



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO

---

FACULTAD DE CIENCIAS

TÉCNICAS DE ANÁLISIS DE CONGLOMERADOS PARA LA  
DEFINICIÓN DE ESTRATOS DE MUESTREO USANDO  
INFORMACIÓN ESPACIAL Y SOCIODEMOGRÁFICA DE MÉXICO

T E S I S

QUE PARA OBTENER EL TÍTULO DE:

LICENCIADA EN MATEMÁTICAS APLICADAS

PRESENTA:

JAZMÍN ALEJANDRA MARTÍNEZ GUERRERO

DIRECTOR DE LA TESIS:

DR. GONZALO PÉREZ DE LA CRUZ

Ciudad Universitaria, CD. MX 2024





Universidad Nacional  
Autónoma de México



**UNAM – Dirección General de Bibliotecas**  
**Tesis Digitales**  
**Restricciones de uso**

**DERECHOS RESERVADOS ©**  
**PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL**

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

*"Para que serve o arrependimento, se isso não muda nada do que se passou? O melhor arrependimento é, simplesmente, mudar."*

# Agradecimientos

Quiero agradecer a mi papá, por su apoyo siempre incondicional. A mi mamá por la presión necesaria y un montón de cariño. Y a mi hermano, por ser una motivación en mi día a día para nunca rendirme.

A Nymeria por desvelarse conmigo todas las noches que le dedique a esta tesis.

Por siempre confiar en todo lo que soñé, cuidarme y guiarme hasta aquí; a Héctor. Sin él no hubiera tenido el valor para cambiarme de carrera. Gracias por priorizar mi felicidad, por hablar por mí cuando me daba miedo hablar y por soñar por mí cuando yo no quería soñar.

A mis amigos, que son uno de los pilares más importantes de mi vida y que sin ellos no podría haber sido la persona que soy ahora:

- A José y Rodrigo por haber sido mis mejores amigos durante toda la carrera, apoyarme, escucharme y enseñarme, sin ustedes la universidad no podría haber sido lo que fue.
- A Paolo por tantos momentos de diversión, aprendizaje y por siempre creer en mí.
- A Alberto porque pensé que había sido una suertuda por haberme quedado en esa clase de álgebra, pero la verdadera suerte fue encontrarte.
- A Pablo por la innumerables platicas aunque eso nos haya costado recurrar álgebra lineal, por quererme a pesar de ser una mandona y sentirme la jefa del equipo de cálculo, por tantas aventuras juntos.
- A Bernardo por construir conmigo la amistad más leal que haya conocido.
- A Yadira por su amistad, apoyo incondicional y ser uno de mis ejemplos a seguir, te admiro tanto.
- A Karla por haberme apoyado y escuchado durante tanto tiempo.
- A Gema, Brenda, Leo, Ana, Mariana, Kenneth, André y a todas las personas que estuvieron, aunque ya no estén.

También quiero agradecer al Doctor G3onzalo, por su infinita paciencia a lo largo de este trayecto y siempre responder mis dudas, de verdad no pude tener un mejor asesor.

A mis profesores: Sergio L3pez, Lizbeth Naranjo, Javier Fernandez, Diana Avella, Sebasti3n Vel3zquez y Yadira Rivas, por motivarme con su excepcional manera de ense1ar.

Finalmente, quiero agradecer a la Universidad Nacional Aut3noma de M3xico, en especial a la Facultad de Ciencias, por darme la mayor cantidad de aprendizajes que he tenido en toda mi vida.

# Índice general

<b>1. Introducción</b>	<b>8</b>
1.1. Motivación . . . . .	8
1.2. Objetivo general . . . . .	9
<b>2. Conceptos básicos de muestreo</b>	<b>12</b>
2.1. Diseños de muestreo . . . . .	12
2.1.1. Muestreo aleatorio simple sin reemplazo ( <i>m.a.s</i> ) . . . . .	16
2.2. El estimador Horvitz-Thompson para totales . . . . .	16
2.2.1. Propiedades básicas . . . . .	17
2.2.2. Estimador HT bajo un m.a.s . . . . .	18
2.3. Determinación del tamaño de la muestra . . . . .	18
2.3.1. Cálculo del tamaño de muestra a partir del estimador HT para totales y con un diseño de muestreo aleatorio simple . . . . .	19
2.4. Muestreos estratificados . . . . .	20
2.4.1. El estimador Horvitz-Thompson en muestreo estratificado con m.a.s al interior de cada estrato . . . . .	20
2.4.2. Construcción de los estratos . . . . .	21
2.5. Efecto de diseño . . . . .	22
<b>3. Aprendizaje estadístico no supervisado</b>	<b>23</b>
3.1. Análisis de conglomerados jerárquico . . . . .	23
3.1.1. Algoritmo . . . . .	24
3.1.2. Métodos de enlace . . . . .	25
3.1.3. Elección del número de conglomerados . . . . .	28
3.2. Análisis de conglomerados jerárquico con restricciones espaciales usando el método Ward . . . . .	30
3.2.1. Algoritmo . . . . .	32
<b>4. Clasificación de los municipios de los Estados Unidos Mexicanos a través del método de conglomeración jerárquica con restricciones espaciales</b>	<b>33</b>
4.0.1. Características sociodemográficas . . . . .	33
4.0.2. Características geográficas . . . . .	47
4.1. Matrices de distancias . . . . .	47
4.1.1. Distancias entre las características sociodemográficas . . . . .	47
4.1.2. Distancias geográficas . . . . .	47
4.2. Parámetros para el uso del algoritmo . . . . .	48
4.3. Clasificación de los municipios . . . . .	49
4.3.1. Elección de los parámetros $\alpha$ y $k$ . . . . .	49

4.4. Evaluación de la estratificación y descripción de los resultados . . . . .	54
4.4.1. Evaluación del modelo . . . . .	54
4.4.2. Comparación de la estratificación resultante con otras estratificacio- nes de interés . . . . .	55
4.4.3. Descripción de la estratificación obtenida . . . . .	56
<b>5. Conclusiones</b>	<b>64</b>
<b>6. Anexo A: Nociones básicas</b>	<b>67</b>
<b>7. Anexo B: Simulación de bases de datos para ilustrar los métodos de enlace</b>	<b>69</b>
<b>8. Anexo C: Código Tesis</b>	<b>74</b>
<b>9. Bibliografía</b>	<b>140</b>

# Resumen

El objetivo de la tesis fue crear una estratificación de los municipios de los Estados Unidos Mexicanos que tomara en cuenta tanto características sociodemográficas como geográficas. Esto con la motivación de crear estratos de muestreo a nivel nacional como los que el INEGI obtiene en la primera etapa de su estratificación para el diseño de muestreo de su Muestra Maestra, es decir, cuando se crean los cuatro estratos sociodemográficos: bajo, medio bajo, medio alto y alto.

Se trabajó con la información de los municipios existentes hasta el 2020 según el Censo de Población y Vivienda realizado por el INEGI ese mismo año y para clasificarlos se utilizó el algoritmo de conglomerados jerárquico con restricciones espaciales utilizando el método de enlace Ward propuesto por Chavent et al. (2018).

Para utilizar el algoritmo son necesarias dos matrices: una de distancias geográficas y otra de distancias entre las características sociodemográficas, así como el peso de las observaciones  $w_i$ , un parámetro de mezcla  $\alpha$  y el número de grupos  $k$ . Para las características sociodemográficas se utilizaron dos bases de datos: los Principales Resultados por Localidad del Censo de Población y Vivienda; diseñados por el INEGI, y los Indicadores de pobreza municipal 2015; creados por el CONEVAL. La información espacial de los municipios se obtuvo del Marco Geoestadístico diseñado por el INEGI.

Por practicidad se decidió darle el mismo peso  $w_i$  a todas las observaciones, sin embargo, respecto a la elección de los parámetros  $\alpha$  y  $k$  se probó con diversos valores, con lo que se obtuvieron distintas formas de estratificar. Para elegir la mejor, se seleccionaron diez variables y se obtuvieron los estimadores de sus totales, utilizando el estimador Horvitz-Thompson en muestreo estratificado con un m.a.s al interior de cada estrato, se calculó la varianza poblacional para cada variable, y se conservó la estratificación que tuvo, en promedio, la menor varianza poblacional.

Para evaluar la estratificación resultante, se comparó la varianza poblacional obtenida de realizar un muestreo aleatorio simple al interior de cada estrato, con la varianza poblacional que se obtendría al llevar a cabo un m.a.s. El experimento se consideró satisfactorio puesto que la varianza obtenida con la estratificación fue menor. Aunado a esto, para analizar el desempeño de la estratificación se comparó su varianza poblacional con la de otras estratificaciones de interés como la estratificación por entidad federativa, por tipo de municipio y el cruce entre éstas. Todo el proceso se llevo a cabo utilizando el lenguaje de programación R.

# Capítulo 1

## Introducción

### 1.1. Motivación

En México, el Instituto Nacional de Estadística y Geografía (INEGI) es el encargado de llevar a cabo el Censo de Población y Vivienda cada diez años. Además, a partir de muestreos probabilísticos el INEGI genera información de diferentes temas cada cierto tiempo; por ejemplo, la Encuesta Nacional de Ocupación y Empleo (ENOE) se realiza trimestralmente, mientras que la Encuesta Nacional de Ingresos y Gastos de los Hogares (ENIGH) se lleva a cabo cada dos años. Aunque sería ideal realizar un censo cada vez que se quiere generar algún tipo de información y con ello obtener datos precisos y a un nivel muy desagregado, entrevistar a toda la población con estas periodicidades sería demasiado complicado y costoso. Por lo cual, basándose en la información del censo en su nivel más desagregado, el INEGI genera su Muestra Maestra, la cual está diseñada para ser representativa, es decir, para reflejar la información de toda la población. Así, cada vez que se quiere generar información el INEGI selecciona submuestras a través de la Muestra Maestra y con esto se evita tener que entrevistar a toda la población en cada ocasión, lo que resulta en una reducción de costos y una mayor eficiencia.

Actualmente, el INEGI está en proceso de actualización de su Muestra Maestra derivada del Censo 2020 (Rodríguez y Heredia, 2023), por lo que se sigue usando la de 2010. Según Landeros (2013) para el diseño de la Muestra Maestra del año 2010 el INEGI realizó los siguientes pasos:

1. **Creación de las Unidades Primarias de Muestreo.** El objetivo de crear Unidades Primarias de Muestreo (UPM) fue obtener agrupaciones de manzanas o localidades homogéneas en números de viviendas que facilitaran los recorridos de campo para realizar las encuestas y con ello la actualización de la muestra. Para agruparlas se utilizaron herramientas como Diagramas de Voronoi, Triangulación de Delaunay, Polígonos de Thiessen y Método de Recocido Simulado. En total se formaron 245,279 UPM.
2. **Estratificación de las UPM.**  
La estratificación se hizo de acuerdo a:
  - Las características sociodemográficas de los habitantes de las viviendas.
  - Las características físicas de las viviendas.

- La ubicación geográfica de las viviendas.

El proceso de estratificación se compuso de dos etapas: la primera consistió en clasificar a las UPM según su perfil sociodemográfico, empleando indicadores extraídos del censo. La segunda se realizó de acuerdo con su ubicación geográfica, la cual se deriva naturalmente de la división política del territorio nacional y del tamaño de las localidades.

Para la primera etapa de la estratificación se utilizó el método de conglomerados *K-means*, empleando 14 indicadores de población y 19 de vivienda, los cuales fueron contruidos con la información del Censo de Población y Vivienda 2010. Como resultado se obtuvieron cuatro estratos a nivel nacional: bajo, medio bajo, medio alto y alto.

En la segunda fase de la estratificación, se llevó a cabo una clasificación adicional de los estratos formados en la primera etapa. En esta segunda clasificación, cada estrato fue diferenciado según la entidad federativa a la que pertenecía, y a su vez, según el tamaño de la localidad a la que estaba asociado. Este proceso resultó en la formación de un total de 746 estratos.

### 3. **Tamaño de la muestra.**

Una vez estratificadas las UPM se calculó el tamaño de muestra necesario para obtener resultados con un nivel de precisión y confiabilidad específicos, considerando la variabilidad de la población y el diseño de muestreo.

Así, la Muestra Maestra del INEGI se compone de un conjunto de UPM seleccionadas aleatoriamente y cuando se quiere generar o actualizar información se toma una submuestra de viviendas de estas UPM en una segunda etapa (Rodríguez y Heredia, 2023).

## 1.2. **Objetivo general**

El objetivo de este trabajo es probar un método de aprendizaje estadístico no supervisado para clasificar a los municipios de los Estados Unidos Mexicanos, de acuerdo al estrato sociodemográfico al que pertenecen y utilizando la información de su ubicación geográfica para complementar este proceso de clasificación. Esta idea surgió con la motivación de querer obtener estratos de muestreo a nivel nacional como los que genera el INEGI en la primera etapa de la estratificación para el diseño de su Muestra Maestra, es decir, cuando se crean los cuatro estratos sociodemográficos a nivel nacional. Cabe destacar que no se pretende sustituir el trabajo realizado por el INEGI, sino sólo probar una metodología para la definición de los estratos.

Se utilizó información a nivel municipal ya que es la información más desagregada y completa disponible para el público en general, y se trabajó con la información de los municipios existentes hasta el 2020 según el Censo de Población y Vivienda realizado por el INEGI de dicho año. Para clasificar los municipios se utilizó el algoritmo de análisis de conglomerados jerárquico con restricciones espaciales, empleando el método de enlace

Ward. Este método fue propuesto por Chavent et al. (2018), para el cual son necesarios los siguientes elementos:

- Una matriz de distancias entre las características sociodemográficas.
- Una matriz de distancias geográficas.
- Un parámetro de mezcla  $\alpha \in [0,1]$ , en donde si  $\alpha = 0$  significa que los grupos son creados sólo considerando las características sociodemográficas y si  $\alpha = 1$  quiere decir que todo el peso se le da a la ubicación geográfica.
- Los pesos de las observaciones, denotados como  $w_i$ .
- El número  $k$  de grupos en los que se clasificarán las observaciones.

Para las características sociodemográficas se utilizaron dos bases de datos: los Principales Resultados por Localidad del Censo de Población y Vivienda 2020 <sup>1</sup> y los Indicadores de pobreza municipal 2015 <sup>2</sup>. Para las distancias geográficas, la información espacial de los municipios se obtuvo del Marco Geoestadístico diseñado por el INEGI <sup>3</sup> y las distancias fueron obtenidas de dos formas distintas; en la primera se calculó la distancia recta entre los centroides de los municipios, y la segunda se basó en analizar la adyacencia entre los municipios.

Respecto a los parámetros; por practicidad se le dio el mismo peso  $w_i$  a todas las observaciones, para el parámetro  $\alpha$  se decidió aprovechar el poder computacional actual y utilizar una malla de 21 puntos, y para determinar el número de grupos  $k$  se utilizaron diversas técnicas como el método del codo, la silueta y gap, con lo que al final se decidió experimentar con  $k = 3, 4$  y  $5$ . Debido a que se ejecutó el algoritmo con las combinaciones de estos parámetros y las dos matrices de distancias, se originaron 126 distintas estratificaciones.

Para elegir la mejor estratificación lo ideal sería obtener muestras a nivel hogar/persona y evaluar las estratificaciones emulando lo que sería el uso que tiene la Muestra Maestra. Dado que esto no es posible se utilizó la base de datos de las Estadísticas Censales a Escalas Geoelectorales <sup>4</sup> ya que es un nivel más desagregado y público que a nivel municipal y con esto se pueden tomar muestras para evaluar las estratificaciones.

Primero se clasificaron a los distritos electorales de acuerdo a las 126 estratificaciones obtenidas anteriormente y después se seleccionaron diez variables: población de 15 años o más con primaria incompleta, población de 8 a 14 años que no sabe leer ni escribir, población de 15 años o más analfabeta, población con discapacidad, población de 3 años y más que habla alguna lengua indígena, población sin afiliación a servicios de salud, viviendas particulares habitadas con piso de tierra, viviendas particulares habitadas que no disponen

---

<sup>1</sup>Disponible en:

<https://www.inegi.org.mx/programas/ccpv/2020/>

<sup>2</sup>Disponible en:

[https://www.coneval.org.mx/Medicion/Paginas/Programas\\_BD\\_municipal.aspx](https://www.coneval.org.mx/Medicion/Paginas/Programas_BD_municipal.aspx)

<sup>3</sup>Disponible en:

<https://www.inegi.org.mx/app/biblioteca/ficha.html?upc=889463807469>

<sup>4</sup>Disponible en: <https://www.inegi.org.mx/programas/ccpv/2020/>

de energía eléctrica, viviendas particulares habitadas que no disponen de agua entubada, y viviendas particulares habitadas que no disponen de drenaje. Para cada variable, en cada estratificación, se calculó el estimador para totales Horvitz-Thompson en muestreo estratificado con muestreo aleatorio simple (m.a.s) al interior de cada estrato, para así poder obtener la varianza de cada estimador y conservar aquella estratificación en donde, en general, para todas las variables el estimador tuviera la menor varianza poblacional. La estratificación elegida fue la obtenida con  $\alpha = 0.25$ ,  $k = 5$  y la matriz de distancias entre centroides.

Con el propósito de analizar el desempeño de la estratificación elegida se comparó la varianza poblacional resultante de esta estratificación con la de un m.a.s, ambos diseños con el mismo tamaño de muestra. En este caso, como la varianza de la estratificación seleccionada fue menor que la del m.a.s., se consideró exitosa en el sentido de que se redujo el error cuadrático medio de los estimadores.

Adicionalmente, se clasificó a los municipios de acuerdo a otras estratificaciones que podrían resultar de interés (por ejemplo, la obtenida solo con la división por entidad federativa), y de forma análoga se calcularon las varianzas poblacionales para éstas nuevas estratificaciones y se compararon con la de la estratificación elegida. Se observó que la estratificación elegida también ayudó a mejorar la precisión de los estimadores.

La tesis está organizada de la siguiente manera. En el capítulo dos se dan las nociones básicas de muestreo. En el capítulo tres se define qué es el aprendizaje estadístico no supervisado y en qué reside una de sus técnicas principales: el análisis de conglomerados jerárquico. También se describe cómo considerar el uso de restricciones espaciales en dicho método. En el capítulo cuatro se realizan distintas estratificaciones de los municipios de los Estados Unidos Mexicanos y se evalúa su desempeño para elegir la mejor. Además, se comparan los resultados obtenidos con la estratificación elegida contra los que se hubieran obtenido al realizar un muestreo aleatorio simple y otras estratificaciones como por entidad federativa, tipo de municipio y el cruce entre éstas. Finalmente, en el capítulo cinco se dan comentarios finales.

## Capítulo 2

# Conceptos básicos de muestreo

En este capítulo se dará una introducción básica acerca de muestreo: qué es un diseño muestral, en qué consisten los diseños muestrales con estratificación, qué es un estimador y para qué sirve, el estimador Horvitz-Thompson para totales y una forma para calcular el tamaño de la muestra. Se comenzará definiendo algunos conceptos básicos, basados en Lohr (2019, pag. 3).

- **Población:** Se define como población al conjunto  $U$  y sus elementos se denotan como  $\{u_1, u_2, \dots, u_N\}$ , donde  $N$  es el tamaño de la población.
- **Muestra:** Subconjunto de una población.
- **Parámetro:** Comúnmente denotado por  $\theta$ , es la medida numérica que resume la información de una característica de la población. Por ejemplo, la edad promedio de los estudiantes inscritos en una universidad o el ingreso salarial total por familia.
- **Censo:** Al ejercicio de medir una o más características en todos los elementos de una población se le llama censo.

Debido a la dificultad y el costo asociados con la realización de un censo, surge la alternativa de tomar mediciones solo en un subconjunto de la población, conocido como muestra. El reto principal del muestreo es obtener una muestra que refleje la información correspondiente al parámetro de interés de toda la población. Ya sea en el censo o al utilizar una muestra, se asume que las mediciones necesarias para calcular los parámetros se llevan a cabo sin error, lo que significa que los valores de las mediciones  $y_1, \dots, y_N$  son fijos.

Las estimaciones del parámetro de interés a menudo presentan un error aleatorio inherente debido a que se basan únicamente en un subconjunto de la población. La magnitud de este error dependerá del diseño de muestreo utilizado (cómo se selecciona la muestra) y del estimador utilizado.

### 2.1. Diseños de muestreo

Sea  $U$  la población de interés de tamaño  $N$ , donde sus elementos se denotan como  $u_1, u_2, \dots, u_N$ ; y cada unidad  $u_k$  tiene un valor fijo asociado  $y_k$ .

El objetivo es estimar el parámetro de interés  $\theta$ , que es una función de  $y_1, \dots, y_N$ , usando una muestra  $s$ , la cual es cualquier subconjunto de  $U$ .

Nótese que hay  $2^N$  diferentes subconjuntos de  $U$ , los cuales conforman el conjunto potencia  $S$ :

$$S = \{\emptyset, \{1\}, \{2\}, \dots, \{1, 2\}, \dots, \{N-1, N\}, \dots, \{1, 2, \dots, N\}\},$$

donde la cardinalidad de  $S$  es  $|S| = \sum_{i=0}^N \binom{N}{i} = 2^N$ .

**Definición 2.1.1 Estimador.**

Un estimador de  $\theta$ , denotado como  $\hat{\theta}$ , es cualquier función de los valores de  $y$  asociados a los elementos en la muestra  $s$  seleccionada:

$$\hat{\theta} = f(y_k, u_k \in s).$$

Notar que  $\hat{\theta}$  tomará un valor diferente para cada muestra  $s$ . Se denotará al tamaño de la muestra  $s$  como  $n_s$ .

**Definición 2.1.2 Diseño muestral.**

Un diseño muestral es una función  $p(\cdot)$  que representa una función de probabilidad sobre  $S$ :

$$p(s) = P(S = s) \quad \forall s \in S,$$

donde  $0 \leq p(s) \leq 1 \quad \forall s \in S$  y  $\sum_{s \in S} p(s) = 1$ .

Esta definición permite que haya elementos en  $S$  cuya probabilidad  $p(s)$  sea cero, lo cual implica que no se podrían observar en la práctica. Ya que estos casos no son los de interés, se define como  $S_0$  al subconjunto de  $S$  tal que  $0 < p(s)$ , dichos elementos conforman el conjunto de muestras posibles.

**Definición 2.1.3 Diseño muestral probabilístico.**

Un diseño muestral probabilístico es un diseño muestral  $p(\cdot)$  que cumple que:

$$\forall u_k \in U \exists s \in S_0 \ni u_k \in s, \tag{2.1}$$

es decir, cada elemento de la población tiene probabilidad positiva de ser seleccionado en la muestra.

**Definición 2.1.4 Probabilidad de inclusión.**

Sea  $u_k \in U$ , el evento "se observa una muestra que contiene al elemento  $u_k$ " se denotará como " $u_k \in S$ ". Es de interés obtener la probabilidad de este evento, la cual se conoce como probabilidad de inclusión del elemento  $u_k$  y se denota como  $\pi_k$ .

**Definición 2.1.5 Función indicadora.**

Para cada elemento  $u_k \in U$ , la función indicadora se define como:

$$I_k = \begin{cases} 1, & \text{si } u_k \in S \\ 0, & \text{en otro caso.} \end{cases} \tag{2.2}$$

Es decir,  $I_k = 1$  representa que se ha observado una muestra que contiene a la unidad  $u_k$ . Por lo que  $\pi_k$  se puede obtener fácilmente a partir de  $I_k$  y de un diseño de muestreo definido, usando la regla de probabilidad total sobre la variable aleatoria  $S$ :

$$\pi_k = P(u_k \in S) = P(I_k = 1) = \sum_{s \in S_0} I(u_k \in s) p(s). \quad (2.3)$$

De forma similar se puede obtener la probabilidad de inclusión de los elementos  $u_k$  y  $u_l$ , esto significa que se observó al elemento  $u_k$  y al elemento  $u_l$ , es decir, " $u_k, u_l \in S$ ", a esta probabilidad se le denota por  $\pi_{kl}$ . Entonces:

$$\pi_{kl} = P(u_k \in S, u_l \in S) = P(I_k = 1, I_l = 1) = \sum_{s \in S_0} I(u_k \in s, u_l \in s) p(s). \quad (2.4)$$

Se tiene el caso particular cuando  $k = l$ :

$$\pi_{kk} = P(u_k \in S) = P(I_k = 1) = \pi_k. \quad (2.5)$$

Una vez que se selecciona la muestra  $s$ , se tiene que:

$$I_k | "S=s" = \begin{cases} 1, & \text{si } u_k \in s \\ 0, & \text{en otro caso.} \end{cases} \quad (2.6)$$

En muchos casos, las variables aleatorias asociadas a la muestra se podrán escribir en términos de las funciones indicadoras. Por ejemplo:

$$n_s = \sum_{u_k \in U} I_k. \quad (2.7)$$

Con función de probabilidad:

$$P(n_s = n) = \sum_{s \in S_0} I(n_s = n) p(s), \quad n \in \{0, \dots, N\}. \quad (2.8)$$

Incluso, para calcular la esperanza de  $n_s$  puede ser más conveniente usar 2.7 en lugar de la función de probabilidad, pues:

$$\begin{aligned} E(n_s) &= E\left(\sum_{u_k \in U} I_k\right) \\ &= \sum_{u_k \in U} E(I_k) \\ &= \sum_{u_k \in U} \pi_k. \end{aligned} \quad (2.9)$$

**Resultado 2.1.1** (*Propiedades de las funciones indicadoras*). Sea un diseño de muestreo  $p(\cdot)$  y sus respectivas probabilidades de inclusión de primer y segundo orden. Las funciones indicadoras definidas en 2.2 están asociadas a variables aleatorias que cumplen que  $\forall u_k, u_l \in U$ :

$$E(I_k) = \pi_k, \quad (2.10)$$

$$V(I_k) = \pi_k(1 - \pi_k), \quad (2.11)$$

$$Cov(I_k, I_l) = \pi_{kl} - \pi_k\pi_l. \quad (2.12)$$

*Demostración.* Por definición se tiene que  $I_k \sim \text{Bernoulli}(\pi_k)$ ,  $u_k \in U$ , pues  $I_k = 1$  representa que se ha observado una muestra que contiene a la unidad  $u_k$ . De lo anterior es directo que  $E(I_k) = \pi_k$  y  $V(I_k) = \pi_k(1 - \pi_k)$ . Por otro lado:

$$\begin{aligned} Cov(I_k, I_l) &= E(I_k I_l) - E(I_k)E(I_l) \\ &= P(I_k = 1, I_l = 1) - \pi_k\pi_l \\ &= \pi_{kl} - \pi_k\pi_l. \end{aligned}$$

Además, sean  $I_1, \dots, I_N$  las variables indicadoras de los  $N$  elementos en la población  $\{u_1, u_2, \dots, u_N\}$  y  $\{a_k, b_k; k = 1, \dots, N\}$  constantes. Entonces:

$$Cov\left(\sum_{u_k \in U} a_k I_k, \sum_{u_l \in U} b_l I_l\right) = \sum_{u_k \in U} \sum_{u_l \in U} a_k b_l Cov(I_k, I_l).$$

Esta ecuación se puede separar en dos casos, cuando  $u_k = u_l$  y cuando  $u_k \neq u_l$ , así:

$$\begin{aligned} \sum_{u_k \in U} \sum_{u_l \in U} a_k b_l Cov(I_k, I_l) &= \sum_{u_k \in U} a_k b_k Cov(I_k, I_k) + \sum_{u_k \in U} \sum_{u_l \in U, l \neq k} a_k b_l Cov(I_k, I_l) \\ &= \sum_{u_k \in U} a_k b_k V(I_k) + \sum_{u_k \in U} \sum_{u_l \in U, l \neq k} a_k b_l Cov(I_k, I_l) \\ &= \sum_{u_k \in U} a_k b_k \pi_k(1 - \pi_k) + \sum_{u_k \in U} \sum_{u_l \in U, l \neq k} a_k b_l (\pi_{kl} - \pi_k\pi_l). \end{aligned}$$

Por lo tanto,

$$Cov\left(\sum_{u_k \in U} a_k I_k, \sum_{u_l \in U} b_l I_l\right) = \sum_{u_k \in U} a_k b_k \pi_k(1 - \pi_k) + \sum_{u_k \in U} \sum_{u_l \in U, l \neq k} a_k b_l (\pi_{kl} - \pi_k\pi_l). \quad (2.13)$$

Existen distintos diseños de muestreo, entre los más populares se encuentran el muestreo Bernoulli, el muestreo aleatorio simple con y sin reemplazo, y el muestreo sistemático. En este trabajo se explicará el muestreo aleatorio simple sin reemplazo, ya que es el que se utilizó en el experimento.

### 2.1.1. Muestreo aleatorio simple sin reemplazo (m.a.s)

Este diseño de muestreo es el más sencillo de todos y es muy usado (aunque costoso), ya que permite la obtención de expresiones sencillas para los estimadores de totales, en particular, aquellos basados en el estimador Horvitz–Thompson. Considerando una población de tamaño  $N$ ,  $U = \{u_1, u_2, \dots, u_N\}$ , y un valor  $n$  fijo,  $n \leq N$ , el m.a.s es aquel en donde cada muestra de tamaño  $n$  tiene la misma probabilidad de ser seleccionada, es decir,

$$S_0 = \{s_1 = \{1, 2, \dots, n\}, \dots, s_{\binom{N}{n}} = \{N - n + 1, \dots, N\}\}, \quad p(s_i) = \frac{1}{\binom{N}{n}} \quad \forall s_i \in S_0. \quad (2.14)$$

Con este diseño se cumple que  $\pi_k = \frac{n}{N}$  y que  $\pi_{kl} = \frac{n(n-1)}{N(N-1)}$ ,  $u_k \neq u_l$ ,  $u_k, u_l \in U$ .

Para tomar una muestra aleatoria simple, se necesita una lista de todas las unidades en la población; esta lista es el llamado marco de muestreo.

El método más simple para seleccionar una muestra con este diseño consiste en generar  $N$  números aleatorios entre 0 y 1, luego seleccionar las unidades correspondientes a los  $n$  números aleatorios más pequeños para que sean la muestra. Por ejemplo, si  $N = 10$  y  $n = 4$ , generamos 10 números aleatorios entre 0 y 1:

unidad $i$	1	2	3	4	5	6	7	8	9	10
número aleatorio	0.837	0.636	0.465	0.609	0.154	0.766	0.821	0.713	0.987	0.469

Los 4 números aleatorios más pequeños son 0.154, 0.465, 0.469 y 0.609, lo que resulta en la muestra con las unidades  $u_3, u_4, u_5$  y  $u_{10}$ .

## 2.2. El estimador Horvitz-Thompson para totales

De acuerdo a la definición 2.1.1, un estimador es una función que se aplica a los datos muestrales para obtener una aproximación de un parámetro poblacional desconocido  $\theta$ .

Muchas veces se está interesado en calcular el total de una variable  $y$ . Esto puede ser el total de viviendas con electricidad o el total de personas que terminaron la educación media superior. Horvitz y Thompson (1951) propusieron un estimador para totales  $\theta = \sum_{k=1}^N y_k$  también conocido como  $\pi$ -estimador, el cual continua siendo en la actualidad uno de los más importantes. Sea  $U$  la población de interés, se define el  $\pi$ -estimador para totales como:

$$\hat{\theta} = \hat{t}_{y\pi} = \sum_{u_k \in S} \frac{y_k}{\pi_k} = \sum_{u_k \in S} w_k y_k, \quad (2.15)$$

donde  $y_k$  es el valor asociado al elemento de la población  $u_k$ . En este estimador,  $\frac{1}{\pi_k} = w_k$  actúa como ponderador del valor  $y_k$ . Al conjunto  $\{w_1, w_2, \dots, w_N\}$  se le conoce como el conjunto de factores de expansión o pesos muestrales, los cuales se usan para asignar un peso relativo a cada unidad de la muestra.

### 2.2.1. Propiedades básicas

El estimador  $\hat{t}_{y\pi}$  tiene las siguientes propiedades:

1. Es un estimador insesgado para  $t_y$ , es decir,

$$E(\hat{t}_{y\pi}) = t_y = \sum_{k=1}^N y_k. \quad (2.16)$$

- 2.

$$V(\hat{t}_{y\pi}) = \sum_{k=1}^N \sum_{l=1}^N \Delta_{kl} \frac{y_k}{\pi_k} \frac{y_l}{\pi_l}, \quad (2.17)$$

donde  $\Delta_{kl} = \pi_{kl} - \pi_k \pi_l$ .

*Demostración.* Primero se observa que:

$$\hat{t}_{y\pi} = \sum_{u_k \in S} \frac{y_k}{\pi_k} = \sum_{u_k \in U} I_k \frac{y_k}{\pi_k},$$

es decir, es un estimador lineal en términos de las variables aleatorias  $I_1, I_2, \dots, I_N$ .

$$\begin{aligned} \text{I. } E(\hat{t}_{y\pi}) &= E\left(\sum_{u_k \in U} I_k \frac{y_k}{\pi_k}\right) \\ &= \sum_{u_k \in U} E\left(I_k \frac{y_k}{\pi_k}\right) \\ &= \sum_{u_k \in U} \frac{y_k}{\pi_k} E(I_k) \\ &= \sum_{u_k \in U} \frac{y_k}{\pi_k} \pi_k \\ &= \sum_{u_k \in U} y_k = t_y \end{aligned}$$

$$\begin{aligned} \text{II. } V(\hat{t}_{y\pi}) &= V\left(\sum_{u_k \in S} \frac{y_k}{\pi_k}\right) \\ &= V\left(\sum_{u_k \in U} I_k \frac{y_k}{\pi_k}\right) \\ &= \text{Cov}\left(\sum_{u_k \in U} I_k \frac{y_k}{\pi_k}, \sum_{u_l \in U} I_l \frac{y_l}{\pi_l}\right) \end{aligned}$$

Como  $\frac{y_k}{\pi_k}, k = 1, \dots, N$ , son constantes, se utiliza 2.13, entonces:

$$V(\hat{t}_{y\pi}) = \sum_{u_k \in U} \frac{y_k^2}{\pi_k} (1 - \pi_k) + \sum_{u_k \in U} \sum_{u_l \in U, l \neq k} \frac{y_k}{\pi_k} \frac{y_l}{\pi_l} (\pi_{kl} - \pi_k \pi_l). \quad (2.18)$$

A  $V(\hat{t}_{y\pi})$  se le conoce como la **varianza poblacional** o teórica y se debe notar que depende de todas las observaciones, es decir, de todos los valores  $y_1, \dots, y_N$ , por lo que no se puede calcular con una muestra específica.

**Resultado 2.2.1** Por ser un estimador insesgado, el error cuadrático medio del estimador HT es igual a su varianza, ya que:

$$\begin{aligned}
 MSE(\hat{t}_{y\pi}) &= E[(\hat{t}_{y\pi} - t_y)^2] \\
 &= E(\hat{t}_{y\pi}^2) - 2t_y E(\hat{t}_{y\pi}) + t_y^2 + E(\hat{t}_{y\pi})^2 - E(\hat{t}_{y\pi})^2 \\
 &= E(\hat{t}_{y\pi}^2) - E(\hat{t}_{y\pi})^2 + [E(\hat{t}_{y\pi}) - t_y]^2 \\
 &\text{Como } E(\hat{t}_{y\pi}) = t_y, \text{ entonces } [E(\hat{t}_{y\pi}) - t_y]^2 = 0, \text{ y por lo tanto} \\
 MSE(\hat{t}_{y\pi}) &= V(\hat{t}_{y\pi}). \tag{2.19}
 \end{aligned}$$

### 2.2.2. Estimador HT bajo un m.a.s

Si se tiene una población  $U = \{u_1, u_2, \dots, u_N\}$  y una muestra de tamaño fijo  $n$ , donde el diseño de muestreo es aleatorio simple sin reemplazo, el estimador para totales se transforma en:

$$\hat{t} = \sum_{u_k \in S} \frac{y_k}{\pi_k} = \frac{N}{n} \sum_{u_k \in S} y_k = N\bar{y}_S,$$

esto porque  $\pi_k = \frac{n}{N}$  y  $\pi_{kl} = \frac{n(n-1)}{N(N-1)}$ ,  $k \neq l$ ,  $u_k, u_l \in U$ .

Partiendo de 2.18 y utilizando este diseño de muestreo, se puede encontrar una expresión más sencilla para  $V(\hat{t}_{y\pi})$ , tal que:

$$V(\hat{t}_{y\pi}) = \frac{N^2}{n} \left(1 - \frac{n}{N}\right) S_{yU}^2. \tag{2.20}$$

Donde  $S_{yU}^2 = \frac{\sum_{k=1}^N (y_k - \bar{y}_U)^2}{(N-1)}$  y  $\bar{y}_U = \frac{\sum_{k=1}^N y_k}{N}$ .

También se puede obtener que:

$$\hat{V}(t_{y\pi}) = \frac{N^2}{n} \left(1 - \frac{n}{N}\right) S_{yS}^2. \tag{2.21}$$

Donde  $S_{yS}^2 = \frac{\sum_{k \in S} (y_k - \bar{y}_S)^2}{(n-1)}$  y  $\bar{y}_S = \frac{\sum_{k \in S} y_k}{n}$ .

## 2.3. Determinación del tamaño de la muestra

Una de las preguntas fundamentales en muestreo es qué tamaño de muestra  $n$  es el adecuado. Para responder esta interrogante se debe decidir qué cantidad de error en las estimaciones es tolerable y equilibrarlo con el costo asociado a tomar una muestra de ese tamaño. Para esto se deben tener definidos los parámetros de interés, el diseño muestral y los estimadores a usar. El tamaño de muestra se debe calcular para cada parámetro de interés y cada dominio de estudio. En general, el cálculo con respecto a los dominios de estudio se realiza de forma jerárquica, empezando con los dominios de estudio de menor cardinalidad para que de esta manera se vayan acumulando los tamaños de muestra.

El tamaño de muestra hace referencia a las unidades en la población de interés que se deben seleccionar. Por ejemplo, si el parámetro de interés fuera el número de hogares

con electricidad, el tamaño de la muestra se calcularía sobre las viviendas. En cambio, si el parámetro de interés fuera el número de personas con secundaria incompleta, el tamaño de la muestra se calcularía sobre los individuos.

Por otro lado, dependiendo del diseño de muestreo cada estimador tiene su propia distribución y por esto, para un tamaño de muestra dado, cada uno proporciona un diferente desempeño y una diferente incertidumbre. La precisión de los estimadores se puede acotar considerando:

$$P\left(|\hat{\theta} - \theta| \leq k\sqrt{V(\hat{\theta})}\right) = 1 - \alpha, \quad (2.22)$$

donde  $k$  se determina dependiendo del valor de  $\alpha$  y de la distribución de  $\hat{\theta}$ . En particular, para el estimador Horvitz-Thompson y  $n$  grande, se suele usar  $k = z_{1-\frac{\alpha}{2}}$ . Además

$$k\sqrt{V(\hat{\theta})}, \quad (2.23)$$

es una cota en términos absolutos sobre el posible error  $|\hat{\theta} - \theta|$  que se observaría con una confianza  $1 - \alpha$  establecida. Es decir, si se repitiera la obtención de una muestra  $B$  veces considerando un diseño de muestreo fijo, entonces se espera que en  $(1 - \alpha) \times 100\%$  de las  $B$  muestras,  $|\hat{\theta} - \theta|$  fuera menor o igual a  $k\sqrt{V(\hat{\theta})}$ .

Con todo esto, se puede proporcionar una cota sobre el error absoluto deseado  $d$ . Por ejemplo, si es de interés que  $|\hat{\theta} - \theta| \leq d$ , esto se puede lograr con una confianza de  $1 - \alpha$  si

$$k\sqrt{V(\hat{\theta})} \leq d. \quad (2.24)$$

Para la determinación del tamaño de muestra se requiere encontrar una relación de  $k\sqrt{V(\hat{\theta})}$  con el valor  $n$  asociado al tamaño de la muestra. En general esto no es fácil, pero hay estimadores y diseños de muestreo en donde sí es posible.

### 2.3.1. Cálculo del tamaño de muestra a partir del estimador HT para totales y con un diseño de muestreo aleatorio simple

Como en este caso el tamaño de muestra se quiere calcular utilizando el estimador HT para totales, en lo siguiente se considera que  $k = z_{1-\frac{\alpha}{2}}$ ,  $\theta = t_y$  y  $\hat{\theta} = \hat{t}_{\pi y} = \sum_{u_k \in S} \frac{y_k}{\pi_k}$ , por lo que la ecuación 2.24 se convierte en:

$$k\sqrt{\frac{N^2}{n}\left(1 - \frac{n}{N}\right)S_{yU}^2} = k\sqrt{N^2\left(\frac{1}{n} - \frac{1}{N}\right)S_{yU}^2} \leq d \quad (2.25)$$

y despejando  $n$  se obtiene:

$$n \geq \frac{1}{\frac{d^2}{N^2 k^2 S_{yU}^2} + \frac{1}{N}} = \frac{\left(\frac{kNS_{yU}^2}{d}\right)^2}{1 + \frac{1}{N}\left(\frac{kNS_{yU}^2}{d}\right)^2}, \quad (2.26)$$

donde  $n$ , el menor valor que cumple esa desigualdad, es el tamaño de muestra recomendado.

## 2.4. Muestreos estratificados

En la práctica, a veces se cuenta con información adicional la cual puede ayudar a mejorar el diseño de muestreo. Si la variable en la que se está interesado toma diferentes valores promedio en distintas subpoblaciones, es posible que se puedan obtener estimaciones más precisas de las cantidades tomando una muestra aleatoria estratificada. Esto consiste en dividir a la población en  $H$  subpoblaciones llamadas estratos.

### Definición 2.4.1 Diseños estratificados

Sea

$$U = \{u_1, u_2, \dots, u_N\}$$

la población de interés de tamaño  $N$ . La población  $U$  se particiona en  $H$  subconjuntos, denotados como  $U_h$ ,  $h = 1, \dots, H$ . Estos subconjuntos son llamados estratos y cumplen por definición:

$$\bigcup_{h=1}^H U_h = U, U_i \neq \emptyset \text{ y } U_i \cap U_j = \emptyset \forall i \neq j; i, j = 1, \dots, H.$$

El número de unidades en el estrato  $h$  se denota como  $N_h$  y  $\sum_{h=1}^H N_h = N$ . Se dice que un diseño es estratificado si en cada estrato  $h$ :

- Se selecciona una muestra aleatoria  $s_h$  de tamaño  $n_h > 0$ , siguiendo un diseño de muestreo probabilístico  $p_h(s_h)$ .
- La selección de la muestra en ese estrato se realiza de forma independiente del resto de estratos.

Es decir, a cada estrato o subconjunto  $U_h$  se le considera como una población por sí mismo. Con estas condiciones la muestra  $s$  se obtiene como:

$$s = \bigcup_{h=1}^H s_h,$$

además  $n_s = \sum_{h=1}^H n_h$ , y dada la independencia en la selección de la muestra entre estratos se tiene que:

$$P(S = s) = p(s) = \prod_{h=1}^H p_h(s_h).$$

Con esta definición, el diseño de muestreo  $p_h(\cdot)$  usado en cada estrato podría ser diferente.

### 2.4.1. El estimador Horvitz-Thompson en muestreo estratificado con m.a.s al interior de cada estrato

**Resultado 2.4.1** *El estimador Horvitz-Thompson en un diseño de muestreo con estratificación y m.a.s al interior de cada estrato se puede expresar como:*

$$\hat{t}_{y\pi} = \sum_{h=1}^H \hat{t}_{h\pi} = \sum_{h=1}^H N_h \sum_{u_k \in S_h} \frac{y_k}{n_h} = \sum_{h=1}^H N_h \bar{y}_{S_h}, \quad (2.27)$$

donde  $\hat{t}_{h\pi} = \sum_{u_k \in S_h} \frac{y_k}{\pi_k}$  es el estimador de  $t_h = \sum_{u_k \in U_h} y_k$ .  
Además:

$$V(\hat{t}_{y\pi}) = \sum_{h=1}^H V(\hat{t}_{h\pi}) = \sum_{h=1}^H \frac{N_h^2}{n_h} \left(1 - \frac{n_h}{N_h}\right) S_{yU_h}^2 = \sum_{h=1}^H \frac{N_h^2}{n_h} S_{yU_h}^2 - \sum_{h=1}^H N_h S_{yU_h}^2, \quad (2.28)$$

donde  $V(\hat{t}_{h\pi})$  es la varianza de  $\hat{t}_{h\pi}$ ,  $S_{yU_h}^2 = \frac{\sum_{u_k \in U_h} (y_k - \bar{y}_{U_h})^2}{N_h - 1}$  y  $\bar{y}_{U_h} = \frac{\sum_{u_k \in U_h} y_k}{N_h}$ .

*Demostración.* Dado que  $s = \bigcup_{h=1}^H s_h$ , entonces:

$$\begin{aligned} \hat{t}_{y\pi} &= \sum_{u_k \in S} \frac{y_k}{\pi_k} \\ &= \sum_{h=1}^H \sum_{u_k \in S_h} \frac{y_k}{\pi_k} \\ &= \sum_{h=1}^H \hat{t}_{h\pi}. \end{aligned} \quad (2.29)$$

Usando la independencia de los diseños de muestreo de cada estrato se obtiene lo correspondiente a la varianza.

#### 2.4.2. Construcción de los estratos

Los aspectos que se consideran para la construcción de estratos son los siguientes:

- **Reducción del ECM de los estimadores.** Si se desea estimar el total de la variable  $y$ , se sugiere construir los estratos de modo que la variable sea muy homogénea en cada uno de ellos. Para lograr esto, se puede utilizar información auxiliar de una o más variables que estén relacionadas con la variable de interés. De esta forma, utilizando cualquier método de aprendizaje no supervisado para clasificación, se pueden identificar grupos homogéneos en relación a esas variables, lo que a su vez producirá cierta homogeneidad con respecto a la variable  $y$ .
- **Aprovechar divisiones ya creadas.** Es posible utilizar divisiones previamente establecidas, que históricamente presentan comportamientos diferenciados sobre la variable de estudio. Por ejemplo, áreas geográficas como entidades federativas o características demográficas como el sexo y la edad.
- **Mejorar la representación y credibilidad del estudio.** En un muestreo unietápico sin estratificación no es posible garantizar que la muestra seleccionada contenga unidades de diferentes grupos que se deseen representar; mientras que en un muestreo estratificado, se podrían incluir estratos contruidos de manera que esos grupos se vean representados. Por ejemplo, en un muestreo aleatorio simple de hogares en el territorio nacional, se podría obtener una muestra donde no existan hogares de cierta entidad federativa, mientras que si se crean estratos a partir de las entidades federativas esto no podría pasar.
- **Coincidencia entre estratos y dominios de estudio.** En múltiples ocasiones, se busca generar resultados para distintos dominios de estudio o subpoblaciones. Dado que la selección en cada estrato es independiente y se asegura la selección de muestra en cada uno, estos podrían coincidir con dominios de estudio, facilitando la estimación, selección de la muestra y definición del tamaño de la muestra.

- **Facilitar la estimación y selección de la muestra.** En términos de mejorar la precisión de las estimaciones en un muestreo, una opción es utilizar un muestreo proporcional al tamaño, sin embargo, la selección y estimación de la varianza pueden ser complicadas. Por otro lado, el uso de un muestreo estratificado podría ser beneficioso ya que se puede aprovechar la información auxiliar representada en la variable tamaño durante la construcción de los estratos, y el diseño dentro de cada estrato podría ser un aleatorio simple, lo que facilita la estimación.
- **Costo.** En general, la implementación de un diseño estratificado puede ser costosa. Además, el número de estratos define un límite inferior en el tamaño de la muestra, ya que es necesario seleccionar muestra en cada estrato, entonces  $n \geq H$ . Además, para estimar la varianza en cada estrato, se recomienda seleccionar más de una unidad por estrato y considerar la posibilidad de que exista no respuesta. De lo contrario, podría ser necesario fusionar estratos para poder estimar las varianzas.

## 2.5. Efecto de diseño

En 1951, Cornfield sugirió medir la eficiencia de un diseño de muestreo mediante la razón entre la varianza que se obtendría de un muestreo aleatorio simple y la varianza obtenida a partir del diseño de muestreo elegido, ambos con  $n$  unidades de observación. En 1965, Kish llamó al recíproco de la razón de Cornfield como *deff* y lo utilizó para resumir el efecto del diseño en la varianza de la estimación (Sarndal et al., 1992, pag. 53).

Cuando el *deff* es menor a 1, significa que el diseño de muestreo es más eficiente que un m.a.s, y hay un efecto significativo del diseño en la varianza. Sin embargo, cuando el *deff* es mayor que 1, indica que el diseño de muestreo aumenta la varianza en comparación con un m.a.s, lo que significa que se necesita un tamaño de muestra mayor para lograr la misma precisión en las estimaciones. El *deff* es calculado de la siguiente manera:

$$deff = \frac{V_{\text{complejo}}(\hat{\theta})}{V_{\text{mas}}(\hat{\theta})}. \quad (2.30)$$

Este trabajo se centrará en el primer aspecto, es decir, usar una técnica de análisis de conglomerados para la definición de estratos con el objetivo de reducir el ECM de los estimadores. Este capítulo se basó principalmente en Pérez de la Cruz (2023), Tillé (2020, sección 3.1) y Lohr (2019, caps. 1, 2 y 4). Se recomienda al lector revisar estos para detalles que no se exponen en este trabajo.

## Capítulo 3

# Aprendizaje estadístico no supervisado

En este capítulo se definirá qué es el aprendizaje estadístico no supervisado y en qué consiste una de sus técnicas principales: el análisis de conglomerados jerárquico. También se describirá cómo considerar el uso de restricciones espaciales en dicho método. En esta sección se usará la notación  $n$ ,  $p$  y  $k$  como en la mayoría de libros sobre análisis de conglomerados, pese a que en el capítulo anterior tenían otro significado.

De acuerdo con James et al. (2021), el aprendizaje estadístico se refiere a un conjunto de herramientas cuyo objetivo principal es obtener el mayor conocimiento posible de determinados datos. Puede ser clasificado como aprendizaje estadístico supervisado y no supervisado. En general, el aprendizaje supervisado consiste en construir un modelo estadístico para predecir o estimar un *output* basado en uno o más *inputs*. Por otro lado, el aprendizaje no supervisado no tiene asociada una variable respuesta, por lo que no interesa realizar predicciones y en su lugar se enfoca en encontrar subgrupos homogéneos dentro de una población y en hallar patrones en las características de los datos. Las dos técnicas más populares para esto son el análisis de conglomerados y el análisis de componentes principales.

### 3.1. Análisis de conglomerados jerárquico

El objetivo principal del análisis de conglomerados es descubrir grupos que sean de interés en los datos. En particular, dado un conjunto de datos con  $n$  observaciones y donde para cada observación se tiene la información de  $p$  variables, la meta es identificar  $k$  grupos con base en las  $p$  variables tales que:

- Cada grupo debe contener al menos una observación.
- Cada observación pertenezca a un sólo grupo.

Esto define una partición del conjunto de  $n$  unidades en  $k$  subconjuntos llamados conglomerados o clústers. Como una gran cantidad de particiones pueden ser encontradas, la búsqueda se restringe a encontrar grupos en donde, respecto a las  $p$  variables, las observaciones sean similares entre ellas y diferentes a las de otros grupos.

Actualmente hay un interés creciente en el análisis de conglomerados, pues hay una necesidad de encontrar grupos en distintos campos de estudio. Por ejemplo, en marketing, con base en variables como características demográficas y de comportamiento, se pueden clasificar a los clientes en distintos grupos y así realizar una publicidad específica para cada uno o identificar a clientes potenciales. En medicina se puede utilizar en la investigación sobre cáncer para clasificar a los pacientes en subgrupos según su perfil de expresión génica y esto puede ser útil para identificar el perfil molecular de pacientes con buen o mal pronóstico, así como para entender la enfermedad y definir el tratamiento más adecuado.

A pesar de que el análisis de conglomerados es bastante intuitivo, su formalización no es sencilla. De hecho posee problemas y retos con los que el usuario debe lidiar. El primero de ellos es que no se existe un conocimiento a priori de la existencia y del número de grupos. Otro problema es el cómo evaluar los grados de similitud o disimilitud entre las observaciones ya que, al contrario del aprendizaje supervisado, en esta clase de técnicas no se cuenta con una variable respuesta por lo que es difícil medir su eficacia. Finalmente, hablando del método jerárquico, una decisión relevante concierne a la elección del método de enlace y la distancia a usar. La peculiaridad del método jerárquico es que no conduce a una sola partición con un número determinado de conglomerados, sino que produce una serie de particiones definidas por una estructura jerárquica (Giordani et al., 2020), por lo que puede ser más amigable que otros métodos ya que no requiere elegir un número  $k$  previo de grupos (como en el método de *K-means*). Para funcionar, este método requiere una matriz de distancias entre las observaciones.

### 3.1.1. Algoritmo

El análisis de conglomerados jerárquico produce una serie de particiones donde los dos conglomerados más similares son sucesivamente fusionados.

Sea  $D_n$  la matriz con las distancias entre cada par de observaciones y  $D_k$ ,  $k \leq n$ , una matriz de distancias entre los  $k$  conglomerados, el algoritmo es el siguiente:

0. Se comienza con la partición en donde cada una de las  $n$  observaciones es tratada como un conglomerado. Sea  $r = 0$ .
1. De acuerdo con  $D_{n-r}$ , se fusionan los dos conglomerados con la mínima distancia entre ellos, con lo que resulta una nueva partición de  $n - r - 1$  conglomerados.
2. Se obtiene una nueva matriz de distancias entre conglomerados  $D_{n-r-1}$ .
3. Si  $n - r - 1 = 1$  parar, de otra forma  $r = r + 1$ , y repetir los pasos 1 y 2.

En el último paso,  $D_2$  tiene orden  $(2 \times 2)$  y contiene las medidas de distancia entre los dos conglomerados que son fusionados para obtener la partición trivial y final con un conglomerado de  $n$  observaciones. Existen diversas formas de calcular  $D_k$ , las cuales dependen del método de enlace que se utilice (James et al., 2021).

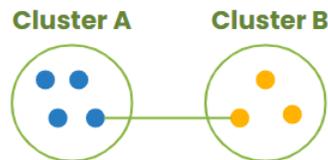
### 3.1.2. Métodos de enlace

El punto crucial en el análisis de conglomerados jerárquico radica en la elección del método para calcular las distancias entre conglomerados (también llamado método de enlace). Los más utilizados se encuentran resumidos en la Figura 3.1 y asumen que ya se ha definido una distancia  $d()$  a usar. En esta figura se considera que  $A$  y  $B$  son conglomerados cualquiera con  $i \in A$  y  $j \in B$ .

#### Método *single*

Se consideran las distancias entre todos los elementos del Clúster A y el Clúster B, y se conserva la mínima.

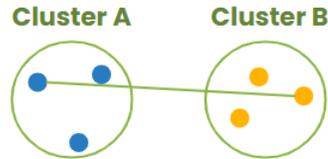
$$d(A, B) = \text{mín } d(i, j)$$



#### Método *complete*

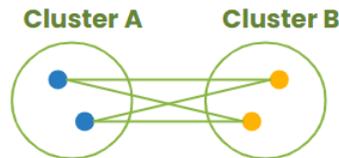
Se consideran las distancias entre todos los elementos del Clúster A y el Clúster B, y se conserva la máxima.

$$d(A, B) = \text{máx } d(i, j)$$



#### Método *average*

Se consideran todas las posibles distancias entre los elementos del Clúster A y el Clúster B, y se promedian.



#### Método *centroid*

Es la distancia entre el centroide del Clúster A y el centroide del Clúster B.



#### Método *ward*

Se consideran las varianzas que resultarían de fusionarse cualesquiera dos clústers. Y se conserva aquella fusión con la que se obtenga la mínima varianza.

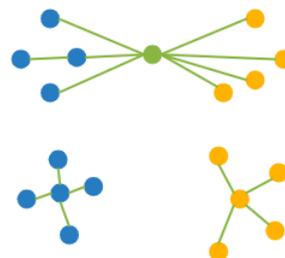


Figura 3.1: Resumen de los métodos más usados para calcular la distancia entre conglomerados. Imagen de autoría propia.

Con cada método se obtienen distintas ventajas y desventajas, y se deberá usar el más conveniente dependiendo del contexto. A continuación se enlistan las más comunes.

- Método *single*: En este método la distancia entre los conglomerados es la distancia entre sus elementos más cercanos, así que solo controla la similitud entre los vecinos más próximos. Por esta razón tiene buen desempeño con conglomerados no elípticos (siempre y cuando la distancia entre ellos no sea tan pequeña) y no tiende a separar grupos grandes, sin embargo, es sensible a *outliers*. También suele separar mal los grupos si hay ruido entre ellos, ya que puede provocar la fusión prematura de grupos con pares cercanos incluso si esos grupos son bastante diferentes en general.
- Método *complete*: La proximidad entre dos grupos es igual a la distancia entre sus dos objetos más distantes, por lo que tiende a producir conglomerados más compactos y no es tan sensible al ruido entre ellos ni a valores atípicos. Funciona mejor en formas elípticas, pero tiende a clasificar mal conglomerados grandes.
- Método *average*: Toma todos los pares de puntos entre un conglomerado y el otro y calcula el promedio de estas distancias, por esta razón suele ser más estable que los métodos *single* y *complete*, y no es tan sensible al ruido entre conglomerados ni a valores atípicos. Sin embargo, los resultados pueden ser variados, por ejemplo, en la Figura 3.2 al utilizarlo se separaron mal los grupos grandes y las formas no elípticas.
- Método *centroid*: La proximidad entre dos grupos es la distancia entre sus centroides geométricos. Estos grupos pueden estar fragmentados y a menos que sus figuras centrales estén separadas entre sí la unión será consistente. No es tan sensible al ruido entre conglomerados ni a valores atípicos. Esta es una de las técnicas menos utilizadas en la práctica ya que es caro computacionalmente.
- Método *ward*: Tiene como objetivo minimizar la varianza total dentro del grupo. Dados  $k$  conglomerados, este método permite la reducción a  $k - 1$  grupos considerando la unión de todas las posibles parejas de conglomerados que pueden ser formadas y conservando aquella en donde el valor de la suma de las desviaciones al cuadrado (ESS)<sup>1</sup> se minimice. Fue creado por Ward J. en 1963<sup>2</sup>, donde:

$$ESS = \sum_{i=1}^n x_i^2 - \frac{1}{n} \left( \sum_{i=1}^n x_i \right)^2. \quad (3.1)$$

A pesar de que funciona mejor con conglomerados elípticos no es sensible al ruido entre ellos ni a valores atípicos. Tampoco tiende a separar grupos grandes y suele ser el mejor método para separar conjuntos de datos donde hay mucho ruido.

Con el propósito de ilustrar las ventajas y desventajas de cada método de enlace descrito previamente se simularon cuatro conjuntos de datos en dos dimensiones. Utilizando la distancia euclidiana, a cada conjunto de datos se le aplicaron los métodos de enlace: *single*, *complete*, *average*, *centroid* y *ward*, y se obtuvieron los resultados mostrados en la Figura 3.2. En el anexo B se detalla cómo fueron simulados los conjuntos de datos.

<sup>1</sup>Sum of the squared deviations, por sus siglas en inglés.

<sup>2</sup>En *Hierarchical Grouping to Optimize an Objective Function* por Ward (1963).

Como se puede observar en la Figura 3.2, con cada método de enlace se generaron distintos resultados, los cuales se pueden resumir como sigue:

- En el conjunto A los datos se clasificaron en tres grupos y debido al ruido entre ellos el método *single* no logró clasificar bien y utilizando este método se obtuvieron dos grupos con una sola observación. El resto de los métodos lo realizó de forma satisfactoria.
- Dado que la forma de los datos en el conjunto B no es elíptica, todos los métodos a excepción del *single* tienen problemas con la clasificación. Sin embargo, el método *Average* casi logra una clasificación correcta, a excepción de un conjunto de puntos naranjas en el triángulo de abajo.
- Debido a que no hay ruido entre grupos en el conjunto C, el método *single* es el que logra una mejor clasificación.
- Para el conjunto D, los métodos que realizan bien la clasificación son el *single* y el *ward*, esto puede ser debido a la forma de los datos y a que no hay ruido entre grupos.

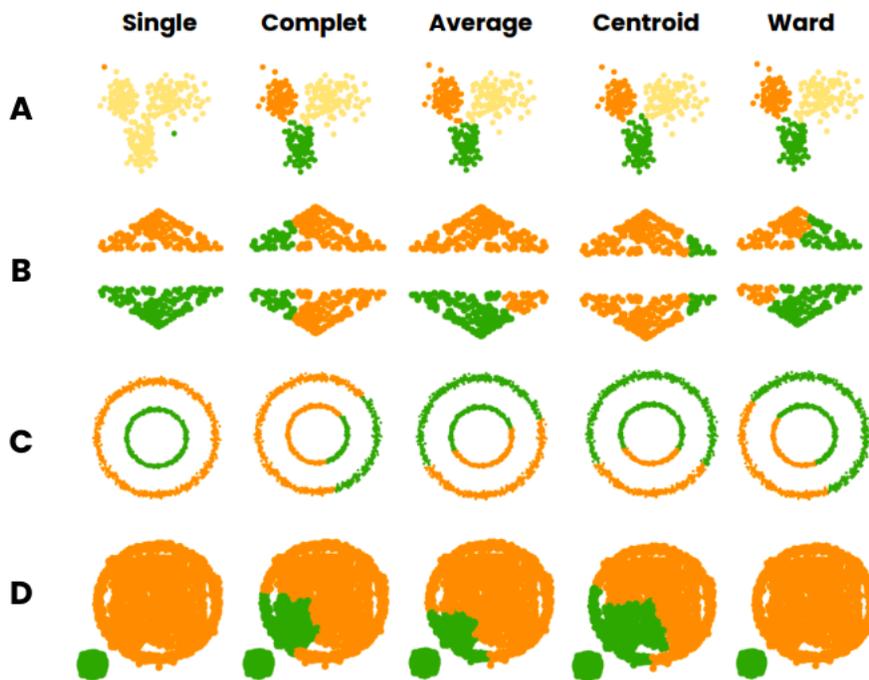


Figura 3.2: Ilustración de los distintos conglomerados obtenidos después de aplicar los métodos de enlace utilizando la distancia euclidiana para cuatro conjuntos de datos simulados. El conjunto A está compuesto de 3 nubes de puntos con ruido entre ellos. El conjunto B está conformado por dos triángulos, uno de ellos es un reflejo del otro y están dispuestos con separación entre sí. El conjunto C contiene dos circunferencias, una adentro de otra y separadas entre sí. El conjunto D exhibe dos círculos rellenos de puntos, colocados con cierta separación. Imagen de autoría propia.

Como se ilustró a través de este ejercicio, cada método de enlace tiene sus ventajas y desventajas, y dependiendo del caso de uso variará el método que se deba implementar. Es importante recordar que en la práctica no es común ver conjuntos de datos con tan sólo dos dimensiones, ni en donde los grupos se puedan diferenciar tan fácilmente a simple vista, así que se procede a explorar los diferentes métodos de enlaces y analizar los resultados.

### 3.1.3. Elección del número de conglomerados

Usualmente en las aplicaciones de la vida real el número de grupos  $k$  es desconocido, por lo que determinarlo es un problema fundamental en el análisis de conglomerados. Desafortunadamente no hay una respuesta definitiva para esta interrogante, el número óptimo de grupos resulta ser subjetivo y depende del contexto. En muchas aplicaciones lo importante es que los grupos sean interpretables y útiles.

Para el método jerárquico la solución más simple consiste en inspeccionar el dendrograma resultante para ver si sugiere un número particular de grupos, sin embargo, esto también es arbitrario ya que muchas veces depende de quien lo mire. Por lo tanto, para resolver esta cuestión se han desarrollado distintos métodos, entre los más populares se encuentran el del codo, la silueta y el estadístico Gap. Según Kassambara (2017), adicionalmente a estos hay más de treinta métodos que han sido publicados. En esta sección se explicarán los tres antes mencionados.

#### Método del codo

Sea  $\{X_{ij}\}$ ,  $i = 1, 2, \dots, n$ ,  $j = 1, 2, \dots, p$ , un conjunto de datos con  $n$  observaciones y  $p$  características, agrupados en  $k$  conglomerados  $C_1, C_2, \dots, C_k$ , donde  $C_r$  denota el conglomerado  $r$  y  $c_r$  a su centroide. Denotemos por  $d(i, c_r)$  a la distancia euclidiana entre la observación  $i$  y el centroide  $c_r$ , entonces:

$$D_r = \left( \sum_{i \in C_r} d(i, c_r) \right)^2 \quad (3.2)$$

es la suma al cuadrado de las distancias de todos los puntos de  $C_r$  a su centroide. Y se define  $WSS$  como:

$$WSS = \sum_{r=1}^k (D_r), \quad (3.3)$$

es decir, la suma de todas las  $D_r$ 's.

Por lo tanto,  $WSS$ <sup>3</sup> mide la compacidad entre los conglomerados y por consiguiente se quiere que esta sea lo más pequeña posible. Lógicamente, mientras más grupos haya, más pequeña será, entonces ¿Cómo elegir hasta qué  $k$  detenerse?. El método del codo, desarrollado por Thorndike en 1953, responde a esta interrogante. Consiste en ver a la  $WSS$  como función del número de conglomerados  $k$  y elegir la  $k$  tal que al añadir otro conglomerado  $WSS$  no disminuya considerablemente, del tal forma que en ese punto se vea una forma similar a la de un codo (Ver Figura 3.3).

<sup>3</sup>Within-clúster sum of squares, por sus siglas en inglés

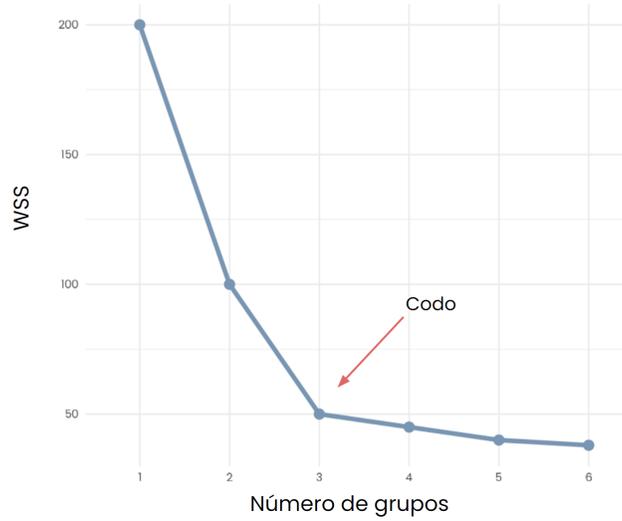


Figura 3.3: Ejemplo del método del codo, donde se determina que el número de conglomerados es tres.

### Método de la silueta

Este método fue propuesto por Rousseeuw en 1987. Consiste en tener  $\{X_{ij}\}$ ,  $i = 1, 2, \dots, n$ ,  $j = 1, 2, \dots, p$ , un conjunto de datos con  $p$  características y  $n$  observaciones, escalados y agrupados en  $k$  conglomerados  $C_1, C_2, \dots, C_k$ , donde el conglomerado  $r$  se denota con  $C_r$  y su cardinalidad  $|C_r| = n_r$ .

Denotemos por  $d(i, i')$  a la distancia euclidiana entre las observaciones  $i$  e  $i'$ , entonces si  $i$  es un punto en el conglomerado  $C_r$ :

$$a_i = \left( \sum_{i' \in C_r} d(i, i') \right) \frac{1}{n_r} \quad (3.4)$$

es el promedio de las distancias entre  $i$  y todos los puntos en el conglomerado  $r$ . Y

$$b_i = \min \left\{ \left( \sum_{j \in C_s} d(i, j) \right) \frac{1}{n_s} \mid C_s \neq C_r \right\} \quad (3.5)$$

es el promedio de las distancias entre  $i$  y todos los puntos del conglomerado  $C_s$  más cercano a  $C_r$ .

Entonces, el ancho de la silueta para el punto  $i$  se define como  $S_i = \frac{(b_i - a_i)}{\max(a_i, b_i)}$ , donde  $S_i \in [-1, 1]$  y se puede interpretar como sigue:

- Si  $S_i$  es cercano a 1 significa que la observación  $i$  está bien agrupada.
- Si  $S_i$  es cercano a 0 significa que la observación  $i$  se encuentra entre dos conglomerados.
- Si  $S_i$  resulta negativo significa que la observación  $i$  probablemente está mal agrupada.

Por lo que  $S_i$  mide que tan bien el objeto  $i$  coincide con su conglomerado asignado y se quiere que en promedio el ancho de la silueta de cada conglomerado sea tan amplio como

sea posible. Este se define como el promedio de  $S_i$  para todos los objetos  $i$  pertenecientes a ese conglomerado. Finalmente, se puede considerar el promedio general del ancho de la silueta como el promedio de los  $S_i$  para todos los objetos  $i$  en el conjunto de datos. En general, para diferentes valores de  $k$  se tendrán distintos promedios generales  $\bar{s}(k)$ . Una forma de elegir la  $k$  adecuada es seleccionando aquella  $k$  cuyo valor  $\bar{s}(k)$  sea el más grande posible.

### Método del estadístico Gap

Supongamos que se tiene un conjunto de datos  $\{X_{ij}\}$ ,  $i = 1, 2, \dots, n$ ,  $j = 1, 2, \dots, p$ , con  $n$  observaciones y  $p$  características, agrupados en  $k$  conglomerados  $C_1, C_2, \dots, C_k$ , donde  $C_r$  denota el conglomerado  $r$  y  $n_r$  la cardinalidad de cada conglomerado. Sea  $d(i, i')$  la distancia euclidiana entre las observaciones  $i$  e  $i'$ , entonces:

$$D_r = \sum_{i, i' \in C_r} d(i, i') \quad (3.6)$$

es la suma de las distancias entre todas las parejas de puntos en el conglomerado  $r$ . Con lo cual se obtiene:

$$W_k = \sum_{r=1}^k \frac{1}{2n_r} D_r. \quad (3.7)$$

A grandes rasgos, la idea de este método es estandarizar la gráfica de  $\log(W_k)$  comparando el cambio de dispersión dentro del conglomerado y el cambio esperado bajo una distribución de referencia. Donde el número óptimo de conglomerados es el valor de  $k$  para el cual el  $\log(W_k)$  caiga lo más alejado posible por debajo de esta curva de referencia. Entonces, la estadística Gap se define como:

$$Gap(k) = E_n^*\{\log(W_k)\} - \log(W_k), \quad (3.8)$$

donde  $E_n^*$  denota el  $\log(W_k)$  bajo la distribución de referencia. El  $k$  elegido será aquel que maximice el valor de  $Gap_n(k)$ .

Respecto a la distribución de referencia, la manera más simple de crearla es hacerlo con una distribución uniforme, donde el máximo y el mínimo de la distribución estarán dados por el máximo y el mínimo de los puntos observados.<sup>4</sup>  $E_n^*\{\log(W_k)\}$  se estima realizando  $B$  copias de la distribución de referencia y obteniendo el promedio del  $\log(W_k)$ . Y finalmente, se elige la  $k$  más pequeña tal que  $Gap(k) \geq Gap(k+1) - s_{k+1}$ . Este método fue desarrollado por Tibshirani et al. (2001) como una alternativa al método del codo.

Para el experimento práctico de este trabajo, la intención es probar con todas las  $k$ 's sugeridas por estos métodos, aunque la elección final estará relacionada con el objetivo de construir estratos que reduzcan el ECM de los estimadores.

## 3.2. Análisis de conglomerados jerárquico con restricciones espaciales usando el método Ward

En algunos problemas de conglomerados es importante aplicar restricciones sobre las posibles soluciones. El tipo más común es la de contigüidad (sobre espacio o tiempo), tales

<sup>4</sup>Otra elección para la distribución de referencia se puede consultar en Tibshirani et al. (2001).

restricciones ocurren cuando los objetos en un conglomerado no sólo necesitan ser similares entre ellos sino también abarcar un conjunto contiguo de objetos.

Para definir qué es un conjunto contiguo, es necesario primero considerar la contigüidad entre cada par de objetos, la cual está dada por una matriz  $\mathbf{C} = (c_{ij})_{n \times n}$  donde  $c_{ij} = 1$  si  $i$  y  $j$  son contiguos y 0 si no. Así, un conglomerado  $C$  es contiguo si existe un camino entre cualquier par de objetos en  $C$ .

En Chavent et al.(2018) se desarrolló un algoritmo de conglomerados jerárquico que incluye restricciones espaciales. Este se emplea usando el método de enlace Ward, dos matrices de distancias (no necesariamente euclidianas)  $D_0$  y  $D_1$ , un parámetro de mezcla  $\alpha \in [0, 1]$  y pesos para las observaciones  $w_i$  (los cuales pueden no ser uniformes). La primera matriz corresponde a las distancias usando las  $p$  características antes descritas y la segunda a las distancias geográficas, por ejemplo la de contigüidad. El parámetro de mezcla  $\alpha$  establece la importancia de las restricciones geográficas, cuando  $\alpha$  incrementa, se le da más importancia a las distancias en  $D_1$  y viceversa. La idea es determinar un valor de  $\alpha$  el cual incremente la contigüidad espacial sin deteriorar demasiado la calidad de la solución con base en las otras variables de interés.

Sea  $\{X_{il}\}$  un conjunto de  $n$  observaciones y  $p$  características ( $l = 1, \dots, p$ ), donde  $w_i$  es el peso de la  $i$ -ésima observación para  $i = 1, 2, \dots, n$ . Consideremos dos matrices de distancias:  $D_0 = [d_{0,ij}]$  y  $D_1 = [d_{1,ij}]$ ,  $i, j = 1, \dots, n$ . Para un valor dado de  $\alpha$  el algoritmo funciona como sigue, considerando que la partición en  $k$  grupos será indexada por:  $\mathcal{C}_k^\alpha$ .

**Definición 3.2.1** La pseudoinerencia mezclada del conglomerado  $C_k^\alpha$  (llamada inercia mezclada de aquí en adelante) se define como:

$$I_\alpha(C_k^\alpha) = (1 - \alpha) \sum_{i \in C_k^\alpha} \sum_{j \in C_k^\alpha} \frac{w_i w_j}{2\mathcal{M}_k^\alpha} d_{0,ij}^2 + \alpha \sum_{i \in C_k^\alpha} \sum_{j \in C_k^\alpha} \frac{w_i w_j}{2\mathcal{M}_k^\alpha} d_{1,ij}^2. \quad (3.9)$$

En donde  $\mathcal{M}_k^\alpha = \sum_{i \in C_k^\alpha} w_i$ , es la suma de los pesos de todos los elementos en el conglomerado  $C_k^\alpha$  y  $d_{0,ij}$  ( $d_{1,ij}$ ) es la distancia normalizada entre las observaciones  $i$  y  $j$  en  $D_0$  ( $D_1$ ).

Entonces, cuando los pesos son uniformes ( $w_i = \frac{1}{n}$ ), la pseudoinerencia queda definida como:

$$I_\alpha(C_k^\alpha) = (1 - \alpha) \sum_{i \in C_k^\alpha} \sum_{j \in C_k^\alpha} \frac{1}{2n|C_k^\alpha|} d_{0,ij}^2 + \alpha \sum_{i \in C_k^\alpha} \sum_{j \in C_k^\alpha} \frac{1}{2n|C_k^\alpha|} d_{1,ij}^2. \quad (3.10)$$

Ya que:

$$\mathcal{M}_k^\alpha = \sum_{i \in C_k^\alpha} W_i = \frac{|C_k|}{n}, \quad (3.11)$$

y por lo tanto:

$$\frac{w_i w_j}{2\mathcal{M}_k^\alpha} = \frac{\frac{1}{n^2}}{\frac{2|C_k|}{n}} = \frac{n}{2n^2|C_k|} = \frac{1}{2n|C_k|}. \quad (3.12)$$

**Definición 3.2.2** La pseudoinercia mezclada de la partición  $\mathcal{P}_k^\alpha = (C_1^\alpha, \dots, C_k^\alpha)$  es la suma de la inercia mezclada de sus conglomerados:

$$W_\alpha(\mathcal{P}_k^\alpha) = \sum_{k=1}^K I_\alpha(C_k^\alpha). \quad (3.13)$$

Para obtener una nueva partición  $\mathcal{P}_k^\alpha$  con  $k$  grupos a partir de la partición  $\mathcal{P}_{k+1}^\alpha$ , la idea es agregar dos conglomerados  $A$  y  $B$  de  $\mathcal{P}_{k+1}^\alpha$  tal que la partición resultante tenga la mínima inercia mezclada. Así, la optimización del problema puede ser expresada como sigue:

$$\min_{A, B \in \mathcal{P}_{k+1}^\alpha} I_\alpha(A \cup B) - I_\alpha(A) - I_\alpha(B). \quad (3.14)$$

### 3.2.1. Algoritmo

- Paso  $k = n$ : inicialización.  
Las distancias se pueden reescalar entre 0 y 1 para que tengan el mismo orden de magnitud.  
La partición inicial  $\mathcal{P}_n^\alpha =: \mathcal{P}_n$  en  $n$  conglomerados (es decir, donde cada conglomerado contiene una observación) es única y por lo tanto no depende de  $\alpha$ .
- Paso  $k = n-1, \dots, 2$ : se obtiene la partición en  $k$  conglomerados a partir de la partición de  $k+1$  conglomerados.  
En cada paso  $k$ , el algoritmo agrega dos conglomerados  $A$  y  $B$  de  $\mathcal{P}_{k+1}^\alpha$  de acuerdo con el problema de optimización en 3.14 de tal forma que, de todas las uniones posibles, la unión seleccionada tenga la inercia mezclada más pequeña.  
Más precisamente el algoritmo agrega dos conglomerados  $A$  y  $B$  tal que la medida de agregación correspondiente

$$\delta_\alpha(A, B) := W_\alpha(\mathcal{P}_{k+1}^\alpha) - W_\alpha(\mathcal{P}_k^\alpha) = I_\alpha(A \cup B) - I_\alpha(A) - I_\alpha(B) \quad (3.15)$$

sea mínima.

- Paso  $k = 1$ : detener. Se obtiene la partición en un conglomerado  $\mathcal{P}_1^\alpha =: \mathcal{P}_1$ . Nótese que dicha partición es única y no depende de  $\alpha$ .

#### Observaciones.

- El algoritmo previo difiere de aplicar directamente el método de Ward a la matriz obtenida a través de la combinación  $D_\alpha = (1 - \alpha)D_0 + \alpha D_1$ .  
El beneficio principal del algoritmo propuesto por Chavent et al. (2018) es que el parámetro de mezcla  $\alpha$  controla la parte de la inercia entre  $D_0$  y  $D_1$  en la ecuación 3.2.2. Este no es el caso cuando se aplica directamente el método de Ward a  $D_\alpha$  ya que este está basado en una única inercia.
- Cuando  $\alpha = 0$  ( $\alpha = 1$ ) el algoritmo jerárquico sólo está basado en la matriz de distancias  $D_0$  ( $D_1$ ). Un procedimiento propuesto para determinar el valor apropiado para  $\alpha$  se puede encontrar en *ClustGeo: an R package for hierarchical clustering with spatial constraints* de Chavent et al. (2018). Sin embargo, en este trabajo se aprovechará el poder computacional y se probará con una malla para distintos valores de  $\alpha$ .

## Capítulo 4

# Clasificación de los municipios de los Estados Unidos Mexicanos a través del método de conglomeración jerárquica con restricciones espaciales

En este capítulo se presenta el resultado de aplicar el método de conglomerados jerárquico con restricciones espaciales para crear una estratificación de los municipios de los Estados Unidos Mexicanos que tomó en cuenta tanto características sociodemográficas como geográficas. Esto con la motivación de crear estratos de muestreo a nivel nacional como los que el INEGI obtiene en la primera etapa de su estratificación para el diseño de muestreo de su Muestra Maestra, es decir, cuando se crean los cuatro estratos sociodemográficos: bajo, medio bajo, medio alto y alto. Se trabajó con la información de los municipios existentes hasta el 2020 según el Censo de Población y Vivienda realizado por el INEGI ese mismo año.

Como se detalló en la sección anterior, para poder utilizar el algoritmo de conglomerados jerárquico con restricciones espaciales son necesarias dos matrices: una que posea las distancias entre las características sociodemográficas y otra que incluya las distancias geográficas. Primero se explicará cómo se seleccionaron y procesaron los datos para las características sociodemográficas.

### 4.0.1. Características sociodemográficas

Para las características sociodemográficas fueron utilizadas las siguientes bases de datos:

- **Indicadores de Pobreza Municipal 2015**<sup>1</sup>. Esta base fue creada por el CONEVAL y es la segunda edición, teniendo como predecesor los Indicadores de Pobreza Municipal 2010. Los indicadores sirven para dar cuenta de la situación de pobreza que existe en el país, los cuales son una herramienta útil par el diseño y la evaluación de

---

<sup>1</sup>Disponible en: <https://www.coneval.org.mx/Medicion/Paginas/PobrezaInicio.aspx>

políticas públicas destinadas a la superación de la pobreza acorde con las características de cada región (CONEVAL, 2018, pag 8). La base de datos está constituida por 37 variables y 2,457 municipios.

- **Principales Resultados por Localidad del Censo de Población y Vivienda 2020<sup>2</sup>.** Estos resultados surgen del Censo de Población y Vivienda, realizado por el INEGI, el cual es el proyecto estadístico de mayor relevancia en el país, pues es la fuente con mayor nivel de desagregación geográfica que proporciona información sobre la dimensión, estructura y distribución en el territorio nacional de la población, y permite cuantificar las viviendas y sus características (INEGI, 2021 a, pag 11). La base de datos contiene los resultados del Censo a nivel localidad y municipal y consta de 232 variables y 2,469 municipios.

La base de datos de los Principales Resultados por Localidad, como su nombre lo dice, se encuentra desglosada a nivel localidad, pero también contiene información a nivel municipal, así que esta base se filtró para conservar únicamente la información de los 2,469 municipios.

Para unir las dos bases se utilizó el nombre de cada estado y municipio como llave primaria, por lo cual fue necesario limpiar estos nombres.

### **Limpieza de datos**

En ambas bases de datos se limpiaron los nombres de los estados y municipios, ya que en muchos casos no coincidían y, sin embargo, se trataba de los mismos, por ejemplo: *Distrito Federal* y *Ciudad de México*. Esta limpieza incluyó la sustitución de abreviaciones en los nombres, por ejemplo: *Gral. Bravo* por *General Bravo*.

Fueron limpiados cuatro nombres de entidades federativas y 31 nombres de municipios para que las bases pudieran ser unidas.

### **Imputación de datos faltantes**

Como se mencionó anteriormente, se trabajó con la información de los municipios creados hasta el 2020 según el Censo de Población y Vivienda de dicho año, sin embargo, de 2015 a 2020 se crearon 12 municipios, por lo que estos no aparecen en los Indicadores de Pobreza Municipal 2015, pero sí en el Censo 2020 del INEGI, mismos que se pueden consultar en el Tabla 4.1. Dado que estos municipios fueron creados a partir de la partición y fusión de otros, se decidió imputar la información en los Indicadores de Pobreza realizando un promedio de los valores de aquellos municipios de los que provienen.<sup>3</sup>

Así mismo existen 11 municipios en la base de datos de los Indicadores de Pobreza que no contienen información (ver Tabla 4.2). Para imputarla, se promedió la información de los municipios circundantes.

---

<sup>2</sup>Disponible en: <https://www.inegi.org.mx/programas/ccpv/2020/>

<sup>3</sup>Esta información se obtuvo consultando <https://www.inegi.org.mx/app/ageeml/>

## Procesamiento de variables

Puesto que la mayoría de los datos se muestran en totales absolutos, es difícil hacer comparaciones entre los municipios y por consiguiente se eligió convertir los datos a proporciones. Para la creación de las proporciones en los Indicadores de Pobreza se dividió la información de cada variable entre la población total del respectivo municipio. Sin embargo, en los datos del Censo no todas las variables tienen la misma población de referencia, por lo que cada una se dividió entre el total que hiciera sentido. Por ejemplo, la *población de 12 años o más* se dividió entre la *población total*, mientras que el *total de viviendas habitadas* se dividió entre el *total de viviendas*. En el caso de las variables asociadas a promedios como el *grado promedio de escolaridad*, las variables se normalizaron restándoles el valor mínimo y dividiéndolas entre el rango para que así todos los datos de las variables estuvieran escalados entre 0 y 1.

### Municipios creados de 2015 a 2020

Estado	Municipio	Estado de origen	Municipio(s) de origen
Baja California	San Quintín	Baja California	Ensenada
Campeche	Seybaplaya	Campeche	Champotón Campeche
Chiapas	Capitán Luis Ángel Vidal	Chiapas	Siltepec
Chiapas	Rincón Chamula San Pedro	Chiapas	Jitotol Rayón Tapilula Pueblo Nuevo - Solistahuacán
Chiapas	El Parral	Chiapas	Villaflores Villa Corzo
Chiapas	Emiliano Zapata	Chiapas	Venustiano Carranza Chiapa de Corzo Acala
Chiapas	Mezcalapa	Chiapas	Ocozocoautla de Espinosa Tecpatán Ostuacán
Chiapas	Honduras de la Sierra	Chiapas	Siltepec
Morelos	Coatetelco	Morelos	Miacatlán
Morelos	Xoxocotla	Morelos	Puente de Ixtla
Morelos	Hueyapan	Morelos	Tetela del Volcán
Quintana Roo	Puerto Morelos	Quintana Roo	Benito Juárez

Tabla 4.1: Municipios nuevos que aparecen en la información del Censo, pero no en los Indicadores de pobreza municipal.

**Municipios sin información**

<b>Estado</b>	<b>Municipio</b>	<b>Estado</b>	<b>Municipios vecinos</b>
Chihuahua	Buenaventura	Chihuahua	Ascensión Nuevo Casas Grandes Galeana Ignacio Zaragoza Namiquipa Chihuahua Ahumada
Chihuahua	Carichí	Chihuahua	Guerrero Bocoyna Guachochi Nonoava San Francisco de Borja Cusihuirachi
Chihuahua	Santa Isabel	Chihuahua	Chihuahua Riva Palacio Cauhtémoc Gran Morelos Dr. Belisario Domínguez Satevó
Chihuahua	Temósachic	Chihuahua	Madera Moris Ocampo Guerrero Matachí Namiquipa Gómez Farías
		Sonora	Sahuaripa Yécora
Chihuahua	Urique	Chihuahua	Guazapares Batopilas de Manuel - Gómez Morín Guachochi Bocoyna Maguarichi Choix

Estado	Municipio	Estado	Municipios vecinos
Oaxaca	Matías Romero Avendaño	Veracruz	Jesús Carranza
		Oaxaca	San Juan Cotzocón San Juan Mazatlán San Juan Guichicovi Santa María Petapa El Barrio de la Soledad Santa María Chimalapa
Oaxaca	San Francisco Chindúa	Oaxaca	San Pedro Topiltepec Santiago Nejapilla Santo Domingo - Tlatayápam San Francisco Nuxaño San Miguel Tecamatlán San Mateo Etlatongo San Juan Sayultepec
Oaxaca	Santa María Chimalapa	Oaxaca	Matías Romero Avendaño El Barrio de la Soledad Asunción Ixtaltepec San Miguel Chimalapa
		Chiapas	Cintalapa
		Veracruz	Las Choapas Uxpanapa Jesús Carranza
Oaxaca	Santa María Petapa	Oaxaca	Matías Romero Avendaño San Juan Guichicovi Santo Domingo Petapa El Barrio de la Soledad
Puebla	San Nicolás de los Ranchos	Estado de México	Amecameca Atlautla
		Puebla	Tochimilco Tianguismanalco Nealtican Calpan Huejotzingo
Sonora	Plutarco Elías Calles	Sonora	Puerto Peñasco Caborca

Tabla 4.2: Municipios en los Indicadores de pobreza municipal que no contienen información.

## Elección de las variables sociodemográficas

Para la elección de las variables sociodemográficas fueron tomados en cuenta los indicadores empleados en la estratificación de la Muestra Maestra 2010 ver INEGI (2019, pag 57) los cuales fueron los siguientes:

<b>Mnemónico</b>	<b>Descripción</b>
<b>Proporción de Población</b>	
PPSSNOSP	Que tiene derecho a recibir servicios médicos en alguna institución de salud pública o privada excepto seguro popular.
PPDER_SS	Derechohabiente a servicios de salud.
PDP3A14A	De 3 a 14 años de edad que asiste a la escuela.
PDP15A24A	De 15 a 24 años de edad que asiste a la escuela.
PDP8A14ALF	De 8 a 14 años de edad que saben leer o escribir.
PDP15YM_SE	De 15 años o más de edad que aprobaron algún grado de escolaridad diferente al nivel preescolar.
PP15PRI_CO	De 15 años o más de edad que tienen como máxima escolaridad 6 grados aprobados en primaria.
PP15SEC_CO	De 15 años o más de edad que tienen como máxima escolaridad 3 grados aprobados en secundaria.
PGDO_ESC	Grado promedio de escolaridad.
PPEA	De 12 años y más que trabajaron; tenían trabajo pero no trabajaron o; buscaron trabajo en la semana de referencia.
PPEA_F	Femenina de 12 años y más que trabajaron; tenían trabajo pero no trabajaron o; buscaron trabajo en la semana de referencia.
PTASAOCUPA	Tasa de ocupación.
TOCU12A17	No ocupada de 12 a 17 años de edad entre la población de 12 a 17 años de edad.
PPOMAYED	Ocupada de 18 y más años de edad entre la población ocupada.
<b>Proporción de Viviendas Particulares Habitadas</b>	
PVIVSINH	Que no tienen hacinamiento.
PVPH_PISDT	Que tienen piso de cemento o firme, madera, mosaico u otro material.
PVPH2YMASD	Que usan para dormir entre 2 y 25 cuartos.
PVPH_2MASC	Que tienen más de un cuarto.
PVPH3YMASC	Que tienen entre 3 y 25 cuartos.
PVPH_C_ELE	Que disponen de luz eléctrica.
PVPHAGUADV	Que tienen disponibilidad de agua entubada dentro de la vivienda,
PVPHAGUADV	o fuera de la vivienda pero dentro del terreno.
PVPH_EXCSA	Que tienen excusado, retrete, sanitario, letrina u hoyo negro.
PVPHDRENAJ	Que tienen drenaje conectado a la red pública, fosa séptica, barranca, grieta, río, lago o mar.
PVDRERED	Que disponen de drenaje conectado a la red pública.
PVEXCAGU	Que disponen de excusado con descarga directa de agua.
PVPH_CSERV	Que disponen de luz eléctrica, agua entubada dentro o fuera de la vivienda, pero dentro del terreno, así como drenaje.
PSIN_HASIN	Que no se encuentran en situación de hacinamiento a nivel manzana.
<b>Proporción de Viviendas Particulares Habitadas que disponen de:</b>	
PVPH_TV	Televisor.
PVPH_AUTOM	Automóvil o camioneta.
PVPH_CEL	Teléfono celular.
PVCELFIJ	Teléfono celular y teléfono fijo.
PV4ELEC	Radio, televisor, refrigerador y lavadora.
PVRADTEL	Radio y televisor.
PVPHCBEN	Todos los bienes.

Tabla 4.3: Indicadores utilizados en la Muestra Maestra 2010.

Sin embargo, para fines de esta tesis sólo se incluyeron algunos, ya que se le otorgó importancia a también representar diversos grupos vulnerables en la población, por ejemplo: población en situación de pobreza, población vulnerable, población de la tercera edad, población que habla alguna lengua indígena, población afroamericana, población con discapacidad o limitación, y población con rezago educativo. Así como también fueron tomadas en cuenta variables de interés popular como: viviendas con acceso a internet o viviendas con teléfono celular. Las variables elegidas, 45 en total, se muestran en la Tabla 4.4, donde también se presentan algunas estadísticas considerando el procesamiento antes descrito.

Nombre de Variable	Descripción	Media	Desviación Estándar	Rango
pobreza_pob	Población en situación de pobreza	0.66	0.21	(0.03 - 1)
pobreza_e_pob	Población en situación de pobreza extrema	0.2	0.18	(0 - 0.97)
pobreza_m_pob	Población en situación de pobreza moderada	0.46	0.12	(0.02 - 0.82)
vul_ing_pob	Población vulnerable por ingreso	0.04	0.04	(0 - 0.24)
nppv_pob	Población no pobre y no vulnerable	0.08	0.1	(0 - 0.66)
ic_segsoc_pob	Población con carencia por acceso a la seguridad social	0.74	0.16	(0.06 - 0.97)
ic_ali_pob	Población con carencia por acceso a la alimentación	0.24	0.12	(0 - 0.86)
carencias_pob	Población con al menos una carencia social	0.88	0.13	(0.32 - 1)
carencias3_pob	Población con al menos tres carencias sociales	0.36	0.21	(0.01 - 0.98)
plb_pob	Población con ingreso inferior a la línea del bienestar	0.69	0.19	(0.04 - 1)
plbm_pob	Población con ingreso inferior a la línea del bienestar mínimo	0.37	0.23	(0.01 - 0.99)
POB65_MAS	Población de 65 años o más	0.1	0.04	(0.01 - 0.32)
PNACOE	Población nacida en otra entidad	0.09	0.09	(0 - 0.7)
P3YM_HLI	Población de 3 años y más que habla alguna lengua indígena	0.17	0.27	(0 - 0.94)
POB_AFRO	Población que se considera afroamericana o afrodescendiente	0.02	0.07	(0 - 0.96)
PCON_DISC	Población con discapacidad	0.06	0.03	(0 - 0.32)
PCON_LIMI	Población con limitación	0.13	0.04	(0.01 - 0.37)
PCLIM_PMEN	Población con algún problema o condición mental	0.01	0	(0 - 0.05)
P15YM_AN	Población de 15 años y más analfabeta	0.07	0.05	(0 - 0.35)
P15YM_SE	Población de 15 años y más sin escolaridad	0.07	0.04	(0 - 0.28)
P15PRI_IN	Población de 15 años y más con primaria incompleta	0.11	0.04	(0 - 0.28)
P15SEC_IN	Población de 15 años y más con secundaria incompleta	0.02	0.01	(0 - 0.09)
P18YM_PB	Población de 18 años y más con educación básica	0.19	0.09	(0.01 - 0.76)
GRAPROES	Grado promedio de escolaridad	0.4	0.13	(0 - 1)
PEA	Población de 12 años y más económicamente activa	0.43	0.08	(0.05 - 0.64)
POCUPADA	Población de 12 años y más ocupada	0.42	0.08	(0.05 - 0.62)
PSINDER	Población sin afiliación a servicios de salud	0.24	0.11	(0.01 - 0.84)
PAFIL_IPRIV	Población afiliada a servicios de salud en una institución privada	0.01	0.02	(0 - 0.58)

HOGJEF_F	Hogares censales con persona de referencia mujer	0.29	0.06	(0.09 - 0.5)
PRO_OCUP_C	Promedio de ocupantes por cuarto en viviendas particulares habitadas	0.33	0.14	(0 - 1)
VPH_PISOTI	Viviendas particulares habitadas con piso de tierra	0.08	0.09	(0 - 0.67)
VPH_1CUART	Viviendas particulares habitadas con sólo un cuarto	0.08	0.06	(0 - 0.49)
VPH_S_ELEC	Viviendas particulares habitadas que no disponen de energía eléctrica	0.02	0.03	(0 - 0.49)
VPH_AGUAFV	Viviendas particulares habitadas que no disponen de agua entubada en el ámbito de la vivienda	0.06	0.09	(0 - 0.79)
VPH_NODREN	Viviendas particulares habitadas que no disponen de drenaje	0.14	0.19	(0 - 0.99)
VPH_NDEAED	Viviendas particulares habitadas que no disponen de energía eléctrica, agua entubada, ni drenaje	0.01	0.01	(0 - 0.28)
VPH_NDACMM	Viviendas particulares habitadas que no disponen de automóvil o camioneta, ni de motocicleta o motoneta	0.59	0.2	(0.04 - 0.98)
VPH_SNBIEN	Viviendas particulares habitadas sin ningún bien	0.05	0.08	(0 - 0.55)
VPH_REFRI	Viviendas particulares habitadas que disponen de refrigerador	0.74	0.21	(0.04 - 0.99)
VPH_LAVAD	Viviendas particulares habitadas que disponen de lavadora	0.56	0.24	(0 - 0.95)
VPH_TV	Viviendas particulares habitadas que disponen de televisor	0.81	0.15	(0.08 - 0.98)
VPH_PC	Viviendas particulares habitadas que disponen de computadora, laptop o tablet	0.18	0.13	(0 - 0.85)
VPH_CEL	Viviendas particulares habitadas que disponen de teléfono celular	0.73	0.18	(0.02 - 0.97)
VPH_INTER	Viviendas particulares habitadas que disponen de Internet	0.27	0.18	(0 - 0.92)
VPH_SINCINT	Viviendas particulares habitadas sin computadora ni Internet	0.68	0.18	(0.03 - 1)

Tabla 4.4: Resumen estadístico de las variables seleccionadas para usarse como características sociodemográficas.

### Breve análisis exploratorio de las variables sociodemográficas seleccionadas

Para tener una comprensión general de la base de datos se realizaron cuatro mapas a través del software *qgis* y se colorearon los municipios de acuerdo a cuatro variables: Población en situación de pobreza, población de 3 años y más que habla alguna lengua indígena, grado promedio de escolaridad y población sin afiliación a servicios de salud. Esto se hizo utilizando la clasificación por quintiles, con las proporciones obtenidas anteriormente, excepto los años promedio de escolaridad ya que esta variable es más fácil de interpretar cuando no está escalada. Además, se dan algunos comentarios sobre las variables relacionadas con las antes mencionadas.

En la Figura 4.1 se puede observar que los estados en donde la población tiene un promedio mayor de años de escolaridad son la Ciudad de México, Baja California Sur, Baja California, Tlaxcala y Quintana Roo, mientras que los que tienen menos promedio de años de escolaridad son Chiapas, Oaxaca, Guerrero, Michoacán y Puebla.

Los tres municipios en los que la población tiene, en promedio, más años de escolaridad son: Benito Juárez en Ciudad de México, San Pedro Garza García en Nuevo León y Miguel Hidalgo en Ciudad de México, con 14.55, 13.16 y 13.11 años respectivamente. En contraste los municipios en los que la población, en promedio, tiene menos años de escolaridad son: Cochoapa el Grande en Guerrero, San Martín Peras en Oaxaca y Batopilas de Manuel Gómez Morín en Chihuahua con 3.4, 3.48 y 3.59 años respectivamente.

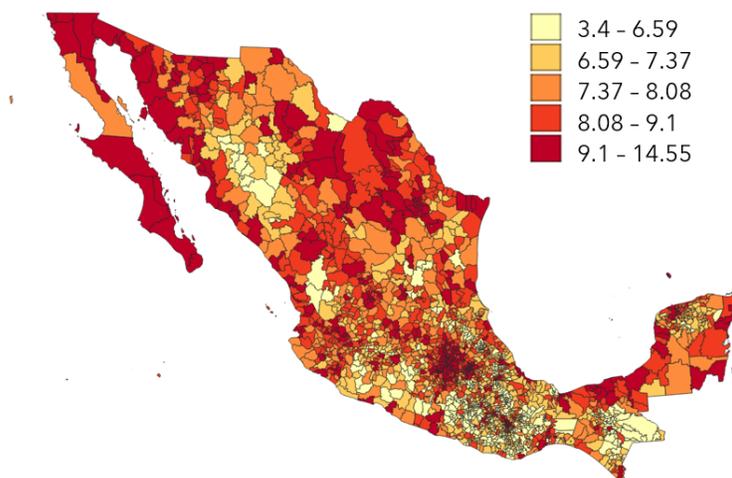


Figura 4.1: Años promedio de escolaridad.

Por su parte Santa María la Asunción en Oaxaca es el municipio del país con mayor proporción (34.61%) de población con 15 años y más analfabeta. Seguido por San Miguel Santa Flor (32.42%) también en Oaxaca y Cochoapa el Grande (28.47%) en Guerrero.

Respecto a la población de 15 años y más sin escolaridad San Miguel Santa Flor encabeza la lista, con 28.22% de su población en esta situación, seguido por Santa María la Asunción (27.92%) y San Juan Mixtepec -Dto. 26 - (27.18%), los tres municipios pertenecientes al estado de Oaxaca.

En la Figura 4.2 se puede observar que la población de 3 años y más que habla alguna lengua indígena predomina en el sur este del país, en su mayoría en los estados de Yucatán, Oaxaca y Chiapas. Mientras que en Aguascalientes menos del 0.01% de la población de 3 años y más habla alguna lengua indígena, seguido por Coahuila y Guanajuato, que también presentan una menor prevalencia en el uso de lenguas indígenas.

En 39 municipios (ver Tabla 4.5) de la República Mexicana, más del 90% de la población de 3 años y más habla alguna lengua indígena, 34 de los cuales pertenecen al estado Oaxaca, tres a Chiapas y dos a Puebla.

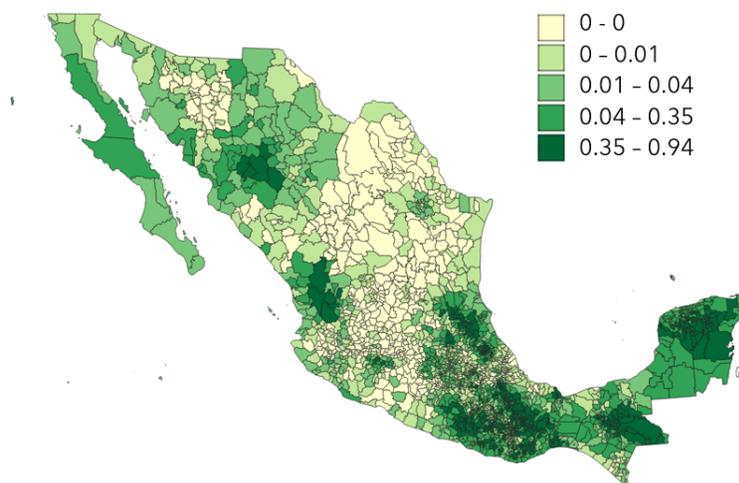


Figura 4.2: Porcentaje de población de 3 años y más que habla alguna lengua indígena.

Municipio	%	Municipio	%
<b>Chiapas</b>		San Pedro Ocoatepec	92.22
Aldama	91.17	San Pedro Quiatoni	90.47
Chamula	90.38	San Pedro Yaneri	92.39
Zinacantán	91.43	San Vicente Lachixió	90.52
<b>Oaxaca</b>		Santa Ana Yareni	91.99
Abejones	91.32	Santa Catalina Quierí	94.3
Mixistlán de la Reforma	92.72	Santa Inés Yatzeche	92.95
San Bartolomé Quialana	90.75	Santa Lucía Miahuatlán	91.82
San Francisco Logueche	90.51	Santa María Temaxcalapa	91.92
San José Lachiguiri	92.38	Santa María Texcatitlán	90.07
San Juan Mixtepec -Dto. 26 -	91.27	Santa María Tlahuitoltepec	90.04
San Juan Petlapa	91.85	Santiago Atitlán	91.45
San Juan Yaeé	92.36	Santiago Lalopa	91.65
San Juan Yatzona	93.18	Santiago Texcalcingo	90.22
San Lucas Camotlán	92.06	Santiago Yaitepec	90.22
San Lucas Quiavini	92.21	Santo Domingo Roayaga	90.01
San Martín Peras	90.33	<b>Puebla</b>	
San Mateo del Mar	90.13	Atlequizayan	90.05
San Miguel Aloápam	90.42	Camocuautla	91.59
San Miguel Quetzaltepec	92.89		
San Miguel Yotao	92.48		
San Pablo Tijaltepec	91.28		
San Pedro Mixtepec -Dto. 26 -	90.95		

Tabla 4.5: Municipios en donde más del 90% de la población de 3 años o más habla alguna lengua indígena, ordenados alfabéticamente por entidad federativa.

Respecto a la población que se considera afromexicana o afrodescendiente, ésta predomina en el estado de Oaxaca, en municipios como San Juan Bautista Lo de Soto (con 95.69% de la población considerándose así), Santa María Cortijo (93.72%) y Santiago Tápexxtla (92.85%).

Por otro lado, el 70.4% de la población en Tizayuca Hidalgo nació en otra entidad, así como 65.68% de Pueblo Viejo Veracruz y 63.34% de Hidalgo en Coahuila.

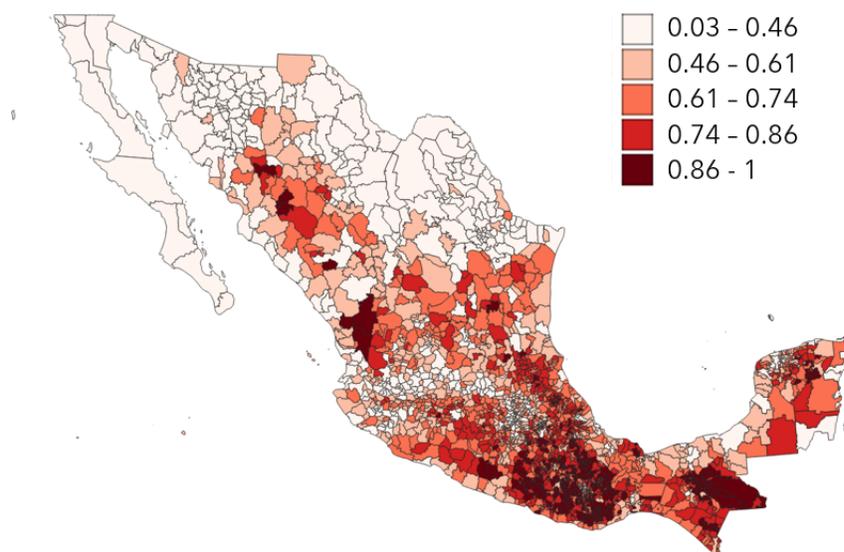


Figura 4.3: Tasa de Pobreza municipal.

La Figura 4.3 muestra la distribución de la pobreza por municipio. Siendo Baja California, Baja California Sur y Ciudad de México los estados menos pobres del país, mientras que un poco más del 50% de los municipios que componen a los estados de Chiapas y Oaxaca tienen un índice de pobreza del 0.86 al 1, es decir, más del 86% de la población en al menos la mitad de los municipios que componen a Chiapas y Oaxaca vive en situación de pobreza.

Aunado a esto, 190 municipios del país, tienen a más del 95% de su población en pobreza extrema, estos pertenecen a los estados de Oaxaca (140), Chiapas (32), Veracruz (7), Guerrero (6) y Puebla (5).

En contraste, los tres municipios con mayor porcentaje de población no pobre y no vulnerable son Benito Juárez con 66.2% de la población, seguido por Miguel Hidalgo (57.7%) y Apodaca (53.1%), los dos primeros pertenecientes a la Ciudad de México y el tercero a Nuevo León.

En la Figura 4.4 se puede observar que los estados con más población sin afiliación a los servicios de salud son: Michoacán, Hidalgo y el Estado de México. Respecto a los municipios, Santa Ana Ateixtlahuaca en Oaxaca lidera esta lista con 83.86% de sus habitantes sin acceso a servicios de salud, seguido por Santa María Ixcatlán (77.87%) y Villa Díaz Ordaz (71.93%), también en Oaxaca. En contraste, los demás municipios del país tienen menos del 66.49% de su población sin afiliación a los servicios de salud.

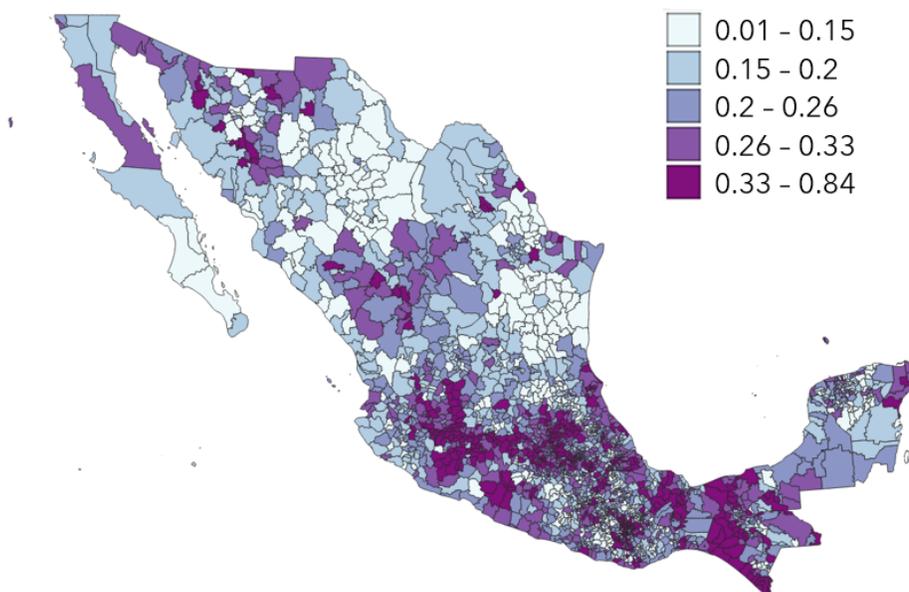


Figura 4.4: Proporción municipal de población sin afiliación a servicios de salud.

### Correlación entre las variables sociodemográficas

Por otro lado, se calculó la correlación de Pearson entre pares de variables (ver Figura 4.5). Entre algunos resultados interesantes, se encontró que existe correlación positiva de 0.78 entre las viviendas sin internet y la pobreza poblacional. La variable con la que más se correlaciona la población de 3 años y más que habla alguna lengua indígena es con la población en pobreza extrema (0.71). Y el grado promedio de escolaridad tiene un alto grado de correlación con las viviendas particulares habitadas que disponen de computadora, laptop o tablet (0.89), así como con la población no pobre y no vulnerable (0.79).

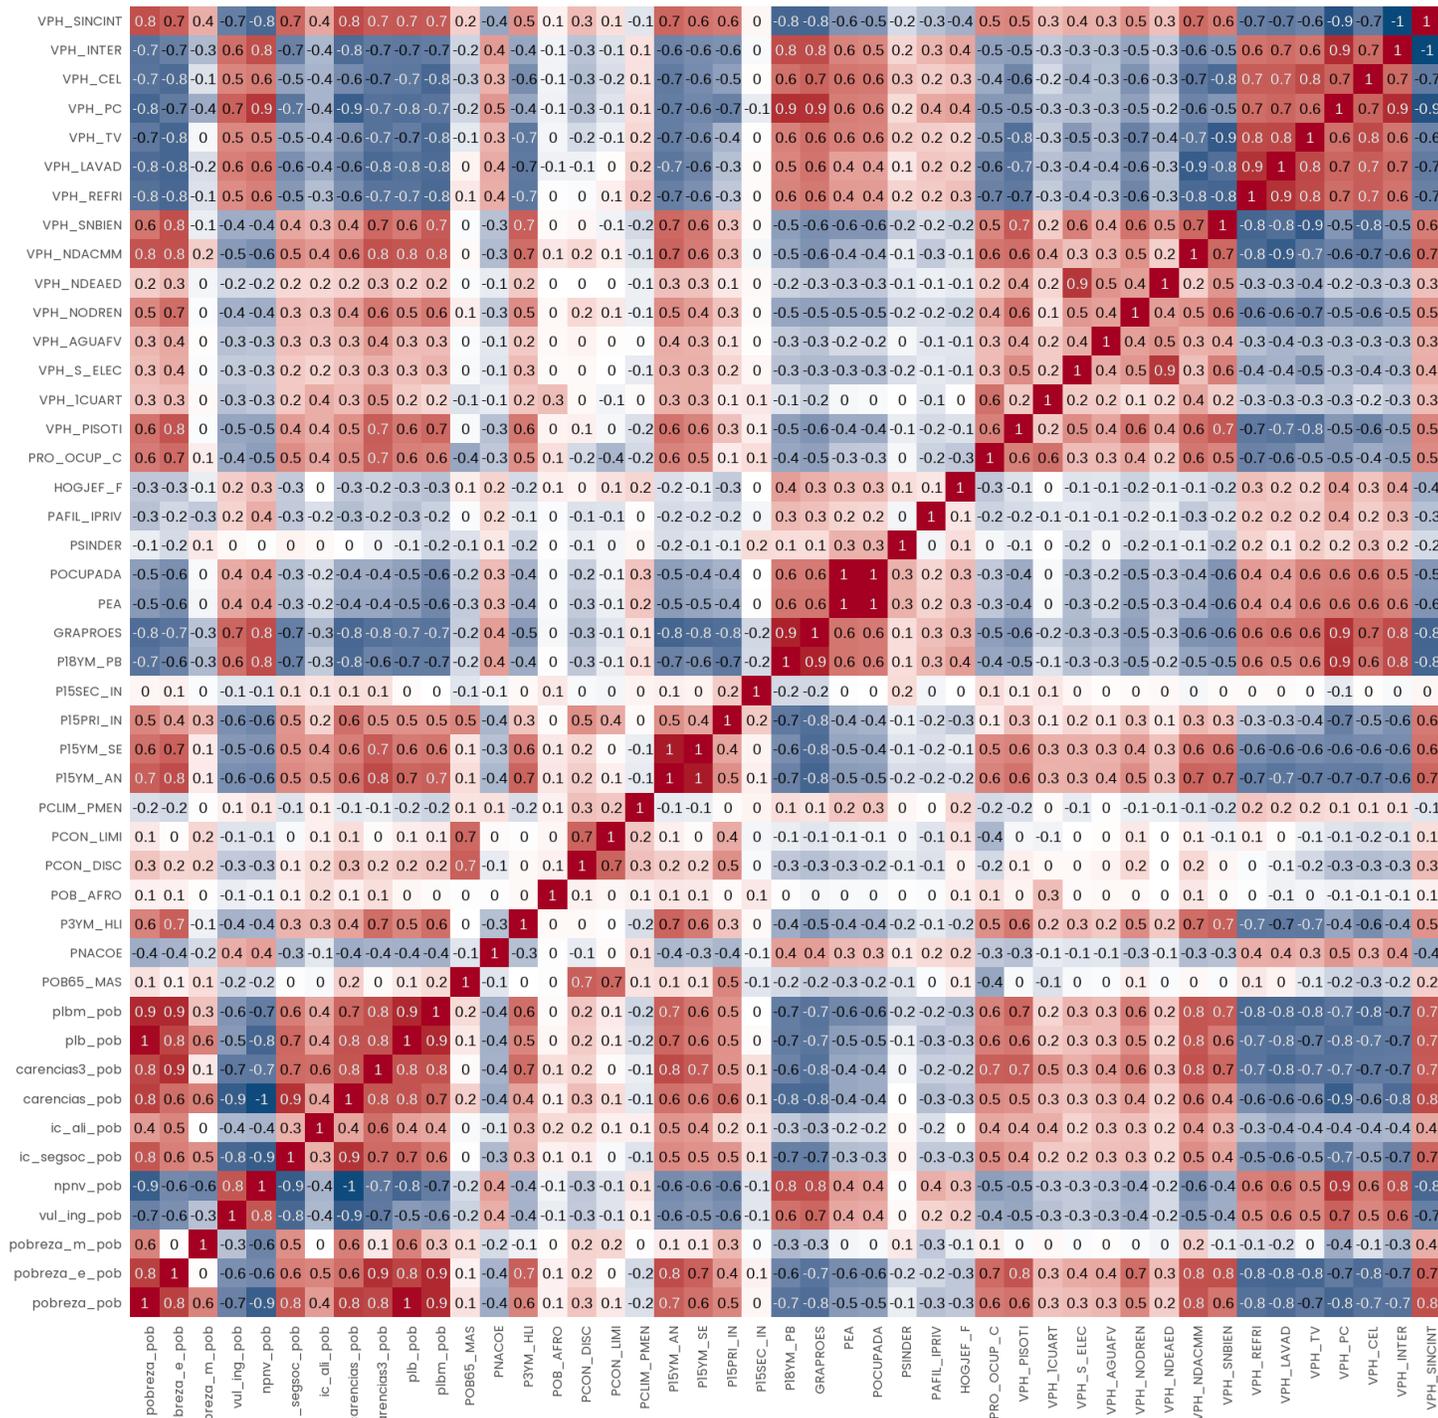


Figura 4.5: Heatmap presentando la correlación de Pearson entre pares de variables socio-demográficas. Se incluye un gradiente rojo a azul, en donde el color blanco significa que la correlación es cero, entre más rojo significa que la correlación es más positiva y entre más azul significa que la correlación es más negativa. Los datos fueron redondeados a un décimal.

## 4.0.2. Características geográficas

Para la base de datos con las ubicaciones geográficas se utilizó el Marco Geoestadístico<sup>4</sup>, desarrollado por el INEGI. El Marco Geoestadístico Nacional es un sistema único y de carácter nacional para referenciar correctamente la información estadística con los lugares geográficos correspondientes; esto se entiende como la delimitación de la República Mexicana en tres niveles de desagregación, llamadas Áreas Geoestadísticas: Estatal (AGEE), Municipal (AGEM) y Básica (AGEB) (INEGI, 2010, pag 2). En este caso fue utilizado a nivel municipal y se compone de 2,469 municipios, los mismos que aparecen en los Principales Resultados por Localidad del Censo de Población y Vivienda 2020.

Específicamente se utilizó el archivo shape que contiene la información de todos los municipios del país hasta el 2020, con 2,469 municipios en total, y a través de la librería `rgdal` (Bivand et al., 2023) estos datos fueron transformados al formato WGS84.

## 4.1. Matrices de distancias

Una vez que se definieron las características geográficas y sociodemográficas que se usarán, se procedió a calcular las matrices de sus distancias.

### 4.1.1. Distancias entre las características sociodemográficas

Para el cálculo de las distancias sociodemográficas se decidió usar la distancia euclidiana, ya que todos los datos son continuos y están escalados.

### 4.1.2. Distancias geográficas

Respecto a las distancias geográficas, se probó con dos formas distintas de determinarlas. La primera consistió en calcular la distancia euclidiana en línea recta entre los centroides de los municipios, ya que otra opción habría sido calcular las distancias entre las carreteras o caminos que conectan a los municipios, pero no se disponía de esa información. La segunda forma de calcular las distancias geográficas se basó en analizar la adyacencia entre municipios.

**Matriz de distancias euclidianas:** Se utilizó la función `st_centroid` de la librería `sf` (Pebesma, 2018) para obtener los centroides de cada municipio y luego se calculó la distancia euclidiana en metros entre cada par de centroides.

**Matriz de distancias binarias:** Para cada municipio se construyó una lista de vecinos basándose en las regiones con límites contiguos, es decir, que compartieran al menos un punto límite. Esto se hizo a través de la función `poly2nb` de la librería `spdep` (Bivand, 2022); después se creó una matriz de adyacencia utilizando la función `nb2mat` y, puesto que se consideró a cada municipio vecino de sí mismo, se colocaron unos en la diagonal. Como se quería obtener una matriz de distancias, se creó una matriz de unos y se le restó la matriz de adyacencias. De esta manera se obtuvo una matriz compuesta por ceros y unos. Así, si la entrada  $(i, j)$  es igual a 0 significa que los municipios  $i$  y  $j$  son vecinos, y si la entrada  $(i, j)$  es igual a 1 significa que no son vecinos.

<sup>4</sup>Disponible en: <https://www.inegi.org.mx/app/biblioteca/ficha.html?upc=889463807469>

## 4.2. Parámetros para el uso del algoritmo

Para el método de conglomeración jerárquica con restricciones espaciales, además de las matrices de distancias son necesarios otros tres parámetros: los pesos de las observaciones  $w_i$ ,  $i = 1, \dots, n$ , un parámetro  $\alpha \in [0, 1]$  el cual determina la importancia que se le da a las ubicaciones geográficas, y el número de grupos  $k$ . Por simplicidad se decidió darle el mismo peso  $w_i$  a todas las observaciones así que los parámetros por elegir fueron  $\alpha$  y  $k$ .

Parámetro  $\alpha$  se optó por aprovechar el poder computacional actual y probar con una malla desde  $\alpha = 0$ , hasta  $\alpha = 1$ , con brincos de 0.05, es decir, 21 valores en total. Se eligió este número ya que no se vio diferencia utilizando una malla más fina.

Para elegir el número de grupos  $k$  primero se graficó el dendrograma (Figura 4.7) en el cual se pueden observar 3, 4 o 6 grupos, sin embargo, con el fin de evitar decisiones subjetivas basadas únicamente en la observación visual del dendrograma se decidió probar con los distintos métodos previamente descritos en el capítulo 3 para tener distintas sugerencias sobre qué  $k$  usar. Para esto se utilizó únicamente la base de datos de las características sociodemográficas y la función `fviz_nbclust` de la librería `factoextra` (Kassambara et al., 2020).

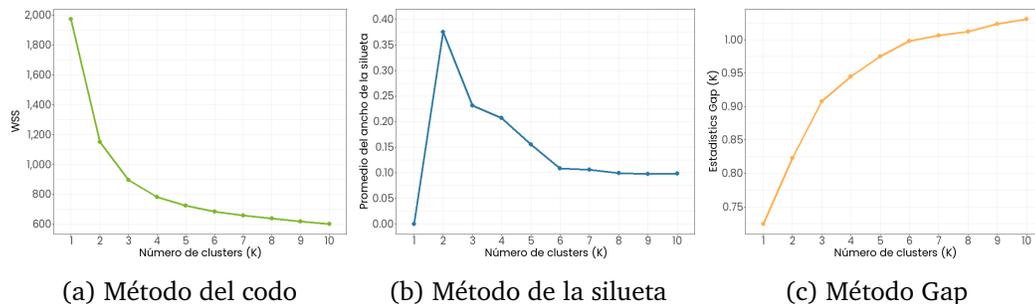


Figura 4.6: Resultados de utilizar diferentes métodos para la elección de  $k$ .

- **Método del codo**: En la Figura 4.6 (a) se puede observar que la pendiente disminuye considerablemente a partir de  $k = 4$ .
- **Método Silhouette**: Como se puede ver en la Figura 4.6 (b), el número recomendado de conglomerados por este método puede ser dos o seis.
- **Método estadística de Gap**: Como se observa en 4.6 (c), el número de grupos sugerido para este caso es  $k = 10$ .

Resumiendo los resultados, el dendrograma mostrado en la Figura 4.7 sugiere 3, 4 o 6 grupos, sin embargo, con el método del codo se sugirieron 4 grupos, con el de la silueta 2 o 6 y con el de gap 10. Como los resultados fueron muy distintos se decidió probar con  $k = 3, 4$  y  $5$ . Se eligió usar una  $k$  pequeña ya que el INEGI sólo creó cuatro estratos sociodemográficos en su Muestra Maestra de 2012.<sup>5</sup>

<sup>5</sup>Para más detalles consultar: *Cómo se hace la ENOE*, INEGI. (2019).

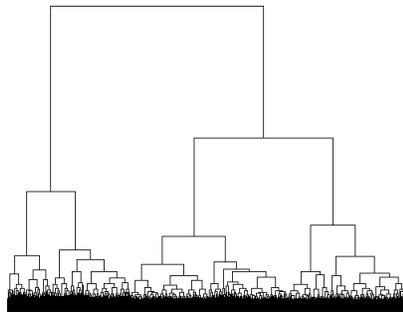


Figura 4.7: Dendrograma obtenido al aplicar el método de conglomerados jerárquico con el método de enlace ward a las características sociodemográficas, el cual sugiere utilizar 3, 4 o 6 grupos.

### 4.3. Clasificación de los municipios

Para la ejecución del algoritmo de conglomerados jerárquico se utilizó la paquetería ClustGeo (Chavent et al., 2021), empleando la función `hclustgeo` para generar el dendrograma y la función `cutree` para elegir el número de grupos. Es importante recordar que la función `hclustgeo` utiliza la distancia euclidiana, con el método de enlace ward para ejecutar el algoritmo de conglomerados jerárquico con restricciones espaciales. Como se tenían 2 matrices con distancias geográficas, 21 opciones de  $\alpha$ 's y 3 opciones para la  $k$ , el algoritmo se ejecutó de 126 formas distintas.

#### 4.3.1. Elección de los parámetros $\alpha$ y $k$

Si se tuviera acceso a los datos con los que cuenta el INEGI (en particular a los del censo), se podrían obtener muestras a nivel hogar/persona, y se evaluarían las estratificaciones emulando lo que sería el uso que tiene la Muestra Maestra (que es ser usada para conseguir muchas submuestras de viviendas/personas para encuestas sobre varios temas) y así se elegiría la mejor estratificación. Dado que eso no es posible, se decidió usar la información de las Estadísticas Censales a escala geoelectorales <sup>6</sup>, ya que es un nivel más desagregado y público que a nivel municipal, de donde se pueden tomar muestras para evaluar las estratificaciones. Para más detalles sobre la creación de esta base consultar la Metodología para el Cálculo de las Estadísticas Censales a Escalas Geoelectorales 2020 (INEGI, 2021 b).

Las Estadísticas Censales a Escala Geoelectorales contienen las mismas variables que los Principales Resultados por Localidad del Censo de Población y Vivienda 2020, pero los datos se desglosan por distritos electorales, en lugar de en localidades. Se decidió utilizar esta base porque es la información con mayor nivel de granularidad disponible y porque es una partición de los resultados a nivel municipal del Censo de Población y Vivienda 2020, en donde cada sección pertenece a un único municipio.

<sup>6</sup>Disponible en: <https://www.inegi.org.mx/programas/ccpv/2020/>

De las Estadísticas Censales se seleccionaron diez variables y se obtuvieron los estimadores de sus totales utilizando el estimador Horvitz-Thompson en muestreo estratificado con m.a.s al interior de cada estrato, para después calcular la varianza poblacional de cada estimador. Se eligió la  $\alpha$ ,  $k$  y matriz de distancias geográficas de aquella estratificación con la que se obtuvo la menor varianza.

La intención fue que las variables seleccionadas consideraran distintos grupos vulnerables, como por ejemplo: población con rezago educativo (P15PRI\_IN, P8A14AN y P15YM\_AN), población con discapacidad (PCON\_DISC), población que habla alguna lengua indígena (P3YM\_HLI), población sin afiliación a servicios de salud (PSINDER) y población en situación de pobreza (VPH\_PISODT, VPH\_S\_ELEC, VPH\_AGUAFV y VPH\_NODREN). Nótese que todas pertenecen al Censo de Población y Vivienda pues la información de los Indicadores de Pobreza sólo tienen como máximo nivel de segmentación el municipal.

La descripción de cada variable y su descripción se enlistan a continuación:

1. P15PRI\_IN: Población de 15 años o más con primaria incompleta.
2. P8A14AN: Población de 8 a 14 años que no sabe leer ni escribir.
3. P15YM\_AN: Población de 15 años o más analfabeta.
4. PCON\_DISC: Población con discapacidad.
5. P3YM\_HLI: Población de 3 años y más que habla alguna lengua indígena.
6. PSINDER: Población sin afiliación a servicios de salud.
7. VPH\_PISODT: Viviendas particulares habitadas con piso de tierra.
8. VPH\_S\_ELEC: Viviendas particulares habitadas que no disponen de energía eléctrica.
9. VPH\_AGUAFV: Viviendas particulares habitadas que no disponen de agua entubada.
10. VPH\_NODREN: Viviendas particulares habitadas que no disponen de drenaje.

Para realizar lo anterior lo primero que se hizo fue identificar a qué estratificación pertenecía cada sección geoelectoral. Ya que las claves de los municipios en las bases de datos a nivel sección y nivel municipio no coinciden, de nuevo fue necesario utilizar como llave primaria el nombre del estado y municipio, para así poder unir ambas bases y saber a qué agrupación pertenecía cada sección. Se limpiaron los nombres y se logró clasificar a 68,786 secciones. De esas, se conservaron aquellas con viviendas y población mayor a cero, es decir, 68,710 secciones.

Lo siguiente fue elegir el tamaño de muestra  $n$ , recordando que se está utilizando el estimador HT para totales con un diseño de m.a.s dentro de cada estrato, la  $n$  se puede calcular a partir de la ecuación 2.26, es decir:

$$n \geq \frac{\left(\frac{kNS_{yU}^2}{d}\right)^2}{1 + \frac{1}{N} \left(\frac{kNS_{yU}^2}{d}\right)^2}, \quad (4.1)$$

con  $k = 1.96$  y  $N = 68,710$ . Donde  $n$  corresponde al tamaño de muestra **total** en el experimento, considerando como población a las secciones geoelectorales.

Para obtener  $d$  (el error absoluto deseado) se calculó el valor real de cada variable (es decir su suma) y multiplicó por 0.05, de esta forma el error absoluto no será mayor al 5%. Los resultados de cada  $n$  sugerida para cada variable se resumen en la Tabla 4.6.

Variable	$\Sigma$	$d$	$n$
P15PRI_IN	7,726,165	386,308	1,822
P8A14AN	412,433	20,622	7250
P15YM_AN	4,451,780	222,589	3,446
PCON_DISC	6,176,499	308,825	1,488
P3YM_HLI	7,354,108	367,705	16,375
PSINDER	32,979,915	1,648,996	2,747
VPH_PISODT	33,818,918	1,690,946	2,324
VPH_S_ELEC	268,564	13,428	13,026
VPH_AGUAFV	1,215,109	60,755	15,573
VPH_NODREN	1,497,889	74,894	10,749

Tabla 4.6: Total real de cada variable, en donde también se muestra el error deseado  $d$  y la sugerencia de  $n$  para el tamaño de muestra.

Con el fin abarcar todos los resultados se conservó el tamaño de muestra sugerido más grande, es decir,  $n = 16,375$  secciones. Este se refiere al tamaño total de la muestra, por lo que se debe calcular el tamaño para cada estrato; para esto se decidió asignar un tamaño de muestra proporcional al tamaño de cada  $N_h$ .

Con esto ya se tienen todos los componentes para poder calcular las varianzas poblacionales según la ecuación 2.28:

$$V(\hat{t}_{y\pi}) = \sum_{h=1}^H \frac{N_h^2}{n_h} \left(1 - \frac{n_h}{N_h}\right) S_{yU_h}^2,$$

$$\text{donde } S_{yU_h}^2 = \frac{\sum_{u_k \in U_h} (y_k - \bar{y}_{U_h})^2}{N_h - 1} \text{ y } \bar{y}_{U_h} = \frac{\sum_{u_k \in U_h} y_k}{N_h}.$$

Se obtuvo una base de datos, en donde las columnas fueron los parámetros utilizados, es decir, 10 columnas correspondientes a cada variable seleccionada, y los renglones a la varianza poblacional obtenida con cada estratificación, o sea la combinación de  $\alpha$ ,  $k$  y matriz de distancias geográficas. Así,  $(i, j)$  corresponde a la varianza poblacional del parámetro  $j$  con la estratificación  $i$ .

Para poder comparar las varianzas de cada parámetro, la base se ordenó de menor a mayor de acuerdo a la varianza poblacional obtenida. Lo cual dio como resultado 10 ordenamientos distintos, y a cada estratificación se le asignó un puntaje de acuerdo a la suma de su lugar en los ordenamientos, por ejemplo, si una agrupación estuvo siete veces en tercer lugar, dos en el segundo, y una en el sexto, obtuvo:  $(7 * 3) + (2 * 2) + 6 = 31$  puntos. Al final se conservó la estratificación que tuvo menos puntos, es decir, la que en general tiene menos varianza poblacional en todos los estimadores.

En la Figura 4.8 se pueden observar los puntajes obtenidos con cada estratificación por cada variable, de la cual se puede rescatar lo siguiente:

- El puntaje máximo fue de 1,196, que se alcanzó con la estratificación que utilizó distancias binarias (es decir la matriz de adyacencia entre municipios),  $\alpha = 1$  y  $k = 3$ .
- El promedio del puntaje para las estratificaciones fue de 613 puntos.
- El puntaje mínimo fue de 99 puntos, el cual pertenece a la **estratificación elegida, resultante de utilizar  $k=5$ ,  $\alpha=0.25$  y la base de distancias geográficas calculadas por centroides.**

La  $k = 5$  quiere decir que los municipios se clasificaron en 5 grupos, y  $\alpha = 0.25$  puede ser interpretado como que se le dio un 25% de peso a las distancias geográficas y el 75% restante a las características sociodemográficas.

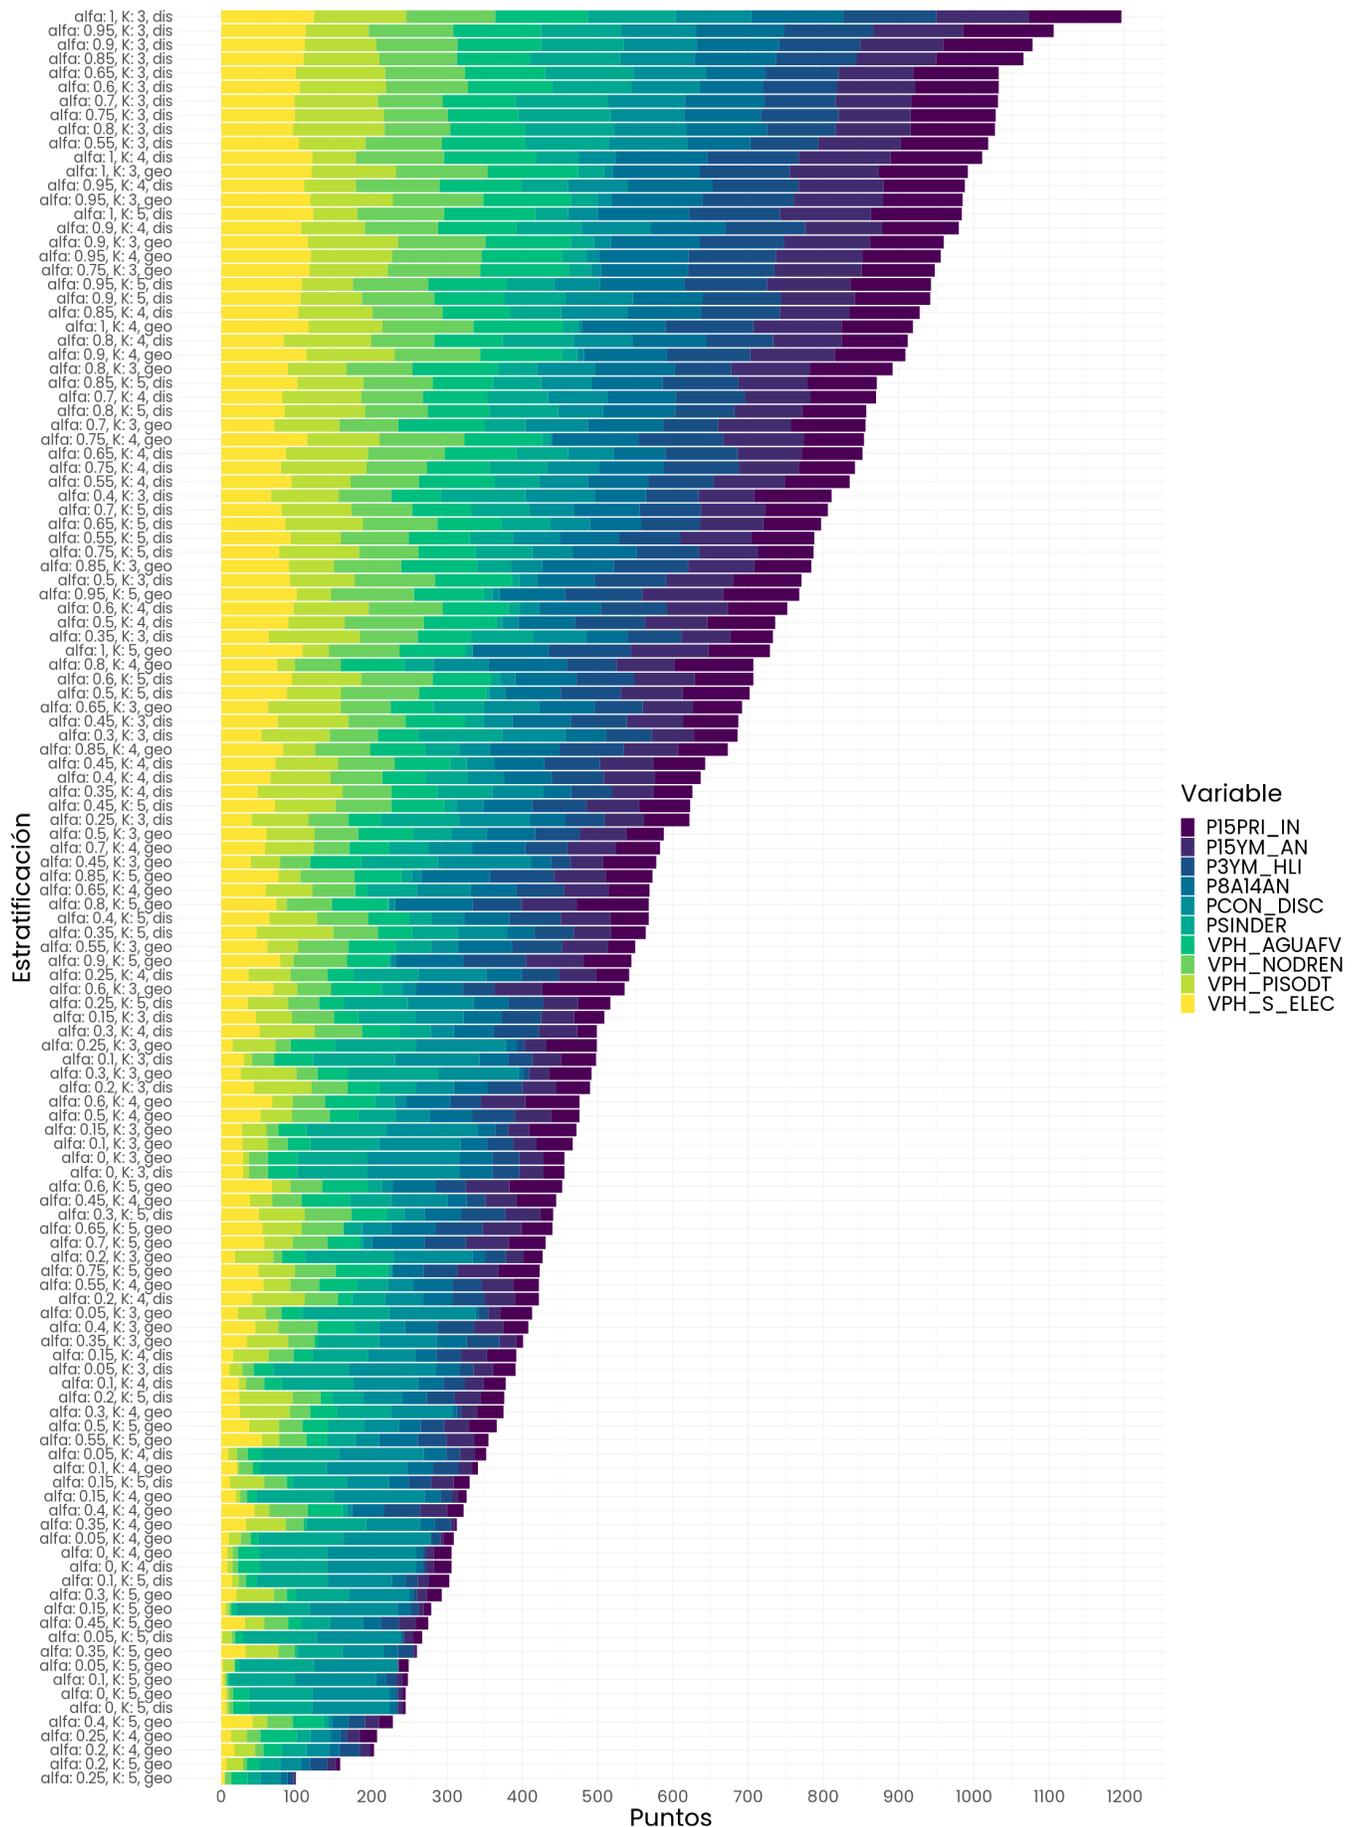


Figura 4.8: Gráfica en donde muestra el puntaje general para cada estratificación. La elegida es la del menor puntaje.

## 4.4. Evaluación de la estratificación y descripción de los resultados

### 4.4.1. Evaluación del modelo

Una vez elegida la mejor estratificación, se evaluó si usarla sería mejor que usar muestreo aleatorio simple. Para esto, se calculó la varianza poblacional resultante de tomar una muestra con un m.a.s. Los resultados se muestran en la Tabla 4.7 <sup>7</sup>. En general, los rankings que ocupa la estratificación elegida son buenos, con el lugar 26 como el más bajo para el parámetro total de población con discapacidad, lo cual significa que para ese parámetro habían 25 estratificaciones mejores que la elegida (en el contexto de tener una menor varianza poblacional) de un total de 126. Por otro lado, lo más recalable es que **las varianzas poblacionales en todos los parámetros fueron menores utilizando la estratificación con muestreo aleatorio simple al interior de cada estrato que realizando un muestreo aleatorio simple**, logrando una disminución de más del 30% en la varianza poblacional de dos parámetros. Esto significa que la estratificación obtenida fue exitosa, ya que se logró disminuir el error cuadrático medio de los estimadores.

Variable	Ranking	Varianza estratificación	Varianza M.A.S	Mejóro	Reducción
P15PRI_IN	1	0.63	0.72	TRUE	-12.51%
P15YM_AN	2	0.31	0.46	TRUE	-31.94%
P3YM_HLI	8	4.68	7.46	TRUE	-37.19%
P8A14AN	10	0.01	0.01	TRUE	-15.62%
PCON_DISC	26	0.37	0.37	TRUE	-1.00%
PSINDER	17	19.58	19.96	TRUE	-1.91%
VPH_AGUAFV	22	0.18	0.19	TRUE	-5.24%
VPH_NODREN	8	0.14	0.18	TRUE	-23.30%
VPH_PISODT	1	17.30	17.64	TRUE	-1.94%
VPH_S_ELEC	4	0.01	0.01	TRUE	-11.27%

Tabla 4.7: Comparación de resultados de realizar el muestreo estratificado y un muestreo aleatorio simple.

Como se detalló en el Capítulo 2 sección 2.5 el *deff* indica cuánto aumenta la varianza de una estimación debido a su diseño de muestreo en comparación con la varianza que se obtendría si se utilizara un diseño de muestreo aleatorio simple, ambos diseños con el mismo tamaño de muestra. En la Tabla 4.8 se muestran los resultados de calcular el *deff* con la estratificación seleccionada. En todos los caso resultó ser menor a uno, lo cual indica una mayor precisión en comparación con el muestreo aleatorio simple.

<sup>7</sup>Los cambios porcentuales fueron calculados sin redondear las varianzas, las varianzas que se muestran están redondeadas a 2 decimales.

<b>P15PRI_IN</b>	<b>P15YM_AN</b>	<b>P3YM_HLI</b>	<b>P8A14AN</b>	<b>PCON_DISC</b>
0.87	0.68	0.63	0.84	0.99
<b>PSINDER</b>	<b>VPH_AGUAFV</b>	<b>VPH_NODREN</b>	<b>VPH_PISODT</b>	<b>VPH_S_ELEC</b>
0.98	0.95	0.77	0.98	0.89

Tabla 4.8: Resultados del *deff*.

#### 4.4.2. Comparación de la estratificación resultante con otras estratificaciones de interés

Se clasificaron a los municipios de acuerdo a otras estratificaciones que podrían resultar de interés, para luego, con las mismas diez variables utilizadas previamente, calcular las varianzas poblacionales de cada estimador, y así poder comparar la varianza poblacional de cada estratificación.

Las estratificaciones comparadas fueron las siguientes:

- a). Estratificación obtenida en la tesis (5 estratos).
- b). Estratificación por entidades federativas (32 estratos).
- c). Estratificación por el tipo de municipio (3 estratos).
- d). Estratificación por el cruce de las entidades federativas con el tipo de municipio (65 estratos).
- e). Estratificación por el cruce de las entidades federativas y la obtenida en la tesis (90 estratos).
- f). Estratificación por el cruce de las entidades federativas, tipo de municipio y la obtenida en la tesis (148 estratos).

Para realizar la clasificación de los municipios en c) se utilizó la base de datos de los Principales Resultados por Localidad del Censo de Población y Vivienda. Se trabajó únicamente con la información de las localidades, categorizando a cada localidad como rural o urbana en función de su población. Con población menor a 2,500 personas las localidades se categorizaron como rurales, y en otro caso como urbanas.

Una vez que se categorizaron las localidades, se procedió a la clasificación de los municipios en tres grupos: Totalmente rural, predominantemente rural y predominantemente urbano. Se consideró que un municipio era totalmente rural si el 100% de sus localidades eran rurales. Si al menos 50% de las localidades eran rurales, se clasificó como predominantemente rural, y si menos del 50% de la población residía en localidades rurales, se categorizó como municipio predominantemente urbano. Resultando:

- 809 municipios totalmente rurales.
- 1,616 municipios predominantemente rurales.
- 44 municipios predominantemente urbanos.

Por otro lado, la estratificación en f) es la que más se aproxima a lo que realizó el INEGI en 2010 para obtener sus 746 estratos, sin embargo, es importante recordar que el INEGI obtuvo los estratos a través de UPM en lugar de municipios, y clasificó primero en cuatro estratos por nivel sociodemográfico y luego los diferenció de acuerdo a la entidad federativa y tamaño de localidad, utilizando cuatro tamaños de localidad.

Los resultados de las varianzas poblacionales para cada estratificación se muestran en la Tabla 4.9.

Variable	a)	b)	c)	d)	e)	f)
P15PRI_IN	0.63	0.62	0.7	0.61	0.57	<b>0.57</b>
P8A14AN	<b>0.01</b>	<b>0.01</b>	<b>0.01</b>	<b>0.01</b>	<b>0.01</b>	<b>0.01</b>
P15YM_AN	0.31	0.35	0.45	0.35	0.28	<b>0.27</b>
PCON_DISC	0.37	0.35	0.37	0.35	<b>0.34</b>	<b>0.34</b>
P3YM_HLI	4.68	6.34	7.32	6.28	4.01	<b>3.91</b>
PSINDER	19.58	17.93	19.75	17.64	17.38	<b>17.21</b>
VPH_PISODT	17.3	16.86	17.47	16.7	16.47	<b>16.38</b>
VPH_S_ELEC	<b>0.01</b>	<b>0.01</b>	<b>0.01</b>	<b>0.01</b>	<b>0.01</b>	<b>0.01</b>
VPH_AGUAFV	0.18	0.18	0.19	0.18	<b>0.17</b>	<b>0.17</b>
VPH_NODREN	0.14	0.17	0.18	0.16	<b>0.13</b>	<b>0.13</b>

Tabla 4.9: Tabla de comparación de varianzas de las estratificaciones.

Como es natural, la estratificación con menor varianza fue la resultante de tener más estratos (columna f, Tabla 4.9), sin embargo, la varianza no disminuye radicalmente si es comparada con la varianza de la estratificación obtenida en la tesis (columna a). Incluso hay casos en donde el uso de solo la estratificación de la tesis obtiene mejores resultados que usar b, c y d, como en P15YM\_AN, P3YM\_HLI y VPH\_NODREN.

#### 4.4.3. Descripción de la estratificación obtenida

Con la estratificación seleccionada los 2,469 municipios fueron clasificados en 5 grupos: 198 (8.02%) en el grupo 1, 304 (12.3%) en el grupo 2, 959 (38.8%) en el grupo 3, 758 (30.7%) en el grupo 4 y 250 (10.1%) en el grupo 5. Ver Figura 4.9.

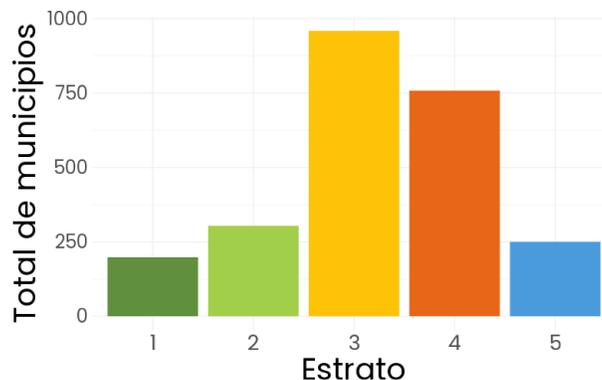


Figura 4.9: Distribución de los municipios en la estratificación.

## Análisis de componentes principales

Para tener una primera visualización de cómo están distribuidos los grupos se decidió usar los componentes principales.

Los componentes principales se obtienen mediante una combinación lineal de las variables originales y sirven como una técnica de reducción de dimensionalidad y también como una de visualización. El primer componente principal representa la dirección en la cual los datos muestran la mayor dispersión o variabilidad, mientras que el segundo componente principal captura la siguiente mayor cantidad de variabilidad no explicada por el primer componente, y así sucesivamente (James et al., 2021).

Para saber qué tanto influyen las variables en cada componente, se debe de obtener la correlación de las variables con el componente de interés. Entre más grande la correlación de la variable  $x$  con el componente  $y$  significa que ésta tiene más peso en ese componente. Usualmente se considera que la correlación es pequeña si es menor a 0.5.

Se obtuvieron los componentes principales de las 45 variables sociodemográficas. Las observaciones sobre el primer y segundo componente principal se muestran en la Figura 4.10, diferenciando a cada grupo con un color diferente.

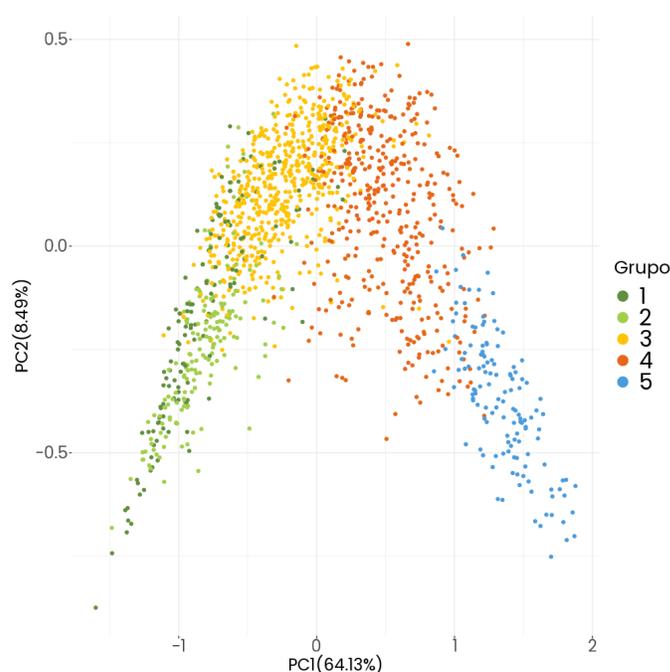


Figura 4.10: Gráfica del primer y segundo componente principal de los datos sociodemográficos utilizando la estratificación seleccionada. Se puede observar que los datos del grupo 1, 2 y 3 tienen valores negativos en el PC1, eso significa que las variables con mayor correlación positiva con el PC1 tendrán menores valores en estos grupos, y al contrario, las variables con mayor correlación negativa tendrán mayores valores en estos grupos. Por el contrario, los grupos 4 y 5 tienen valores positivos en el PC1, eso quiere decir que las variables correlacionadas con el PC1 positivamente tendrán un mayor valor en los grupos 4 y 5.

Las correlaciones entre cada variable y el primer componente principal (CP1) se muestran en la Tabla 4.10. La variable con mayor correlación en sentido positivo es la pobreza\_pob, esto significa que a mayor valor en el CP1, mayor pobreza. Y de acuerdo a la Figura 4.10 esto quiere decir que los grupos 1 y 2 tienen menor pobreza (ya que sus valores en el CP1 son negativos), mientras que el grupo 5 es el que tiene mayor pobreza.

Por otro lado, la variable VPH\_PC tiene correlación negativa, la interpretación es que a mayores valores en el CP1, menores en la variable, esto quiere decir que los municipios pertenecientes al grupo 5 y 4 tienen menos viviendas con computadoras en comparación a los municipios pertenecientes a los grupos 1, 2 y 3.

De hecho, todas las variables con alta correlación en sentido positivo están asociadas a mayor pobreza o carencias, mientras que las que tienen sentido negativo están asociadas a tener bienes básicos. Es decir, a mayor valor en el CP1 se tendrá un menor porcentaje en cuanto a tener computadora, lavadora, internet, televisión y celular; además de un menor grado escolar. Con esto en mente, el primer componente principal resume muchas variables en términos de falta de bienes o mayor pobreza, de manera que un mayor valor en el CP1 indica mayor falta de bienes y pobreza.

Variable	Correlación	Variable	Correlación
pobreza_pob	0.91	POB65_MAS	0.15
pobreza_e_pob	0.90	PCON_LIMI	0.09
carencias3_pob	0.90	P15SEC_IN	0.09
plbm_pob	0.89	POB_AFRO	0.08
VPH_SINCINT	0.88	PCLIM_PMEN	-0.18
plb_pob	0.87	PSINDER	-0.18
carencias_pob	0.85	PAFIL_IPRIV	-0.32
P15YM_AN	0.84	HOGJEF_F	-0.34
VPH_NDACMM	0.80	PNACOE	-0.47
VPH_SNBIEN	0.77	POCUPADA	-0.63
P15YM_SE	0.76	PEA	-0.65
VPH_PISOTI	0.74	vul_ing_pob	-0.74
ic_segsoc_pob	0.73	P18YM_PB	-0.82
P3YM_HLI	0.68	VPH_REFRI	-0.83
PRO_OCUP_C	0.65	nprnv_pob	-0.83
VPH_NODREN	0.65	VPH_CEL	-0.83
P15PRI_IN	0.60	VPH_TV	-0.83
ic_ali_pob	0.48	VPH_INTER	-0.84
VPH_S_ELEC	0.46	VPH_LAVAD	-0.85
VPH_AGUAFV	0.42	GRAPROES	-0.88
VPH_NDEAED	0.37	VPH_PC	-0.89
VPH_1CUART	0.35		
pobreza_m_pob	0.30		
PCON_DISC	0.27		

Tabla 4.10: Correlación entre variables sociodemográficas y el primer componente principal. Sólo se incluyen valores diferentes a cero, después de dos decimales.

En la Tabla 4.11 se muestran las correlaciones entre las variables y el segundo componente principal. A diferencia del primer componente principal, en el segundo las variables no tienen correlaciones demasiado altas, las más destacables son POB65\_MAS, PCON\_DISC y PCON\_LIMI, todas ellas negativas. La interpretación de esto es que los municipios pertenecientes a los grupos 1, 2 y 5 tienen más población de 65 años o más que los municipios en los grupos 3 y 4. Lo mismo pasa para la población con discapacidad y población con limitación.

Variable	Correlación	Variable	Correlación
PRO_OCUP_C	0.45	PNACOE	0.10
VPH_SNBIEN	0.41	P15YM_SE	0.08
npnv_pob	0.35	P15YM_AN	0.08
VPH_PISOTI	0.34	PEA	0.06
P3YM_HLI	0.34	POCUPADA	0.04
VPH_NDEAED	0.32	PSINDER	-0.06
VPH_S_ELEC	0.32	plb_pob	-0.08
P18YM_PB	0.29	pobreza_pob	-0.12
VPH_PC	0.26	ic_segsoe_pob	-0.19
GRAPROES	0.24	VPH_SINCINT	-0.20
vul_ing_pob	0.24	PCLIM_PMEN	-0.23
VPH_1CUART	0.22	VPH_TV	-0.24
VPH_NODREN	0.22	VPH_LAVAD	-0.27
VPH_INTER	0.22	VPH_REFRI	-0.32
pobreza_e_pob	0.21	carencias_pob	-0.33
VPH_AGUAFV	0.20	pobreza_m_pob	-0.54
VPH_NDACMM	0.18	P15PRI_IN	-0.57
PAFIL_IPRIV	0.16	PCON_LIMI	-0.60
carencias3_pob	0.14	PCON_DISC	-0.63
ic_ali_pob	0.11	POB65_MAS	-0.68

Tabla 4.11: Correlación entre variables sociodemográficas y el segundo componente principal. Sólo se incluyen valores diferentes a cero, después de dos decimales.

### Análisis descriptivo por grupos

La información de los grupos resultantes se resumió en las Tablas 4.12 y 4.13. La primera tabla muestra el resumen estadístico por cada grupo, considerando la media y el rango. Por su parte, la Tabla 4.13 muestra las proporciones de cada grupo por entidad federativa.

De la Tabla 4.12 se puede deducir lo siguiente:

- Los grupos con menor población en pobreza son el 1 y 2, mientras que en los grupos 3, 4 y 5 la población tiene más carencias.
- En promedio hay más población de 65 años y más en el grupo 4 (12%) y menor en el grupo 2 (9%).
- La población con alguna discapacidad o limitación es proporcional en todos los grupos (aproximadamente 6% de población con discapacidad y 12% con limitación).

- El grupo 2 es el que lidera el promedio de años de escolaridad y menor porcentaje de población con primaria y secundaria incompleta, seguido por el grupo 1 y 3.
- El grupo 2 es el que tiene más población ocupada, en promedio 47%, mientras que el grupo 3 es el que menos tiene (30%).
- En general el grupo 1 y 2 son los que tienen más bienes como refrigerador, lavadora, computadora, teléfono celular e internet.

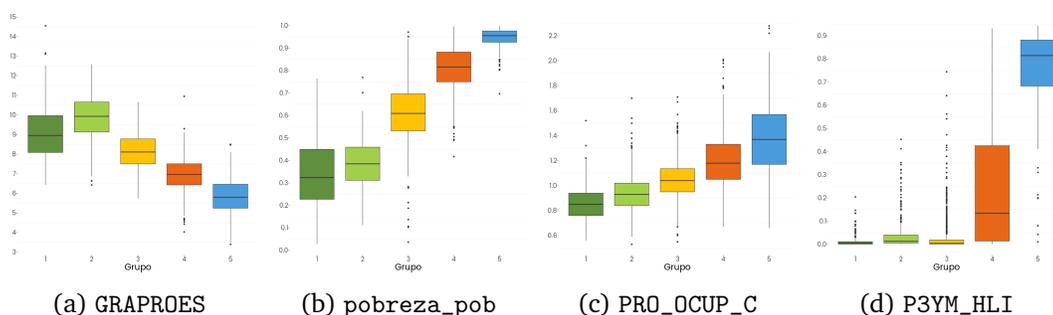


Figura 4.11: Diagramas de cajas de las variables: Grado promedio de escolaridad, pobreza poblacional, promedio de ocupantes por cuarto y población de 3 años o más que habla alguna lengua indígena.

Algunas de las variables mostradas en la Tabla 4.12 se seleccionaron y en la Figura 4.11 se presenta la información mediante box plots, de lo cual se puede extraer lo siguiente:

En (a), se puede observar que el grupo 2 cuenta con el mayor grado promedio de escolaridad, con una mediana de 9.93 años y un mínimo de 6.43 años, mientras que el grupo 5 alcanza solamente un máximo de 8.5 años y mediana de 5.8 años.

Respecto a la pobreza poblacional en (b) se observa que el grupo 5 tiene el primer lugar, seguido por los grupos 4, 3, 2 y 1, en términos de mediana. En el grupo 5, en promedio, el 95% de la población vive en pobreza, mientras que en el grupo 1, solamente el 34% de la población lo hace. Y como se observa en (c) el grupo 5 también tiene mayor promedio de ocupantes por cuarto (1.39 en promedio).

En (d), se muestra que la pobreza poblacional y la población de tres años o más que habla alguna lengua indígena están correlacionadas. De hecho, el grupo 5, siendo el más pobre, también es el que tiene el mayor porcentaje de población hablante de lengua indígena.

Variable	Grupo 1	Grupo 2	Grupo 3	Grupo 4	Grupo 5
pobreza_pob	0.34 (0.03 - 0.76)	0.38 (0.11 - 0.77)	0.61 (0.04 - 0.97)	0.81 (0.42 - 1)	0.94 (0.7 - 1)
pobreza_e_pob	0.03 (0 - 0.23)	0.04 (0.01 - 0.13)	0.11 (0 - 0.48)	0.29 (0.04 - 0.77)	0.56 (0.23 - 0.97)
pobreza_m_pob	0.3 (0.03 - 0.57)	0.34 (0.1 - 0.64)	0.5 (0.04 - 0.78)	0.52 (0.22 - 0.82)	0.38 (0.02 - 0.67)
vul_ing_pob	0.07 (0 - 0.24)	0.09 (0.01 - 0.23)	0.04 (0 - 0.2)	0.01 (0 - 0.11)	0 (0 - 0.03)
nprv_pob	0.22 (0.02 - 0.66)	0.23 (0.02 - 0.44)	0.08 (0 - 0.25)	0.02 (0 - 0.13)	0 (0 - 0.05)
ic_segsoc_pob	0.55 (0.2 - 0.91)	0.51 (0.2 - 0.85)	0.76 (0.36 - 0.94)	0.82 (0.06 - 0.96)	0.86 (0.29 - 0.97)
ic_ali_pob	0.15 (0.01 - 0.37)	0.18 (0.03 - 0.57)	0.23 (0 - 0.53)	0.27 (0.01 - 0.71)	0.36 (0.02 - 0.86)
carencias_pob	0.71 (0.32 - 0.98)	0.68 (0.39 - 0.96)	0.88 (0.58 - 1)	0.97 (0.8 - 1)	0.99 (0.92 - 1)
carencias3_pob	0.12 (0.01 - 0.5)	0.14 (0.03 - 0.4)	0.28 (0.03 - 0.67)	0.49 (0.11 - 0.81)	0.69 (0.36 - 0.98)
plb_pob	0.41 (0.04 - 0.77)	0.48 (0.16 - 0.8)	0.65 (0.05 - 0.98)	0.82 (0.45 - 1)	0.95 (0.72 - 1)
plbm_pob	0.13 (0.01 - 0.43)	0.14 (0.03 - 0.5)	0.28 (0.02 - 0.88)	0.5 (0.08 - 0.96)	0.78 (0.44 - 0.99)
POB65_MAS	0.11 (0.03 - 0.22)	0.09 (0.01 - 0.27)	0.1 (0.04 - 0.23)	0.12 (0.01 - 0.32)	0.1 (0.03 - 0.27)
PNACOE	0.11 (0.01 - 0.63)	0.16 (0 - 0.7)	0.1 (0 - 0.66)	0.06 (0 - 0.45)	0.02 (0 - 0.14)
P3YM_HLI	0.01 (0 - 0.2)	0.04 (0 - 0.45)	0.03 (0 - 0.74)	0.24 (0 - 0.93)	0.76 (0.01 - 0.94)
POB_AFRO	0.01 (0 - 0.11)	0.02 (0 - 0.24)	0.02 (0 - 0.39)	0.04 (0 - 0.96)	0.02 (0 - 0.38)
PCON_DISC	0.06 (0.02 - 0.12)	0.05 (0.02 - 0.1)	0.06 (0.02 - 0.13)	0.07 (0 - 0.32)	0.06 (0 - 0.21)
PCON_LIMI	0.13 (0.07 - 0.24)	0.12 (0.06 - 0.2)	0.12 (0.04 - 0.23)	0.14 (0.02 - 0.37)	0.12 (0.01 - 0.28)
PCLIM_PMEN	0.01 (0 - 0.02)	0.01 (0 - 0.02)	0.01 (0 - 0.03)	0.01 (0 - 0.05)	0.01 (0 - 0.03)
P15YM_AN	0.03 (0 - 0.1)	0.03 (0.01 - 0.08)	0.05 (0.01 - 0.16)	0.1 (0 - 0.24)	0.16 (0.02 - 0.35)
P15YM_SE	0.03 (0 - 0.12)	0.03 (0.01 - 0.09)	0.05 (0.01 - 0.17)	0.09 (0 - 0.25)	0.14 (0.02 - 0.28)
P15PRI_IN	0.09 (0.01 - 0.22)	0.06 (0.02 - 0.25)	0.1 (0.03 - 0.23)	0.13 (0 - 0.28)	0.13 (0.04 - 0.26)
P15SEC_IN	0.03 (0 - 0.09)	0.02 (0.01 - 0.05)	0.02 (0.01 - 0.06)	0.02 (0 - 0.09)	0.03 (0.01 - 0.06)
P18YM_PB	0.26 (0.05 - 0.76)	0.32 (0.09 - 0.56)	0.2 (0.07 - 0.41)	0.14 (0.02 - 0.31)	0.09 (0.01 - 0.23)
GRAPROES	0.51 (0.27 - 1)	0.57 (0.27 - 0.82)	0.43 (0.21 - 0.65)	0.32 (0.06 - 0.68)	0.22 (0 - 0.46)
PEA	0.44 (0.28 - 0.64)	0.48 (0.28 - 0.56)	0.45 (0.15 - 0.58)	0.4 (0.05 - 0.58)	0.32 (0.11 - 0.58)
POCUPADA	0.43 (0.26 - 0.62)	0.47 (0.27 - 0.55)	0.44 (0.14 - 0.57)	0.4 (0.05 - 0.58)	0.3 (0.09 - 0.58)
PSINDER	0.21 (0.04 - 0.57)	0.24 (0.05 - 0.44)	0.28 (0.03 - 0.66)	0.23 (0.02 - 0.78)	0.18 (0.01 - 0.84)
PAFIL_IPRIV	0.02 (0 - 0.38)	0.02 (0 - 0.17)	0.01 (0 - 0.08)	0 (0 - 0.16)	0 (0 - 0.58)
HOGJEF_F	0.29 (0.15 - 0.48)	0.31 (0.13 - 0.43)	0.29 (0.09 - 0.45)	0.27 (0.12 - 0.50)	0.26 (0.11 - 0.50)
PRO_OCUP_C	0.19 (0.02 - 0.57)	0.24 (0 - 0.67)	0.3 (0.01 - 0.67)	0.38 (0.08 - 0.85)	0.49 (0.07 - 1)
VPH_PISOTI	0.02 (0 - 0.31)	0.02 (0 - 0.09)	0.05 (0 - 0.36)	0.11 (0 - 0.62)	0.24 (0.02 - 0.67)
VPH_1CUART	0.04 (0.01 - 0.34)	0.06 (0.01 - 0.49)	0.06 (0.01 - 0.32)	0.1 (0 - 0.37)	0.09 (0.01 - 0.44)
VPH_S_ELEC	0.02 (0 - 0.12)	0.01 (0 - 0.03)	0.01 (0 - 0.14)	0.02 (0 - 0.34)	0.05 (0 - 0.49)
VPH_AGUAFV	0.02 (0 - 0.16)	0.02 (0 - 0.18)	0.05 (0 - 0.79)	0.08 (0 - 0.62)	0.13 (0 - 0.7)
VPH_NODREN	0.05 (0 - 0.43)	0.03 (0 - 0.18)	0.07 (0 - 0.78)	0.19 (0 - 0.98)	0.46 (0.01 - 0.99)
VPH_NDEAED	0 (0 - 0.04)	0 (0 - 0.02)	0 (0 - 0.13)	0.01 (0 - 0.15)	0.02 (0 - 0.28)
VPH_NDACMM	0.35 (0.07 - 0.66)	0.44 (0.15 - 0.75)	0.5 (0.17 - 0.93)	0.72 (0.04 - 0.97)	0.88 (0.51 - 0.98)
VPH_SNBIEI	0.01 (0 - 0.1)	0.01 (0 - 0.03)	0.02 (0 - 0.21)	0.07 (0 - 0.39)	0.22 (0.02 - 0.55)
VPH_REFRI	0.92 (0.62 - 0.99)	0.9 (0.72 - 0.98)	0.83 (0.42 - 0.98)	0.64 (0.07 - 0.95)	0.35 (0.04 - 0.82)
VPH_LAVAD	0.78 (0.32 - 0.95)	0.78 (0.53 - 0.94)	0.67 (0.17 - 0.93)	0.43 (0.05 - 0.88)	0.14 (0 - 0.57)
VPH_TV	0.91 (0.37 - 0.98)	0.93 (0.7 - 0.97)	0.88 (0.54 - 0.97)	0.74 (0.08 - 0.93)	0.51 (0.1 - 0.95)
VPH_PC	0.3 (0.05 - 0.85)	0.37 (0.08 - 0.69)	0.2 (0.01 - 0.42)	0.09 (0 - 0.31)	0.04 (0 - 0.17)
VPH_CEL	0.88 (0.52 - 0.97)	0.9 (0.39 - 0.96)	0.82 (0.22 - 0.94)	0.64 (0.02 - 0.95)	0.44 (0.07 - 0.94)
VPH_INTER	0.41 (0.03 - 0.92)	0.51 (0.1 - 0.83)	0.31 (0.02 - 0.69)	0.16 (0 - 0.55)	0.08 (0 - 0.45)
VPH_SINCINT	0.53 (0.06 - 0.88)	0.43 (0.14 - 0.88)	0.64 (0.3 - 0.96)	0.8 (0.03 - 1)	0.9 (0.55 - 1)

Tabla 4.12: El resumen estadístico de las variables de acuerdo al estrato de pertenencia de los municipios. El primer número corresponde a la media, y los números entre paréntesis corresponden al rango, es decir, el valor mínimo y el máximo.

Estado	Grupo 1	Grupo 2	Grupo 3	Grupo 4	Grupo 5
Aguascalientes	-	4 (36.36%)	7 (63.64%)	-	-
Baja California	6 (100%)	-	-	-	-
Baja California Sur	5 (100%)	-	-	-	-
Campeche	-	5 (41.67%)	4 (33.33%)	3 (25%)	-
Chiapas	-	1 (0.81%)	38 (30.65%)	55 (44.35%)	30 (24.19%)
Chihuahua	16 (23.88%)	37 (55.22%)	1 (1.49%)	10 (14.93%)	3 (4.48%)
Ciudad de México	16 (100%)	-	-	-	-
Coahuila	32 (84.21%)	2 (5.26%)	4 (10.53%)	-	-
Colima	-	4 (40%)	6 (60%)	-	-
Durango	27 (69.23%)	-	11 (28.21%)	-	1 (2.56%)
Guanajuato	-	5 (10.87%)	41 (89.13%)	-	-
Guerrero	-	-	27 (33.33%)	37 (45.68%)	17 (20.99%)
Hidalgo	-	11 (13.1%)	51 (60.71%)	21 (25%)	1 (1.19%)
Jalisco	-	30 (24%)	93 (74.4%)	1 (0.8%)	1 (0.8%)
Michoacán	-	3 (2.65%)	105 (92.92%)	5 (4.42%)	-
Morelos	-	6 (16.67%)	29 (80.56%)	1 (2.78%)	-
México	-	36 (28.8%)	71 (56.8%)	18 (14.4%)	-
Nayarit	1 (5%)	3 (15%)	13 (65%)	2 (10%)	1 (5%)
Nuevo León	6 (11.76%)	20 (39.22%)	25 (49.02%)	-	-
Oaxaca	-	31 (5.44%)	67 (11.75%)	305 (53.51%)	167 (29.3%)
Puebla	-	5 (2.3%)	79 (36.41%)	123 (56.68%)	10 (4.61%)
Querétaro	-	4 (22.22%)	13 (72.22%)	1 (5.56%)	-
Quintana Roo	-	7 (63.64%)	-	4 (36.36%)	-
San Luis Potosí	-	3 (5.17%)	41 (70.69%)	13 (22.41%)	1 (1.72%)
Sinaloa	17 (94.44%)	1 (5.56%)	-	-	-
Sonora	72 (100%)	-	-	-	-
Tabasco	-	1 (5.88%)	15 (88.24%)	1 (5.88%)	-
Tamaulipas	-	6 (13.95%)	37 (86.05%)	-	-
Tlaxcala	-	16 (26.67%)	42 (70%)	2 (3.33%)	-
Veracruz	-	26 (12.26%)	85 (40.09%)	83 (39.15%)	18 (8.49%)
Yucatán	-	33 (31.13%)	-	73 (68.87%)	-
Zacatecas	-	4 (6.9%)	54 (93.1%)	-	-

Tabla 4.13: Número y porcentaje de municipios, en cada estado, pertenecientes a cada estrato.

De toda la información previa para cada grupos se puede resumir lo siguiente:

- **Grupo 1:** Consta de **198 municipios (8.02% del total)**. Es el grupo con menor población en situación en pobreza y el segundo con más años promedio de escolaridad. Baja California, Baja California Sur, Ciudad de México y Sonora están conformados en su totalidad por municipios en este grupo, mientras que Sinaloa y Coahuila poseen el 94.4% y 84.2% de sus municipios en este grupo respectivamente. Cabe resaltar que sólo 10 estados de la república mexicana cuentan con algún municipio en este estrato.
- **Grupo 2:** Lo constituyen **304 municipios (12.3% del total)**. Es el grupo con mayores índices de educación, es decir, es el grupo con menos población con primaria y secundaria incompleta, así como con más población de 18 años y más con educación posbásica y con mayor promedio de escolaridad. Es el segundo grupo con menor población en situación de pobreza y en algunos casos el grupo con menos carencias, por ejemplo es el grupo que tiene más viviendas con televisión, celular, internet y computadora. Más de la mitad de los municipios de Chihuahua y Quintana Roo pertenecen a este grupo.

- **Grupo 3:** Se compone de **959 municipios (38.8% del total)**. Es el tercer grupo menos vulnerable y pobre, y también el tercero con mayores índices de escolaridad. En este grupo están categorizados la mayoría de municipios y sólo 7 estados no tienen ningún municipio perteneciente a este grupo. Guanajuato (89%), Michoacán (92%), Tabasco (88%) y Tamaulipas (86%) tienen más del 85% de sus municipios en este grupo.
- **Grupo 4:** Con **758 municipios (30.7% del total)**. Es el segundo grupo más pobre y vulnerable. Es el grupo con más población en situación de pobreza moderada y el segundo con menor índice de educación. Yucatán (69%), Puebla (57%) y Oaxaca (54%) poseen más del 50% de sus municipios con esta clasificación.
- **Grupo 5: Constituye el grupo más pobre y vulnerable**, contiene **250 municipios (10.1% del total)** y sólo 11 estados son parte de este estrato, entre los cuales se encuentran Oaxaca, Chiapas y Guerrero con más del 20% de sus municipios en esta estratificación. Es el grupo con más hablantes de lengua indígena, mayor población con carencias y menor grado de escolaridad.

En la Figura 4.12 se muestran los municipios de México utilizando la clasificación resultante de la estratificación seleccionada. Se puede observar que el grupo 1 y 2 están principalmente en el norte del país, mientras que el 3 abarca el centro, y el cuatro el sur.

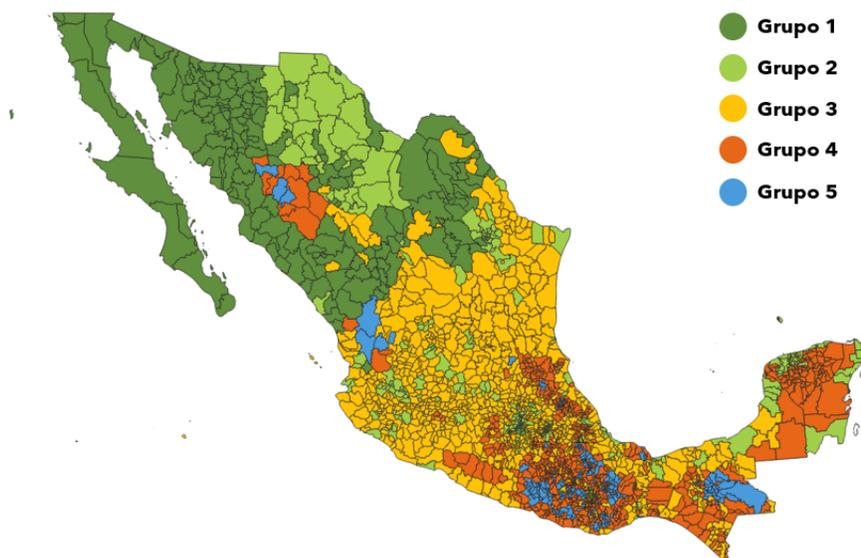


Figura 4.12: Mapa de los Estados Unidos Mexicanos utilizando la estratificación elegida.

## Capítulo 5

# Conclusiones

En esta sección se discutirán las decisiones tomadas para la realización de esta tesis, así como las dificultades enfrentadas a lo largo del proceso.

La motivación de esta tesis fue crear una estratificación de los municipios en los Estados Unidos Mexicanos similar a como lo hace el INEGI en la primera etapa de su estratificación, es decir, cuando se crean los cuatro estratos a nivel nacional, pero en este caso incluyendo restricciones geográficas desde un inicio.

La estratificación se realizó a nivel municipal debido a que es la información más desagregada y completa para el público en general, utilizando la base de los Principales Resultados por Localidad del Censo de Población y Vivienda 2020. No se hizo a nivel localidad, ya que en las localidades más chicas no aparece la información completa. El hacerlo de esta manera también sirvió para poder utilizar los Indicadores de Pobreza Municipal 2015 del CONEVAL y así contar con más información sociodemográfica para hacer la estratificación.

El utilizar dos bases de datos de distintas fuentes representó un reto ya que nos enfrentamos a lo siguiente:

- a). Unir las bases de datos por los nombres de los estados y municipios fue complicado debido a que no todos los nombres coinciden y están sucios, por ejemplo, en la base de datos del INEGI existen municipios aparentemente duplicados ya que ambos aparecen dos veces con el mismo nombre y en el mismo estado: San Juan Mixtepec y San Pedro Mixtepec. Buscando estos nombres en los Indicadores de Pobreza Municipal se observa que los nombres correctos son San Juan Mixtepec -Dto. 08 -, San Juan Mixtepec -Dto. 26 -, San Pedro Mixtepec -Dto. 22 - y San Pedro Mixtepec -Dto. 26 -. Para diferenciar a cuál correspondía cada municipio, se obtuvo la población total y se relacionó a aquel municipio del INEGI en el que la población total fuera similar a la población total registrada por el CONEVAL.
- b). Una vez realizado lo anterior, se logró intersecar a 2,433 municipios de los 2,469 totales. Para poder unir todos fue necesario limpiar los nombres quitando abreviaciones o simplemente modificando los nombres, por ejemplo Heroica Ciudad de Juchitán de Zaragoza por Juchitán de Zaragoza.
- c). Había datos faltantes en la base de datos del CONEVAL, algunos correspondían a mu-

nicipios formados entre 2015 y 2020, y otros simplemente no tenían información. La información fue imputada promediando los datos de los municipios vecinos, esto se hizo así porque muchas veces municipios vecinos tienen características similares. En total se imputaron 23 municipios faltantes utilizando la información de otros 90 municipios.

Una vez que las bases de datos fueron unidas, la mayoría de variables fueron transformadas a proporciones ya que así es más fácil hacer comparaciones entre municipios porque a veces los municipios varían mucho respecto al total de su población. Esto podría haberse omitido o incluso trabajar con otro tipo de transformaciones, sin embargo, se hizo así porque se pretendía que la comparación entre municipios fuera fácil e intuitiva.

Ya que de unir ambas bases resultaron 246 variables, se seleccionaron sólo algunas. Esto porque muchas están correlacionadas y no es práctico incluirlas todas. Se seleccionaron algunas de las variables que se utilizaron para la realización de la Muestra Maestra del INEGI, pero también se agregaron otras que podrían resultar de interés actual o que involucran a grupos vulnerables para que estos quedaran representados en cada grupo. Sin embargo, es importante notar que el probar distintas variables podría generar distintas estratificaciones.

Se probó con dos tipos de distancias para los datos geográficos, sin embargo, pueden explorarse otras formas de distancias, por ejemplo, tomando otro punto de referencia en los municipios (no el centroide) o calcular la distancia con las rutas que comunican a los municipios.

Respecto a los parámetros requeridos por el algoritmo:

- Se probó con distintos métodos para seleccionar el número adecuado de grupos, y se llegó a una decisión final considerando lo realizado por INEGI que fue crear cuatro estratos en la primera etapa de la estratificación. En una segunda etapa, como se vio en la comparación de la estratificación resultante con otras estratificaciones de interés, se podría diferenciar cada grupo por tipo de municipio o por estado. También se podría haber elegido un número grande de grupos desde el principio, como  $32 * 4 = 128$  que es el resultado máximo de lo que correspondería diferenciar los cuatro estratos por cada entidad federativa.
- Para la elección de  $\alpha$  se probó con varias mallas, pero se vio que no había gran diferencia entre usar una malla de 21 puntos o más, por lo que se conservó esta.
- Se le dio el mismo peso a todas las características geográficas, sin embargo, para otros proyectos, algunas variables podrían tener más importancia que otras por lo que podrían ponderarse de distinta manera.

En cuanto al tiempo de ejecución del código, es muy rápido, excepto en la parte que se ejecutan los métodos para sugerir el número de grupos, en especial el método gap que tarda aproximadamente 40 minutos. Todo lo demás no toma más de 3 minutos.

Respecto a la elección de la mejor estratificación otro de los retos de esta tesis fue que incluso tratándose del mismo Censo, a distintas escalas, las claves de los municipios y estados no corresponden, por lo que se tuvo que hacer la unión nuevamente por nombre

del estado y municipio, teniendo que realizar un proceso parecido al que se realizó para obtener la base de datos de las características sociodemográficas (cuando se unieron los Indicadores de Pobreza Municipal y los Principales Resultados del Censo 2020), ya que algunos nombres en la base de datos a nivel localidad y geoelectoral cambian, aunque ambos provengan del Censo 2020 realizado por el INEGI.

Por simplicidad se eligió estimador HT para totales ya que es fácil calcular la varianza poblacional, sin embargo, se puede elegir otro estimador distinto (como promedios o porcentajes) e incluso combinarlos.

Se eligieron diez variables que se consideraron de importancia para seleccionar la estratificación, sin embargo, se pudieron seleccionar cualquiera otras e incluso todas. Se hizo así porque se pretendía que la estratificación elegida tuviera poca varianza poblacional en las variables de interés. También se pudo haber elegido otra forma de determinar la mejor estratificación, sin embargo, la idea de los rankings era ver en promedio cuál estratificación tenía menos varianza en todas las variables.

Los números de muestra sugeridos por el método empleado fueron muy variables, pero se decidió conservar el más grande para abarcar todos los demás casos.

Los resultados presentados en esta tesis muestran que la estratificación seleccionada, mediante el método de conglomerados jerárquico con restricciones espaciales ha sido efectiva para mejorar la precisión de las estimaciones de la población en comparación con el diseño de muestreo aleatorio simple sin reemplazo. Esto se evidencia por la menor varianza poblacional asociada al diseño de muestreo con estratificación. En algunos casos, se mejoró la precisión de los estimadores hasta en un 30%. Otro indicador que demuestra que se mejoró la precisión de los estimadores fue el *deff*, pues en todos los casos los resultados fueron menores a uno.

Finalmente, ya que usualmente los municipios cercanos tienen condiciones similares y eso se podría aprovechar, se consideró que el usar restricciones geográficas fue de utilidad.

Cabe resaltar que el objetivo de este trabajo no fue replicar el trabajo que realiza el INEGI, sino evaluar un método particular de análisis de conglomerados para la creación de estratos de muestreo, utilizando solamente información de acceso público.

## Capítulo 6

# Anexo A: Nociones básicas

### Análisis de componentes principales

Si se quisieran visualizar  $n$  observaciones con  $p$  características como parte del análisis exploratorio, se podría hacer examinando las gráficas  $2D$  de los datos; cada una con dos características a la vez y así resultando  $\binom{p}{2} = \frac{p(p-1)}{2}$  gráficas. Por ejemplo si  $p = 20$  resultarían 190 gráficas, de las cuales ninguna de ellas sería informativa ya que sólo contendrían una pequeña fracción del total de la información en los datos.

Por lo tanto es requerido un mejor método para visualizar las  $n$  observaciones cuando  $p$  es grande. Lo ideal sería encontrar una representación de baja dimensionalidad que contuviera tanta información como fuese posible; el análisis de componentes principales provee una herramienta para hacerlo.

La idea es que cada una de las  $n$  observaciones viven en un espacio  $p$ -dimensional, pero no todas las dimensiones son igual de importantes. Así el análisis de componentes principales (PCA, por sus siglas en inglés) se encarga de encontrar las dimensiones más importantes, donde la importancia se mide por la variación de las observaciones a lo largo de cada dimensión. Cada una de las dimensiones encontradas por el PCA es una combinación lineal de las  $p$  características. A continuación se explica cómo encontrar estas dimensiones (o componentes principales).

El primer componente principal ( $Z_1$ ) de un conjunto de características  $x_1, x_2, \dots, x_p$  es la combinación lineal normalizada:

$$Z_1 = \phi_{11}X_1 + \phi_{21}X_2 + \dots + \phi_{p1}X_p, \quad (6.1)$$

tal que tiene la varianza más grande. Normalizada significa que  $\sum_{j=1}^p \phi_{j1}^2 = 1$ . Los elementos  $\phi_{11}, \phi_{21}, \dots, \phi_{p1}$  son llamados los *loadings* del primer componente principal.

### Cálculo de los componentes principales

Para calcular el primer componente principal de un conjunto de datos  $\mathbf{X}$  de  $n \times p$ , todos los datos son centrados con media cero y luego se busca la combinación lineal:

$$z_{i1} = \phi_{11}x_{i1} + \phi_{21}x_{i2} + \dots + \phi_{p1}x_{ip}, \quad (6.2)$$

tal que tenga la mayor varianza muestral, sujeta a  $\sum_{j=1}^p \phi_{j1}^2 = 1$ . Es decir, el vector *loading* del primer componente principal ( $\phi_1 = [\phi_{11} \ \phi_{21} \ \dots \ \phi_{p1}]^T$ ) resuelve el problema de optimización:

$$\max_{\phi_{11}, \dots, \phi_{p1}} \left\{ \frac{1}{n} \sum_{i=1}^n \left( \sum_{j=1}^p \phi_{j1} x_{ij} \right)^2 \right\} \text{ sujeto a } \sum_{j=1}^p \phi_{j1}^2 = 1. \quad (6.3)$$

De la ecuación 6.2, la función objetivo se puede escribir como  $\frac{1}{n} \sum_{i=1}^n z_{i1}^2$ . Como  $\frac{1}{n} \sum_{i=1}^n x_{ij} = 0$ , el promedio de  $z_{11}, \dots, z_{n1}$  será cero también. Por eso la función objetivo de 6.3 es solo la varianza muestral de los  $n$  valores de  $z_{i1}$ . Los valores  $z_{11}, \dots, z_{n1}$  son llamados los *scores* del componente principal. El problema 6.3 puede ser resuelto con álgebra lineal utilizando los vectores propios. El vector *loading*  $\phi_1$  define la dirección en la que que los datos varían más.

Sea  $\mathbf{X}$  una matriz que representa a un conjunto de  $n$  observaciones y  $p$  características, donde  $x_{ki}$  es la  $k$ -ésima observación con la característica  $i$ . Para obtener los componentes principales se debe realizar lo siguiente:

1. Se calcula  $\mathbf{A}$ : la matriz de covarianzas de  $\mathbf{X}$ , donde

$$\text{cov}(X_i, X_j) = \frac{1}{n-1} \sum_{k=1}^n (x_{ki} - \bar{X}_i)(x_{kj} - \bar{X}_j). \quad (6.4)$$

2. Se calculan los valores y vectores propios de  $\mathbf{A}$ .
3. Los vectores propios se ordenan según la magnitud de su valor propio. Y cada uno corresponde a los diferentes componentes principales.

### Proporción de Varianza explicada

Es natural preguntarse qué tanta información en un conjunto de datos se pierde al proyectar las observaciones en los primeros componentes principales, esto se traduce a saber cuánta varianza no está contenida en los primeros componente principales. Para esto se utiliza la proporción de varianza explicada, la cuál esta definida como:

$$\sum_{j=1}^p \text{Var}(\mathbf{A}_j) = \sum_{j=1}^p \frac{1}{n} \sum_{i=1}^n x_{ij}^2, \quad (6.5)$$

y la varianza explicada por el  $m$ -ésimo componente principal es:

$$\frac{1}{n} \sum_{i=1}^n z_{im}^2 = \frac{1}{n} \sum_{i=1}^n \left( \sum_{j=1}^p \phi_{jm} x_{ij} \right)^2. \quad (6.6)$$

Por lo tanto, la proporción de varianza explicada (PVE por sus siglas en inglés) del  $m$ -ésimo componente principal está dada por:

$$\frac{\sum_{i=1}^n \left( \sum_{j=1}^p \phi_{jm} x_{ij} \right)^2}{\sum_{j=1}^p \sum_{i=1}^n x_{ij}^2}. \quad (6.7)$$

La PVE de cada componente principal es una cantidad positiva. Para calcular PVE acumulada de los  $M$  componentes principales, simplemente se suma la ec. 6.7 hasta los primeros  $M$  componentes.

## Capítulo 7

# Anexo B: Simulación de bases de datos para ilustrar los métodos de enlace

Para lo mostrado en la Figura 3.2 se simularon cuatro bases de datos. Para la primera se utilizó la distribución normal, creando tres conjuntos de datos en dos dimensiones. Para la segunda se utilizó la función `mlbench.shapes` de la librería `mlbench` (Leisch et al., 2021), la cual permite generar conjuntos de datos con distintas formas geométricas. Y los dos últimos conjuntos de datos se simularon a través de funciones de senos y cosenos. El código para simular las bases de datos, agruparlas y graficarlas de acuerdo a cada método de enlace se muestra a continuación.

```
1 pacman::p_load(NbClust, ClustGeo, ggplot2, readxl, purrr,
2                 cluster, factoextra, tidyr, dplyr, scales,
3                 mlbench, showtext, paletteer)
4
5 font_add_google(c("Poppins"))
6 showtext_auto()
7
8
9 metodos <- c("single", "complete", "average", "centroid", "ward")
10
11 # esta función obtiene la agrupación para los métodos:
12 # single, complete, average, centroid y ward
13 obten_clusters <- function(data, k){
14
15     distance <- dist(scale(data), method = 'euclidean')
16     complete <- hclust(distance, method = 'complete')
17     data$complete <- cutree(complete, k = k)
18
19     average <- hclust(distance, method = 'average')
20     data$average <- cutree(average, k = k)
21
22     single <- hclust(distance, method = 'single')
```

```

23 data$single <- cutree(single, k = k)
24
25 centroid <- hclust(distance, method = 'centroid')
26 data$centroid <- cutree(centroid, k = k)
27
28 ward <- hclust(distance, method = 'ward.D')
29 data$ward <- cutree(ward, k = k)
30
31 data <- data%>%
32   mutate(complete = as.factor(complete),
33          average = as.factor(average),
34          single = as.factor(single),
35          centroid = as.factor(centroid),
36          ward = as.factor(ward))
37 return(data)
38 }
39
40 # funci n para crear las gr ficas con distintos m todos
41 obten_Grafica <- function(data,metodo_enlace,tamano_punto){
42   # la variable x debe llamarse V1
43   # la variable y debe llamarse V2
44   G <- ggplot(data,aes(x=V1,y=V2))+
45     theme_void()+
46     theme(text=element_text(family="Poppins", size=10),
47           plot.title = element_text(face="bold", size=10),
48           legend.title = element_blank(),
49           axis.title = element_blank(),
50           axis.text = element_blank(),
51           panel.grid.major = element_blank(),
52           panel.grid.minor = element_blank(),
53           panel.border = element_blank(),
54           panel.background = element_blank(),
55           legend.position="none")
56
57   if(metodo_enlace=="single"){
58     G <- G+geom_point(aes(color=factor(single)),size=tamano_
59       punto)+
60     labs(title="Clusters creados con el m todo single")
61   return(G)
62 }
63 else if(metodo_enlace=="complete"){
64   G <- G+geom_point(aes(color=factor(complete)),size=tamano_
65     punto)+
66   labs(title="Clusters creados con el m todo complete")
67   return(G)
68 }
69 else if(metodo_enlace=="average"){
70   G <- G+geom_point(aes(color=factor(average)),size=tamano_

```

```

        punto)+
69     labs(title="Clusters creados con el m todo average")
70     return(G)
71   }
72   else if(metodo_enlace=="centroid"){
73     G <- G+geom_point(aes(color=factor(centroid)),size=tamano_
74       punto)+
75     labs(title="Clusters creados con el m todo cetroid")
76     return(G)
77   }
78   else if(metodo_enlace=="ward"){
79     G <- G+geom_point(aes(color=factor(ward)),size=tamano_
80       punto)+
81     labs(title="Clusters creados con el m todo ward")
82     return(G)
83   }else{
84     G <- paste(metodo_enlace, "No es un m todo v lido.",
85       "Elige un m todo v lido: single, complete, centroid,
86       ward o average")
87   }
88   return(print(G))
89 }
90
91 # paletas de colores:
92 paletteer_d("ggthemes::excel_Vapor_Trail")
93 paletteer_d("ggthemes::excel_Depth")
94 paletteer_d("ggthemes::excel_Gallery")
95
96
97 # Tres grupos con ruido
98 set.seed(6)
99 data <- data.frame(V1=c(rnorm(100,5,2),
100                       rnorm(100,1,1),
101                       rnorm(100,-2,1)),
102                   V2=c(rnorm(100,5,1),
103                       rnorm(100,1,1),
104                       rnorm(100,5,1)))
105
106 plot(data)
107 data_with_clusters <- obten_clusters(data,3)
108
109 for(m in metodos){
110   g <- obten_Grafica(data_with_clusters,m,8)+
111     scale_color_manual(values=c("#FFE082", "#54A021", "#FF8F00"))
+

```

```

112     labs(title="")
113   plot(g)
114   ggsave(g,filename = paste0("tres_clusters_",m,".png"),
115         device = "png",width = 5,height = 5, dpi=150)
116 }
117
118
119 # triangulos
120 base <- mlbench.shapes(n=800)
121 data <- as.data.frame(base$x)%>%
122   rename(V1=x4)%>%
123   filter(V1>0,
124         V2>0)
125
126 data <- rbind(data%>%
127               mutate(V2=V2-.5),
128               data%>%
129               mutate(V2=(V2-.5)*-1))
130 plot(data)
131
132 data_with_clusters <- obten_clusters(data,2)
133 for(m in metodos){
134   g <- (obten_Grafica(data_with_clusters,m,8)+
135         scale_color_manual(values=c("#FF8F00", "#54A021")))+
136   labs(title="")
137   plot(g)
138   ggsave(g,filename = paste0("triangulos_",m,".png"),
139         device = "png",width = 5,height = 5, dpi=150)
140 }
141
142
143 # dos clusters de diferentes tama os (uno muy grande)
144 genera_circulos <- function(r,a){
145   set.seed(6)
146   theta = runif(1000, 0,2*pi)
147   x = cos(theta) + rnorm(100, 0, 0.03)
148   y = sin(theta) + rnorm(100, 0, 0.03)
149   data <- data.frame(V1=x,
150                     V2=y)
151
152   d<-data*r
153   plot(d)
154   set.seed(6)
155   circulo <- rbind(data.frame(V1=runif(1000,-a,a),
156                               V2=runif(1000,-a,a)),d)
157   return(circulo)
158 }
159 data <- rbind(genera_circulos(10,8),

```

```

160             genera_circulos(2,1.8)-11)
161 plot(data)
162
163 data_with_clusters <- obten_clusters(data,2)
164 for(m in metodos){
165     g <- obten_Grafica(data_with_clusters,m,8)+
166         scale_color_manual(values=c("#FF8F00", "#54A021"))+
167         labs(title="")
168     plot(g)
169     ggsave(g,filename = paste0("dos_clusters_",m,".png"),
170           device = "png",width = 5,height = 5, dpi=150)
171 }
172
173
174 # Dos circulos uno dentro y otro fuera
175 theta = runif(1000, 0,2*pi)
176 x = cos(theta) + rnorm(100, 0, 0.03)
177 y = sin(theta) + rnorm(100, 0, 0.03)
178 data <- data.frame(V1=x,
179                   V2=y)
180
181 data <- rbind(data, data*0.5)
182 plot(data)
183 data_with_clusters <- obten_clusters(data,2)
184 for(m in metodos){
185     g <- (obten_Grafica(data_with_clusters,m,3)+
186         scale_color_manual(values=c("#FF8F00", "#54A021")))+
187         labs(title="")
188
189     plot(g)
190     ggsave(g,filename = paste0("circulos_",m,".png"),
191           device = "png",width = 5,height = 5, dpi=150)
192 }

```

## Capítulo 8

# Anexo C: Código Tesis

El código utilizado en esta tesis se muestra a continuación. Todos los datos son públicos y se han referenciado las fuentes a lo largo del documento.

El archivo `Comparacion_Variables.xlsx` que fue creado para filtrar las variables seleccionadas se puede encontrar en <https://github.com/Jaz2608Tesis>. Sin embargo, los resultados se pueden replicar sin éste.

```
1 pacman::p_load(readr, magrittr, dplyr, tidyr, purrr, tibble,
2                 ggplot2, lubridate, leaflet, rgdal, sf, rgdal)
3
4
5 # Establece la configuración del lenguaje
6 Sys.setlocale(locale="es_ES.UTF-8")
7
8 input <- "C:/Users/amartinez/Documents/Proyecto"
9 output <- "C:/Users/amartinez/Documents/Proyecto/imagenes"
10 setwd(input)
11
12 # * * * * *
13 # 0.0 Se cargan los poligonos de los municipios =====
14 # * * * * *
15
16 # Marco Geoestadístico. Censo de Población y Vivienda 2020
17 # Se descarga de:
18 #https://www.inegi.org.mx/app/biblioteca/ficha.html?upc
19 # =889463807469
20 # Directorio donde se encuentran los poligonos de los
21 # municipios
22 setwd(paste0(input, "/data/poligonos_inegi"))
23
24 # Poligonos de todos los municipios del país
25 datos_espaciales <- readOGR("00mun.shp",
```

```

25         verbose = FALSE,
26         encoding = "UTF-8")
27
28 dim(datos_espaciales@data) # son 2469 municipios
29
30 # Se transforman los datos al formato WGS84
31 datos_espaciales %<>% spTransform(CRS("+proj=longlat +datum=
      WGS84"))
32
33 # Se grafica el mapa de la rep blica dividido por municipios
34 plot(datos_espaciales, main = "Mapa de la rep blica mexicana
      \ndivido por municipios",
35       xlab = "Longitud", ylab = "Latitud")
36
37
38
39 # * * * * *
      * *
40 # 0.1 Se cargan las distancias ====
41 # * * * * *
      * *
42
43 # Se calculan las matrices D0 y D1 por distancias y por vecinos
44
45 # Se ubican los centroides y calculando las distancias
46 # Se convierte a un objeto espacial
47 datos_espaciales.sf <- sf::st_as_sf(datos_espaciales)
48
49 # Calcula los centroides geogr ficos
50 Centroids <- st_centroid(datos_espaciales.sf)
51 # plot(Centroids)
52 # plot(datos_espaciales.sf)
53
54 # Calcula la distancia hacia los crentroides
55 D1.geo <- st_distance(Centroids) # Matriz de distancias D1
56 D1.geo <- as.dist(D1.geo)
57
58 # Se construye una lista de vecinos basandose en las regiones
      con
59 # limites contiguos
60 list.nb <- spdep::poly2nb(datos_espaciales)
61
62 # Se contrsuye la matriz de adyacencias
63 A <- spdep::nb2mat(list.nb, style="B")
64 # Se pone unos en la diagonal
65 diag(A) <- 1
66
67 D1.dis <- 1-A # Esto se hace porque se esta calculando la
      matriz

```

```

68 # de distancias
69 D1.dis <- as.dist(D1.dis)
70
71 # * * * * *
72 # 1.1: Integración y limpieza de los datos ====
73 # * * * * *
74 # Se cargan y limpian los datos que sirven para calcular
75 # las distancias sociodemograficas
76
77 pacman::p_load(dplyr, stringr, stringi, readxl, tidyr)
78 options(scipen=999)
79
80 # Se cargan los datos del coneval
81 # https://www.coneval.org.mx/Medicion/Paginas/Programas_BD_
82   municipal.aspx
83 setwd(paste0(input, "/data/coneval"))
84 coneval <- read.csv("indicadores de pobreza municipal 2015.csv"
85   ,
86   encoding = "latin1")
87
88 # Se cargan los datos del inegi a nivel municipal
89 # https://www.inegi.org.mx/programas/ccpv/2020/#datos_abiertos
90 setwd(paste0(input, "/data/censo_inegi"))
91 temp <- list.files(pattern = ".csv")
92 myfiles <- lapply(temp, read.csv, encoding = "UTF-8")
93 inegi <- do.call(rbind, myfiles)
94 rm(temp);rm(myfiles)
95
96 # Existen columnas en donde las proporciones para las variables
97 # del coneval son calculadas
98 # previamente, se descartan ya que estan redondeadas
99 coneval <- coneval %>%
100   select(-c("pobreza", "pobreza_e", "pobreza_m", "vul_car",
101     "vul_ing", "npnv", "ic_rezedu", "ic_asalud",
102     "ic_segsov", "ic_cv", "ic_sbv", "ic_ali",
103     "carencias", "carencias3", "plb", "plbm"))
104
105 # El nombre de la columna X.U.FEFF.ENTIDAD en la base del inegi
106 # se reemplaza por ENTIDAD
107 names(inegi)[which(names(inegi)=="X.U.FEFF.ENTIDAD")] = "
108   ENTIDAD"
109
110 # Se conserva únicamente el total por municipio en la base del
111   inegi,
112 # y se descartan variables que no son de interés
113 inegi <- inegi%>% filter(NOM_LOC=='Total del Municipio')%>%

```

```

110 select(-c("LOC", "NOM_LOC" ,
111           "LONGITUD", "LATITUD", "ALTITUD") )
112
113 # En el INEGI y el coneval las claves de los municipios
114 # son distintas, as que esas no sirven para hacer un join
115 summary(coneval$MUN)
116 summary(inegi$MUN)
117
118
119 # * * * * *
120 # 1.2: Cambios de los nombres en municipios y estados ====
121 # * * * * *
122 unique(inegi$NOM_ENT)
123 unique(coneval$entidad_federativa)
124
125 # Se reemplazan los nombres de los estados
126 inegi<-inegi%>%
127   mutate(NOM_ENT=case_when(
128     NOM_ENT=='Michoac n de Ocampo' ~ 'Michoac n',
129     NOM_ENT=='Veracruz de Ignacio de la Llave' ~ 'Veracruz',
130     NOM_ENT=='Coahuila de Zaragoza' ~ 'Coahuila',
131     TRUE ~ NOM_ENT))
132
133 coneval<- coneval%>%
134   mutate(entidad_federativa=case_when(
135     entidad_federativa=='Distrito Federal'~'Ciudad de M xico',
136     TRUE ~ entidad_federativa))%>%
137   rename(NOM_ENT=entidad_federativa,
138         NOM_MUN=municipio,
139         ENTIDAD=clave_entidad,
140         MUN=clave_municipio)
141
142 # Con esto se ve si las combinaciones entre los nombres de los
143 # estados y municipios son nicos para poderlos usar
144 # como llave primaria
145
146 inegi%>%
147   group_by(NOM_ENT, NOM_MUN)%>%
148   summarise(total=n())%>%
149   filter(total>1)
150
151 coneval%>%
152   group_by(NOM_ENT, NOM_MUN)%>%
153   summarise(total=n())%>%
154   filter(total>1)
155

```

```

156 # Con el coneval s se puede hacer una llave unica uniendo
157 # los nombres, pero para el inegi se tienen que arreglar
158
159
160 # "San Juan Mixtepec"
161 inegi%>%
162   filter(NOM_MUN=="San Juan Mixtepec")
163 coneval %>%
164   filter(str_detect(NOM_MUN, "San Juan Mixtepec"))
165
166 # "San Pedro Mixtepec"
167 inegi%>%
168   filter(NOM_MUN=="San Pedro Mixtepec")
169 coneval %>%
170   filter(str_detect(NOM_MUN, "San Pedro Mixtepec"))
171
172 # Se puede inferir por su poblaci n cu l es cu l
173 inegi<-inegi%>%
174   mutate(NOM_MUN=case_when(
175     MUN=='208' & NOM_ENT=='Oaxaca'~ 'San Juan Mixtepec -Dto.
176       08 -',
177     MUN=='209' & NOM_ENT=='Oaxaca'~ 'San Juan Mixtepec -Dto.
178       26 -',
179     MUN=='318' & NOM_ENT=='Oaxaca'~ 'San Pedro Mixtepec -Dto.
180       22 -',
181     MUN=='319' & NOM_ENT=='Oaxaca'~ 'San Pedro Mixtepec -Dto.
182       26 -',
183     TRUE ~ NOM_MUN)
184   )
185
186 # Se quitan las claves del coneval ya que ahora no ser n
187   necesarias
188 coneval <- coneval%>% select(-c("ENTIDAD", "MUN"))
189
190 # Ahora se pueden unir las bases de datos
191 interseccion_inegi_coneval <- merge(coneval, inegi,
192   by=c("NOM_ENT", "NOM_MUN"))
193
194 # notemos que:
195 #   en el inegi hay 2469 renglones
196 #   en el coneval hay 2457 renglones
197 #   en la intersecci n hay 2433 renglones
198
199 # Vemos aquellos que est n en el coneval pero no en la
200   interseccion
201 dif_coneval <- setdiff(coneval%>%select(NOM_ENT, NOM_MUN),
202   interseccion_inegi_coneval%>%
203     select(NOM_ENT, NOM_MUN))%>%

```

```

198 arrange((NOM_MUN))
199
200 # se tienen 24 registros que estan en el coneval
201 # pero no en la interseccion
202
203 # Vemos aquellos que est n en el inegi pero no en la
204     interseccion
205 dif_inegi <-setdiff(inegi%>%select(NOM_ENT, NOM_MUN),
206                     interseccion_inegi_coneval%>%
207                     select(NOM_ENT, NOM_MUN))%>%
208                     arrange((NOM_MUN))
209 # se tienen 36 registros que estan en el inegi
210 # pero no en la intersecci n
211
212 # Se tienen que cambiar aquellos que sean los mismos pero el
213     nombre
214 coneval <- coneval %>%
215     mutate(NOM_MUN=
216         case_when(
217             NOM_MUN=='Acambay' & NOM_ENT=='M xico' ~
218                 'Acambay de Ru z Casta eda',
219             NOM_MUN=='Batopilas' & NOM_ENT=='Chihuahua' ~
220                 'Batopilas de Manuel G mez Mor n',
221             NOM_MUN=='Dr. Arroyo'& NOM_ENT=='Nuevo Le n' ~
222                 'Doctor Arroyo',
223             NOM_MUN=='Dr. Coss'& NOM_ENT=='Nuevo Le n' ~
224                 'Doctor Coss',
225             NOM_MUN=='Dr. Gonz lez'& NOM_ENT=='Nuevo Le n' ~
226                 'Doctor Gonz lez',
227             NOM_MUN=='Carmen'& NOM_ENT=='Nuevo Le n' ~
228                 'El Carmen',
229             NOM_MUN=='Gral. Bravo'& NOM_ENT=='Nuevo Le n' ~
230                 'General Bravo',
231             NOM_MUN=='Gral. Escobedo'& NOM_ENT=='Nuevo Le n' ~
232                 'General Escobedo',
233             NOM_MUN=='Gral. Ter n'& NOM_ENT=='Nuevo Le n' ~
234                 'General Ter n',
235             NOM_MUN=='Gral. Trevi o'& NOM_ENT=='Nuevo Le n' ~
236                 'General Trevi o',
237             NOM_MUN=='Gral. Zaragoza'& NOM_ENT=='Nuevo Le n' ~
238                 'General Zaragoza',
239             NOM_MUN=='Gral. Zuazua'& NOM_ENT=='Nuevo Le n' ~
240                 'General Zuazua',
241             NOM_MUN=='Heroica Ciudad de Juchit n de Zaragoza'

```

```

241     &
242     NOM_ENT=='Oaxaca' ~
243     'Juchit n de Zaragoza',
244     NOM_MUN=='Jonacatepec'& NOM_ENT=='Morelos' ~
245     'Jonacatepec de Leandro Valle',
246     NOM_MUN=='Jos Joaquin de Herrera'&
247     NOM_ENT=='Guerrero' ~
248     'Jos Joaquin de Herrera',
249     NOM_MUN=='Medell n' & NOM_ENT=='Veracruz'~
250     'Medell n de Bravo',
251     NOM_MUN=='San Mateo Yucutind ' & NOM_ENT=='Oaxaca
252     ,~
253     'San Mateo Yucutindoo',
254     NOM_MUN=='Santiago Chazumba'& NOM_ENT=='Oaxaca' ~
255     'Villa de Santiago Chazumba',
256     NOM_MUN=='Silao' & NOM_ENT=='Guanajuato' ~
257     'Silao de la Victoria',
258     NOM_MUN=='Tlaltizap n'& NOM_ENT=='Morelos' ~
259     'Tlaltizap n de Zapata',
260     NOM_MUN=='Tezoatl n de Segura y Luna'&
261     NOM_ENT=='Oaxaca' ~
262     'Heroica Villa Tezoatlan De Segura Y Luna, Cuna
263     De La Independencia De Oaxaca',
264     NOM_MUN=='Tlaltizap n'& NOM_ENT=='Morelos' ~
265     'Tlaltizap n de Zapata',
266     NOM_MUN=='Tlaquepaque'& NOM_ENT=='Jalisco' ~
267     'San Pedro Tlaquepaque',
268     NOM_MUN=='Villa de Tututepec de Melchor Ocampo'&
269     NOM_ENT=='Oaxaca' ~
270     'Villa de Tututepec',
271     NOM_MUN=='Zacualpan'& NOM_ENT=='Morelos' ~
272     'Zacualpan de Amilpas',
273     TRUE ~ NOM_MUN)
274 )
275
276 inegi<- inegi%>%
277   mutate(NOM_MUN = case_when(NOM_MUN == "Heroica Villa
278     Tezoatl n de Segura y Luna, Cuna de" ~
279     'Heroica Villa Tezoatlan De Segura Y Luna, Cuna De La
280     Independencia De Oaxaca',
281     TRUE ~ NOM_MUN))
282
283 # Si se vuelven a correr las intersecciones en el coneval hay 0
284 interseccion_inegi_coneval <- merge(coneval, inegi,
285                                     by=c("NOM_ENT", "NOM_MUN"))
286 dif_coneval <- setdiff(coneval%>%select(NOM_ENT, NOM_MUN),
287                       interseccion_inegi_coneval%>%
288                       select(NOM_ENT, NOM_MUN))%>%

```

```

283 arrange((NOM_MUN))
284 dif_inegi <-setdiff(inegi%>%select(NOM_ENT, NOM_MUN),
285                   interseccion_inegi_coneval%>%
286                   select(NOM_ENT, NOM_MUN))%>%
287 arrange((NOM_MUN))
288
289
290 # Existen 12 municipios nuevos, que aparecen en la encuesta del
291   inegi 2020
292 # pero no aparecen en la encuesta del coneval del 2015
293 # * * * * *
294 # 2.0: Join entre coneval e inegi====
295 # * * * * *
296 inegi_y_coneval <- merge(inegi, coneval,
297                          by=c("NOM_ENT", "NOM_MUN"),
298                          all.x=TRUE)
299
300 # * * * * *
301 # 2.1: Transformar las variables del INEGI a proporciones ====
302 # * * * * *
303
304
305 # Los datos del inegi van desde POBTOT hasta TAMLOC, saldr n
306   warnings porque TAMLOC no es nmerica
307 subdata_inegi <- inegi[which(colnames(inegi_y_coneval)=="POBTOT
308   "):
309                       which(colnames(inegi_y_coneval)=="
310                             TAMLOC")]
311
312 # Se convierten los datos a numericos
313 subdata_inegi <- as.data.frame(sapply(subdata_inegi, as.numeric
314   ))
315
316 # Se usa un archivo auxiliar para calcular las tasas del inegi,
317 # en este archivo se define entre qu variable se divide cada
318   una
319 setwd(input)
320 para_tasas_inegi <- read_excel("Comparacion_Variables.xlsx")%>%
321   select(Variables, dividir_entre)%>%
322   drop_na()
323 names(para_tasas_inegi) <- c("variable", "division")
324
325 # Se realiza la conversion

```

```

321 for(v in 1:dim(para_tasas_inegi)[1]){
322   variable <- para_tasas_inegi$variable[v]
323   division <- para_tasas_inegi$division[v]
324   if(division=="no se divide"){
325     subdata_inegi[variable]<-subdata_inegi[variable]
326   }else{
327     subdata_inegi[variable]<-subdata_inegi[variable]/
328     subdata_inegi[division]
329   }
330 };rm(v)
331
332
333
334 # * * * * *
335 # 2.2: Transformar las variables del CONEVAL a proporciones
336 # * * * * *
337
338 # Las variables del coneval se divien entre 'poblacion', a
339 # partir de la variable
340 # pobreza_pob y hasta plbm_pob, se agrega tambi n el estado y
341 # municipio
342 # El coneval tiene 12 na'as y 11 "n.d", en estos renglones no
343 # se pueden
344 # hacer operaciones
345 subdata_coneval <- inegi_y_coneval[
346   which(colnames(inegi_y_coneval)=="poblacion"):
347   which(colnames(inegi_y_coneval)=="plbm_pob")]
348
349 subdata_coneval <- as.data.frame(sapply(subdata_coneval, as.
350   numeric))
351
352 # se calculan las tasas desde pobreza_pob hasta la ltima
353 # columna
354 for (i in names(subdata_coneval)[-1]){
355   subdata_coneval[i] <- (subdata_coneval[i])/
356   (subdata_coneval["poblacion"])
357 }
358 rm(i) # Salen warnings por los NA's de los estados que no
359 # tienen info para el coneval
360
361 # Se agrega la poblaci n total, el estado y municipio a las
362 # dos subdatas
363 # y al del inegi tambi n se le agrega las claves

```

```

359 subdata_coneval <- cbind(inegi_y_coneval[
360     which(colnames(inegi_y_coneval)=="NOM_MUN")],
361     subdata_coneval)
362 subdata_coneval <- cbind(inegi_y_coneval[
363     which(colnames(inegi_y_coneval)=="NOM_ENT")],
364     subdata_coneval)
365
366 subdata_inegi <- cbind(inegi[which(colnames(inegi)=="MUN")],
367     subdata_inegi)
368 subdata_inegi <- cbind(inegi[which(colnames(inegi)=="ENTIDAD")
369     ],
370     subdata_inegi)
371 subdata_inegi <- cbind(inegi[which(colnames(inegi)=="NOM_MUN")
372     ],
373     subdata_inegi)
374
375
376
377 # * * * * *
378 # 3.1: Imputar los datos faltantes ====
379 # * * * * *
380
381
382 # Se ve si hay datos faltantes
383 which(apply(subdata_inegi, 2, function(x) any(is.na(x)))==TRUE)
384 # Hay datos faltantes en TAMLOC pero esa se quitar
385
386 which(apply(subdata_coneval, 2, function(x) any(is.na(x)))==
387     TRUE)
388 length(which(apply(subdata_coneval, 2, function(x) any(is.na(x)
389     ))==TRUE))
390 # Existen 17 datos faltantes para todas las columnas en los
391     datos del coneval
392
393 # Estos son:
394 faltantes <- which((rowSums(is.na(subdata_coneval)) > 0) ==
395     TRUE) #162 en total
396 faltantes
397 length(faltantes) #23 datos faltantes en la base del coneval
398
399 # Se van a modificar las variables del coneval, es decir, desde
400     pobreza_pob
401 # hasta plbm_pob

```

```

397 i <- which(names(subdata_coneval)=="pobreza_pob")
398 j <- which(names(subdata_coneval)=="plbm_pob")
399
400 # Son 12 los municipios que surgieron entre 2015 y 2020 por lo
    que
401 # aparecen en la base de datos del inegi pero no del coneval
402 # Esta informaci n se obtuvo de AGEEML_2021682212978.csv
403
404
405 # * * * * * San Quint n -
    Baja California
406 # Proviene de: (1)
407 # NOM_MUN: Ensenada
408 # NOM_ENT: Baja California
409
410 subdata_coneval[which(subdata_coneval['NOM_ENT'] == 'Baja
    California' &
411
    subdata_coneval['NOM_MUN'] == 'San
    Quint n'),i:j] <- subdata_coneval[
412
    which(subdata_coneval['NOM_ENT'] == 'Baja
    California' &
413
    subdata_coneval['NOM_MUN'] == 'Ensenada')
    , i:j]
414
415 # * * * * * Seybaplaya -
    Campeche
416 # Proviene de: (2)
417 # NOM_MUN: Champot n
418 # NOM_ENT: Campeche
419
420 imputar <- subdata_coneval[which(subdata_coneval['NOM_ENT'] ==
    'Campeche' &
421
    subdata_coneval['NOM_MUN'] == 'Champot n'),i:j]
422
423 # NOM_MUN: Campeche
424 # NOM_ENT: Campeche
425 imputar <- rbind(imputar, subdata_coneval[
426
    which(subdata_coneval['NOM_ENT'] == 'Campeche' &
427
    subdata_coneval['NOM_MUN'] == 'Campeche'),i:j])
428
429
430 imputar <- sapply(imputar, as.numeric)
431 imputar <- as.data.frame(t(apply((imputar),MARGIN=2,FUN=mean)))
432
433
434 subdata_coneval[which(subdata_coneval['NOM_ENT'] == 'Campeche'
    &
435
    subdata_coneval['NOM_MUN'] == 'Seybaplaya'),i:j] <- imputar

```

```

436
437 rm(imputar)
438
439
440 # * * * * * Capit n Luis ngel Vidal -
    Chiapas
441 # Proviene de: (1)
442 # NOM_MUN: Siltepec
443 # NOM_ENT: Chiapas
444
445 subdata_coneval[which(subdata_coneval['NOM_ENT'] == 'Chiapas' &
446                      subdata_coneval['NOM_MUN'] == 'Capit n Luis
                        ngel Vidal'), i:j] <- subdata_coneval[
447                      which(subdata_coneval['NOM_ENT'] == 'Chiapas' &
448                      subdata_coneval['NOM_MUN'] == 'Siltepec'), i:j]
449
450
451 # * * * * * Rinc n Chamula San Pedro -
    Chiapas
452 # Proviene de: (4)
453
454 # NOM_MUN: Jitotol
455 # NOM_ENT: Chiapas
456
457 imputar <- subdata_coneval[which(subdata_coneval['NOM_ENT'] ==
    'Chiapas' &
458                      subdata_coneval['NOM_MUN'] == 'Jitotol'), i:j]
459
460 # NOM_MUN: Ray n
461 # NOM_ENT: Chiapas
462
463 imputar <- rbind(imputar, subdata_coneval[which(subdata_coneval
    ['NOM_ENT'] == 'Chiapas' &
464                      subdata_coneval['NOM_MUN'] == 'Ray n'), i:j])
465
466 # NOM_MUN: Tapilula
467 # NOM_ENT: Chiapas
468
469 imputar <- rbind(imputar, subdata_coneval[which(subdata_coneval
    ['NOM_ENT'] == 'Chiapas' &
470                      subdata_coneval['NOM_MUN'] == 'Tapilula'), i:j])
471
472
473 # NOM_MUN: Pueblo Nuevo Solistahuac n
474 # NOM_ENT: Chiapas
475
476 imputar <- rbind(imputar, subdata_coneval[which(subdata_coneval
    ['NOM_ENT'] == 'Chiapas' &

```

```

477         subdata_coneaval['NOM_MUN'] == 'Pueblo Nuevo
           Solistahuac n'),i:j])
478
479 imputar <- sapply(imputar, as.numeric)
480 imputar <- as.data.frame(t(apply((imputar),MARGIN=2,FUN=mean)))
481
482
483 subdata_coneaval[which(subdata_coneaval['NOM_ENT'] == 'Chiapas' &
484                       subdata_coneaval['NOM_MUN'] == 'Rinc n Chamula San
           Pedro'),i:j] <- imputar
485
486 rm(imputar)
487
488 # * * * * * El Parral - Chiapas
489 # Proviene de: (2)
490
491 # NOM_MUN: Villaflores
492 # NOM_ENT: Chiapas
493
494 imputar <- subdata_coneaval[which(subdata_coneaval['NOM_ENT'] ==
           'Chiapas' &
495                               subdata_coneaval['NOM_MUN'] == 'Villaflores'),i:j]
496
497 # NOM_MUN: Villa Corzo
498 # NOM_ENT: Chiapas
499
500 imputar <- rbind(imputar, subdata_coneaval[which(subdata_coneaval
           ['NOM_ENT'] == 'Chiapas' &
501                               subdata_coneaval['NOM_MUN'] == 'Villa Corzo'),i:j])
502
503
504 imputar <- sapply(imputar, as.numeric)
505 imputar <- as.data.frame(t(apply((imputar),MARGIN=2,FUN=mean)))
506
507
508 subdata_coneaval[which(subdata_coneaval['NOM_ENT'] == 'Chiapas' &
509                       subdata_coneaval['NOM_MUN'] == 'El
           Parral'),i:j] <- imputar
510
511 rm(imputar)
512
513
514 # * * * * * Emiliano Zapata -
           Chiapas
515 # Proviene de: (3)
516
517 # NOM_MUN: Venustiano Carranza
518 # NOM_ENT: Chiapas

```

```

519
520 imputar <- subdata_coneval[which(subdata_coneval['NOM_ENT'] ==
    'Chiapas' &
521     subdata_coneval['NOM_MUN'] == 'Venustiano Carranza'),i:j]
522
523 # NOM_MUN: Chiapa de Corzo
524 # NOM_ENT: Chiapas
525
526 imputar <- rbind(imputar, subdata_coneval[
527     which(subdata_coneval['NOM_ENT'] == 'Chiapas' &
528     subdata_coneval['NOM_MUN'] == 'Chiapa de Corzo'),i:j
    ])
529
530 # NOM_MUN: Acala
531 # NOM_ENT: Chiapas
532
533 imputar <- rbind(imputar, subdata_coneval[which(subdata_coneval
    [
534     'NOM_ENT'] == 'Chiapas' &
535     subdata_coneval['NOM_MUN'] == 'Acala'),i:j])
536
537 imputar <- sapply(imputar, as.numeric)
538 imputar <- as.data.frame(t(apply((imputar),MARGIN=2,FUN=mean)))
539
540
541 subdata_coneval[which(subdata_coneval['NOM_ENT'] == 'Chiapas' &
542     subdata_coneval['NOM_MUN'] == 'Emiliano Zapata'),
543     i:j] <- imputar
544
545 rm(imputar)
546
547 # * * * * * Mezcalapa - Chiapas
548 # Proviene de: (3)
549
550 # NOM_MUN: Ocozocoautla de Espinosa
551 # NOM_ENT: Chiapas
552
553 imputar <- subdata_coneval[which(subdata_coneval['NOM_ENT'] ==
    'Chiapas' &
554     subdata_coneval['NOM_MUN'] == 'Ocozocoautla de
        Espinosa'),i:j]
555
556
557 # NOM_MUN: Tecpat n
558 # NOM_ENT: Chiapas
559
560 imputar <- rbind(imputar, subdata_coneval[

```

```

561         which(subdata_coneval['NOM_ENT'] == 'Chiapas' &
562             subdata_coneval['NOM_MUN'] == 'Tecpat n'),i:j))
563
564 # NOM_MUN: Ostuac n
565 # NOM_ENT: Chiapas
566
567 imputar <- rbind(imputar, subdata_coneval[
568     which(subdata_coneval['NOM_ENT'] == 'Chiapas' &
569         subdata_coneval['NOM_MUN'] == 'Ostuac n'),i:j])
570
571 imputar <- sapply(imputar, as.numeric)
572 imputar <- as.data.frame(t(apply((imputar),MARGIN=2,FUN=mean)))
573
574
575 subdata_coneval[which(subdata_coneval['NOM_ENT'] == 'Chiapas' &
576     subdata_coneval['NOM_MUN'] == 'Mezcalapa'),i:j] <-
577     imputar
578
579 rm(imputar)
580
581 # * * * * * Honduras de la Sierra -
582     Chiapas
583 # Proviene de: (1)
584
585 # NOM_MUN: Siltepec
586 # NOM_ENT: Chiapas
587
588 subdata_coneval[which(subdata_coneval['NOM_ENT'] == 'Chiapas' &
589     subdata_coneval['NOM_MUN'] == 'Honduras de la
590     Sierra'), i:j] <- subdata_coneval[
591     which(subdata_coneval['NOM_ENT'] == 'Chiapas' &
592         subdata_coneval['NOM_MUN'] == 'Siltepec'),i:j]
593
594 # * * * * * Coatetelco - Morelos
595 # Proviene de: (1)
596
597 # NOM_MUN: Miacatl n
598 # NOM_ENT: Morelos
599
600 subdata_coneval[which(subdata_coneval['NOM_ENT'] == 'Morelos' &
601     subdata_coneval['NOM_MUN'] == 'Coatetelco'),i:j
602     ] <- subdata_coneval[
603     which(subdata_coneval['NOM_ENT'] == 'Morelos' &
604         subdata_coneval['NOM_MUN'] == 'Miacatl n'),i:j
605     ]

```

```

604 # * * * * * Xoxocotla - Morelos
605 # Proviene de: (1)
606
607 # NOM_MUN: Puente de Ixtla
608 # NOM_ENT: Morelos
609
610 subdata_coneval[which(subdata_coneval['NOM_ENT'] == 'Morelos' &
611 subdata_coneval['NOM_MUN'] == 'Xoxocotla'),i:j]
612 <- subdata_coneval[
613 which(subdata_coneval['NOM_ENT'] == 'Morelos' &
614 subdata_coneval['NOM_MUN'] == 'Puente de Ixtla'
615 ),i:j]
616
617 # * * * * * Hueyapan - Morelos
618 # Proviene de: (1)
619
620 # NOM_MUN: Tetela del Volc n
621 # NOM_ENT: Morelos
622
623 subdata_coneval[which(subdata_coneval['NOM_ENT'] == 'Morelos' &
624 subdata_coneval['NOM_MUN'] == 'Hueyapan'),i:j]
625 <- subdata_coneval[
626 which(subdata_coneval['NOM_ENT'] == 'Morelos' &
627 subdata_coneval['NOM_MUN'] == 'Tetela del
628 Volc n'),i:j
629 ]
630
631 # * * * * * Puerto Morelos - Quintana
632 # Proviene de: (1)
633 # NOM_MUN: Benito Ju rez
634 # NOM_ENT: Quintana Roo
635
636 subdata_coneval[which(subdata_coneval['NOM_ENT'] == 'Quintana
637 Roo' &
638 subdata_coneval['NOM_MUN'] == 'Puerto Morelos')
639 , i:j] <- subdata_coneval[
640 which(subdata_coneval['NOM_ENT'] == 'Quintana
641 Roo' &
642 subdata_coneval['NOM_MUN'] == 'Benito Ju rez')
643 ,i:j]
644
645 rm(i);rm(j)

```

```

643 # * * * * *
      * * * * *
644 # * * * * * Otros municipios que no tienen datos en el
      coneval * * * * *
645 # * * * * *
      * * * * *
646
647 faltantes <- which(is.na(subdata_coneval$vul_car_pob)==TRUE)
648 length(faltantes)
649
650 subdata_coneval[faltantes,c("NOM_ENT","NOM_MUN")]
651 i <- which(names(subdata_coneval)== "pobreza_pob")
652 j <- which(names(subdata_coneval)== "plbm_pob")
653
654 subdata_coneval[faltantes,c("NOM_ENT","NOM_MUN")]
655
656
657 # * * * * *
      Buenaventura - Chihuahua
658 # Vecinos: (7) LISTO ***
659 # Ascensi n - Chihuahua
660 # Nuevo Casas Grandes - Chihuahua
661 # Galeana - Chihuahua
662 # Ignacio Zaragoza - Chihuahua
663 # Namiquipa - Chihuahua
664 # Chihuahua - Chihuahua
665 # Ahumada - Chihuahua
666
667
668 # Ascensi n - Chihuahua
669 imputar <- subdata_coneval[which(subdata_coneval['NOM_ENT'] ==
      'Chihuahua' &
670                               subdata_coneval['NOM_MUN'] == '
      Ascensi n'),i:j]
671 # Nuevo Casas Grandes - Chihuahua
672 imputar <- rbind(imputar, subdata_coneval[
673                 which(subdata_coneval['NOM_ENT'] == 'Chihuahua' &
674                 subdata_coneval['NOM_MUN'] == 'Nuevo Casas Grandes')
      ,i:j])
675 # Galeana - Chihuahua
676 imputar <- rbind(imputar, subdata_coneval[
677                 which(subdata_coneval['NOM_ENT'] == 'Chihuahua' &
678                 subdata_coneval['NOM_MUN'] == 'Galeana'),i:j])
679 # Ignacio Zaragoza - Chihuahua
680 imputar <- rbind(imputar, subdata_coneval[
681                 which(subdata_coneval['NOM_ENT'] == 'Chihuahua' &
682                 subdata_coneval['NOM_MUN'] == 'Ignacio Zaragoza'),i:
      j])

```

```

683 # Namiquipa - Chihuahua
684 imputar <- rbind(imputar, subdata_coneval[
685     which(subdata_coneval['NOM_ENT'] == 'Chihuahua' &
686     subdata_coneval['NOM_MUN'] == 'Namiquipa'),i:j])
687 # Chihuahua - Chihuahua
688 imputar <- rbind(imputar, subdata_coneval[
689     which(subdata_coneval['NOM_ENT'] == 'Chihuahua' &
690     subdata_coneval['NOM_MUN'] == 'Chihuahua'),i:j])
691 # Ahumada - Chihuahua
692 imputar <- rbind(imputar, subdata_coneval[which(subdata_coneval
693     ['NOM_ENT'] == 'Chihuahua' &
694     subdata_coneval['NOM_MUN'] == 'Ahumada'),i:j])
695
696 imputar <- sapply(imputar, as.numeric)
697 imputar <- as.data.frame(t(apply((imputar),MARGIN=2,FUN=mean)))
698
699 subdata_coneval[which(subdata_coneval['NOM_ENT'] == 'Chihuahua'
700     &
701     subdata_coneval['NOM_MUN'] == 'Buenaventura'),i
702     :j] <- imputar
703
704 rm(imputar)
705
706 # * * * * *
707 # Carich - Chihuahua
708 # Vecinos: (6) LISTO ***
709 # Guerrero - Chihuahua
710 # Bocoyna - Chihuahua
711 # Guachochi - Chihuahua
712 # Nonoava - Chihuahua
713 # San Francisco de Borja - Chihuahua
714 # Cusihuiiriachi - Chihuahua
715
716 # Guerrero - Chihuahua
717 imputar <- subdata_coneval[which(subdata_coneval['NOM_ENT'] ==
718     'Chihuahua' &
719     subdata_coneval['NOM_MUN'] == 'Guerrero'),i:j]
720 # Bocoyna - Chihuahua
721 imputar <- rbind(imputar, subdata_coneval[
722     which(subdata_coneval['NOM_ENT'] == 'Chihuahua' &
723     subdata_coneval['NOM_MUN'] == 'Bocoyna'),i:j])
724 # Guachochi - Chihuahua
725 imputar <- rbind(imputar, subdata_coneval[

```

```

726         which(subdata_coneaval['NOM_ENT'] == 'Chihuahua' &
727               subdata_coneaval['NOM_MUN'] == 'Nonoava'),i:j])
728 #   San Francisco de Borja - Chihuahua
729 imputar <- rbind(imputar, subdata_coneaval[
730               which(subdata_coneaval['NOM_ENT'] == 'Chihuahua' &
731                     subdata_coneaval['NOM_MUN'] == 'San Francisco de
732                       Borja'),i:j])
733 #   Cusihuiiriachi - Chihuahua
734 imputar <- rbind(imputar, subdata_coneaval[which(subdata_coneaval
735           ['NOM_ENT'] == 'Chihuahua' &
736           subdata_coneaval['NOM_MUN'] == 'Cusihuiiriachi'),i:j])
737
738 imputar <- sapply(imputar, as.numeric)
739 imputar <- as.data.frame(t(apply((imputar),MARGIN=2,FUN=mean)))
740
741 subdata_coneaval[which(subdata_coneaval['NOM_ENT'] == 'Chihuahua'
742 &
743                       subdata_coneaval['NOM_MUN'] == 'Carich
744                         '),i:j] <- imputar
745
746 rm(imputar)
747
748 # * * * * *
749 #   Santa Isabel - Chihuahua
750 # Vecinos: (6) LISTO ***
751 #   Chihuahua - Chihuahua
752 #   Riva Palacio - Chihuahua
753 #   Cuauht moc - Chihuahua
754 #   Gran Morelos - Chihuahua
755 #   Dr. Belisario Dom nguez - Chihuahua
756 #   Satev - chihuahua
757
758 #   Chihuahua - Chihuahua
759 imputar <- subdata_coneaval[which(subdata_coneaval['NOM_ENT'] ==
760 'Chihuahua' &
761                               subdata_coneaval['NOM_MUN'] == 'Chihuahua'),i:j]
762 #   Riva Palacio - Chihuahua
763 imputar <- rbind(imputar, subdata_coneaval[
764               which(subdata_coneaval['NOM_ENT'] == 'Chihuahua' &
765                     subdata_coneaval['NOM_MUN'] == 'Riva Palacio'),i:j])
766 #   Cuauht moc - Chihuahua
767 imputar <- rbind(imputar, subdata_coneaval[
768               which(subdata_coneaval['NOM_ENT'] == 'Chihuahua' &
769                     subdata_coneaval['NOM_MUN'] == 'Cuauht moc'),i:j])
770 #   Gran Morelos - Chihuahua
771 imputar <- rbind(imputar, subdata_coneaval[

```

```

768         which(subdata_coneval['NOM_ENT'] == 'Chihuahua' &
769               subdata_coneval['NOM_MUN'] == 'Gran Morelos'),i:j])
770 #   Dr. Belisario Dom nguez - Chihuahua
771 imputar <- rbind(imputar, subdata_coneval[
772               which(subdata_coneval['NOM_ENT'] == 'Chihuahua' &
773                   subdata_coneval['NOM_MUN'] == 'Dr. Belisario
774                       Dom nguez'),i:j])
774 #   Satev - chihuahua
775 imputar <- rbind(imputar, subdata_coneval[
776               which(subdata_coneval['NOM_ENT'] == 'Chihuahua' &
777                   subdata_coneval['NOM_MUN'] == 'Satev '),i:j])
778
779 imputar <- sapply(imputar, as.numeric)
780 imputar <- as.data.frame(t(apply((imputar),MARGIN=2,FUN=mean)))
781
782 subdata_coneval[which(subdata_coneval['NOM_ENT'] == 'Chihuahua'
783                       &
784                       subdata_coneval['NOM_MUN'] == 'Santa Isabel'),i:
785                       j] <- imputar
786
787 rm(imputar)
788
789 # * * * * *
790 #   Tem sachic - Chihuahua
791 # Vecinos: (9) LISTO ***
792 #   Madera - Chihuahua
793 #   Moris - Chihuahua
794 #   Ocampo - Chihuahua
795 #   Guerrero - Chihuahua
796 #   Matach - Chihuahua
797 #   Namiquipa - Chihuahua
798 #   G mez Far as - Chihuahua
799 #   Sahuaripa - Sonora - 052
800 #   Y cora - Sonora - 069
801
802 #   Madera - Chihuahua 1
803 imputar <- subdata_coneval[which(subdata_coneval['NOM_ENT'] ==
804                                 'Chihuahua' &
805                                 subdata_coneval['NOM_MUN'] == 'Madera'),i:j]
806 #   Moris - Chihuahua 2
807 imputar <- rbind(imputar, subdata_coneval[
808               which(subdata_coneval['NOM_ENT'] == 'Chihuahua' &
809                   subdata_coneval['NOM_MUN'] == 'Moris'),i:j])
810 #   Ocampo - Chihuahua 3
811 imputar <- rbind(imputar, subdata_coneval[
812               which(subdata_coneval['NOM_ENT'] == 'Chihuahua' &
813                   subdata_coneval['NOM_MUN'] == 'Ocampo'),i:j])

```

```

811 # Guerrero - Chihuahua 4
812 imputar <- rbind(imputar, subdata_coneval[
813     which(subdata_coneval['NOM_ENT'] == 'Chihuahua' &
814     subdata_coneval['NOM_MUN'] == 'Guerrero'),i:j])
815 # Matach - Chihuahua 5
816 imputar <- rbind(imputar, subdata_coneval[
817     which(subdata_coneval['NOM_ENT'] == 'Chihuahua' &
818     subdata_coneval['NOM_MUN'] == 'Matach '),i:j])
819 # Namiquipa - Chihuahua 6
820 imputar <- rbind(imputar, subdata_coneval[
821     which(subdata_coneval['NOM_ENT'] == 'Chihuahua' &
822     subdata_coneval['NOM_MUN'] == 'Namiquipa'),i:j])
823 # Gomez Far as - Chihuahua 7
824 imputar <- rbind(imputar, subdata_coneval[
825     which(subdata_coneval['NOM_ENT'] == 'Chihuahua' &
826     subdata_coneval['NOM_MUN'] == 'Gomez Far as'),i:j]
827 ])
828 # Sahuaripa - Sonora 8
829 imputar <- rbind(imputar, subdata_coneval[
830     which(subdata_coneval['NOM_ENT'] == 'Sonora' &
831     subdata_coneval['NOM_MUN'] == 'Sahuaripa'),i:j])
832 # Ycora - Sonora 9
833 imputar <- rbind(imputar, subdata_coneval[
834     which(subdata_coneval['NOM_ENT'] == 'Sonora' &
835     subdata_coneval['NOM_MUN'] == 'Ycora'),i:j])
836
837 imputar <- sapply(imputar, as.numeric)
838 imputar <- as.data.frame(t(apply((imputar),MARGIN=2,FUN=mean)))
839
840 subdata_coneval[which(subdata_coneval['NOM_ENT'] == 'Chihuahua'
841 &
842     subdata_coneval['NOM_MUN'] == 'Tem sachi'),i:
843     j] <- imputar
844
845 rm(imputar)
846
847 # * * * * *
848 Urique - Chihuahua
849 # Vecinos:(6) LISTO ***
850 # Guazapares - Chihuahua
851 # Batopilas de Manuel Gomez Mor n - Chihuahua
852 # Guachochi - Chihuahua
853 # Bocoyna - Chihuahua
854 # Maguarichi - Chihuahua
855 # Choix - Sinaloa
856
857 # Guazapares - Chihuahua

```

```

855 imputar <- subdata_coneval[which(subdata_coneval['NOM_ENT'] ==
      'Chihuahua' &
856         subdata_coneval['NOM_MUN'] == 'Guazapares'),i:j]
857 # Batopilas de Manuel Gomez Mor n - Chihuahua
858 imputar <- rbind(imputar, subdata_coneval[
859     which(subdata_coneval['NOM_ENT'] == 'Chihuahua' &
860         subdata_coneval['NOM_MUN'] == 'Batopilas de Manuel
      Gomez Mor n'),i:j])
861 # Guachochi - Chihuahua
862 imputar <- rbind(imputar, subdata_coneval[
863     which(subdata_coneval['NOM_ENT'] == 'Chihuahua' &
864         subdata_coneval['NOM_MUN'] == 'Guachochi'),i:j])
865 # Bocoyna - Chihuahua
866 imputar <- rbind(imputar, subdata_coneval[
867     which(subdata_coneval['NOM_ENT'] == 'Chihuahua' &
868         subdata_coneval['NOM_MUN'] == 'Bocoyna'),i:j])
869 # Maguarichi - Chihuahua
870 imputar <- rbind(imputar, subdata_coneval[
871     which(subdata_coneval['NOM_ENT'] == 'Chihuahua' &
872         subdata_coneval['NOM_MUN'] == 'Maguarichi'),i:j])
873 # Choix - Sinaloa
874 imputar <- rbind(imputar, subdata_coneval[
875     which(subdata_coneval['NOM_ENT'] == 'Sinaloa' &
876         subdata_coneval['NOM_MUN'] == 'Choix'),i:j])
877
878 imputar <- sapply(imputar, as.numeric)
879 imputar <- as.data.frame(t(apply((imputar),MARGIN=2,FUN=mean)))
880
881 subdata_coneval[which(subdata_coneval['NOM_ENT'] == 'Chihuahua'
      &
882         subdata_coneval['NOM_MUN'] == 'Urique'),i:j] <-
      imputar
883
884 rm(imputar)
885
886 # * * * * * Mat as Romero
      Avenda o - Oaxaca
887 # Vecinos:(7) LISTO*** , en realidad 5 porque 427 no tiene info
      , ni el 407 *
888 # 091 - Veracruz - Jes s Carranza
889 # 190 - Oaxaca - San Juan Cotzoc n
890 # 207 - Oaxaca - San Juan Mazatl n
891 # 198 - Oaxaca - San Juan Guichicovi
892 # 427 - Oaxaca - Santa Mar a Petapa *
893 # 010 - Oaxaca - El Barrio de la Soledad
894 # 407 - Oaxaca - Santa Mar a Chimalapa *
895
896

```

```

897 # 091 - Veracruz - Jes s Carranza 1
898 imputar <- subdata_coneval[
899     which(subdata_coneval['NOM_ENT'] == 'Veracruz' &
900     subdata_coneval['NOM_MUN'] == 'Jes s Carranza'),i:
      j]
901 # 190 - Oaxaca - San Juan Cotzoc n 2
902 imputar <- rbind(imputar, subdata_coneval[
903     which(subdata_coneval['NOM_ENT'] == 'Oaxaca' &
904     subdata_coneval['NOM_MUN'] == 'San Juan Cotzoc n')
      ,i:j])
905 # 207 - Oaxaca - San Juan Mazatl n 3
906 imputar <- rbind(imputar, subdata_coneval[
907     which(subdata_coneval['NOM_ENT'] == 'Oaxaca' &
908     subdata_coneval['NOM_MUN'] == 'San Juan Mazatl n')
      ,i:j])
909 # 198 - Oaxaca - San Juan Guichicovi 4
910 imputar <- rbind(imputar, subdata_coneval[
911     which(subdata_coneval['NOM_ENT'] == 'Oaxaca' &
912     subdata_coneval['NOM_MUN'] == 'San Juan Guichicovi'
      ),i:j])
913
914 # 427 - Oaxaca - Santa Mar a Petapa (no tiene datos para
      imputar as que se descarta)
915 #imputar <- rbind(imputar, subdata_coneval[which(subdata_
      coneval['NOM_ENT'] == 'Oaxaca' &
916 #
      subdata_coneval['
      NOM_MUN'] == 'Santa Mar a Petapa'),i:j])
917
918 # 010 - Oaxaca - El Barrio de la Soledad 5
919 imputar <- rbind(imputar, subdata_coneval[
920     which(subdata_coneval['NOM_ENT'] == 'Oaxaca' &
921     subdata_coneval['NOM_MUN'] == 'El Barrio de la
      Soledad'),i:j])
922
923 # 407 - Oaxaca - Santa Mar a Chimalapa, tampoco tiene datos
924 #imputar <- rbind(imputar, subdata_coneval[which(subdata_
      coneval['NOM_ENT'] == 'Oaxaca' &
925 #
      subdata_coneval['
      NOM_MUN'] == 'Santa Mar a Chimalapa'),i:j])
926
927
928 imputar <- sapply(imputar, as.numeric)
929 imputar <- as.data.frame(t(apply((imputar),MARGIN=2,FUN=mean)))
930
931 subdata_coneval[which(subdata_coneval['NOM_ENT'] == 'Oaxaca' &
932     subdata_coneval['NOM_MUN'] == 'Mat as Romero
      Avenda o'),i:j] <- imputar
933

```

```

934 rm(imputar)
935
936 # * * * * * San Francisco
    Chind a - Oaxaca
937 # Vecinos: (7) LISTO ***
938 # 332 - Oaxaca - San Pedro Topiltepec
939 # 479 - Oaxaca - Santiago Nejapilla
940 # 518 - Oaxaca - Santo Domingo Tlatay pam
941 # 147 - Oaxaca - San Francisco Nuxa o
942 # 281 - Oaxaca - San Miguel Tecomatl n
943 # 250 - Oaxaca - San Mateo Etlatongo
944 # 215 - Oaxaca - San Juan Sayultepec
945
946
947 # 332 - Oaxaca - San Pedro Topiltepec 1
948 imputar <- subdata_coneval[
949     which(subdata_coneval['NOM_ENT'] == 'Oaxaca' &
950     subdata_coneval['NOM_MUN'] == 'San Pedro Topiltepec'
951     ),i:j]
952
953 # 479 - Oaxaca - Santiago Nejapilla 2
954 imputar <- rbind(imputar, subdata_coneval[
955     which(subdata_coneval['NOM_ENT'] == 'Oaxaca' &
956     subdata_coneval['NOM_MUN'] == 'Santiago Nejapilla')
957     ,i:j])
958
959 # 518 - Oaxaca - Santo Domingo Tlatay pam 3
960 imputar <- rbind(imputar, subdata_coneval[
961     which(subdata_coneval['NOM_ENT'] == 'Oaxaca' &
962     subdata_coneval['NOM_MUN'] == 'Santo Domingo
963     Tlatay pam'),i:j])
964
965 # 147 - Oaxaca - San Francisco Nuxa o 4
966 imputar <- rbind(imputar, subdata_coneval[
967     which(subdata_coneval['NOM_ENT'] == 'Oaxaca' &
968     subdata_coneval['NOM_MUN'] == 'San Francisco
969     Nuxa o'),i:j])
970
971 # 281 - Oaxaca - San Miguel Tecomatl n 5
972 imputar <- rbind(imputar, subdata_coneval[
973     which(subdata_coneval['NOM_ENT'] == 'Oaxaca' &
974     subdata_coneval['NOM_MUN'] == 'San Miguel
975     Tecomatl n'),i:j])
976
977 # 250 - Oaxaca - San Mateo Etlatongo 6
978 imputar <- rbind(imputar, subdata_coneval[
979     which(subdata_coneval['NOM_ENT'] == 'Oaxaca' &
980     subdata_coneval['NOM_MUN'] == 'San Mateo Etlatongo'
981     ),i:j])
982
983 # 215 - Oaxaca - San Juan Sayultepec 7
984 imputar <- rbind(imputar, subdata_coneval[
985     which(subdata_coneval['NOM_ENT'] == 'Oaxaca' &
986     subdata_coneval['NOM_MUN'] == 'San Juan Sayultepec'
987     ),i:j])

```

```

    ),i:j])
975
976 imputar <- sapply(imputar, as.numeric)
977 imputar <- as.data.frame(t(apply((imputar),MARGIN=2,FUN=mean)))
978
979 subdata_coneval[which(subdata_coneval['NOM_ENT'] == 'Oaxaca' &
980     subdata_coneval['NOM_MUN'] == 'San Francisco
    Chind a'),i:j] <- imputar
981
982 rm(imputar)
983 # * * * * * Santa Mar a
    Chimalapa - Oaxaca
984 # Vecinos: (8) LISTO *
985 # 057 - Oaxaca - Mat as Romero Avenda o
986 # 010 - Oaxaca - El Barrio de la Soledad
987 # 005 - Oaxaca - Asunci n Ixtaltepec
988 # 265 - Oaxaca - San Miguel Chimalapa
989 # 017 - Chiapas - Cintalapa
990 # 061 - Veracruz - Las Choapas
991 # 210 - Veracruz - Uxpanapa
992 # 091 - Veracruz - Jes s Carranza
993
994
995 # 057 - Oaxaca - Mat as Romero Avenda o 1
996 imputar <- subdata_coneval[
997     which(subdata_coneval['NOM_ENT'] == 'Oaxaca' &
998     subdata_coneval['NOM_MUN'] == 'Mat as Romero
    Avenda o'),i:j]
999 # 010 - Oaxaca - El Barrio de la Soledad 2
1000 imputar <- rbind(imputar, subdata_coneval[
1001     which(subdata_coneval['NOM_ENT'] == 'Oaxaca' &
1002     subdata_coneval['NOM_MUN'] == 'El Barrio de la
    Soledad'),i:j])
1003 # 005 - Oaxaca - Asunci n Ixtaltepec 3
1004 imputar <- rbind(imputar, subdata_coneval[
1005     which(subdata_coneval['NOM_ENT'] == 'Oaxaca' &
1006     subdata_coneval['NOM_MUN'] == 'Asunci n Ixtaltepec
    '),i:j])
1007 # 265 - Oaxaca - San Miguel Chimalapa 4
1008 imputar <- rbind(imputar, subdata_coneval[
1009     which(subdata_coneval['NOM_ENT'] == 'Oaxaca' &
1010     subdata_coneval['NOM_MUN'] == 'San Miguel Chimalapa
    '),i:j])
1011 # 017 - Chiapas - Cintalapa 5
1012 imputar <- rbind(imputar, subdata_coneval[
1013     which(subdata_coneval['NOM_ENT'] == 'Chiapas' &
1014     subdata_coneval['NOM_MUN'] == 'Cintalapa'),i:j])
1015 # 061 - Veracruz - Las Choapas 6

```

```

1016 imputar <- rbind(imputar, subdata_coneval[
1017     which(subdata_coneval['NOM_ENT'] == 'Veracruz' &
1018     subdata_coneval['NOM_MUN'] == 'Las Choapas'),i:j])
1019 # 210 - Veracruz - Uxpanapa 7
1020 imputar <- rbind(imputar, subdata_coneval[
1021     which(subdata_coneval['NOM_ENT'] == 'Veracruz' &
1022     subdata_coneval['NOM_MUN'] == 'Uxpanapa'),i:j])
1023 # 091 - Veracruz - Jes s Carranza 8
1024 imputar <- rbind(imputar, subdata_coneval[
1025     which(subdata_coneval['NOM_ENT'] == 'Veracruz' &
1026     subdata_coneval['NOM_MUN'] == 'Jes s Carranza'),i:
1027     j])
1028 imputar <- sapply(imputar, as.numeric)
1029 imputar <- as.data.frame(t(apply((imputar),MARGIN=2,FUN=mean)))
1030
1031 subdata_coneval[which(subdata_coneval['NOM_ENT'] == 'Oaxaca' &
1032     subdata_coneval['NOM_MUN'] == 'Santa
1033     Mar a Chimalapa'),i:j] <- imputar
1034
1034 rm(imputar)
1035 # * * * * * Santa Mar a
1036     Petapa - Oaxaca
1037 # Vecinos: (4) LISTO *
1038 # 057 - Oaxaca - Mat as Romero Avenda o
1039 # 198 - Oaxaca - San Juan Guichicovi
1040 # 513 - Oaxaca - Santo Domingo Petapa
1041 # 010 - Oaxaca - El Barrio de la Soledad
1042
1043 # 057 - Oaxaca - Mat as Romero Avenda o 1
1044 imputar <- subdata_coneval[
1045     which(subdata_coneval['NOM_ENT'] == 'Oaxaca' &
1046     subdata_coneval['NOM_MUN'] == 'Mat as Romero
1047     Avenda o'),i:j]
1048 # 010 - Oaxaca - San Juan Guichicovi 2
1049 imputar <- rbind(imputar, subdata_coneval[
1050     which(subdata_coneval['NOM_ENT'] == 'Oaxaca' &
1051     subdata_coneval['NOM_MUN'] == 'San Juan Guichicovi'
1052     ),i:j])
1053 # 513 - Oaxaca - Santo Domingo Petapa 3
1054 imputar <- rbind(imputar, subdata_coneval[
1055     which(subdata_coneval['NOM_ENT'] == 'Oaxaca' &
1056     subdata_coneval['NOM_MUN'] == 'Santo Domingo Petapa
1057     '),i:j])
1058 # 010 - Oaxaca - El Barrio de la Soledad 4
1059 imputar <- rbind(imputar, subdata_coneval[
1060     which(subdata_coneval['NOM_ENT'] == 'Oaxaca' &

```

```

1058         subdata_coneval['NOM_MUN'] == 'El Barrio de la
           Soledad'),i:j])
1059
1060 imputar <- sapply(imputar, as.numeric)
1061 imputar <- as.data.frame(t(apply((imputar),MARGIN=2,FUN=mean)))
1062
1063 subdata_coneval[which(subdata_coneval['NOM_ENT'] == 'Oaxaca' &
1064                      subdata_coneval['NOM_MUN'] == 'Santa
           Mar a Petapa'),i:j] <- imputar
1065 rm(imputar)
1066
1067 # * * * * * San Nicol s de
           los Ranchos - Puebla
1068 # Vecinos: (7) LISTO ***
1069 # 009 - NOM_ENT de M xico - Amecameca
1070 # 015 - NOM_ENT de M xico - Atlautla
1071 # 188 - Puebla - Tochimilco
1072 # 175 - Puebla - Tianguismanalco
1073 # 102 - Puebla - Nealtican
1074 # 026 - Puebla - Calpan
1075 # 074 - Puebla - Huejotzingo
1076
1077 # 009 - NOM_ENT de M xico - Amecameca 1
1078 imputar <- subdata_coneval[
1079     which(subdata_coneval['NOM_ENT'] == 'M xico' &
1080          subdata_coneval['NOM_MUN'] == 'Amecameca'),i:j]
1081 # 015 - NOM_ENT de M xico - Atlautla 2
1082 imputar <- rbind(imputar, subdata_coneval[
1083     which(subdata_coneval['NOM_ENT'] == 'M xico' &
1084          subdata_coneval['NOM_MUN'] == 'Atlautla'),i:j])
1085 # 188 - Puebla - Tochimilco 3
1086 imputar <- rbind(imputar, subdata_coneval[
1087     which(subdata_coneval['NOM_ENT'] == 'Puebla' &
1088          subdata_coneval['NOM_MUN'] == 'Tochimilco'),i:j])
1089 # 175 - Puebla - Tianguismanalco 4
1090 imputar <- rbind(imputar, subdata_coneval[
1091     which(subdata_coneval['NOM_ENT'] == 'Puebla' &
1092          subdata_coneval['NOM_MUN'] == 'Tianguismanalco'),i:
           j])
1093 # 102 - Puebla - Nealtican 5
1094 imputar <- rbind(imputar, subdata_coneval[
1095     which(subdata_coneval['NOM_ENT'] == 'Puebla' &
1096          subdata_coneval['NOM_MUN'] == 'Nealtican'),i:j])
1097 # 026 - Puebla - Calpan 6
1098 imputar <- rbind(imputar, subdata_coneval[
1099     which(subdata_coneval['NOM_ENT'] == 'Puebla' &
1100          subdata_coneval['NOM_MUN'] == 'Calpan'),i:j])
1101 # 074 - Puebla - Huejotzingo 7

```

```

1102 imputar <- rbind(imputar, subdata_coneval[
1103     which(subdata_coneval['NOM_ENT'] == 'Puebla' &
1104     subdata_coneval['NOM_MUN'] == 'Huejotzingo'),i:j])
1105
1106 imputar <- sapply(imputar, as.numeric)
1107 imputar <- as.data.frame(t(apply((imputar),MARGIN=2,FUN=mean)))
1108
1109 subdata_coneval[which(subdata_coneval['NOM_ENT'] == 'Puebla' &
1110     subdata_coneval['NOM_MUN'] == 'San Nicol s de
1111     los Ranchos'),i:j] <- imputar
1112
1113 rm(imputar)
1114
1115 # * * * * * General Plutarco
1116 # El as Calles - Sonora
1117 # Vecinos: (2) LISTO ***
1118 # 048 - Sonora - Puerto Pe asco
1119 # 017 - Sonora - Caborca
1120
1121 # 048 - Sonora - Puerto Pe asco
1122 imputar <- subdata_coneval[which(subdata_coneval['NOM_ENT'] ==
1123     'Sonora' &
1124     subdata_coneval['NOM_MUN'] == 'Puerto Pe asco'),i:
1125     j]
1126 # 017 - Sonora - Caborca
1127 imputar <- rbind(imputar, subdata_coneval[
1128     which(subdata_coneval['NOM_ENT'] == 'Sonora' &
1129     subdata_coneval['NOM_MUN'] == 'Caborca'),i:j])
1130
1131 imputar <- sapply(imputar, as.numeric)
1132 imputar <- as.data.frame(t(apply((imputar),MARGIN=2,FUN=mean)))
1133
1134 subdata_coneval[
1135     which(subdata_coneval['NOM_ENT'] == 'Sonora' &
1136     subdata_coneval['NOM_MUN'] == 'General Plutarco El as Calles
1137     '),i:j] <- imputar
1138
1139 rm(imputar)
1140
1141 rm(i);rm(j)
1142
1143 # Comprobaci n de que ya no hay NOM_MUNs faltantes de datos
1144 faltantes <- which(is.na(subdata_coneval$vul_ing_pob)==TRUE)
1145 length(faltantes)
1146 rm(faltantes)
1147
1148 # * * * * *

```

```

1145 # 3.2: Juntar todos los datos municipales INEGI y CONEVAL ====
1146 # * * * * *
1147 # * *
1147 setwd(input)
1148 variables_inegi <- read_excel("Comparacion_Variables.xlsx")
1149
1150 # Se comprueban las dimensiones:
1151
1152 # Se deben tener 2469 renglones
1153 dim(subdata_coneval)[1]==2469
1154 dim(subdata_inegi)[1]==2469
1155
1156 # las columnas deben de ser las mismas
1157 dim(inegi)[2]==dim(subdata_inegi)[2]
1158 dim(coneval)[2]==dim(subdata_coneval)[2]
1159
1160 # se debe pegar por NOM_ENT y NOM_MUN
1161 names(subdata_inegi)
1162 names(subdata_coneval)
1163
1164 # Se deben de juntar los datos de las proporciones en una sola
1165 # base de nuevo
1165 data_tasas <- merge(subdata_coneval,subdata_inegi, by=c("NOM_
1166 ENT","NOM_MUN"))
1166 nombres_limpios <- data_tasas%>%select(NOM_ENT,NOM_MUN, ENTIDAD
1167 , MUN)
1167 # Menos dos porque son las llaves
1168 dim(inegi)[2]+dim(coneval)[2]-2==dim(data_tasas)[2]
1169
1170
1171 # El ltimo detalle es hacer que todas las variables queden
1172 # entre
1172 # 0 y 1, estas son los promedios
1173 min_max_norm <- function(x) {
1174 (x - min(x)) / (max(x) - min(x))
1175 }
1176
1177 data_tasas %>% select_if(~any(. > 1))
1178 # identificamos los nombres y buscamos alguna coincidencia con
1179 # pro (usualmente as se llaman
1180 # los promedios)
1180 mayores_a_1<-names(data_tasas %>% select_if(~any(. > 1)))
1181 mayores_a_1[grep("PRO",mayores_a_1)]
1182
1183 # tambi n se checa a "mano"

```

```

1184 mayores_a_1
1185 # y los que son promedios son:
1186 # PROM_HNV: Promedio de hijas e hijos nacidos vivos
1187 # GRAPROES
1188 # GRAPROES_F
1189 # GRAPROES_M
1190 # PROM_OCUP
1191 # PRO_OCUP_C
1192
1193
1194 data_tasas <- data_tasas%>%
1195   mutate(PROM_HNV=min_max_norm(data_tasas$PROM_HNV),
1196          GRAPROES=min_max_norm(data_tasas$GRAPROES),
1197          GRAPROES_F=min_max_norm(data_tasas$GRAPROES_F),
1198          GRAPROES_M=min_max_norm(data_tasas$GRAPROES_M),
1199          PROM_OCUP=min_max_norm(data_tasas$PROM_OCUP),
1200          PRO_OCUP_C=min_max_norm(data_tasas$PRO_OCUP_C))
1201
1202 # Se borran variables que ya no se utilizar n
1203 rm(list=setdiff(ls(), c("inegi", "coneval", "data_tasas",
1204                        "inegi_y_coneval", "claves_ENT_MUN",
1205                        "nombres_limpios",
1206                        "input", "output",
1207                        "D1.dis", "D1.geo")))
1208
1209 # * * * * *
1210 # 4 Obtener la clasificaci n socioeconomica ====
1211 # * * * * *
1212 pacman::p_load(NbClust, ClustGeo, ggplot2, readxl, purrr,
1213                cluster, factoextra, tidyr, dplyr, scales, ape)
1214
1215 setwd(input)
1216
1217
1218
1219 # * * * * *
1220 # 4.1 Se seleccionan las variables ====
1221 # * * * * *
1222 obten_data <- function(var){
1223   variables_inegi <- read_excel("Comparacion_Variables.xlsx",
1224                                sheet = "Variables")
1225
1226   var_conservadas_inegi <- variables_inegi%>%
1227     select(Variables, var)%>%

```

```

1228     drop_na()
1229
1230
1231     # necesitamos todas las variables del coneval, excepto
1232     poblacion
1233     variables_coneval <- names(coneval)[names(coneval) != "
1234     poblacion"]
1235     variables_inegi <- var_conservadas_inegi$Variables
1236
1237     # ahora se conservan nicamente esas variables, menos el
1238     nombre de
1239     # la entidad y del municipio
1240     data <- data_tasas%>%
1241     select(c(variables_coneval, variables_inegi))
1242
1243     return(data)
1244 }
1245
1246 sociodemo<-obten_data("Nuevo")
1247
1248 datos_sociodemo <- sociodemo%>%
1249     select(-c(vul_car_pob, ic_rezedu_pob, ic_asalud_pob, ic_cv_pob,
1250             ic_sbv_pob))
1251 rm(sociodemo)
1252 names(datos_sociodemo)
1253
1254 # * * * * *
1255 # 4.2 Resumen de las variables utilizadas ====
1256 # * * * * *
1257
1258 # Para calcular las medias
1259 datos_sociodemo %>%
1260     select(-NOM_ENT, -NOM_MUN)%>%
1261     summarise(across(everything(), ~round(mean(.), 2)))
1262
1263 # Para calcular la desviaci n estandar
1264 datos_sociodemo %>%
1265     select(-NOM_ENT, -NOM_MUN)%>%
1266     summarise(across(everything(), ~round(sd(.), 2)))
1267
1268 # Para el rango
1269 datos_sociodemo %>%
1270     select(-NOM_ENT, -NOM_MUN)%>%
1271     summarise(across(everything(), ~round(min(.), 2)))
1272
1273 datos_sociodemo %>%

```

```

1273 select(-NOM_ENT, -NOM_MUN)%>%
1274 summarise(across(everything(),~round(max(.), 2)))
1275
1276 # * * * * *
1277 # 4.3 Descripci n de las variables sociodemogr ficas ====
1278 # * * * * *
1279
1280 # Se clasifican los a os promedio de escolaridad, para poder
1281 # dar datos de cu nto % del municipio pertenece a cada quintil
1282
1283 inegi%>%
1284 select(NOM_ENT, NOM_MUN, GRAPROES)%>%
1285 mutate(GRAPROES = as.numeric(GRAPROES))%>%
1286 group_by(NOM_ENT)%>%
1287 summarise(promedio_estado = mean(GRAPROES))%>%
1288 arrange((promedio_estado))
1289
1290 # Para saber los municipios en donde m s a os de escolaridad
1291 # se tiene
1292 inegi%>%
1293 select(NOM_ENT, NOM_MUN, GRAPROES)%>%
1294 mutate(GRAPROES = as.numeric(GRAPROES))%>%
1295 arrange(desc(GRAPROES))
1296
1297 # P15YM_AN Poblaci n de 15 a os y m s analfabeta
1298 datos_sociodemo%>%
1299 select(NOM_ENT, NOM_MUN, P15YM_AN)%>%
1300 arrange(desc(P15YM_AN))%>%
1301 top_n(10)%>%
1302 mutate(P15YM_AN = 100*round(P15YM_AN,4))
1303
1304
1305 # P15YM_SE Poblaci n de 15 a os y m s sin escolaridad
1306 datos_sociodemo%>%
1307 select(NOM_ENT, NOM_MUN, P15YM_SE)%>%
1308 arrange(desc(P15YM_SE))%>%
1309 top_n(10)%>%
1310 mutate(P15YM_SE = 100*round(P15YM_SE,4))
1311
1312 # Se clasifican la poblaci n de habla indigena de acuerdo a
1313 # los quintiles
1314 datos_sociodemo%>%
1315 select(NOM_ENT, NOM_MUN, P3YM_HLI)%>%
1316 group_by(NOM_ENT)%>%
1317 mutate(total_municipios = n())%>%
1318 mutate(P3YM_HLI = as.numeric(P3YM_HLI))%>%
1319 mutate(P3YM_HLI = round(P3YM_HLI,2))%>%

```

```

1319 mutate(clasificacion = case_when(
1320   P3YM_HLI <= 0 ~ "1",
1321   P3YM_HLI > 0 & P3YM_HLI <= 0.01 ~ "2",
1322   P3YM_HLI > 0.01 & P3YM_HLI <= 0.04 ~ "3",
1323   P3YM_HLI > 0.04 & P3YM_HLI <= 0.35 ~ "4",
1324   TRUE ~ "5"
1325 ))%>%
1326 group_by(NOM_ENT, total_municipios, clasificacion)%>%
1327 summarise(total_grupo=n())%>%
1328 mutate(porcentaje_grupo = 100 * total_grupo / total_
1329   municipios)%>%
1330 filter(clasificacion %in% c("1"))%>%
1331 filter(porcentaje_grupo > 80) %>%
1332 arrange(porcentaje_grupo)
1333 poblacion90ind <- datos_sociodemo%>%
1334 select(NOM_ENT, NOM_MUN, P3YM_HLI)%>%
1335 mutate(P3YM_HLI = as.numeric(P3YM_HLI))%>%
1336 filter(P3YM_HLI>.9)%>%
1337 mutate(P3YM_HLI = 100*round(P3YM_HLI,4))
1338
1339 table(poblacion90ind$NOM_ENT)
1340
1341
1342 # POB_AFRO Poblaci n que se considera afromexicana o
1343   afrodescendiente
1344 datos_sociodemo%>%
1345 select(NOM_ENT, NOM_MUN, POB_AFRO)%>%
1346 arrange(desc(POB_AFRO))%>%
1347 top_n(10)%>%
1348 mutate(POB_AFRO = 100*round(POB_AFRO,4))
1349
1350 # PNACOE Poblaci n nacida en otra entidad
1351 datos_sociodemo%>%
1352 select(NOM_ENT, NOM_MUN, PNACOE)%>%
1353 arrange(desc(PNACOE))%>%
1354 top_n(10)%>%
1355 mutate(PNACOE = 100*round(PNACOE,4))
1356
1357 # pobreza_pob Poblaci n en situaci n de pobreza
1358 pobreza_extrema <- datos_sociodemo%>%
1359 select(NOM_ENT, NOM_MUN, pobreza_pob)%>%
1360 arrange(desc(pobreza_pob))%>%
1361 filter(pobreza_pob > 0.95)%>%
1362 mutate(pobreza_pob = 100*round(pobreza_pob,4))
1363 table(pobreza_extrema$NOM_ENT)
1364

```

```

1365
1366 # Poblaci n sin afiliaci n a servicios de salud
1367 datos_sociodemo%>%
1368   select(NOM_ENT, NOM_MUN, PSINDER)%>%
1369   group_by(NOM_ENT)%>%
1370   mutate(total_municipios = n())%>%
1371   mutate(PSINDER = as.numeric(PSINDER))%>%
1372   mutate(PSINDER = round(PSINDER,2))%>%
1373   mutate(clasificacion = case_when(
1374     PSINDER < 0.15 ~ "1",
1375     PSINDER >= 0.15 & PSINDER < 0.2 ~ "2",
1376     PSINDER >= 0.2 & PSINDER < 0.26 ~ "3",
1377     PSINDER >= 0.26 & PSINDER < 0.33 ~ "4",
1378     TRUE ~ "5"
1379   ))%>%
1380   group_by(NOM_ENT, total_municipios, clasificacion)%>%
1381   summarise(total_grupo=n())%>%
1382   mutate(porcentaje_grupo = 100 * total_grupo / total_
1383     municipios)%>%
1384   filter(clasificacion %in% c("5"))%>%
1385   filter(porcentaje_grupo > 40) %>%
1386   arrange(porcentaje_grupo)
1387
1388 # PSINDER Poblaci n sin afiliaci n a servicios de salud
1389 datos_sociodemo%>%
1390   select(NOM_ENT, NOM_MUN, PSINDER)%>%
1391   arrange(desc(PSINDER))%>%
1392   mutate(PSINDER = 100*round(PSINDER,4))
1393
1394 # * * * * *
1395 # 4.4 Se busca una K adecuada ====
1396 # * * * * *
1397 # Para el Dendrograma
1398 DO <- dist(datos_sociodemo%>%
1399   select(- NOM_ENT, - NOM_MUN),
1400   method="euclidean")
1401
1402 # gr fica del dendrograma
1403 distancia <- dist(subset(datos_sociodemo,
1404   select = -c(NOM_ENT, NOM_MUN)))
1405 tree <- hclust(distancia, method = "ward.D2")
1406 plot(tree, cex = 0.6, hang = -1)
1407
1408 # Con el m todo del codo
1409 elbow <- fviz_nbclust(x = datos_sociodemo%>%

```

```

1410         select(- NOM_ENT,- NOM_MUN),
1411         FUNcluster = hcut, linecolor="#91B83F",
1412         method = "wss", k.max = 10)
1413
1414 ggplot(data=elbow$data, aes(x=clusters, y=y, group=1))+
1415   labs(title = "N mero ptimo de clusters con el m todo del
1416     codo",
1417     x="N mero de clusters (K)", y="WSS")+
1418   geom_point(size=3, color="#7CB728")+
1419   geom_line(size=1.5, color="#7CB728")+
1420   theme_bw()+
1421   theme(text = element_text(family="Poppins"),
1422     plot.title = element_blank(),
1423     axis.title = element_text(size=19),
1424     axis.text = element_text(size=18))+
1425   scale_y_continuous(label=comma, n.breaks=8)
1426
1427 setwd(output)
1428 ggsave(filename = "codo.png",
1429   device = "png",width = 8,height = 6, dpi=100)
1430
1431 # Con el m todo silhouette
1432 silhouette <- fviz_nbclust(x = datos_sociodemo%>%
1433   select(- NOM_ENT,- NOM_MUN),
1434   FUNcluster = hcut, linecolor="#3
1435     FB8AF",
1436   method = "silhouette", k.max = 10)
1437
1438 ggplot(data=silhouette$data, aes(x=clusters, y=y, group=1))+
1439   labs(title = "N mero ptimo de clusters con el m todo de
1440     la silueta",
1441     x="N mero de clusters (K)", y="Promedio del ancho de la
1442     silueta")+
1443   geom_point(size=3, color="#2A77A4")+
1444   geom_line(size=1.5, color="#2A77A4")+
1445   theme_bw()+
1446   theme(text = element_text(family="Poppins"),
1447     plot.title = element_blank(),
1448     axis.title = element_text(size=19),
1449     axis.text = element_text(size=18))+
1450   scale_y_continuous(label=comma, n.breaks=8, limits = c
1451     (0,0.4))
1452 setwd(output)
1453 ggsave(filename = "silueta.png",
1454   device = "png",width = 8,height = 6, dpi=100)
1455
1456 # Con el m todo gap

```

```

1453 gap <- fviz_nbclust(x = datos_sociodemo%>%
1454     select(- NOM_ENT,- NOM_MUN ),
1455     FUNcluster = hcut, linecolor="#F08080",
1456     method = "gap_stat", k.max = 10)
1457
1458
1459 ggplot(data=gap$data, aes(x=clusters, y=gap, group=1))+
1460     labs(title = "N mero ptimo de clusters con el m todo gap"
1461     ,
1462     x="N mero de clusters (K)", y="Estad stics Gap (K)")+
1463     geom_point(size=3, color="#FFAE4D")+
1464     geom_line(size=1.5, color="#FFAE4D")+
1465     theme_bw()+
1466     theme(text = element_text(family="Poppins"),
1467     plot.title = element_blank(),
1468     axis.title = element_text(size=19),
1469     axis.text = element_text(size=18))+
1470     scale_y_continuous(label=comma, n.breaks=8)
1471
1472 setwd(output)
1473 ggsave(filename = "gap.png",
1474     device = "png",width = 8,height = 6, dpi=100)
1475 # * * * * *
1476 # 4.5 Creaci n de clusters ====
1477 # * * * * *
1478
1479 # Se crea la secuencia de 21 alfas
1480 malla <- seq(0,1,by=0.05)
1481
1482 # Funci n para ejecutar el algoritmo y guardar los resultados
1483 # con cada alfa
1484 malla_alfas_ks <- function(d0,d1,Ks){
1485     data_aux <- data.frame(matrix(nrow = dim(data_tasas)[1]))
1486     alphas <- malla
1487     data <- data_tasas%>%
1488     select(NOM_ENT,NOM_MUN,ENTIDAD,MUN)
1489
1490     for(K in Ks){
1491         for(i in 1:length(alphas)){
1492             a <- alphas[i]
1493             tree <- hclustgeo(d0, d1, alpha=a)
1494             clusters <- data.frame(cutree(tree, K))
1495             name <- paste0("alfa_",a,".K_",K)
1496             names(clusters) <- name
1497             data <- cbind(data,clusters)

```

```

1497   }
1498 }
1499
1500
1501
1502   return(data)
1503 }
1504
1505
1506 # D0, D1.dis, D1.geo
1507 DO_D1.dis <- malla_alfas_ks(D0,D1.dis,Ks=c(3,4,5))
1508 DO_D1.geo <- malla_alfas_ks(D0,D1.geo,Ks=c(3,4,5))
1509
1510
1511
1512 # # se guardan los datos que nos interesan
1513 rm(list=setdiff(ls(), c("DO_D1.dis",
1514                        "DO_D1.geo",
1515                        "data_tasas",
1516                        "nombres_limpios",
1517                        "inegi", "coneval",
1518                        "inegi_y_coneval",
1519                        "datos_sociodemo",
1520                        "claves_ENT_MUN", "input", "output")))
1521
1522 # * * * * *
1523 # 5.0 Elecci n de cl steres ====
1524 # * * * * *
1525
1526 # Se cargan los datos del censo con los que se calcular la
1527   varianza poblacional
1528 setwd(paste0(input, "/data/eceg_2020_csv/conjunto_de_datos/"))
1529
1530 seccion <- read.csv("INE_SECCION_2020.csv")%>%
1531   mutate(across(c(where(is.character)), as.numeric))%>%
1532   rename(MUN=MUNICIPIO)
1533
1534 # se comprueba que la base de secci n sea una partici n de la
1535   del inegi por municipios
1536 sum(seccion$POBTOT)
1537 sum(data_tasas$POBTOT)
1538
1539 dim(seccion%>%
1540   group_by(ENTIDAD, MUN)%>%
1541   summarise(total=n()))
1542 # pero las claves de los municipios no coinciden por lo que no
1543   se podr n unir de esta forma

```

```

1542 summary(seccion$MUN)
1543 summary(data_tasas$MUN)
1544
1545 # por ejemplo:
1546 inegi_y_coneval%>%
1547   filter(ENTIDAD==3)%>%
1548   distinct(NOM_ENT, NOM_MUN, ENTIDAD, MUN)
1549
1550 seccion%>%
1551   filter(ENTIDAD==3)%>%
1552   distinct(ENTIDAD, MUN)
1553
1554
1555 # Como la clave de municipio no coincide se tiene que hacer una
1556   limpieza
1557 # de los nombres para poder hacer el join
1558
1559 # * * * * *
1560 # 5.1 Limpieza en los nombres de secciones ====
1561 # * * * * *
1562
1563
1564 # Como la clave de municipio no coincide en ambas bases se
1565   tiene que hacer una limpieza
1566 # de los nombres para poder hacer el join
1567
1568 obten_secciones<-function(){
1569   # Se ocupa el catalogo de las secciones para poder tener sus
1570     nombres
1571   setwd(paste0(input, "/data/eceg_2020_csv/catalogos/"))
1572   cat_secciones_2020 <- read.csv("cat_secciones_2020.csv",
1573     encoding = "latin1")%>%
1574     distinct(CVE_ENT, CVE_MUN, DESC_MUN)%>%
1575     rename(ENTIDAD=CVE_ENT, NOM_MUN=DESC_MUN)%>%
1576     mutate(NOM_MUN=str_to_title(NOM_MUN),
1577       NOM_MUN=chartr(" ", "aeiou", NOM_MUN),
1578       NOM_MUN=chartr(" ", "AEIOU", NOM_MUN))
1579
1580 # * * * * *
1581 # Se hacen los cambios generales que se hicieron en INEGI -
1582   municipios
1583 # * * * * *
1584 # Los que dicen Gral. se reemplazan por General y Dr. por
1585   Doctor
1586 cat_secciones_2020$NOM_MUN <- gsub("Gral.",
1587   "General", cat_secciones_
1588     2020$NOM_MUN)

```

```

1584 cat_secciones_2020$NOM_MUN <- gsub("Dr.",
1585                                     "Doctor", cat_secciones_
1586                                             2020$NOM_MUN)
1587
1588 # Los municipios de San Juan Mixtepec y San Pedro Mixtepec
1589 # vienen repetidos
1590 cat_secciones_2020 <- cat_secciones_2020%>%
1591   mutate(NOM_MUN=case_when(
1592     CVE_MUN=='208' & ENTIDAD=='20'~ 'San Juan Mixtepec -Dto.
1593     08 -',
1594     CVE_MUN=='209' & ENTIDAD=='20'~ 'San Juan Mixtepec -Dto.
1595     26 -',
1596     CVE_MUN=='318' & ENTIDAD=='20'~ 'San Pedro Mixtepec -Dto.
1597     . 22 -',
1598     CVE_MUN=='319' & ENTIDAD=='20'~ 'San Pedro Mixtepec -Dto.
1599     . 26 -',
1600     TRUE ~ NOM_MUN)
1601   )%>%
1602   mutate(NOM_MUN=
1603     case_when(
1604       ENTIDAD==5 & NOM_MUN=="Cuatrociénegas" ~
1605         "Cuatro Ciénegas",
1606
1607       ENTIDAD==7 & NOM_MUN=="Villacomaltitlan" ~
1608         "Villa Comaltitlan",
1609
1610       ENTIDAD==8 & NOM_MUN=="Doctor Belisario
1611         Dominguez" ~
1612         "Dr. Belisario Dominguez",
1613
1614       ENTIDAD==10 & NOM_MUN=="Simon Bolivar" ~
1615         "General Simon Bolivar",
1616
1617       ENTIDAD==17 & NOM_MUN=="Jonacatepec" ~
1618         "Jonacatepec De Leandro Valle",
1619
1620       ENTIDAD==20 & NOM_MUN=="H Villa Tezoatlan Segura
1621         Y Luna Cuna Ind Oax" ~
1622         "Heroica Villa Tezoatlan De Segura Y Luna,
1623         Cuna De La Independencia De Oaxaca",
1624       ENTIDAD==20 & NOM_MUN=="Heroica Ciudad De
1625         Juchitan De Zaragoza" ~
1626         "Juchitan De Zaragoza",
1627       ENTIDAD==20 & NOM_MUN=="Santiago Chazumba" ~
1628         "Villa De Santiago Chazumba",
1629
1630       ENTIDAD==29 & NOM_MUN=="Zitlaltepec De Trinidad

```

```

1622         Sanchez Santos" ~
1623         "Ziltlaltepec De Trinidad Sanchez Santos",
1624
1625         ENTIDAD==30 & NOM_MUN=="Cosamaloapan" ~
1626         "Cosamaloapan De Carpio",
1627         ENTIDAD==30 & NOM_MUN=="Ozuluama" ~
1628         "Ozuluama De Mascare as",
1629         ENTIDAD==30 & NOM_MUN=="Zontecomatlan" ~
1630         "Zontecomatlan De Lopez Y Fuentes",
1631
1632         ENTIDAD==19 & NOM_MUN=="Carmen" ~
1633         "El Carmen",
1634         TRUE ~ NOM_MUN
1635     ))%>%
1636     rename(MUN=CVE_MUN)
1637
1638     # # secciones es la base que ya tiene ENTIDAD y NOM_MUN, lo
1639     # que permitir unirla con las bases de partici n
1640     secciones <- merge(seccion,cat_secciones_2020,by=c("ENTIDAD",
1641     "MUN"),
1642     all.x = TRUE)%>%
1643     filter(! ( ( ENTIDAD==4 & MUN==12) |
1644     ( ENTIDAD==20 & MUN==317) |
1645     ( ENTIDAD==20 & MUN==316) ) )
1646
1647     return(secciones)
1648 }
1649 secciones <- obten_secciones()
1650
1651 # Haciendo una exploraci n de la base de datos, nos percatamos
1652 # que
1653 # algunos datos son negativos, los quitamos
1654 secciones <- secciones%>%
1655     filter(TVIVPARHAB>0,
1656     POBTOT>0)
1657
1658 limpia_nombres<-function(data){
1659     df <- data%>%
1660     mutate(NOM_MUN=str_to_title(NOM_MUN),
1661     NOM_MUN=chartr(" ", "aeiou", NOM_MUN),
1662     NOM_MUN=chartr(" ", "AEIOU", NOM_MUN))
1663     return(df)
1664 }
1665 D0_D1.dis <- limpia_nombres(D0_D1.dis)
1666 D0_D1.geo <- limpia_nombres(D0_D1.geo)

```

```

1666
1667
1668 # * * * * *
1669 # 5.2 Estimando el tama o de muestra ====
1670 # * * * * *
1671
1672 tamaño_muestra <- function(k,N,S_yu,d){
1673   numerador <- ((k * N * S_yu) / d)^2
1674   denominador <- 1 + ( (1/N) * ( ( k*N*S_yu)/d ) ^2) )
1675   return(numerador/denominador)
1676 }
1677
1678 calculo_d <- function(var){
1679   suma <- as.character(prettyNum(sum(secciones[var]),
1680                               big.mark=",", scientific=FALSE
1681                               ))
1682   print(paste0("El valor verdadero de ",var , " es ", suma))
1683   d <- round(sum(secciones[var])*0.05,0)
1684   print(paste0("Por lo que d es igual a ",
1685               as.character(prettyNum(d, big.mark=",",
1686                                     scientific=FALSE))))
1687   return(d)
1688 }
1689 k = 1.96
1690 N = dim(secciones)[1]
1691
1692
1693 # Los parametros que se tratar n de estimar son:
1694
1695 # 1. Poblaci n con 15 a os o m s con primaria incompleta
1696 # data_tasas | secciones
1697 # P15PRI_IN | P15PRI_IN
1698 tm_P15PRI_IN = tamaño_muestra(k,N,
1699                               sqrt(var(secciones$P15PRI_IN)),
1700                               calculo_d("P15PRI_IN"))
1701
1702 # 2. Poblaci n de 8 a 14 a os que no sabe leer ni escribir
1703 # data_tasas | secciones
1704 # P8A14AN | P8A14AN
1705 tm_P8A14AN = tamaño_muestra(k,N,
1706                               sqrt(var(secciones$P8A14AN)),
1707                               calculo_d("P8A14AN"))
1708
1709 # 3. Poblaci n de 15 a os o m s analfabeta
1710 # data_tasas | secciones
1711 # P15YM_AN | P15YM_AN
1712 tm_P15YM_AN = tamaño_muestra(k,N,

```

```

1713         sqrt(var(secciones$P15YM_AN)),
1714         calculo_d("P15YM_AN"))
1715
1716 # 4. Poblaci n con discapacidad
1717 # data_tasas | secciones
1718 # PCON_DISC | PCON_DISC
1719 tm_PCON_DISC = tamaño_muestra(k,N,
1720         sqrt(var(secciones$PCON_DISC)),
1721         calculo_d("PCON_DISC"))
1722
1723 # 5. Poblaci n de 3 a os y m s que habla alguna lengua
1724     ind gena
1725 # data_tasas | secciones
1726 # P3YM_HLI | P3YM_HLI
1727 tm_P3YM_HLI = tamaño_muestra(k,N,
1728         sqrt(var(secciones$P3YM_HLI)),
1729         calculo_d("P3YM_HLI"))
1730
1731 # 6. Poblaci n sin afiliaci n a servicios de salud
1732 # data_tasas | secciones
1733 # PSINDER | PSINDER
1734 tm_PSINDER = tamaño_muestra(k,N,
1735         sqrt(var(secciones$PSINDER)),
1736         calculo_d("PSINDER"))
1737
1738 # 7. Viviendas particulares habitadas con piso de tierra
1739 # data_tasas | secciones
1740 # VPH_PISODT | VPH_PISODT
1741 tm_VPH_PISODT = tamaño_muestra(k,N,
1742         sqrt(var(secciones$VPH_PISODT))
1743         ,
1744         calculo_d("VPH_PISODT"))
1745
1746 # 8. Viviendas particulares habitadas que no disponen
1747 # de energ a electrica
1748 # data_tasas | secciones
1749 # VPH_S_ELEC | VPH_S_ELEC
1750 tm_VPH_S_ELEC = tamaño_muestra(k,N,
1751         sqrt(var(secciones$VPH_S_ELEC))
1752         ,
1753         calculo_d("VPH_S_ELEC"))
1754
1755 # 9. Viviendas particulares habitadas que no disponen de agua
1756     entubada
1757 # data_tasas | secciones
1758 # VPH_AGUAFV | VPH_AGUAFV
1759 tm_VPH_AGUAFV = tamaño_muestra(k,N,

```

```

1757         sqrt(var(secciones$VPH_AGUAFV))
1758     ,
1759     calculo_d("VPH_AGUAFV"))
1760 # 10. Viviendas particulares habitadas que no disponen de
1761     drenaje
1762 # data_tasas | secciones
1763 # VPH_NODREN | VPH_NODREN
1764 tm_VPH_NODREN = tamaño_muestra(k,N,
1765     sqrt(var(secciones$VPH_NODREN))
1766     ,
1767     calculo_d("VPH_NODREN"))
1768
1769 # * * * * *
1770 # El número más grande de tamaño de muestra
1771 # Es el que se tomar
1772
1773 max(tm_P15PRI_IN,
1774     tm_P8A14AN,
1775     tm_P15YM_AN,
1776     tm_PCON_DISC,
1777     tm_P3YM_HLI,
1778     tm_PSINDER,
1779     tm_VPH_PISODT,
1780     tm_VPH_S_ELEC,
1781     tm_VPH_AGUAFV,
1782     tm_VPH_NODREN)
1783 # Por lo tanto, el valor de la n debe de ser: 16,375.28
1784
1785 # * * * * *
1786 n <- round(max(tm_P15PRI_IN,
1787     tm_P8A14AN,
1788     tm_P15YM_AN,
1789     tm_PCON_DISC,
1790     tm_P3YM_HLI,
1791     tm_PSINDER,
1792     tm_VPH_PISODT,
1793     tm_VPH_S_ELEC,
1794     tm_VPH_AGUAFV,
1795     tm_VPH_NODREN),0)
1796 n
1797 # * * * * *
1798
1799
1800
1801 # * * * * *

```

```

1802 # 5.3 Obtenci n de varianzas poblacionales ====
1803 # * * * * *
1804
1805 # Se calcula la varianza poblacional para cada par metro
1806
1807 variables <- c("P15PRI_IN",
1808               "P8A14AN",
1809               "P15YM_AN",
1810               "PCON_DISC",
1811               "P3YM_HLI",
1812               "PSINDER",
1813               "VPH_PISODT",
1814               "VPH_S_ELEC",
1815               "VPH_AGUAFV",
1816               "VPH_NODREN")
1817
1818 dimension <- 63
1819
1820
1821
1822 obten_df_varianzas_poblacionales<-function(variables ,data){
1823   # variable <- variables [1]
1824   # data <- D0_D1.dis
1825   # i <-57
1826   obten_varianzas_poblacionales <- function(data,variable){
1827     # Lo primero es hacer el join entre secciones y
1828     # la forma de particionar
1829     base <- merge(secciones%>%
1830                   select(c("ENTIDAD", "NOM_MUN", "SECCION",
1831                             variable)),
1832                   data%>%
1833                   select(-c(MUN, NOM_ENT)), by=c("ENTIDAD", "
1834                             NOM_MUN"),
1835                   all.x=TRUE)
1836
1837     # Las primeras columnas estar n ordenadas de esta forma:
1838     #   ENTIDAD | NOM_MUN | SECCION | Variable
1839     # se debe de hacer la agrupaci n a partir de la columnas 5
1840
1841     obten_VP <- function(base,variable,i){
1842       # la i es de donde va a correr el for, es para que
1843       # agarre la forma de agrupar
1844       base_temp <- base[,c(1:4,i)] # con esto ya tengo
1845       # las agrupaciones de las secciones
1846       names(base_temp)[5]<-"Cluster"
1847       #Asignaci n del tama o de muestra en cada estrato
1848       #Proporcional a Nh, es decir  $nh \sim n * Nh/N$ 
1849       varianza_poblacional <-

```

```

1848     base_temp%>%
1849     group_by(Cluster)%>%
1850     summarise(Nh=n(), # total de poblacion por cada grupo
1851               nh=ceiling(n*Nh/N), # se calcula la n de cada
1852               h
1853               Syh2=var(eval(parse(text=variable))),
1854               #varianza del conjunto h
1855               Vh=(Nh^2/nh)*(1-nh/Nh)*Syh2 )%>%
1856     #calculo de la varianza
1857     mutate_if(is.numeric, ~replace(., is.na(.), 0))
1858     #existen grupos con una observacion por lo cual
1859     # la varianza poblacional de ah debe de ser cero
1860
1861     VP <- sum(varianza_poblacional$Vh)/
1862     sum(varianza_poblacional$Nh)^2
1863     VP
1864     return(VP)
1865 }
1866
1867 varianzas_poblacionales <- data.frame()
1868
1869 for(i in 5:dim(base)[2]){
1870     varianzas_poblacionales <- rbind(varianzas_poblacionales,
1871                                     data.frame(
1872                                         agrupacion = names(base)
1873                                         [i],
1874                                         varianza_poblacional = obten_VP(base,
1875                                         variable,i))
1876                                     )
1877 }
1878
1879 names(varianzas_poblacionales)[2]<-paste0("vp_",variable)
1880 return(varianzas_poblacionales)
1881 }
1882
1883 df_varianzas_poblacionales <- data.frame(matrix(NA,
1884                                             nrow = dimension, ncol = 0))
1885
1886 for(variable in variables){
1887     df_varianzas_poblacionales <- cbind(df_varianzas_
1888     poblacionales,
1889                                         obten_varianzas_poblacionales
1890                                         (
1891                                             data,variable)[,2] )
1892 }
1893
1894 names(df_varianzas_poblacionales) <- variables
1895 df_varianzas_poblacionales
1896

```

```

1891
1892 nombres_agrupaciones<-data.frame()
1893 for(i in 5:dim(data)[2]){
1894     nombres_agrupaciones <- rbind(nombres_agrupaciones ,
1895                                   data.frame(
1896                                     agrupacion = names(data)[i])
1897     )
1898 }
1899 nombres_agrupaciones
1900
1901 df_varianzas_poblacionales <- cbind(
1902     nombres_agrupaciones ,
1903     df_varianzas_poblacionales)
1904 return(df_varianzas_poblacionales)
1905 }
1906
1907 vp_D0_D1.dis <- obten_df_varianzas_poblacionales(variables ,D0_
1908   D1.dis)
1909 vp_D0_D1.geo <- obten_df_varianzas_poblacionales(variables ,D0_
1910   D1.geo)
1911
1912 vp_D0_D1.dis$data_frame <- "vp_D0_D1.dis"
1913 vp_D0_D1.geo$data_frame <- "vp_D0_D1.geo"
1914
1915 # Se une toda la informaci n en un nico data frame
1916 data <- rbind(vp_D0_D1.dis ,
1917               vp_D0_D1.geo)
1918
1919 # * * * * *
1920 # 6.0 Elecci n de la partici n ====
1921 # * * * * *
1922
1923 # Se ve el minimo para cada variable y a que agrupaci n
1924 # y base de datos pertenece
1925
1926 for(i in variables){
1927     print(paste0("Para la variable: ", i))
1928     print(data%>%
1929           filter(eval(parse(text=i))==min(data[i])))
1930 }
1931
1932
1933 df_eleccion<-data.frame()
1934
1935 # * * * * *
1936

```

```

1937 # 6.1 Reanqueo de variables ====
1938 # * * * * *
1939
1940 # Se rankea para cada variable, qui n tiene la menor
1941 # varianza poblacional
1942 for(i in variables){
1943   df_eleccion<-rbind(df_eleccion,
1944                      data%>%
1945                        select(agrupacion,data_frame,i)%>%
1946                        mutate(rank = dense_rank(eval(
1947                          parse(text=i))))%>%
1948                        select(agrupacion,data_frame,rank)%>%
1949                        mutate(variable = i)%>%
1950                        arrange(rank))
1951 }
1952
1953
1954
1955 # Se obtiene la varianza con un muestreo aleatorio simple
1956 df_VarMAS <- data.frame()
1957 for(i in variables){
1958   df_VarMAS <- rbind(df_VarMAS,
1959                     data.frame(variable = i,
1960                               VarMAS = as.numeric((1/n)*
1961                                                     (1-(n/N))*var(secciones[i])) ) )
1962   #VarMAS = as.numeric((N^2/n)*(1-(n/N))*var(secciones[i])) ) )
1963 }
1964
1965
1966 # Se conserva
1967 suma_rank <- df_eleccion%>%
1968   group_by(agrupacion,data_frame)%>%
1969   summarise(puntos=sum(rank))%>%
1970   mutate(estratificacion = paste0(agrupacion,"_",data_frame))
1971   %>%
1972   mutate(estratificacion = gsub("vp_D0_D1.", "",
1973                                estratificacion))%>%
1974   mutate(estratificacion = gsub("alfa_", "alfa: ",
1975                                estratificacion))%>%
1976   mutate(estratificacion = gsub(".K_", ", K: ", estratificacion
1977   ))%>%
1978   mutate(estratificacion = gsub("_", ", ", estratificacion))%>%
1979   arrange(puntos)
1980
1981 suma_rank
1982 suma_rank$estratificacion

```

```

1981 # Se realiza una grafica para que se puedan visualizar los
1982 # m s f cilmente
1983
1984 resumen_ranks <- df_eleccion%>%
1985   mutate(estratificacion = paste0(agrupacion,"_",data_frame))
1986     %>%
1987   mutate(estratificacion = gsub("vp_D0_D1.", "",
1988     estratificacion))%>%
1989   mutate(estratificacion = gsub("alfa_", "alfa: ",
1990     estratificacion))%>%
1991   mutate(estratificacion = gsub(".K_", ", K: ", estratificacion
1992     ))%>%
1993   mutate(estratificacion = gsub("_", ", ", estratificacion))%>%
1994   select(estratificacion, variable, rank)%>%
1995   mutate(estratificacion = factor(estratificacion, levels=suma_
1996     rank$estratificacion))
1997
1998 # colores <- c("#F2BED1","#D988B9","#9D76C1","#176B87",
1999 #             "#64CCC5","#EAFFD0", "#A2C579","#D2DE32",
2000 #             "#FFE17B","#FD8D14")
2001
2002 library(paletter)
2003 colores <- paletter_c("grDevices::Viridis", 10)
2004
2005 # Stacked barplot with multiple groups
2006 ggplot(data=resumen_ranks, aes(x=rank,
2007   y=estratificacion,
2008   fill=variable)) +
2009   scale_fill_manual(values=colores)+
2010   geom_bar(stat="identity")+
2011   theme_bw()+
2012   labs(x = "Puntos", y = "Estratificaci n")+
2013   theme(text = element_text(family="Poppins"),
2014     plot.title = element_text(size=20,hjust = 0.5),
2015     axis.title.x = element_text(size=30),
2016     axis.title.y = element_text(size=30),
2017     axis.text.y = element_text(size=18,
2018       colour = "#505050"),
2019     axis.text.x = element_text(size=20,
2020       colour = "#505050"),
2021     panel.background = element_rect(fill = "white",
2022       colour = "white"),
2023     plot.background = element_rect(fill = "white",
2024       colour = "white"),
2025     panel.grid = element_line(color = "#F1F1F2",
2026       linetype = 1),

```

```

2023     legend.title = element_text(size=30),
2024     legend.text = element_text(size=25),
2025     panel.border = element_blank(),
2026     axis.ticks = element_blank(),
2027     axis.line = element_blank()+
2028     scale_x_continuous(n.breaks = 10)+
2029     guides(fill=guide_legend(title="Variable"))
2030
2031 # setwd(output)
2032 #
2033 # ggsave(filename = "Ranks_variables.png",
2034 #         device = "png",width = 22, height =30 , dpi=100)
2035
2036 # Para saber cu ntos puntos obtuvo cada estratificaci n
2037 resumen_ranks%>%
2038   group_by(estratificacion)%>%
2039   summarise(total= sum(rank))%>%
2040   arrange(desc(total))
2041
2042 mean((resumen_ranks%>%
2043       group_by(estratificacion)%>%
2044       summarise(total= sum(rank))%>%
2045       arrange(desc(total)))$total)
2046
2047 # La que obtuvo menos puntos fue la de alfa=0.25 K=5
2048 # y usando la distancia entre centroides
2049 data%>%
2050   filter(agrupacion=="alfa_0.25.K_5",
2051          data_frame=="vp_D0_D1.geo")
2052
2053 # Se ve el promedio de las varianzas as como los rangos
2054 for(i in 2:11){
2055   print(paste0(names(data)[i], ": ", "Promedio: ",
2056               round(mean(data[,i]),2),
2057               " Rango: ", "(",
2058               round(max(data[,i]),2),
2059               "-", round(min(data[,i]),2), ")"))
2060
2061   print("-----")
2062 }
2063
2064 # Varianza poblacional para cada variable:
2065 data%>%
2066   select(c("data_frame", "agrupacion" , variables))%>%
2067   filter((agrupacion == "alfa_0.25.K_5") &
2068          (data_frame=="vp_D0_D1.geo"))%>%
2069   mutate(across(where(is.numeric), round, 4))
2070

```

```

2071 # Rank que ocupa cada variable
2072 ranks <- c()
2073 for(i in variables){
2074   print(i)
2075   row <- data%>%
2076     select(agrupacion, data_frame, i)%>%
2077     mutate(rank = dense_rank(eval(parse(text=i))))%>%
2078     select(agrupacion, data_frame, rank)%>%
2079     arrange(rank)%>%
2080     filter((agrupacion == "alfa_0.25.K_5") &
2081            (data_frame=="vp_D0_D1.geo"))
2082
2083   print(row)
2084   ranks <- append(ranks, row$rank)
2085
2086 }
2087 mean(ranks)
2088
2089 # * * * * *
2090 # 6.2 Evaluaci n del modelo ====
2091 # * * * * *
2092 a <- "alfa_0.25.K_5"
2093 df <- "vp_D0_D1.geo"
2094 decimales <- 2
2095
2096
2097 merge(
2098   data%>%
2099     filter(agrupacion==a,
2100            data_frame==df)%>%
2101     pivot_longer(!c(agrupacion, data_frame),
2102                  names_to="variable", values_to="varianza")%>%
2103     select(variable, varianza),
2104   df_VarMAS,
2105   by="variable"
2106 )%>%
2107   mutate(mejoro=varianza<VarMAS)%>%
2108   # mutate(radio = varianza/VarMAS)
2109   mutate(reduccion=100*((VarMAS-varianza)/VarMAS))%>%
2110   mutate(varianza=round(varianza, decimales),
2111          VarMAS=round(VarMAS, decimales),
2112          reduccion=round(reduccion, decimales))
2113 # select(-mejoro)%>%
2114 # mutate(across(where(is.numeric), ~round(., 2)))
2115
2116 # * * * * *
2117 # 7.0 Evaluaci n de otras estratificaciones ====
2118 # * * * * *

```

```

2119
2120
2121 # * * * * *
2122 # 7.1 Clasificaci n de municipios r/u ====
2123 # * * * * *
2124
2125 # Informaci n de las localidades obtenida de:
2126 # https://www.inegi.org.mx/programas/ccpv/2020/#datos_abiertos
2127 # Principales resultados por localidad (ITER)
2128 # Estados Unidos Mexicanos
2129
2130
2131 setwd(paste0(input, "/data/localidades/"))
2132 localidades_raw <- read.csv("conjunto_de_datos_iter_00CSV20.csv
    ")
2133
2134 # Localidades urbanas
2135 # Son aqu llas que tienen una poblaci n mayor o igual
2136 # a 2 500 habitantes o que sean cabeceras
2137 # municipales, independiente de su poblaci n.
2138 # Las localidades urbanas se representan en forma de pol gono.
2139 # Localidades rurales
2140 # Son todas las que tienen una poblaci n menor a 2 500
2141 # habitantes y no son cabeceras municipales.
2142 # Las localidades rurales se representan con un tri ngulo
2143 # o con un punto.
2144 #
2145 # https://www.inegi.org.mx/rnm/index.php/catalog/315/download/
    9636
2146
2147
2148 # Municipio totalmente rural =
2149 # 100% de la poblaci n en localidades rurales
2150 # Municipio predominantemente rural =
2151 # m s del 50% y menos del 100% de la poblaci n en localidades
    rurales
2152 # Municipio predominantemente urbano =
2153 # menos del 50% de la poblaci n en localidades rurales
2154
2155 # Aqu tampoco coinciden las claves entre las bases de
    localidades y secciones
2156 summary(localidades_raw$MUN)
2157 summary(secciones$MUN)
2158
2159
2160
2161 localidades <- localidades_raw%>%
2162   filter_at(vars(NOM_LOC, NOM_ENT, NOM_MUN),

```

```

2163         ~!grepl("Total", .))%>%
2164 select(ENTIDAD,MUN,NOM_ENT, NOM_MUN,POBTOT)%>%
2165 mutate(POBTOT = as.numeric(POBTOT))%>%
2166 mutate(clasificacion_localidad = case_when(
2167     POBTOT<2500 ~ "rural",
2168     TRUE ~ "urbana"
2169 ))%>%
2170 group_by(ENTIDAD,MUN,NOM_ENT,NOM_MUN,clasificacion_localidad)
2171     %>%
2172 summarise(clasificacion_total = n())%>%
2173 group_by(ENTIDAD,MUN) %>%
2174 mutate(porcentaje = round(100 *
2175     clasificacion_total / sum(clasificacion_total),4))
2176
2177 municipios_clasificados_raw <- localidades%>%
2178 group_by(ENTIDAD,MUN,NOM_ENT,NOM_MUN)%>%
2179 filter(porcentaje == max(porcentaje))%>%
2180 mutate(clasificacion_municipio = case_when(
2181     clasificacion_localidad == "rural" &
2182     porcentaje == 100 ~ "Totalmente rural",
2183     clasificacion_localidad == "rural" &
2184     (porcentaje > 50 & porcentaje <= 100) ~
2185     "Predominantemente rural",
2186     TRUE ~ "Predominantemente urbano"
2187 ))%>%
2188 distinct(ENTIDAD,MUN,NOM_ENT,NOM_MUN,clasificacion_municipio)
2189
2190
2191 # Se deben de limpiar los nombres de los municipios
2192 # en la base de localidades
2193 clean_names_municipios_localidades<-function(){
2194 # Se ocupa el catalogo de las secciones para poder
2195 # tener sus nombres
2196 municipios <- municipios_clasificados_raw%>%
2197     mutate(NOM_MUN=str_to_title(NOM_MUN),
2198         NOM_MUN=chartr("          ", "aeiou", NOM_MUN),
2199         NOM_MUN=chartr("          ", "AEIOU", NOM_MUN))%>%
2200     rename(CVE_MUN = MUN)
2201
2202 # * * * * *
2203 # Se hacen los cambios generales que se hicieron
2204 # en INEGI - municipios
2205 # * * * * *
2206
2207 # Los que dicen Gral. se reemplazan por General y Dr. por
2208     Doctor
2209 municipios$NOM_MUN <- gsub("Gral.", "General", municipios$NOM

```

```

2209     _MUN)
2210     municipios$NOM_MUN <- gsub("Dr.", "Doctor", municipios$NOM_
2211     MUN)
2212
2213     # Los municipios de San Juan Mixtepec y San Pedro Mixtepec
2214     vienen repetidos
2215     municipios_clean <- municipios%>%
2216     mutate(NOM_MUN=case_when(
2217       CVE_MUN=='208' & ENTIDAD== '20'~
2218       'San Juan Mixtepec -Dto. 08 -',
2219       CVE_MUN=='209' & ENTIDAD== '20'~
2220       'San Juan Mixtepec -Dto. 26 -',
2221       CVE_MUN=='318' & ENTIDAD== '20'~
2222       'San Pedro Mixtepec -Dto. 22 -',
2223       CVE_MUN=='319' & ENTIDAD== '20'~
2224       'San Pedro Mixtepec -Dto. 26 -',
2225       TRUE ~ NOM_MUN)
2226     )%>%
2227     mutate(NOM_MUN=
2228       case_when(
2229         ENTIDAD==5 & NOM_MUN=="Cuatrociénegas" ~
2230         "Cuatro Ciénegas",
2231
2232         ENTIDAD==7 & NOM_MUN=="Villacomaltitlan" ~
2233         "Villa Comaltitlan",
2234
2235         ENTIDAD==8 & NOM_MUN=="Doctor Belisario
2236         Dominguez" ~
2237         "Dr. Belisario Dominguez",
2238
2239         ENTIDAD==10 & NOM_MUN=="Simon Bolivar" ~
2240         "General Simon Bolivar",
2241
2242         ENTIDAD==17 & NOM_MUN=="Jonacatepec" ~
2243         "Jonacatepec De Leandro Valle",
2244
2245         ENTIDAD==20 &
2246         NOM_MUN=="H Villa Tezoatlan Segura Y Luna Cuna
2247         Ind Oax" ~
2248         "Heroica Villa Tezoatlan De Segura Y Luna, Cuna
2249         De La Independencia De Oaxaca",
2250
2251         ENTIDAD==20 &
2252         NOM_MUN=="Heroica Ciudad De Juchitan De Zaragoza
2253         " ~
2254         "Juchitan De Zaragoza",
2255
2256         ENTIDAD==20 &
2257         NOM_MUN=="Santiago Chazumba" ~
2258         "Villa De Santiago Chazumba",
2259

```

```

2250
2251     ENTIDAD==29 &
2252     NOM_MUN=="Zitlaltepec De Trinidad Sanchez Santos
2253         " ~
2254         "Zitlaltepec De Trinidad Sanchez Santos",
2255
2256     ENTIDAD==30 &
2257     NOM_MUN=="Cosamaloapan" ~
2258     "Cosamaloapan De Carpio",
2259     ENTIDAD==30 &
2260     NOM_MUN=="Ozuluama" ~
2261     "Ozuluama De Mascare as",
2262     ENTIDAD==30 &
2263     NOM_MUN=="Zontecomatlan" ~
2264     "Zontecomatlan De Lopez Y Fuentes",
2265
2266     ENTIDAD==19 & NOM_MUN=="Carmen" ~ "El Carmen",
2267     TRUE ~ NOM_MUN
2268     ))>%
2269     rename(MUN=CVE_MUN)>%ungroup()
2270
2271
2272     return(municipios_clean)
2273 }
2274 municipios_clasificados <- clean_names_municipios_localidades()
2275
2276
2277 # Se obtiene un resumen de las clasificaciones de los
2278     municipios
2279     municipios_clasificados>%
2280     group_by(clasificacion_municipio)>%
2281     summarise(total=n())
2282
2283 # Se comprueba que no haya municipios que no vayan a matchear
2284     en el join
2285     rbind(secciones>%distinct(ENTIDAD, NOM_MUN)>%
2286         mutate(base="secciones"),
2287         municipios_clasificados>%
2288         distinct(ENTIDAD, NOM_MUN)>%
2289         mutate(base="municipios clasi"))>%
2290     group_by(ENTIDAD, NOM_MUN)>%
2291     mutate(total=n())>%
2292     arrange(total)
2293
2294 # Se crean las diferentes estratificaciones
2295 # Recordando la estratificaci n elegida

```

```

2295 a <- "alfa_0.25.K_5"
2296 df <- "vp_D0_D1.geo"
2297
2298
2299
2300 secciones_clasificadas <- secciones%>%
2301   left_join(municipios_clasificados,
2302             by=c("ENTIDAD", "NOM_MUN"))%>%
2303   left_join(D0_D1.geo%>%select(ENTIDAD, NOM_MUN, a),
2304             by=c("ENTIDAD", "NOM_MUN"))%>%
2305   mutate(Entidad_TipoMunicipio =
2306           paste0("Entidad: ", ENTIDAD, " - ",
2307                 "Tipo Municipio: ", clasificacion_municipio))%>%
2308   rename(Cluster = a)%>%
2309   mutate(Entidad_EstratificacionTesis =
2310           paste0("Entidad: ", ENTIDAD, " ",
2311                 "Cluster: ", Cluster))%>%
2312   mutate(Entidad_TipoMunicipio_EstratificacionTesis =
2313           paste0("Entidad: ", ENTIDAD, " ",
2314                 "Tipo Municipio: ", clasificacion_municipio,
2315                 " ",
2316                 "Cluster: ", Cluster))
2317
2318 # 32
2319 dim(table(secciones_clasificadas$ENTIDAD))
2320 # 3
2321 dim(table(secciones_clasificadas$clasificacion_municipio))
2322 # 32 * 3
2323 dim(table(secciones_clasificadas$Entidad_TipoMunicipio))
2324 # 32 * 5
2325 dim(table(secciones_clasificadas$Entidad_EstratificacionTesis))
2326 # 32 * 5 * 3
2327 dim(table(secciones_clasificadas$Entidad_TipoMunicipio_
2328           EstratificacionTesis))
2329
2329 resumen <- secciones_clasificadas%>%select(ENTIDAD, NOM_MUN,
2330                                             clasificacion_municipio,
2331                                             Cluster,
2332                                             Entidad_TipoMunicipio,
2333                                             Entidad_EstratificacionTesis,
2334                                             Entidad_TipoMunicipio_
2335                                             EstratificacionTesis)
2336
2336 # resumen%>%
2337 #   filter(Cluster==3)%>%
2338 #   left_join(D0_D1.geo%>%distinct(NOM_ENT, NOM_MUN, ENTIDAD,

```

```

2339     MUN))%>%
#   distinct(NOM_ENT)
2340
2341 # * * * * *
2342 # 7.2 C lculo de vairanzas con diferentes estratificaciones
=====
2343 # * * * * *
2344
2345 # La variables de las que se calcular n las varianzas
2346
2347 variables <- c("P15PRI_IN",
2348               "P8A14AN",
2349               "P15YM_AN",
2350               "PCON_DISC",
2351               "P3YM_HLI",
2352               "PSINDER",
2353               "VPH_PISODT",
2354               "VPH_S_ELEC",
2355               "VPH_AGUAFV",
2356               "VPH_NODREN")
2357
2358 # Funci n para obtener las varianzas, recibe la agrupaci n
2359 # por la que se calcular n las varianzas
2360
2361 obten_varianzas <- function(base, agrupacion){
2362   obten_VP <- function(variable,agrupacion){
2363     #Asignaci n del tama o de muestra en cada estrato
2364     #Proporcional a Nh, es decir  $nh \sim n * Nh/N$ 
2365     varianza_poblacional <-
2366       base%>%
2367       group_by(eval(parse(text=agrupacion)))%>%
2368       summarise(Nh=n(), # total de poblaci n por cada grupo
2369                nh=ceiling(n*Nh/N), # se calcula la n de cada h
2370                Syh2=var( eval(parse(text=variable)) ), #
2371                varianza del conjunto h
2372                Vh=(Nh^2/nh)*(1-nh/Nh)*Syh2 )%>% #calculo de la
                varianza
2373     mutate_if(is.numeric, ~replace(., is.na(.), 0)) #existen
                grupos con una observaci n
2374     # por lo cual la varianza poblacional de ah debe de ser
                cero
2375
2376     VP <- sum(varianza_poblacional$Vh)/sum(varianza_poblacional
2377        $Nh)^2
2378     VP
2379     return(VP)
2380   }
2381 }

```

```

2380 varianzas_df <- data.frame(matrix(nrow = 0, ncol = 2))
2381 names(varianzas_df) <- c("Variable", "Varianza")
2382
2383 for(variable in variables){
2384   row <- data.frame(Variable = variable,
2385                     Varianza = obten_VP(variable, agrupacion)
2386                               )
2387   varianzas_df <- rbind(varianzas_df, row)
2388 }
2389 return(varianzas_df)
2390 }
2391
2392 # Estratificaci n de la tesis
2393 varianza_estratificacion <- obten_varianzas(secciones_
2394   clasificadas, "Cluster")%>%
2395   rename(varianza_estratificacion = Varianza)
2396 # Tiene que dar lo mismo obtenido anteriormente
2397 data%>%
2398   filter(agrupacion==a,
2399          data_frame==df)
2400 varianza_estratificacion
2401
2402 # Varianza por estado
2403 # Tiene 32 estratos
2404 varianza_entidad <- obten_varianzas(
2405   secciones_clasificadas, "ENTIDAD")%>%
2406   rename(varianzas_entidad = Varianza)
2407
2408 # Varianza por la clasificaci n del municipio
2409 # Tiene 3 estratos
2410 varianza_clasificacionMunicipio <- obten_varianzas(
2411   secciones_clasificadas, "clasificacion_municipio")%>%
2412   rename(varianza_clasificacionMunicipio = Varianza)
2413
2414 # Varianza por entidad y tipo de municipio
2415 # Tiene 32*4 estratos
2416 varianza_entidad_clasificacionMunicipio <- obten_varianzas(
2417   secciones_clasificadas, "Entidad_TipoMunicipio")%>%
2418   rename(varianza_entidad_clasificacionMunicipio = Varianza)
2419
2420 # Varianza por entidad y estratificaci n tesis
2421 # Tiene 32*5 estratos
2422 varianza_entidad_estratificacion <- obten_varianzas(
2423   secciones_clasificadas, "Entidad_EstratificacionTesis")%>%
2424   rename(varianza_entidad_estratificacion = Varianza)
2425
2426 # Varianza por entidad, tipo de municipio y estratificaci n
2427   tesis

```

```

2425 # Tiene 32*4*5 estratos
2426 varianza_entidad_clasificacionMunicipio_estratificacion <-
      obten_varianzas(
2427 secciones_clasificadas,"Entidad_TipoMunicipio_
      EstratificacionTesis")%>%
2428 rename(varianza_entidad_clasificacionMunicipio_
      estratificacion = Varianza)
2429
2430 varianzas <- varianza_estratificacion%>%
2431 left_join(varianza_entidad)%>%
2432 left_join(varianza_estratificacion)%>%
2433 left_join(varianza_clasificacionMunicipio)%>%
2434 left_join(varianza_entidad_clasificacionMunicipio)%>%
2435 left_join(varianza_entidad_estratificacion)%>%
2436 left_join(varianza_entidad_clasificacionMunicipio_
      estratificacion)
2437
2438 varianzas <- varianzas %>%
2439 mutate_if(is.numeric, round, digits=2)
2440
2441
2442
2443 # * * * * *
2444 # 8.0 Descripci n de los resultados ====
2445 # * * * * *
2446
2447 # * * * * *
2448 # 8.1 Correlaciones variables sociodemo ====
2449 # * * * * *
2450 library(reshape2);library(showtext)
2451 font_add_google(c("Special Elite"))
2452 font_add_google(c("Poppins"))
2453 showtext_auto()
2454
2455 heat <- melt(datos_sociodemo%>%
2456             mutate(id=paste0(NOM_ENT,"_",NOM_MUN))%>%
2457             select(-c(NOM_ENT,NOM_MUN) ) )
2458
2459 # Se obtiene la correlacion
2460 cormat <- round(cor(datos_sociodemo%>%select(-c(NOM_ENT,NOM_MUN
      ) ) ),2)
2461 melted_cormat <- melt(cormat)
2462
2463
2464 ggplot(data = melted_cormat, aes(x=Var1, y=Var2, fill=value)) +
2465 geom_tile()+
2466 # scale_fill_gradient(low = "yellow", high = "red", na.value
      = NA)+

```

```

2467 scale_fill_gradient2(low = "#004779", high = "#A50021", mid =
      "white",
2468                       na.value = NA, guide = "colourbar",
2469                       aesthetics = "fill")+
2470 labs(title = "Correlaci n entre variables
      sociodemogr ficas con el m todo de pearson")+
2471 theme_bw()+
2472 theme(text = element_text(family="Poppins"),
2473       plot.title = element_text(size=20,hjust = 0.5),
2474       axis.title = element_blank(),
2475       axis.text.x = element_text(size=15,
2476                                   family="Special Elite",
2477                                   angle=90, hjust = 1),
2478       axis.text.y = element_text(size=15,
2479                                   family="Special Elite"),
2480       panel.background = element_rect(fill = "white",
2481                                       colour = "white"),
2482       plot.background = element_rect(fill = "white",
2483                                       colour = "white"),
2484       panel.grid = element_blank(),
2485       legend.title = element_blank(),
2486       legend.text = element_text(size=14),
2487       panel.border = element_blank(),
2488       axis.ticks = element_blank(),
2489       axis.line = element_blank())
2490
2491
2492 # setwd(output)
2493 # ggsave(filename = "correlaciones.png",
2494 #         device = "png",width = 10,height = 10 , dpi=100)
2495
2496
2497 # * * * * *
2498 # 8.2 PCA ====
2499 # * * * * *
2500 estratificacion <- D0_D1.geo[c("alfa_0.25.K_5", "ENTIDAD", "MUN")
      ]>%
2501   left_join(nombres_limpios)
2502
2503
2504 datos_estratos <- merge(estratificacion, datos_sociodemo,
2505                       by=c("NOM_ENT", "NOM_MUN"))>%
2506   rename(grupos="alfa_0.25.K_5")>%
2507   mutate(grupos=as.character(grupos))>%
2508   mutate(grupos=case_when(
2509     grupos == "3" ~ "1",
2510     grupos == "1" ~ "2",
2511     grupos == "2" ~ "3",
2512     TRUE ~ grupos

```

```

2513 ))>%
2514 mutate(grupos=factor(grupos,levels=c("1","2","3","4","5")))
2515
2516 # Se hace el analisis de pca
2517 library(ggfortify)
2518
2519 df_PCA <- datos_estratos%>%
2520   select(-c(NOM_ENT,NOM_MUN,ENTIDAD,MUN,grupos))
2521
2522 pca.obj <- prcomp(df_PCA)
2523
2524 colores <- c("#608F3D","#A2CF49","#FEC306","#E76618","#4A9BDC")
2525 ggplot(data = data.frame('Grupo' = datos_estratos$grupos,
2526                           pca.obj$x[,1:2])) +
2527   geom_point(aes(x = PC1, y = PC2, col = Grupo)) +
2528   theme_bw() +
2529   scale_color_manual(values=colores)+
2530   labs(x="PC1(64.13%)", y="PC2(8.49%)")+
2531   theme(text = element_text(family="Poppins"),
2532         plot.title = element_text(size=20,hjust = 0.5),
2533         axis.title = element_text(size=19),
2534         legend.title = element_text(size=20),
2535         legend.text = element_text(size=25),
2536         axis.text = element_text(size=18),
2537         panel.border = element_blank(),
2538         panel.background = element_blank()+
2539   guides(color = guide_legend(override.aes = list(size = 5)))
2540
2541
2542 # setwd(output)
2543 # ggsave(filename = "PCA.png",
2544 #         device = "png",width = 10,height = 10 , dpi=100)
2545
2546
2547 # Se obtiene la correlacion entre las variables y el PCA1
2548
2549 library("FactoMineR")
2550 res.pca <- PCA(df_PCA, graph = FALSE)
2551 res.desc <- dimdesc(res.pca, axes = c(1,2), proba = 0.05)
2552
2553 corr_PCA1 <- as.data.frame(res.desc$Dim.1)%>%
2554   select(quantile.correlation)%>%
2555   mutate(quantile.correlation = round(quantile.correlation,2))
2556 corr_PCA1
2557
2558
2559 corr_PCA2 <- as.data.frame(res.desc$Dim.2)%>%
2560   select(quantile.correlation)%>%

```

```

2561 mutate(quanti.correlation = round(quanti.correlation,2))
2562 corr_PCA2
2563
2564
2565 # * * * * *
2566 # 8.3 Total de municipios por grupo ====
2567 # * * * * *
2568
2569 total_municipios <- datos_estratos%>%
2570   group_by(grupos)%>%
2571   summarise(total=n())%>%
2572   mutate(porcentaje = round(100*total/sum(total),2))
2573
2574 names(total_municipios) = str_to_title(names(total_municipios))
2575 total_municipios
2576 ggplot(data=total_municipios, aes(x=Grupos, y=Total,
2577                                   fill=Grupos)) +
2578   scale_fill_manual(values=colores)+
2579   geom_bar(stat="identity")+
2580   theme_bw()+
2581   labs(x = "Estrato", y = "Total de municipios")+
2582   theme(text = element_text(family="Poppins"),
2583         plot.title = element_text(size=20,hjust = 0.5),
2584         axis.title.x = element_text(size=30),
2585         axis.title.y = element_text(size=30),
2586         axis.text.y = element_text(size=18,
2587                                     colour = "#505050"),
2588         axis.text.x = element_text(size=20,
2589                                     colour = "#505050"),
2590         panel.background = element_rect(fill = "white",
2591                                         colour = "white"),
2592         plot.background = element_rect(fill = "white",
2593                                         colour = "white"),
2594         panel.grid = element_line(color = "#F1F1F2",
2595                                   linetype = 1),
2596         legend.title = element_text(size=30),
2597         legend.text = element_text(size=25),
2598         panel.border = element_blank(),
2599         axis.ticks = element_blank(),
2600         legend.position = "none",
2601         axis.line = element_blank()+
2602   scale_y_continuous(n.breaks = 5)
2603
2604 setwd(output)
2605 ggsave(filename = "total_grupos_barras.png",
2606         device = "png", width = 8, height = 5, dpi=100)
2607
2608

```

```

2609
2610 # * * * * *
2611 # 8.4 BoxPlots ====
2612 # * * * * *
2613 obten_boxplot <- function(base){
2614   g <- ggplot(base, aes(x=grupos, y=var, fill=grupos)) +
2615     geom_boxplot()+
2616     scale_fill_manual(values=colores)+
2617     theme_bw()+
2618     scale_y_continuous(n.breaks=10)+
2619     theme(text = element_text(family="Poppins"),
2620           plot.title = element_blank(),
2621           axis.title = element_text(size=25),
2622           legend.title = element_text(size=20),
2623           legend.text = element_text(size=18),
2624           axis.text = element_text(size=18, color="#4D4D4D"),
2625           panel.grid.major = element_blank(),
2626           panel.border = element_blank(),
2627           legend.position = "none")+
2628     labs(y=' ', x="Grupo")
2629   return(g)
2630 }
2631
2632 # Grado promedio de escolaridad
2633 obten_boxplot(datos_estratos%>%select(grupos, ENTIDAD, MUN)%>%
2634               left_join(inegi)%>%select(grupos, GRAPROES)%>%
2635               mutate(GRAPROES = as.numeric(GRAPROES))%>%
2636               rename(var = GRAPROES))
2637
2638 setwd(output)
2639 ggsave(filename = "Box_plot_GRAPROES.png",
2640         device = "png",width = 10, height = 10 , dpi=100)
2641
2642
2643 # Pobreza poblacional
2644 obten_boxplot(datos_estratos%>%select(grupos, pobreza_pob)%>%
2645               mutate(pobreza_pob = as.numeric(pobreza_pob))
2646               %>%
2647               rename(var = pobreza_pob))
2648
2649 setwd(output)
2649 ggsave(filename = "Box_plot_pobreza_pob.png",
2650         device = "png",width = 10, height = 10 , dpi=100)
2651
2652
2653 # Promedio de ocupantes por cuarto
2654 obten_boxplot(datos_estratos%>%select(grupos, ENTIDAD, MUN)%>%
2655               left_join(inegi)%>%select(grupos, PRO_OCUP_C)%>%

```

```

2656         mutate(PRO_OCUP_C = as.numeric(PRO_OCUP_C))%>%
2657         rename(var = PRO_OCUP_C)
2658
2659 setwd(output)
2660 ggsave(filename = "Box_plot_PRO_OCUP_C.png",
2661         device = "png",width = 10, height = 10 , dpi=100)
2662
2663
2664 # Poblaci n de habla ind gena
2665 obten_boxplot(datos_estratos%>%select(grupos ,P3YM_HLI)%>%
2666             mutate(P3YM_HLI = as.numeric(P3YM_HLI))%>%
2667             rename(var = P3YM_HLI))
2668
2669 setwd(output)
2670 ggsave(filename = "Box_plot_P3YM_HLI.png",
2671         device = "png",width = 10, height = 10 , dpi=100)
2672
2673
2674 # * * * * *
2675 # 8.5 Descripci n de los boxplots ====
2676 # * * * * *
2677
2678 # Para los a os promedio de escolaridad
2679 datos_estratos%>%select(grupos , ENTIDAD , MUN)%>%
2680 left_join(inegi)%>%select(grupos , GRAPROES)%>%
2681 mutate(GRAPROES = as.numeric(GRAPROES))%>%
2682 group_by(grupos)%>%
2683 summarise(promedio = mean(GRAPROES),
2684           minimo = min(GRAPROES),
2685           maximo = max(GRAPROES),
2686           mediana = median(GRAPROES))
2687
2688
2689 # Pobreza poblacional
2690 datos_estratos%>%select(grupos ,pobreza_pob)%>%
2691 mutate(pobreza_pob = as.numeric(pobreza_pob))%>%
2692 group_by(grupos)%>%
2693 summarise(promedio = mean(pobreza_pob),
2694           minimo = min(pobreza_pob),
2695           maximo = max(pobreza_pob),
2696           mediana = median(pobreza_pob))
2697
2698 # Ocupantes por cuarto
2699 datos_estratos%>%select(grupos , ENTIDAD , MUN)%>%
2700 left_join(inegi)%>%select(grupos ,PRO_OCUP_C)%>%
2701 mutate(PRO_OCUP_C = as.numeric(PRO_OCUP_C))%>%
2702 group_by(grupos)%>%
2703 summarise(promedio = mean(PRO_OCUP_C),

```

```

2704         minimo = min(PRO_OCUP_C),
2705         maximo = max(PRO_OCUP_C),
2706         mediana = median(PRO_OCUP_C))
2707
2708
2709 # * * * * *
2710 # 8.6 # Municipios en cada grupo por estado ====
2711 # * * * * *
2712 estratos_por_estados <- datos_estratos%>%
2713   group_by(NOM_ENT, grupos)%>%
2714   summarise(total=n())%>%
2715   group_by(NOM_ENT)%>%
2716   mutate(porcentaje = total /sum(total))%>%
2717   mutate(info = paste0(total ,
2718     " (", 100 * round(porcentaje,4), "%)")
2719     %>%
2720   select(grupos, info)%>%
2721   pivot_wider(names_from = grupos, values_from = info)%>%
2722   rename(grupo_1 = '1',
2723     grupo_2 = '2',
2724     grupo_3 = '3',
2725     grupo_4 = '4',
2726     grupo_5 = '5')%>%
2727   select(NOM_ENT, grupo_1, grupo_2, grupo_3, grupo_4, grupo_5)
2728   %>%
2729   mutate_all(~replace(., is.na(.), "-"))
2730
2731 #write.csv(estratos_por_estados,"estratos_por_estados.csv",row.
2732   names=FALSE)
2733
2734 # * * * * *
2735 # 8.7 # Tabla de variables promedio(rango) ====
2736 # * * * * *
2737
2738 names(datos_estratos)
2739
2740 medias_grupos <- datos_estratos%>%
2741   select(-NOM_ENT, -NOM_MUN, -ENTIDAD, -MUN)%>%
2742   group_by(grupos)%>%
2743   mutate(grupos = case_when(
2744     grupos == "1" ~ "grupo_1",
2745     grupos == "2" ~ "grupo_2",
2746     grupos == "3" ~ "grupo_3",
2747     grupos == "4" ~ "grupo_4",
2748     grupos == "5" ~ "grupo_5"
2749   ))%>%
2750   summarise(across(everything(), mean))

```

```

2749
2750 min_grupos <- datos_estratos%>%
2751   select(-NOM_ENT, -NOM_MUN, -ENTIDAD, -MUN)%>%
2752   group_by(grupos)%>%
2753   mutate(grupos = case_when(
2754     grupos == "1" ~ "grupo_1",
2755     grupos == "2" ~ "grupo_2",
2756     grupos == "3" ~ "grupo_3",
2757     grupos == "4" ~ "grupo_4",
2758     grupos == "5" ~ "grupo_5"
2759   ))%>%
2760   summarise(across(everything(), min))
2761
2762
2763 max_grupos <- datos_estratos%>%
2764   select(-NOM_ENT, -NOM_MUN, -ENTIDAD, -MUN)%>%
2765   group_by(grupos)%>%
2766   mutate(grupos = case_when(
2767     grupos == "1" ~ "grupo_1",
2768     grupos == "2" ~ "grupo_2",
2769     grupos == "3" ~ "grupo_3",
2770     grupos == "4" ~ "grupo_4",
2771     grupos == "5" ~ "grupo_5"
2772   ))%>%
2773   summarise(across(everything(), max))
2774
2775 nombres_variables <- names(datos_estratos)[-c(1:5)]
2776
2777 medias_t <- as.data.frame(t(medias_grupos)[-1,])%>%
2778   mutate(V1 = as.numeric(V1),
2779     V2 = as.numeric(V2),
2780     V3 = as.numeric(V3),
2781     V4 = as.numeric(V4),
2782     V5 = as.numeric(V5))%>%
2783   mutate(variable = nombres_variables)%>%
2784   mutate(across(where(is.numeric), round, digits=2))
2785
2786 min_t <- as.data.frame(t(min_grupos)[-1,])%>%
2787   mutate(V1 = as.numeric(V1),
2788     V2 = as.numeric(V2),
2789     V3 = as.numeric(V3),
2790     V4 = as.numeric(V4),
2791     V5 = as.numeric(V5))%>%
2792   mutate(variable = nombres_variables)%>%
2793   mutate(across(where(is.numeric), round, digits=2))
2794
2795 max_t <- as.data.frame(t(max_grupos)[-1,])%>%
2796   mutate(V1 = as.numeric(V1),

```

```

2797     V2 = as.numeric(V2),
2798     V3 = as.numeric(V3),
2799     V4 = as.numeric(V4),
2800     V5 = as.numeric(V5))%>%
2801 mutate(variable = nombres_variables)%>%
2802 mutate(across(where(is.numeric), round, digits=2))
2803
2804
2805 names(medias_t) <- c(paste0(c("grupo_1", "grupo_2",
2806                             "grupo_3", "grupo_4",
2807                             "grupo_5"), "_media"), "variable")
2808 names(min_t) <- c(paste0(c("grupo_1", "grupo_2",
2809                             "grupo_3", "grupo_4",
2810                             "grupo_5"), "_min"), "variable")
2811 names(max_t) <- c(paste0(c("grupo_1", "grupo_2",
2812                             "grupo_3", "grupo_4",
2813                             "grupo_5"), "_max"), "variable")
2814
2815
2816 resumen_variables <- medias_t%>%
2817 left_join(min_t)%>%
2818 left_join(max_t)%>%
2819 mutate(grupo_1 = paste0(grupo_1_media,
2820                           " (", grupo_1_min,
2821                           " - ", grupo_1_max, ")"))%>%
2822 mutate(grupo_2 = paste0(grupo_2_media,
2823                           " (", grupo_2_min,
2824                           " - ", grupo_2_max, ")"))%>%
2825 mutate(grupo_3 = paste0(grupo_3_media,
2826                           " (", grupo_3_min,
2827                           " - ", grupo_3_max, ")"))%>%
2828 mutate(grupo_4 = paste0(grupo_4_media,
2829                           " (", grupo_4_min,
2830                           " - ", grupo_4_max, ")"))%>%
2831 mutate(grupo_5 = paste0(grupo_5_media,
2832                           " (", grupo_5_min,
2833                           " - ", grupo_5_max, ")"))%>%
2834 select(variable, grupo_1, grupo_2, grupo_3, grupo_4, grupo_5)
2835
2836
2837 # write.csv(resumen_variables, "resumen_grupos.csv", row.names =
    FALSE)

```

## Capítulo 9

# Bibliografía

- Bivand, R. (2022). R Packages for Analyzing Spatial Data: A Comparative Case Study with Areal Data Geographical Analysis, 54(3), 488-518.  
<https://doi.org/10.1111/gean.12319>
- Bivand, R. y Keitt, T., Rowlingson, B. (2023). rgdal: Bindings for the 'Geospatial' Data Abstraction Library. R package version 1.6-4.  
<https://CRAN.R-project.org/package=rgdal>
- Chavent, M., Kuentz-Simonet, V., Labenne, A. y Saracco, J. (2018). ClustGeo: an R package for hierarchical clustering with spatial constraints. *Computational Statistics*, 33, 1799–1822.  
<https://doi.org/10.1007/s00180-018-0791-1>
- Chavent, M., Kuentz, V., Labenne, A. y Saracco, J. (2021). ClustGeo: Hierarchical Clustering with Spatial Constraints. R package version 2.1.  
<https://CRAN.R-project.org/package=ClustGeo>
- CONEVAL. (2018). *Informe de pobreza en los municipios de México 2015*. CONEVAL.
- Giordani, P., Ferraro, M. y Martella, F. (2020). *An Introduction to Clustering with R*. Springer.
- INEGI. (2010). *Manual de cartografía geoestadística*. INEGI.
- INEGI. (2019). *Cómo se hace la ENOE 2019*. INEGI.
- INEGI. (2021) a). *Censo de Población y Vivienda 2020: marco conceptual*. INEGI.
- INEGI. (2021) b). *Metodología para el cálculo de las Estadísticas Censales a Escalas Geoelectorales 2020*. INEGI.
- INEGI. (2022). *Programa anual de trabajo*. INEGI.
- James, G., Witten, D. y Hastie, T. (2021). *An introduction to Statistical Learning With applications in R*. Springer.
- Kassambara, A. (2017). *Practical Guide To Cluster Analysis in R*. STHDA.

- Kassambara, A. y Mundt, F. (2020). *factoextra: Extract and Visualize the Results of Multivariate Data Analyses*. R package version 1.0.7.  
<https://CRAN.R-project.org/package=factoextra>
- Landeros, A. (2013). *Reunión nacional de estadística*. INEGI.  
<https://www.inegi.org.mx/contenidos/eventos/2013/fne/P-AnaMariaLanderos.pdf>
- Leisch, F. y Dimitriadou, E. (2021). *Machine Learning Benchmark Problems*. R package version 2.1
  
- Lohr, S. (2019). *Sampling Design and Analysis*. Wiley.
- Pebesma, E., (2018). Simple Features for R: Standardized Support for Spatial Vector Data. *The R Journal* 10 (1), 439-446.  
<https://doi.org/10.32614/RJ-2018-009>
- Pérez de la Cruz, G. (2023). *Notas de clase. Muestreo. Semestre 2022-1*. Facultad de Ciencias, UNAM.
- Rodríguez Muñoz, J. y Heredia Hernández, O. (11 de junio de 2023). *La muestra maestra de viviendas: Diseño, actualización y uso* [Archivo de Vídeo]. Youtube. Canal Seminario de Estadística y Actuaría Facultad de Ciencias  
[https://www.youtube.com/watch?v=U7RYp1x-VP0ab\\_channel](https://www.youtube.com/watch?v=U7RYp1x-VP0ab_channel)  
=SeminariodeEstad%C3%ADsticayActuar%C3%ADaFacultaddeCiencias
  
- Rousseeuw, P. (1987). Silhouettes: a graphical aid to the interpretation and validation of cluster analysis. *Computational and Applied Mathematics*, 20, 53-65.  
[https://doi.org/10.1016/0377-0427\(87\)90125-7](https://doi.org/10.1016/0377-0427(87)90125-7)
- Sarndal, C., Swensson, B. y Wretman, J. (1992). *Model Assisted Survey Sampling*. Springer.
- Tillé, Y. (2020). *Sampling and estimation from finite populations*. Wiley.
- Thorndike, R. (1953). Who belongs in the family. *Psychometrika*, 18, 267-276.  
<https://doi.org/10.1007/BF02289263>
- Tibshirani, R., Walther, G. y Hastie, T. (2001). Estimating the Number of Clusters in a Data Set Via the Gap Statistic. *Journal of the Royal Statistical Society Series B*, 63(2), 411-423.  
<https://doi.org/10.1111/1467-9868.00293>
- Ward, J. (1963). Hierarchical Grouping to Optimize an Objective Function. *Journal of the American Statistical Association*, 58 (301), 236-244.  
<https://doi.org/10.1080/01621459.1963.10500845>