


## Tema III: Datos Ordenados.

---

Maicel Monzón


# Para Modelar La Dieta Se Requiere Datos Precisos Y Fáciles De Analizar

## Modelado de Dieta Usando Datos HCES



# Se abordarán métodos para estructurar datos desordenados.

## Fuentes Diversas de Datos de Consumo



- ¿Qué son los Datos Ordenados?
- ¿Por qué son Importantes?
- Datos Desordenados Comunes
- Funciones Clave de la biblioteca `tidyr`

1. `pivot_longer()`
2. `pivot_wider()`
3. `separate()`
4. `unite()`

“Todas las **familias felices se parecen** unas a otras, pero cada **familia infeliz lo es a su manera.**”

*León Tolstoy*

“Todos los **conjuntos de datos ordenados se parecen** unos a otros, pero cada conjunto de **datos desordenado lo es a su manera**” *Hadley Wickham*

**tidydata:** Un estándar para organizar datos de manera consistente.

Existen **tres principios** que definen un conjunto de datos ordenados.

**Table 1:** conjunto de datos

Col_ID	var 1	var 2	var 3
obs 1	valor 1,1	valor 1,2	valor 1,3
obs ...	valor .,1	valor .,2	valor .,3
obs n	valor n,1	valor n,2	valor n,3

# Principios de Tidydata (datos ordenados)

1. Cada **variable** debe tener su **propia columna**.
2. Cada **observación** debe tener su **propia fila**.
3. Cada **valor** debe tener su **propia celda**.

pais	anio	casos	poblacion
afganistán	1999	745	19987071
afganistán	2000	2666	20595360
brasil	1999	37737	172006362
brasil	2000	80488	174504898
china	1999	212258	1272915272
china	2000	213766	1280428583

pais	anio	casos	poblacion
afganistán	1999	745	19987071
afganistán	2000	2666	20595360
brasil	1999	37737	172006362
brasil	2000	80488	174504898
china	1999	212258	1272915272
china	2000	213766	1280428583

pais	anio	casos	poblacion
Afganistán	1999	745	19987071
Afganistán	2000	2666	20595360
Brasil	1999	37737	172006362
Brasil	2000	80488	174504898
China	1999	212258	1272915272
China	2000	213766	1280428583

## Ejemplo de datos ordenados

Ej. distribución de ingresos y miembros por hogares

```
# A tibble: 3 x 3
```

	ID_Hogar	Ingreso	Miembros
	<dbl>	<dbl>	<dbl>
1	101	8500	4
2	102	12000	4
3	102	12000	3

- **Consistencia:** Facilita el aprendizaje.
- **Compatibilidad:** `dplyr`, `gtsummary`, y otros paquetes del tidyverse están diseñados para trabajar con datos ordenados.
- **Eficiencia:** Reduce errores y facilita la manipulación, visualización y análisis.

## El enfoque facilita crear nuevas variables (percapita)

$$pct = Ingreso / Miembros$$

```
hogares_tidy %>%  
  mutate(pct=Ingreso/Miembros)
```

```
# A tibble: 3 x 4
```

	ID_Hogar	Ingreso	Miembros	pct
	<dbl>	<dbl>	<dbl>	<dbl>
1	101	8500	4	2125
2	102	12000	4	3000
3	102	12000	3	4000

## Orígenes del desorden de datos

- 1 Desconocimiento de principios para organizar datos eficazmente.

**Falta de familiaridad**

- 2 Organización centrada en entrada, no en análisis.

**Enfoque en la entrada**

**Datos desordenados** 

- **Problema 1:** Una variable distribuida en múltiples columnas.
- **Problema 2:** Una observación dispersa en múltiples filas.
- **Problema 3:** Múltiples variables almacenadas en una columna.
- **Problema 4:** Diferentes tipos de datos almacenados en la misma columna.
- **Problema 5:** Variables almacenadas tanto en filas como en columnas.

# Problema.1 La variable tiempo está distribuida en múltiples columnas

- Se requiere **pivotar** de formato ancho a formato largo

**Datos desordenados**

1: Variable distribuida en múltiples columnas

Alimento	Enero	Febrero	Marzo
Arroz	150	140	160
Pollo	100	90	110
Verduras	200	180	210

**Formato ancho**



**Datos ordenados**

Alimento	Mes	Gramos
Arroz	Enero	150
Arroz	Febrero	140
Arroz	Marzo	160
Pollo	Enero	100
Pollo	Febrero	90
Pollo	Marzo	110
Verduras	Enero	200
Verduras	Febrero	180
Verduras	Marzo	210

**Formato Largo**

## Problema.2 La variable nutriente para un individuo específico está dispersa en múltiples filas

- Se requiere **pivotar** de **formato largo** a **formato ancho**

### Datos desordenados

2: Una observación dispersa en múltiples filas.


Formato Largo

ID	nutriente	cantidad
101	Proteína	70
101	Carbohidratos	250
102	Proteína	60
102	Carbohidratos	300

### Datos ordenados

ID	Proteína	Carbohidratos
101	70	250
102	60	300

Formato ancho



## Problema.3 Múltiples variables almacenadas en una misma columna.

- Alimento y comida almacenadas en la variable **Alimento\_Comida** separada por un guión requiere separar la variable.

### Datos desordenados

3: Múltiples variables almacenadas en una columna.

Alimento_Comida	Gramos
Leche_Desayuno	200
Pan_Cena	50
Carne_Almuero	150

separar

### Datos ordenados

Alimento	Comida	Gramos
Leche	Desayuno	200
Pan	Cena	50
Carne	Almuero	150

## Problema 4: Diferentes tipos de datos almacenados en la misma columna.

### Datos desordenados

4: Diferentes tipos de datos almacenados en la misma columna.

ID	año	mes	día
1	2,023	10	26
2	2,023	11	15
3	2,024	1	1

unir

### Datos ordenados

```
# A tibble: 3 × 2
  ID fecha
<dbl> <chr>
1     1 2023-10-26
2     2 2023-11-15
3     3 2024-1-1
```

- **`tidyr`**: Un paquete clave en el **`tidyverse`** para ordenar datos desordenados.
- funciones principales
- `pivot_longer()`
- `pivot_wider()`
- `separate`
- `unite`

## funcion de tidyr: `pivot_longer()`

- **Función:** Convierte datos “anchos” a “largos”.
- **Uso:** Cuando los nombres de las columnas son valores, no variables.

## Argumentos Clave de `pivot_longer()`

- **cols**: Columnas a pivotar. Selecciona las columnas a transformar.
- **names\_to**: Nombre de la nueva columna para los nombres de las columnas originales. Define el nombre de la columna que contendrá los nombres de las columnas originales.
- **values\_to**: Nombre de la nueva columna para los valores de las celdas. Define el nombre de la columna que contendrá los valores de las celdas.

## funcion de tidyr: pivot\_wider()

- **Función:** Convierte datos “largos” a “anchos”.
- **Uso:** Observación dispersa en filas.

## Argumentos Clave de `pivot_wider()`

- `names_from`: Columna para nombres de nuevas columnas.
- `values_from`: Columna para llenar las nuevas columnas.

## funcion de `tidyr`: `separate()`

- **Función:** Divide una columna en múltiples columnas
- **Uso:** Cuando una columna contiene múltiples variables combinadas

## Argumentos Clave de `separate()`

- `cols` : La columna que se va a separar
- `into` : Vector de nombres para las nuevas columnas
- `sep`: El carácter o la posición donde se va a separar la columna. Ej “\_”

## funcion de `tidyr`: `unite()`

- **Función:** Combina múltiples columnas en una sola columna
- **Uso:** Cuando los componentes de una sola variable están dispersos en múltiples columnas

## Argumentos Clave de `unite()`

- `cols` : El nombre de la nueva columna combinada
  - `...` : Las columnas que se van a unir
  - `sep`: El carácter separado
- `remove`: Eliminar las columnas de entrada