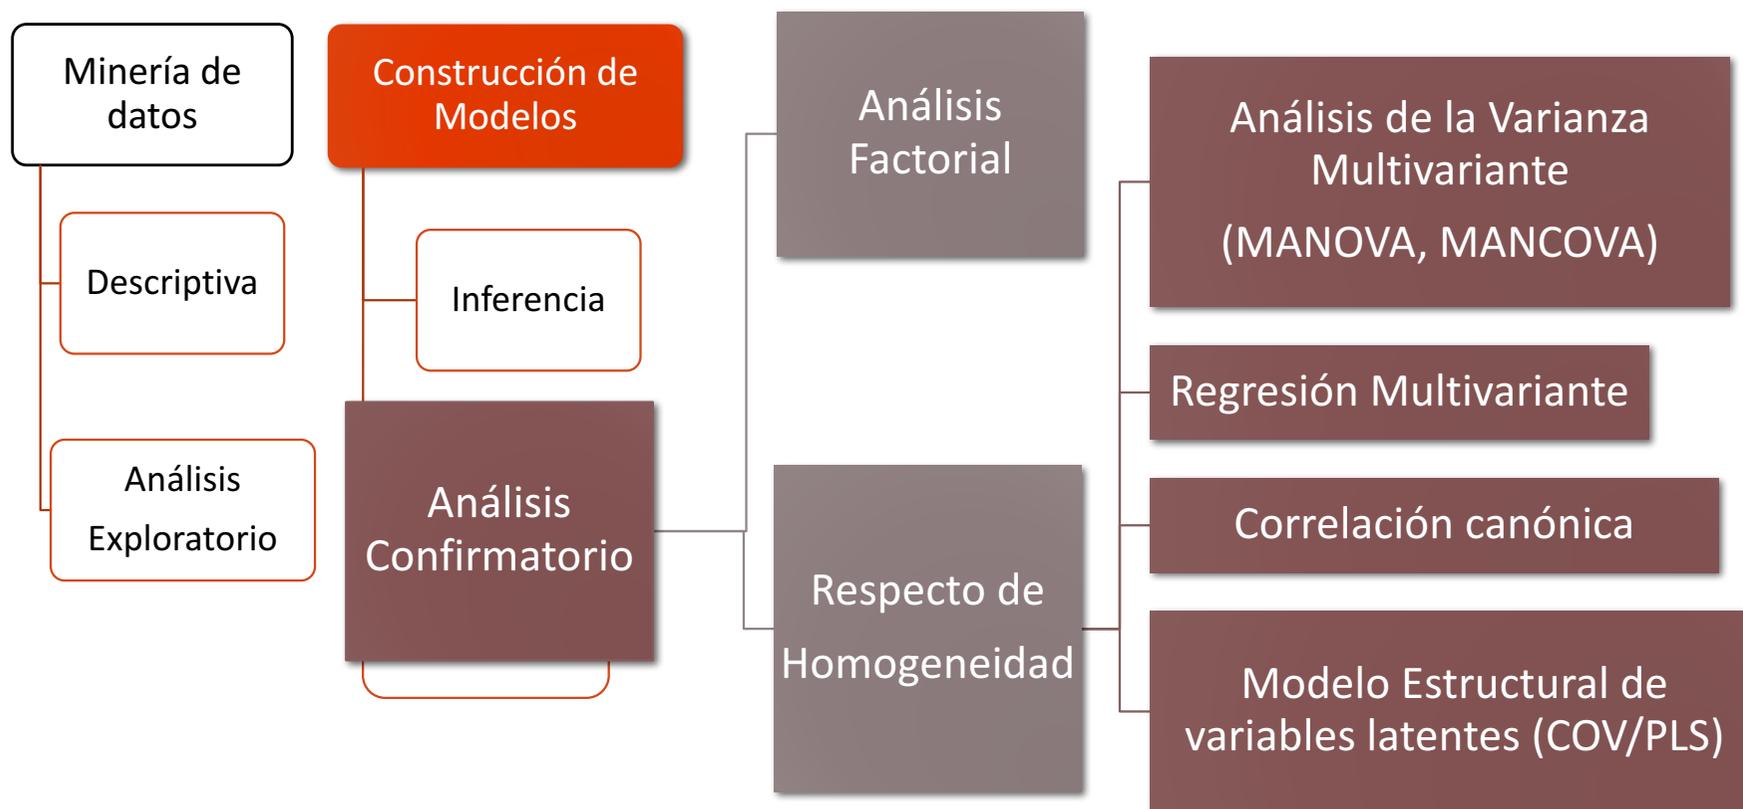
## I.2. Estructura



## I.2. Estructura



## I.2. Estructura



## I.2. Estructura

Objetivos	Descriptiva	Inferencia
Resumir datos	Descripción de datos	Construcción de Modelos
Obtener indicadores	<ul style="list-style-type: none"> <li>Componentes Principales (ACP)</li> <li>Escalado Multidimensional</li> <li>Análisis de Correspondencias (ANACOR)</li> </ul>	Análisis Factorial (AF)
Clasificar	Análisis de conglomerados (Clúster)	Análisis Discriminante
Agrupar	Análisis de conglomerados	Clasificación con mezclas
Relacionar variables	<ul style="list-style-type: none"> <li>Correlación, Contingencia</li> <li>Regresión Múltiple</li> </ul>	<ul style="list-style-type: none"> <li>Correlación Canónica</li> <li>Ecuaciones Estructurales (COV/PLS)</li> </ul>

Fuente: Peña

## I.3. Software

Objetivos	Público Objetivo	Licencia	Interface/ Programación
SPSS	Ciencias Sociales	Privativa	Interface
STATA	Empresa	Privativa	Interface
SAS	Empresa	Privativa/gratuita	Programación
R	General e Investigación	Open Source	Programación
Rstudio	Empresas/general	Privativa / Open Source	Programación
RKward	General	Open Source	Interface
Smart PLS	Investigación/Empresa Ecuaciones Estructurales	Privativa	Interface
Matlab	Científicos e investigadores	Privativa	Lenguaje de alto nivel
Mathematica Wolfram	Matemáticos e investigadores	Privativa	Lenguaje de alto nivel
Orange 3 / Python	General y Data Mining	Free / comercial	Gui/python

## I.4. AMV: Valor teórico

Combinación lineal de variables con ponderaciones determinadas empíricamente (Hair)

$$VT = \sum_{i=1}^n w_i x_i = \hat{y}_j$$

- $X$  : Variables observadas
- $w_i$ : ponderaciones AMV
- $Y$ : Variables dependientes

- **Significado:** valor único que mejor se adapta al objeto de nuestra investigación.
  - **Regresión Múltiple:**  $Y$  guarda la mejor correlación con  $X$
  - **Discriminante:**  $Y$  busca maximizar las diferencias entre grupos.
  - **Factorial:**  $Y$  representa mejor la dimensionalidad

## 1.4. Error de medida

Validez

- Grado en que la medida representa con precisión lo que se supone que representa
- = "Precisión en la definición de la variable" + "pregunta correcta en cuestionario"

Fiabilidad

- CN: Validez
- Grado en que la variable observada mide el valor verdadero y está libre de error
- Estadísticos consistentes:  $\Delta$  nº experimentos  $\rightarrow$   $\Delta$  regularidad estadística

## 1.4. Error de medida

---

Grado en que los valores observados no son representativos de los valores verdaderos.

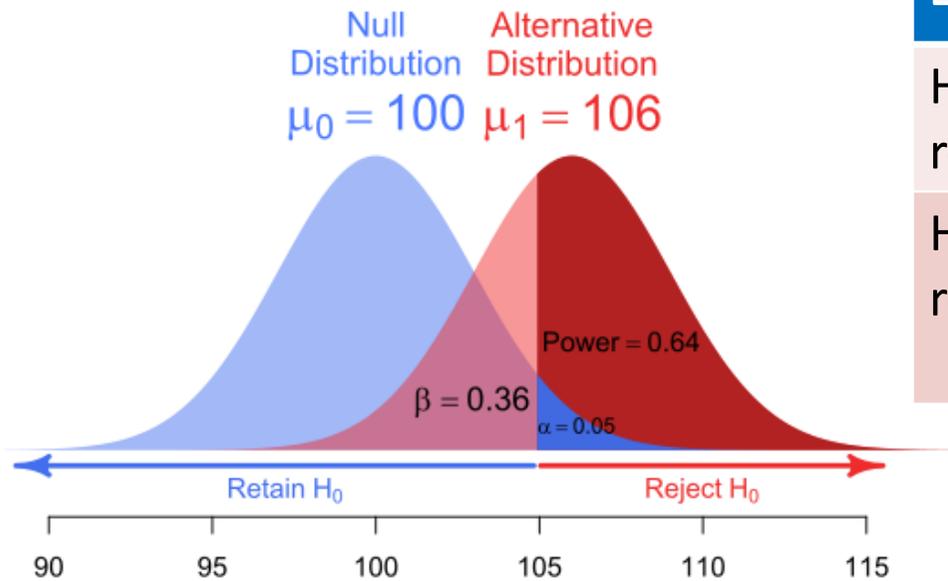
Hipótesis: todas las variables tienen observaciones con errores de medida

Causas:

- Imprecisión en el proceso de medida
- Mal diseño cuestionario
- Incapacidad del encuestado para contestar adecuadamente

Efecto: debilita las relaciones entre las variables

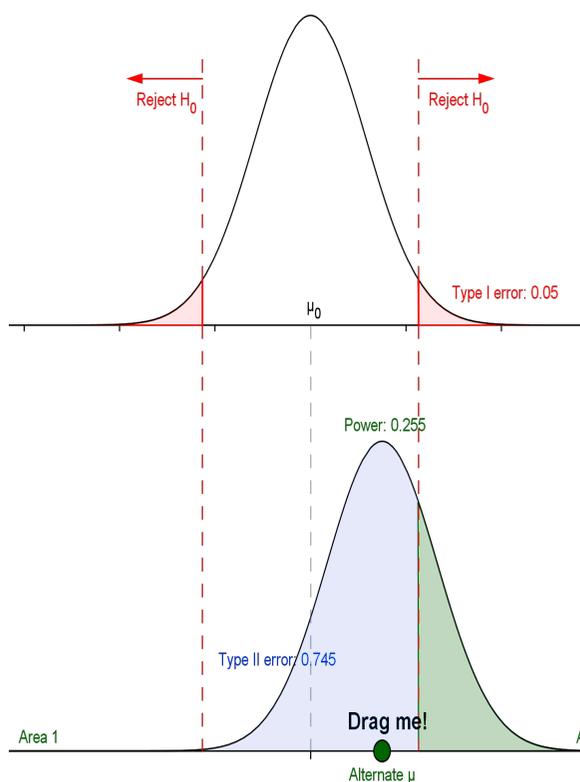
# I.4. Significación estadística vs. Potencia del contraste



Decisión Estadística	Realidad	
	$H_0$ : cierta	$H_0$ : falsa
$H_0$ : No rechazar	$\gamma = 1 - \alpha$ nivel de confianza	$\beta$ (error tipo II)
$H_0$ : rechazar	$\alpha$ (error tipo I)	$1 - \beta$ (potencia)

$1 - \beta$ : dicta la probabilidad de éxito en la búsqueda de las diferencias, si es que existen realmente

## I.4. Factores que influyen en la potencia



### Efecto Tamaño

- Diferencia entre hipótesis alternativas
- Se basa en la correlación efectiva

### Nivel de Significación

- $\nabla \alpha \rightarrow \nabla (1 - \beta)$
- Se reduce la posibilidad de encontrar un efecto negativo significativo

### Tamaño muestral (n)

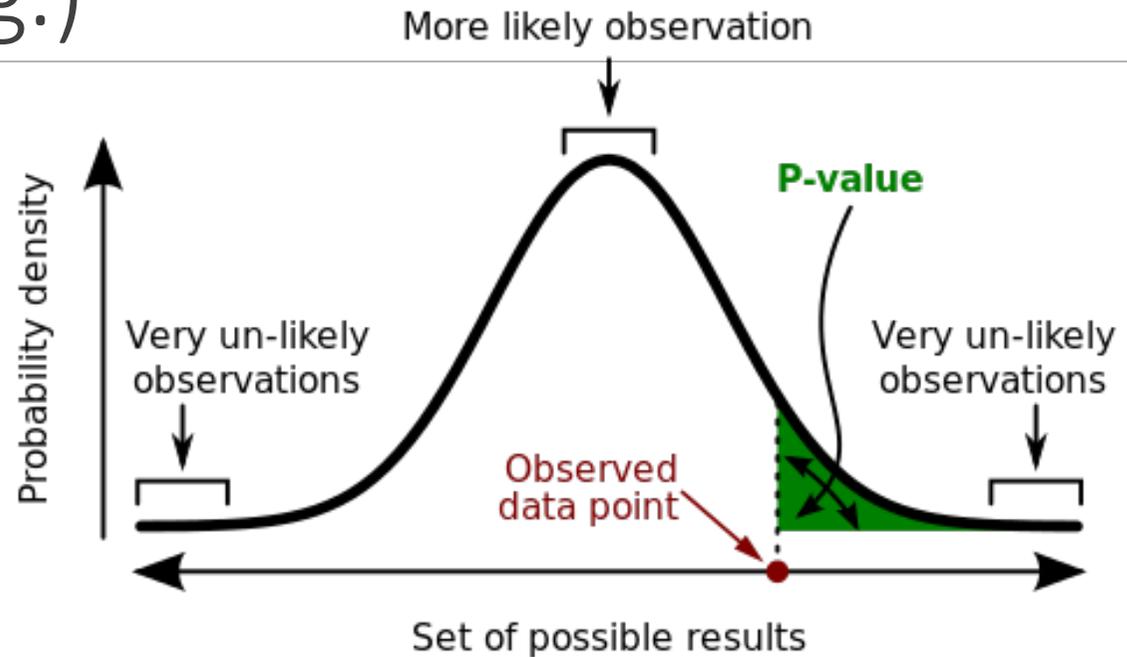
- $\Delta n \rightarrow$  puede producir demasiada potencia (los efectos pequeños serán cada vez más significativos).

## 1.4. p-valor (sig.)

La falacia de la  
condición transpuesta

$$P(\hat{y}/H_0) \neq P(H_0/\hat{y})$$

Usar el p-valor como un resultado cierto a nivel poblacional es un error atroz desde el punto de vista lógico



A **p-value** (shaded green area) is the probability of an observed (or more extreme) result assuming that the null hypothesis is true.

## 1.5. Selección técnica AMV

ES - MÉTODOS ESTADÍSTICOS Y  
CONSTRUCCIÓN DE MODELOS

### Regresión múltiple (explica la relación lineal).

Sirve para explicar el comportamiento de una única variable dependiente en función del comportamiento de otras.

Sólo sirve para predecir si las variables independientes son indicadores adelantados (ARIMA, alisado exponencial...).

### Análisis discriminante múltiple (clasifica).

Sirve para clasificar en relación a una variable dependiente categórica (no métrica) construida a partir de un conjunto de variables independientes cuantitativas y continuas.

Predice la verosimilitud de una entidad respecto de un conjunto de identidades estadísticas (categorías) expresadas en funciones discriminantes.

## 1.5. Selección técnica AMV

---

ES - MÉTODOS ESTADÍSTICOS Y  
CONSTRUCCIÓN DE MODELOS

### Regresión logística (clasifica).

Cumple la misma función que el discriminante, pero con distinta metodología.

MANOVA (Análisis Multivariante de la varianza) y MANCOVA (Análisis Multivariante de la Varianza que incluye la Covarianza).

- ANOVA: compara la media de una variable de distintas poblaciones simultáneamente bajo el supuesto de igualdad de varianzas.
- MANOVA: compara varios valores medios de distintas variables en distintas muestras simultáneamente. Las variables independientes son categóricas.
- MANCOVA = MANOVA + COVARIABLES.

# 1.5. Selección técnica AMV

---

ES - MÉTODOS ESTADÍSTICOS Y  
CONSTRUCCIÓN DE MODELOS

## **Análisis conjunto.**

Se busca ordenar las preferencias respecto a un conjunto de objetos partiendo de información múltiple de carácter cualitativo (atributos).

## **Correlación canónica (H. Hotteling).**

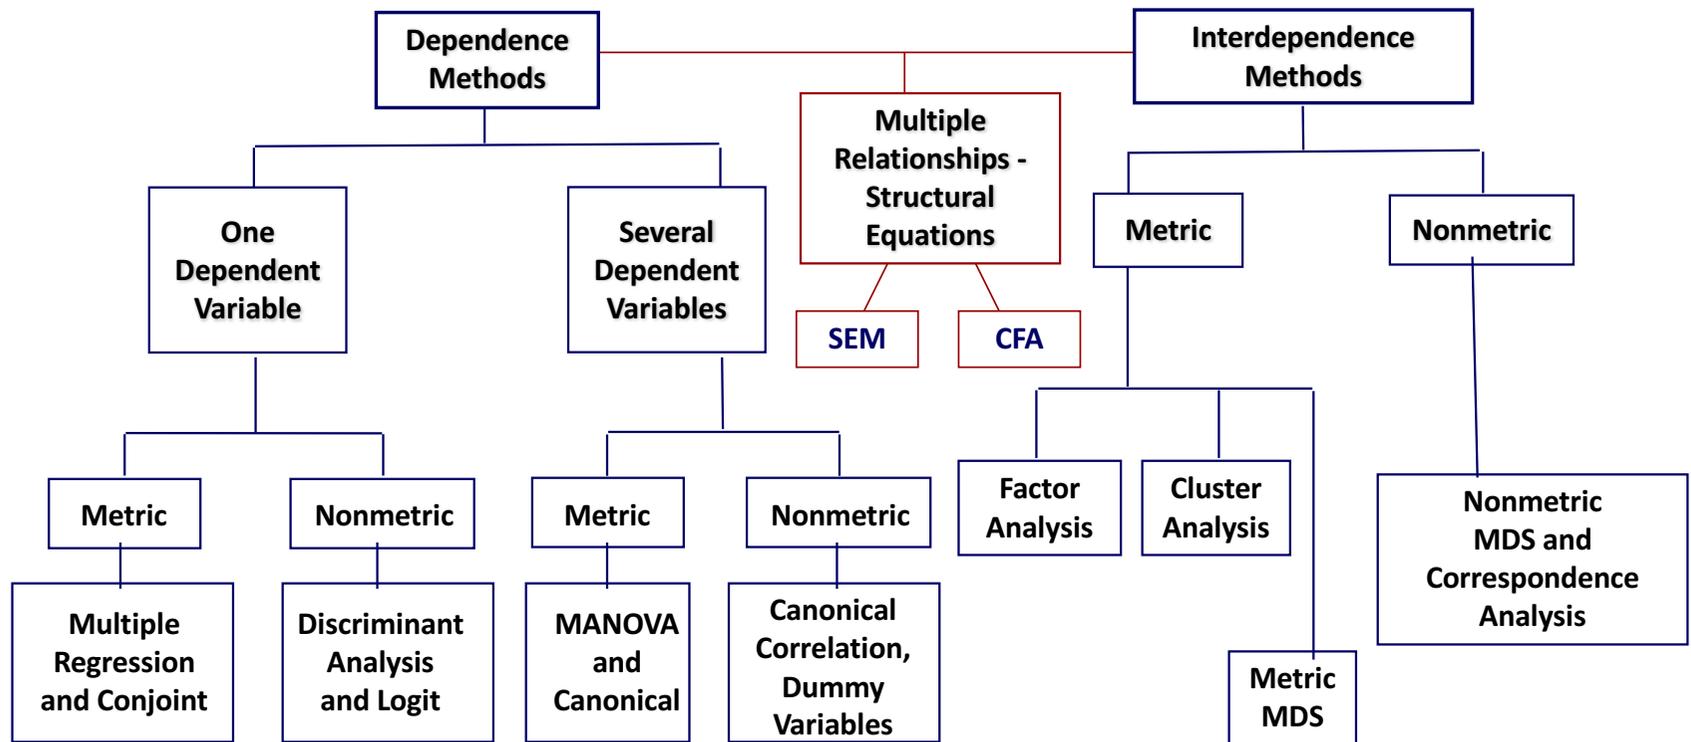
Busca relaciones entre dos grupos de variables y la validez de las mismas. Se diferencia de la Regresión múltiple en que hay muchas dependientes.

## **Modelos de ecuaciones estructurales (SEM).**

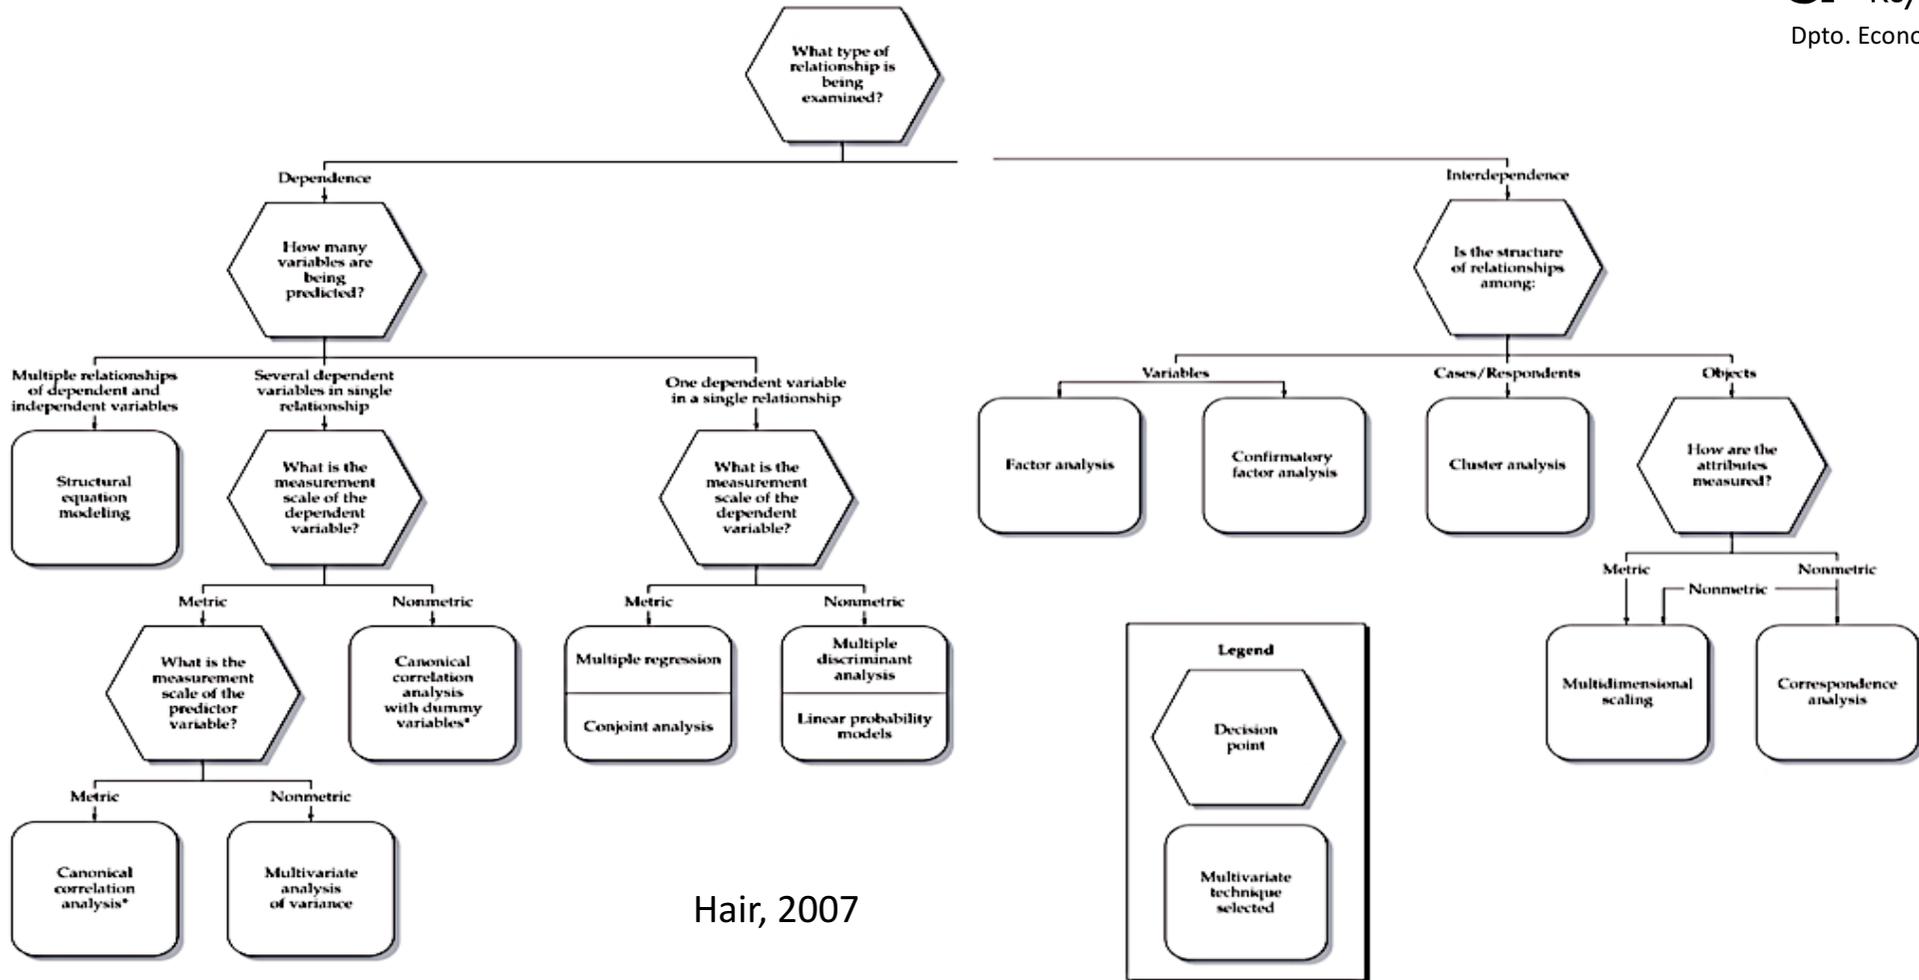
Estima múltiples relaciones de dependencia e interdependencia con los componentes: modelo de medida y modelo estructural. Las ecuaciones estructurales es el método confirmatorio por excelencia.

# 1.5. Selección técnica AMV

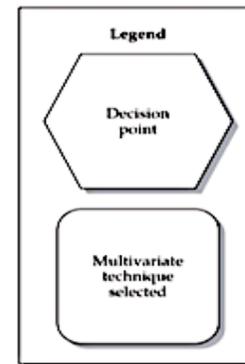
ES - MÉTODOS ESTADÍSTICOS Y CONSTRUCCIÓN DE MODELOS



Hair, 2007



Hair, 2007



# Fuentes

---

1. Daniel Peña (2002) Análisis de datos multivariantes, McGrawHill, Madrid, Tema 2, p.1-12.
2. Hair et al (2007) Análisis Multivariante, Pearson Prentice Hall, Madrid.p.1-28
3. [my.ilstu.edu/~wjschne/138/Psychology138Lab14.html](http://my.ilstu.edu/~wjschne/138/Psychology138Lab14.html)
4. [https://upload.wikimedia.org/wikipedia/commons/3/3a/P-value\\_in\\_statistical\\_significance\\_testing.svg](https://upload.wikimedia.org/wikipedia/commons/3/3a/P-value_in_statistical_significance_testing.svg)
5. <http://www.melbapplets.ms.unimelb.edu.au/?portfolio=power-of-a-hypothesis-test>