

# Missing data analysis in longitudinal data. How to analyze it?



Jorge J. Curto García



M0.185 - TFM-Estadística y Bioinformática  
Máster Universitario en Bioinformática y Bioestadística  
UOC-UB

Nombre Profesor/a: **Núria Pérez**  
PRA: Alexandre Sánchez Pla

Barcelona, 10 de Enero 2018



## OBJETIVOS

### ▶ Objetivo general

- ▶ Contextualizar el problema que generan los datos perdidos en el análisis de datos longitudinales y describir los métodos actuales disponibles para abordar dicho problema.

### ▶ Objetivos específicos

- ▶ Caracterización de los estudios con datos longitudinales.
- ▶ Definición de datos faltantes
- ▶ Contextualización del problema de los datos perdidos en el análisis de los datos longitudinales.
- ▶ Identificación los métodos actuales de tratamiento de datos perdidos y determinar las bondades y limitaciones de estos métodos.
- ▶ Ejemplificación de la aplicación de los métodos estudiados mediante el análisis de una base de datos longitudinales en el ámbito de la biomedicina.

## ENFOQUE

### ▶ Sección teórica

- ▶ Recopilación bibliográfica acerca del análisis de datos longitudinales y la problemática de los datos perdidos
- ▶ Revisión exhaustiva de los distintos métodos actuales para el tratamiento de los datos faltantes
- ▶ Búsqueda de librerías disponibles en R



### ▶ Sección practica

- ▶ Búsqueda online de una base de datos longitudinales
- ▶ Generación de un informe estadístico dinámico con el análisis descriptivo e inferencial de los datos originales, generación de datos perdidos y el análisis del tratamiento de los datos faltantes (R, Rstudio y Markdown)

## DATOS LONGITUDINALES

- ▶ “En general” obtendremos datos longitudinales cuando la variable/variables de interés se recoge en mediciones sucesivas a lo largo del tiempo, porque el interés se halla en analizar el cambio en función del tiempo.
- ▶ Los estudios de datos longitudinales pueden ser observacionales o de intervención y tanto prospectivos como retrospectivos.
- ▶ 3 elementos clave <sup>(1)</sup>:
  - ▶ El seguimiento
  - ▶ Más de 2 medidas
  - ▶ Análisis que tenga en cuenta dichas medidas.
- ▶ **OBJETIVO:** *analizar los “patrones interindividuales de cambio intraindividual”*<sup>(2)</sup>



(1) Delgado M., Llorca J. Estudios longitudinales: concepto y particularidades. Rev. Esp. [Salud Pública](http://www.monografias.com/trabajos902/estudios-longitudinales/estudios-longitudinales.shtml#ixzz4bCQlxJyU), mar.-abr. 2004, vol.78, no.2, p.141-148. ISSN 1135-5727. <http://www.monografias.com/trabajos902/estudios-longitudinales/estudios-longitudinales.shtml#ixzz4bCQlxJyU>

(2) Nesselroade, J. R. y Baltes, P. B. (Eds.) (1979). Longitudinal research in the study of behaviour and development. New York: Academic Press.

Missing data analysis in longitudinal data. How to analyze it?

## MÉTODOS DE ANÁLISIS DE DATOS LONGITUDINALES

- ▶ Englobados en el contexto de los modelos lineales generalizados
- ▶ Herramientas convencionales de regresión:
  - ▶ relacionar el **efecto** con las diferentes exposiciones
  - ▶ Correlación de las **medidas entre sujetos**.
  - ▶ Tratar covariables dependientes del tiempo
- ▶ Difiere en función de la naturaleza de la variable respuesta

## DATOS PERDIDOS (datos faltantes/missing data)

- ▶ Foco de dificultad en el análisis de datos longitudinales
- ▶ En la investigación (clínica/social/biomédica, etc) es lo habitual (lo excepcional es su ausencia)
- ▶ Los motivos de aparición son variados (falta de consentimiento, problema técnico, no asistencia, etc)
- ▶ Tipos (Rubin 1976):
  - ▶ **MCAR** (missing completely at random): Datos perdidos completamente al azar
  - ▶ **MAR** (missing at random): Datos perdidos al azar
  - ▶ **MNAR** (missing not at random): Datos perdidos no ignorables o no debidos al azar

## TRATAMIENTO DE DATOS PERDIDOS

- ▶ En el desarrollo de un estudio de investigación:
  - ▶ **DISEÑO:** Prever la posible presencia de datos faltantes en el cálculo del tamaño muestral
  - ▶ **RECOGIDA DE DATOS:** Adecuada monitorización para aumentar la calidad de los datos 
  - ▶ **ANÁLISIS DE DATOS:** Identificar casos/variables afectadas por su presencia y los posibles patrones, para decidir el tipo de tratamiento que se lleva a cabo previo al análisis de los objetivos del estudio.

## TRATAMIENTO DE DATOS PERDIDOS: MÉTODOS

- ▶ **ELIMINACIÓN:** eliminación de los casos/eliminación por pares
- ▶ **IMPUTACIÓN SIMPLE:** sustitución por la media/ regresión simple/ vecino más cercano/ regresión estocástica / Imputación por la observación previa (LOCF Last Observation Carried Forward)
- ▶ **MÉTODOS MODERNOS:** Algoritmo de expectación-maximización (EM)/ Algoritmo de imputación múltiple (MI) /Fully Conditional Specification (FCS)/ Full Information Maximum Likelihood (FIML)

## TRATAMIENTO DE DATOS PERDIDOS: IMPUTACIÓN MÚLTIPLE

### ▶ 3 FASES

- ▶ **IMPUTACIÓN:** Se generan  $m$  copias del conjunto de datos
  - ▶ Diversas estrategias, destacan Markov Chain Monte Carlo o el algoritmo de Equiparación de media predictiva (PMM)
- ▶ **ANÁLISIS:** En cada copia del conjunto de datos se lleva a cabo el análisis (con técnicas estadísticas)
- ▶ **COMBINACIÓN DE LOS RESULTADOS:** Se obtiene una estimación global como promedio de las  $m$  estimaciones.



## TRATAMIENTO DE DATOS PERDIDOS: BONDADDES Y LIMITACIONES

En general, los métodos de imputación no aleatoria (no estocásticos) reducen variabilidad y se ha de asumir el mecanismo MCAR o MAR.

- ▶ **Eliminación:** Pérdida de eficacia por reducción del tamaño muestral, requiere asumir MCAR y la muestra sigue siendo insesgada.
- ▶ **Media:** reducción de varianza y produce sesgo.
- ▶ **Regresión:** reduce el sesgo pero también la variabilidad.
- ▶ **LOCF:** Se distorsiona el comportamiento a lo largo del tiempo afectando a diferencias entre grupos y las estimaciones de los parámetros.

los *métodos estocásticos (imputación aleatoria)* generan múltiples conjuntos de datos basados en los valores observados y reduciendo la posibilidad de que se produzca sesgo estadístico y a su vez maximizan la variabilidad

## LIBRERIAS R

Existen multitud de librerías para el tratamiento de valores perdidos:

- ▶ **MissingDataGUI, VIM, VIMGUI, MICE, Amelia, HMISC, MI.**
- ▶ **VIM:** Herramientas muy útiles para la visualización gráfica de los datos faltantes y datos imputados
- ▶ **MICE:** Paquete muy completo con múltiples opciones desde no estocástica/no aleatoria (media) a modelos de imputación aleatoria para datos continuos (predictive mean matching PMM, normal), datos binarios (regresión logística), datos categóricos no ordenados (regresión logística politémica) y datos categóricos ordenados (odds proporcionales).



## EJEMPLIFICACIÓN: PLAN DE ANÁLISIS

- ▶ Selección, presentación y análisis descriptivo de la base de datos seleccionada.
- ▶ Generación de nuevas bases de datos (dataframes en R) con datos faltantes generados de manera aleatoria, 3 escenarios: 10%, 20% y 30%.
- ▶ Tratamiento de los datos faltantes para cada una de las bases de datos generadas anteriormente.
- ▶ Reproducción de los análisis originales publicados por los autores (base de datos completa).
- ▶ Reproducción de los análisis originales publicados por los autores con las bases de datos generadas tras el tratamiento de los datos faltantes.
- ▶ Comparación de los resultados de los dos pasos anteriores.

## EJEMPLIFICACIÓN: ANÁLISIS ORIGINAL



- ▶ **Base de datos:** Estudio PREVEND es de acceso público en “The Dryad Digital Repository”, Prueba RFFT (prueba cognitiva que evalúa la función ejecutiva FE), 2 variables principales: N° de diseños únicos y N° de errores perseverantes (3 mediciones consecutivas).
- ▶ Los autores reportaron, en 2515 participantes, un aumento significativo ( $p_{tendencia} < 0.001$ ) en el número medio (DE) de diseños únicos en el RFFT incrementándose de 73 (26) en la primera medición, a 79 (27) en la segunda medición y a 83 (26) en la tercera. Además dicho aumento se asoció negativamente con la edad (disminuyó con 0,23 por incremento de un año) y no se halló relación con el nivel educativo.
- ▶ Resultados similares se obtuvieron para los errores perseverantes

Se reprodujeron los mismos resultados que los autores.

Missing data analysis in longitudinal data. How to analyze it?

# EJEMPLIFICACIÓN: GENERACIÓN Y ANÁLISIS DE DATOS FALTANTES (ESCENARIO 10%)

- 1) Se generaron aleatoriamente 3 escenarios: 10%, 20% y 30% de datos faltantes en las variables principales. No se hallan patrones (paquete VIM)




Missing data analysis in longitudinal data. How to analyze it?

# EJEMPLIFICACIÓN: GENERACIÓN Y ANÁLISIS DE DATOS FALTANTES (ESCENARIO 10%)


Se corroboró la ausencia de patrones de los datos faltantes y de relación entre la presencia y ausencia de datos faltantes con las características basales. Además se obtuvo un resultado no significativo al aplicar el test Little's MCAR-test, que permitió asumir que los datos faltantes generados aleatoriamente en el escenario del 10% son MCAR (se obtuvieron resultados similares para el escenario del 20%, y 30% y también para la variable *nº de errores perseverantes*).




Edad según presencia de datos faltantes



Género vs Presencia NA







Nivel de educación vs Presencia NA



Missing data analysis in longitudinal data. How to analyze it?

# EJEMPLIFICACIÓN: TRATAMIENTO DE DATOS FALTANTES (ESCENARIO 10%)

- ▶ 4 métodos: Eliminación de casos, media (*con mice*), regresión (*con mice*), imputación múltiple (*con mice*, PMM, 5 iteraciones)



Missing data analysis in longitudinal data. How to analyze it?




## EJEMPLIFICACIÓN: ANÁLISIS DE RESULTADOS ORIGINALES VS IMPUTADOS (ESCENARIO 10%)

Tipo de análisis	Análisis original	Listwise	Media	Regresión	IM (5, PMM)
Modelo	Modelo 3				
Variables	B (DE), IC95% (p-valor)				
Edad	-0.66 (0.053), -0.76 to -0.55 (<0.001)	-0.69 (0.062), -0.81 to -0.57 (<0.001)	-0.61 (0.053), -0.72 to -0.51 (<0.001)	-0.67 (0.051), -0.76 to -0.57 (<0.001)	-0.66 (0.053), -0.76 to -0.56 (<0.001)
Sexo: Hombre	Ref.	Ref.	Ref.	Ref.	Ref.
Sexo: Mujer	1.38 (0.725), -0.04 to 2.8 (0.058)	1.14 (0.853), -0.53 to 2.82 (0.18)	1.01 (0.68), -0.33 to 2.34 (0.139)	1.27 (0.719), -0.14 to 2.68 (0.077)	1.16 (0.723), -0.25 to 2.58 (0.108)
NE: Escuela primaria	Ref.	Ref.	Ref.	Ref.	Ref.
NE: Secundaria inicial	6.63 (1.568), 3.55 to 9.7 (<0.001)	6.66 (1.866), 3 to 10.32 (<0.001)	5.63 (1.469), 2.75 to 8.51 (<0.001)	6.57 (1.555), 3.52 to 9.62 (<0.001)	6.7 (1.562), 3.64 to 9.77 (<0.001)
NE: Secundaria superior	13.04 (1.597), 9.91 to 16.17 (<0.001)	12.24 (1.896), 8.52 to 15.96 (<0.001)	10.94 (1.496), 8.01 to 13.87 (<0.001)	12.76 (1.583), 9.66 to 15.86 (<0.001)	12.84 (1.59), 9.72 to 15.95 (<0.001)
NE: Universitaria	25.35 (1.561), 22.28 to 28.41 (<0.001)	24.56 (1.846), 20.94 to 28.18 (<0.001)	21.97 (1.462), 19.1 to 24.84 (<0.001)	25.04 (1.547), 22 to 28.07 (<0.001)	25.14 (1.555), 22.09 to 28.19 (<0.001)
Medida (nº consecutivo)	17.11 (1.032), 15.09 to 19.14 (<0.001)	24.56 (1.207), 13.97 to 18.71(0.18)	15.2 (1.098), 13.04 to 17.35(<0.001)	16.64 (0.952), 14.77 to 18.51(<0.001)	16.9 (1.021), 14.9 to 18.9(<0.001)
Edad x Medida (nº consecutivo)	-0.23 (0.019), -0.27 to -0.19 (<0.001)	-0.22 (0.023), -0.27 to -0.18 (<0.001)	-0.2 (0.02), -0.24 to -0.16 (<0.001)	-0.23 (0.018), -0.26 to -0.19 (<0.001)	-0.23 (0.019), -0.27 to -0.19 (<0.001)
AIC	65103.7	47020.5*	65528.5	64291.2	65187.4
Varianza residual	14.3	14.2*	15.1	13.2	14.1

## EJEMPLIFICACIÓN: CONCLUSIONES

Teniendo en cuenta los 3 escenarios:

- IM (basada en el algoritmo PMM) de la función “mice”, presenta resultados robustos y presenta estimaciones cercanas a los resultados originales.
- Cabe destacar que con el método de regresión (método norm.predict, “mice”), la imputación es eficaz en general (datos faltantes cumplen MCAR).
- Con el método de sustitución por la media (método mean, “mice”), la imputación es peor que las anteriores y hay que tener en cuenta el problema de baja variabilidad que generará en los datos.
- Utilizar métodos de eliminación cuando el mecanismo de datos perdidos MCAR, conlleva pérdida de eficacia aunque la muestra permanezca insesgada.



# MATERIAL PRESENTADO

- PRESENTACIÓN ORAL (FORMATO PPT)
- MEMORIA (FORMATO PDF)
- INFORME ESTADÍSTICO (FORMATO PDF)
- INFORME ESTADÍSTICO DINÁMICO REPRODUCIBLE (FORMATO MARKDOWN-RSTUDIO)