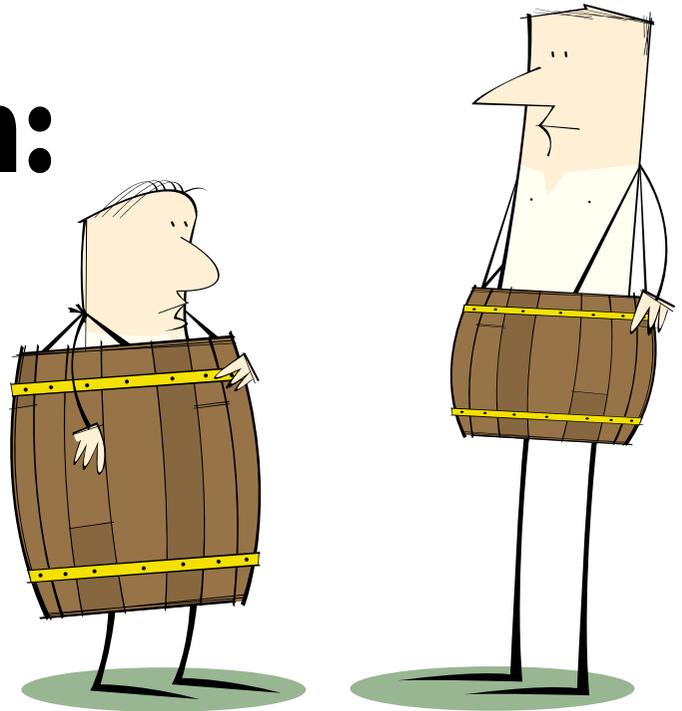


Niveles de marginación: una estrategia multivariada de clasificación

Alfredo Bustos*



Men wearing Barrels. ©iStockphoto.com/jcgwakerfield

Este documento plantea el uso de una estrategia de clasificación en el estudio de la marginación y del bienestar sustentada en un criterio propuesto para la búsqueda de las alternativas con mayor homogeneidad. Se parte de revisar el método de conglomeración según el grado de marginación, usado por el Consejo Nacional de Población (CONAPO), basada en la primera componente principal calculada a partir de las versiones estandarizadas de los indicadores seleccionados. La estrategia obtiene diversas clasificaciones con base en una o más de las componentes principales de los indicadores sin estandarizar, lo que resuelve las limitaciones identificadas. La mejor clasificación se determina usando el criterio propuesto. La aplicación de esta estrategia se ejemplifica con información municipal del II Censo de Población 2005, también usada por el CONAPO. Se muestra que, para el ejemplo, la conglomeración óptima de municipios se alcanza cuando se usan las dos primeras componentes principales.

Palabras clave: clasificación, conglomeración, estratificación, componentes principales, marginación.

The use of a strategy for the classification of geographical units in the study of marginalization and well-being, supported by a proposed criterion for the search of more homogeneous alternatives, is introduced. The conglomeration method by degree of marginalization, used in Mexico by CONAPO, which is based on the first principal component computed from standardized versions of the selected indicators, is reviewed. In order to solve the identified limitations, the strategy whose use is being proposed obtains alternative classifications based on one or more principal components from the non-standardized indicators. The best classification is then determined using the proposed homogeneity criterion. The application of the strategy is exemplified using municipal information from the II Censo de Población y Vivienda 2005, in Mexico as used by CONAPO. It is shown that, for this data, the optimal classification of municipalities is reached when only the first two principal components are used.

Keywords: Classification, clustering, stratification, principal components, marginality.

* Actuario por la UNAM, maestro en Estadística e Investigación de Operaciones por el IIMAS de la UNAM y doctor en Estadística por la London School of Economics de la Universidad de Londres. Es investigador en el INEGI. Sus áreas de interés, entre otras, son el ajuste de modelos a partir de datos provenientes de encuestas (distribución del ingreso) y la estimación para áreas pequeñas, el uso de registros administrativos para la estimación del tamaño de la población inmigrante. Es miembro del SNI, Nivel I (alfredo.bustos@inegi.org.mx).

Nota: agradezco los comentarios del doctor Gerardo Leyva y de la maestra Miriam Romo, quienes contribuyeron a mejorar este trabajo.

Introducción

Hoy en día es frecuente escuchar que la implementación de tal o cual política pública, que busca atacar un problema de naturaleza multidimensional, ha sido basada en algún indicador compuesto o en alguna aplicación de éste. Sobra decir que un índice desarrollado de forma inadecuada puede limitar el efecto esperado de la aplicación de recursos fiscales (de montos casi siempre importantes) en la población a la que son dirigidos. Es por esta razón que se ha vuelto muy importante mejorar nuestra capacidad tanto para realizar los cálculos requeridos como para evaluar los resultados que así se obtengan. En general, los métodos para obtener indicadores compuestos han seguido siendo objeto de análisis y mejora; de cualquier modo, aún es frecuente encontrar indicadores de este tipo contruidos mediante procedimientos y métodos más o menos rudimentarios.

Por su parte, en relación con nuestra capacidad para evaluar los resultados, hay —en general— ausencia de respuestas a la pregunta: ¿se puede medir de mejor manera lo que se quiere medir? Por ejemplo, en presencia de alguno de los indicadores de mayor uso actual para la ordenación de países o regiones (por ejemplo, el índice de desarrollo humano de la Organización de las Naciones Unidas), resulta difícil determinar si alguna modificación al valor del coeficiente de uno de los indicadores componentes mejora o empeora la descripción que el índice compuesto resultante hace del fenómeno en cuestión. En mi opinión, es claro que se requiere desarrollar la capacidad para medir, además, qué tan bien se mide lo que se desea medir.

La naturaleza multidimensional de los aspectos que se busca conocer trae consigo la dificultad adicional de comunicar los resultados alcanzados. Por esta razón se ha recurrido a procedimientos simples y fáciles de explicar. Por ello, llama la atención que el esfuerzo pionero del CONAPO (iniciado durante la primera mitad de la década de los 90 y basado en metodologías no tradicionales) haya encontrado buena aceptación y amplia aplicación. En efecto, el uso del análisis de componentes principales (ACP)

como parte de la metodología permitió incorporar al análisis la covariabilidad de los indicadores utilizados, como lo exige un tratamiento formal del análisis de fenómenos multidimensionales o multivariados.

En relación con el análisis de componentes principales, la Organización para la Cooperación y el Desarrollo Económicos (OCDE) publicó en el 2005 un manual¹ para apoyar la elaboración de indicadores compuestos en el que se refiere al uso de esta técnica. Entre sus fortalezas, destaca su capacidad de resumir un conjunto de indicadores básicos en tanto se preserva la proporción máxima posible de la variación total en el archivo de datos original. Indica que las mayores ponderaciones son asignadas a los indicadores básicos que muestran la mayor variación entre países y destaca que ésta es una propiedad deseable para realizar comparaciones entre naciones, ya que los indicadores básicos que son parecidos entre ellas carecen de interés, pues no pueden explicar las diferencias en desempeño. En contrapartida, los autores del manual señalan entre las debilidades del método que las correlaciones no representan necesariamente la influencia real de los indicadores básicos en el fenómeno que está siendo medido; del mismo modo, indican que es sensible a modificaciones en los datos, así como a la presencia de observaciones aberrantes que pueden introducir variabilidad espuria.

Ya que a lo largo del texto se hará referencia a técnicas multivariadas de conglomeración (o clasificación o estratificación), conviene recordar otros esfuerzos encaminados a establecer clasificaciones socioeconómicas de áreas geográficas en México, desde el nivel de área geoestadística básica (AGEB) hasta el de entidad federativa. El Instituto Nacional de Estadística y Geografía (INEGI) desarrolló uno que, en sus orígenes, fue denominado *niveles de bienestar*; más adelante, el nombre fue cambiado por el de *regiones socioeconómicas de México* y es éste por el que aún se le identifica en el sitio de Internet del Instituto. Aunque este enfoque recono-

¹ Nardo, M.; Saisana, M.; Saltelli, A.; Tarantola, S.; Hoffman, A.; Giovannini, E. (2005). *Handbook on Constructing Composite Indicators: Methodology and User Guide*. OECD Statistics Working Paper, recuperado en: [www.oilis.oecd.org/olis/2005doc.nsf/LinkTo/NT00002E4E/\\$FILE/JT00188147.PDF](http://www.oilis.oecd.org/olis/2005doc.nsf/LinkTo/NT00002E4E/$FILE/JT00188147.PDF)

ce la naturaleza multidimensional del bienestar al incorporar un número importante de indicadores, el procedimiento estadístico de clasificación al que recurre (conocido como *k*-medias) basa la clasificación de una unidad en la distancia euclidiana entre ésta y los centroides de los conglomerados², en otras palabras, no aprovecha la información relativa a las correlaciones entre los indicadores utilizados.

Al respecto, el ya citado manual de la OCDE señala que el análisis de conglomerados es otra herramienta para clasificar grandes cantidades de información en conjuntos más tratables, y ha sido también usado en el desarrollo de indicadores compuestos para agrupar información sobre países basada en su semejanza con base en diferentes indicadores básicos; además, sirve como: a) un método meramente estadístico de agregación de los indicadores; b) una herramienta de diagnóstico para explorar el impacto del uso de diversas metodologías durante la fase de construcción del indicador compuesto; c) un método para la disseminación de información sobre el indicador compuesto, sin perder la que se refiere a las dimensiones de los indicadores básicos y d) un método para seleccionar grupos de países para imputar datos faltantes con el propósito de reducir la varianza de los valores imputados.

El transcurso de casi dos décadas desde la aparición del primero de los estudios sobre el tema, así como la inminente realización del Censo de Población y Vivienda 2010, hacen necesaria la evaluación de la metodología y de sus resultados con el fin de elaborar una propuesta que incorpore desarrollos recientes y ayude a mejorar los efectos de su aplicación. Parece conveniente, en vista de lo que ya ha sido comentado, tomar como punto de partida en esta tarea la propuesta metodológica original. De este modo, la siguiente sección se ocupa de la descripción de la metodología hasta ahora utilizada; concluye con una visión crítica que pretende destacar algunos aspectos que, a nuestro juicio, merecen especial atención. La segunda sección plantea una metodología alternativa que atiende las limitaciones identificadas. Ambas son

² http://en.wikipedia.org/wiki/K-means_clustering#Standard_algorithm

comparadas haciendo uso de la base de datos municipal que el CONAPO tiene disponible en su sitio de Internet, para el ejercicio del 2005. Los resultados numéricos se muestran en la tercera sección.

Cuando el número de variables es grande o se piensa que algunas de éstas no contribuyen a identificar la estructura de los conglomerados en el conjunto de datos, es posible llevar a cabo, de forma secuencial, la aplicación de modelos continuos y discretos; por ejemplo, diversos investigadores han realizado primero un análisis de componentes principales y, después, un algoritmo de conglomeración, usando los valores de las primeras componentes, lo que se ha dado en llamar *análisis en tándem*. Algunos de los resultados numéricos presentados en este trabajo se obtienen haciendo uso de este tipo de análisis, ya que se pretende hacer un esfuerzo por reducir la dimensión del problema en nuestra búsqueda por identificar una solución óptima. En consecuencia, se hace necesario proponer una medida que permita discernir cuáles son las mejores opciones; de esto se ocupa la cuarta sección.

A lo largo del documento, el uso de las metodologías discutidas será ejemplificado mediante su aplicación a la base de datos por municipio utilizada por el CONAPO.³ Mediante la aplicación del criterio desarrollado, se evalúa cada una de las alternativas de donde se pueden alcanzar algunas conclusiones y elaborar propuestas. Es posible destacar aquí tres resultados para estos datos:

- El valor más pequeño (y, en consecuencia, la peor clasificación para los municipios, según el criterio propuesto) se obtiene para la publicada por el CONAPO en el 2006.
- Las clasificaciones obtenidas haciendo uso, por un lado, de los nueve indicadores básicos y, por el otro, de las nueve componentes principales de su matriz de covarianzas son idénticas. Esto parecería indicar que no hay pérdida de información al pasar de uno a otro conjunto.

³ CONAPO. (2006). *Índices de marginación, 2005*. México, DF, recuperado en www.conapo.gob.mx/index.php?option=com_content&view=article&id=126&Itemid=204

- Sin embargo, la clasificación con la que se alcanza el mayor valor del criterio presentado y, en consecuencia, la óptima, es la obtenida haciendo uso sólo de las primeras dos componentes principales de la matriz de covarianzas. Esto parecería indicar que la reducción de dimensiones es útil, y que tanto las redundancias mostradas por el conjunto original de datos como el ruido que éstos contienen han sido tomados en cuenta de manera adecuada y eliminados para los fines de clasificación planteados.

Para la elaboración de esta nota, se ha decidido concentrarse en los aspectos meramente técnicos de los procedimientos de conglomeración. Las discusiones de carácter conceptual relativas a la conveniencia de incluir o no alguno de los temas o de los indicadores usados, o de la mayor influencia de uno en particular sobre resultados alcanzados pertenecen a trabajos de otra naturaleza. Con mayor razón, las implicaciones sociales, programáticas o presupuestales quedan fuera de los alcances de esta discusión, cuyo propósito principal es señalar y corregir las limitaciones de los procedimientos en uso.

Índice de marginación

De acuerdo con lo que señalan diversas publicaciones del CONAPO el "...índice de marginación es una medida-resumen que permite diferenciar entidades federativas y municipios según el impacto global de las carencias que padece la población, como resultado de la falta de acceso a la educación, la residencia en viviendas inadecuadas, la percepción de ingresos monetarios insuficientes y las relacionadas con la residencia en localidades pequeñas.

"Así, el índice de marginación considera cuatro dimensiones estructurales de la marginación; identifica nueve formas de exclusión y mide su intensidad espacial como porcentaje de la población que no participa del disfrute de bienes y servicios esenciales para el desarrollo de sus capacidades básicas.

En el esquema 1.1 pueden verse las nueve formas de exclusión social de origen estructural que capta el índice de marginación, así como los indicadores utilizados.

"Es importante señalar que para la estimación del índice de marginación se utilizaron como fuentes de información los resultados definitivos del II Censo de Población y Vivienda 2005 y la Encuesta Nacional de Ocupación y Empleo (ENOE) correspondiente al cuarto trimestre del mismo año. El Censo permite medir ocho de los nueve indicadores que integran el índice de marginación para las 32 entidades federativas y los 2 454 municipios del país existentes en el 2005, mientras que la ENOE proporciona la información sobre el nivel de ingresos de la población ocupada en las entidades federativas, a partir de la cual se estimó el indicador correspondiente a nivel municipal. Con ello se busca mantener al máximo la integridad del marco conceptual, las dimensiones, formas de exclusión e indicadores de los índices de marginación estimados por el CONAPO con base en los datos de los censos generales de Población y Vivienda de 1990 y 2000."

La metodología estadística detrás del ejercicio *índice de marginación* del CONAPO, según se desprende del *Anexo C. Metodología de estimación del índice de marginación*, incluido en la citada publicación del 2006, tiene como objetivo el siguiente:

"Se busca generar un índice de marginación que **evalúe el impacto global de las carencias** y que cumpla, además, con ciertas características que faciliten el análisis de la expresión territorial de la marginación:

1. **Reduzca la dimensionalidad original** y, al mismo tiempo, **retenga y refleje al máximo posible la información referida a la dispersión de los datos** en cada uno de los nueve indicadores, así como las relaciones entre ellos, y
2. **Permita establecer una ordenación** entre las unidades de observación: estados, municipios o localidades."

Esquema conceptual de la marginación^a

Concepto	Dimensiones socioeconómicas	Formas de exclusión	Indicadores para medir la intensidad de la exclusión	Índice de marginación
<p>Marginación: fenómeno estructural múltiple que valora dimensiones, formas e intensidades de exclusión en el proceso de desarrollo y en el disfrute de sus beneficios.</p>	Educación	Analfabetismo.	1. Porcentaje de población de 15 años o más analfabeta (ANALF). ^b	Intensidad global de la marginación socioeconómica.
		Población sin primaria completa.	2. Porcentaje de población de 15 años o más sin primaria completa (PRIMINC).	
	Vivienda	Viviendas particulares sin agua entubada.	3. Porcentaje de ocupantes en viviendas particulares sin agua entubada (SINAGUA).	
		Viviendas particulares sin drenaje ni servicio sanitario exclusivo.	4. Porcentaje de ocupantes en viviendas particulares sin drenaje ni servicio sanitario exclusivo (SINDREN).	
		Viviendas particulares con piso de tierra.	5. Porcentaje de ocupantes en viviendas particulares con piso de tierra (PITIERR).	
		Viviendas particulares sin energía eléctrica.	6. Porcentaje de ocupantes en viviendas particulares sin energía eléctrica (SINELEC).	
		Viviendas particulares con algún nivel de hacinamiento.	7. Porcentaje de viviendas particulares con algún nivel de hacinamiento (HACINA).	
	Ingresos monetarios	Población ocupada que percibe hasta 2 salarios mínimos.	8. Porcentaje de población ocupada con ingresos de hasta 2 salarios mínimos (HASTA2).	
	Distribución de la población	Localidades con menos de 5 mil habitantes	9. Porcentaje de población en localidades con menos de 5 mil habitantes (MENOS5K).	

a CONAPO (2004). *Índice absoluto de marginación, 1990-2000*. México, DF, recuperado en www.conapo.gob.mx/index.php?option=com_content&view=article&id=300&Itemid=194

b Mnemónicos a ser usados en este artículo entre paréntesis.

Aunque la publicación mencionada no lo explica como tal, los sucesivos ejercicios para el estudio de la marginación han buscado satisfacer un objetivo complementario. En efecto, el índice de marginación obtenido es usado como insumo en un procedimiento univariado para la conglomeración de las unidades geográficas consideradas, del cual se dice que es óptimo.⁴ Los cinco estratos resultantes se denominan como de muy alto, alto, medio, bajo y muy bajo grado de marginación. Con frecuencia, la elaboración y aplicación de programas públicos (tanto federales como estatales) hacen referencia a esta conglomeración más que a los valores mismos del índice. Ejemplo de lo señalado lo representan los siguientes programas:

- Oportunidades. Opera a nivel nacional en más de 92 mil localidades de los municipios de mayor marginación, en áreas rurales, urbanas y grandes metrópolis.
- Programas regionales para zonas de alta marginación e indígenas.
- 3x1 para Migrantes. De acuerdo con la Secretaría de Desarrollo Social, impulsará 2 mil proyectos en el 2010 en las localidades más marginadas de México.
- Para la Adquisición de Activos Productivos para la Acuicultura y Pesca, de la Secretaría de Agricultura, Ganadería, Desarrollo Rural, Pesca y Alimentación.
- De centros deportivos municipales de muy alta marginación, del estado de Oaxaca.
- Convenio de Desarrollo Social y Humano (CODESOLH). A través de éste se canalizan recursos a los 37 municipios de muy alta y alta marginación en Michoacán de Ocampo.

Cada uno de los nueve porcentajes (indicadores del esquema 1.1) referidos arriba es calculado tomando en cuenta la población que no especificó encontrarse en la condición correspondiente. Tales cantidades son, además, estandarizadas lo que resulta de sustraer de cada uno de los valores el promedio nacional del indicador y de dividir la

anterior diferencia entre la desviación estándar del indicador. En otras palabras, se calcula:

$$Z_{ij} = \frac{I_{ij} - \bar{I}_j}{ds_j} \quad (1)$$

donde:

Z_{ij} = indicador estandarizado j ($j=1, \dots, 9$), de la unidad de observación i ($i=1, \dots, 32$, en el caso estatal o $i=1, \dots, 2442$, para el de los municipios en el 2000).

I_{ij} = indicador socioeconómico básico j (es decir, antes de ser estandarizado), de la unidad de análisis i .

\bar{I}_j = promedio aritmético de los valores del indicador j .

ds_j = desviación estándar insesgada del indicador socioeconómico j .

Los indicadores estandarizados así obtenidos representan el insumo para una rutina estadística que obtiene las denominadas componentes principales. Esto es equivalente a usar la matriz de correlaciones como insumo para el ACP, la cual es un arreglo que resume la información relativa a la correlación entre indicadores. En vista de la estandarización, la varianza de cada uno de los indicadores será igual a 1 por lo que en la diagonal de la matriz de correlaciones ese valor se repetirá tantas veces como indicadores estén siendo considerados. Como se verá adelante, el hecho de que los valores de las varianzas de todos los indicadores sean iguales (y, en este caso, iguales a 1) puede contradecir el propósito del ACP que, entre otras cosas, busca establecer la dirección de máxima desigualdad, en general identificada con la primera componente principal.

De este modo, el índice de marginación adquiere la forma de una combinación lineal de los indicadores estandarizados:

$$IM_i = \sum_{j=1}^9 a_j Z_{ij} \quad (2)$$

⁴ Procedimiento de Dalenius, óptimo en el sentido de mínimo coeficiente de variación en la estimación conglomerada del promedio de un indicador; en este caso, la primera componente principal.

donde:

- IM_i = valor del índice de marginación para una unidad geográfica i .
- j = subíndice que denota cada uno de los indicadores de marginación ($j=1,\dots,9$).
- a_j = ponderación que se asigna al j -ésimo indicador de marginación.
- Z_{ij} = valor estandarizado del j -ésimo indicador de marginación.

Los autores del documento afirman que el "...índice de marginación así calculado corresponde a la primera componente del ACP. Puede demostrarse que la primera componente es la combinación de las variables originales que *mejor resume, en un solo valor, la información del conjunto* de los nueve indicadores..."; para mayor precisión, vale la pena decir que la primera componente es la combinación de las variables cuya varianza es máxima. Se supone

que es en este sentido que se dice que es la que mejor resume, en un solo valor, la información del conjunto de los nueve indicadores. La aplicación de la anterior metodología será ejemplificada a partir de los datos del Censo 2005, así como de la ENOE del cuarto trimestre del mismo año, en que el CONAPO basó su índice de marginación municipal, 2005.⁵

El cuadro 2 muestra un resumen de los resultados de la aplicación del ACP a este conjunto de datos. Como podrá observarse, la *varianza* de la primera componente principal alcanza un valor apenas superior a 50% de la suma de las varianzas de los indicadores estandarizados, la que, en vista de la estandarización a que son sometidos los indicadores, coincide con el número de éstos.

⁵ www.conapo.gob.mx/index.php?option=com_content&view=article&id=126&Itemid=204

Cuadro 1

Correlaciones entre los nueve indicadores básicos

	ANALF	PRIMINC	SINDREN	SINELEC	SINAGUA	HACINA	PITIERR	MENOS5K	HASTA2
ANALF	1.000								
PRIMINC	0.871	1.000							
SINDREN	0.360	0.362	1.000						
SINELEC	0.434	0.417	0.301	1.000					
SINAGUA	0.436	0.404	0.206	0.507	1.000				
HACINA	0.663	0.572	0.336	0.378	0.398	1.000			
PITIERR	0.730	0.659	0.178	0.546	0.540	0.636	1.000		
MENOS5K	0.444	0.597	0.255	0.291	0.275	0.299	0.430	1.000	
HASTA2	0.677	0.736	0.232	0.286	0.320	0.657	0.627	0.593	1.000

Cálculos propios mediante Minitab usando archivo de datos encontrado el 20 de noviembre de 2009 en www.conapo.gob.mx/publicaciones/margina2005/AnexoB.xls

Cuadro 2

Valores propios de la matriz de correlaciones

Eigenvalor	Proporción	Acumulada
4.8556	54.0%	54.0%
1.0356	11.5%	65.5%
0.8973	10.0%	75.4%
0.7274	8.1%	83.5%
0.4880	5.4%	88.9%
0.4258	4.7%	93.7%
0.2595	2.9%	96.5%
0.2169	2.4%	99.0%
0.0938	1.0%	100.0%
Total = 9.0000		

Cálculos propios mediante Minitab usando archivo de datos encontrado el 20 de noviembre de 2009 en www.conapo.gob.mx/publicaciones/margina2005/AnexoB.xls

Aun cuando, en efecto, dicha componente principal representa el “mejor resumen *individual* de la información del conjunto de los nueve indicadores”, conviene preguntarse si tal resumen es suficientemente adecuado para los propósitos planteados; por ejemplo, es necesario considerar a las tres primeras componentes principales para lograr una explicación de la *variabilidad total* (suma de las varianzas de los indicadores insumo del ACP) superior a 75%, o hasta 6, para rebasar 90 por ciento.

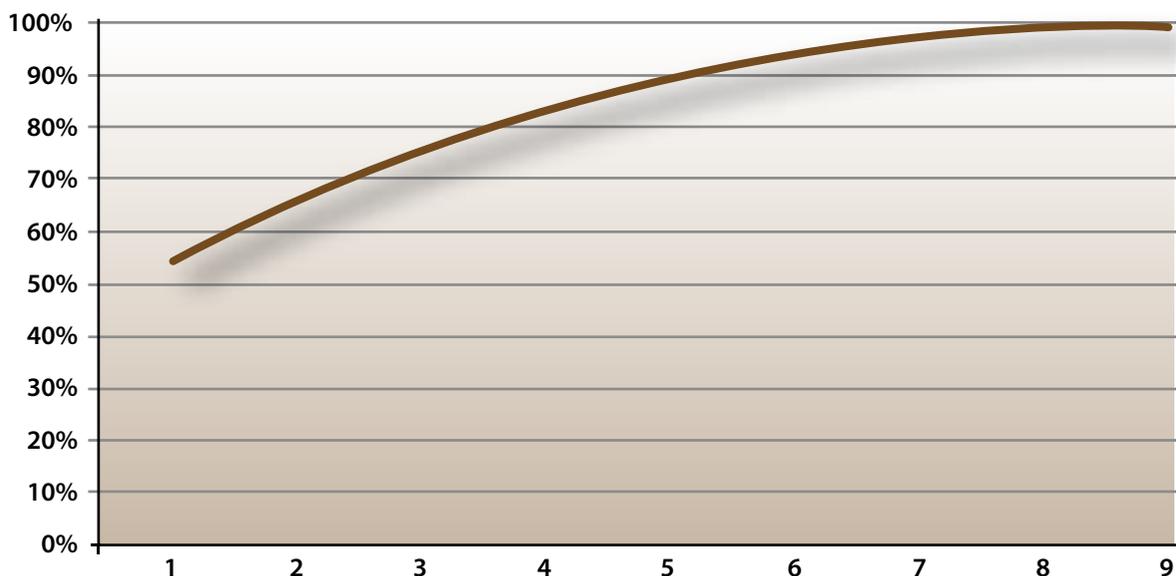
El anterior resumen puede ser representado como se muestra en la gráfica 1. Si bien es clara la desproporción del valor del mayor valor propio o

característico respecto al de cada uno de los otros, la suma de éstos casi iguala al de aquél. En otras palabras (y en términos de lo que en este contexto se entiende como explicación), basar cualesquiera conclusiones exclusivamente en la primera componente principal equivale a ignorar casi tanta información como la que se está aprovechando.

El tamaño de los estratos obtenidos por el CONAPO de acuerdo con su nivel de marginación se muestra en el cuadro 3. Vale la pena destacar que los municipios con alto y muy alto grado de marginación totalizan 1 251, es decir, casi 50% de los 2 454 considerados.

Gráfica 1

Valor acumulado de los valores propios obtenidos a partir del análisis de componentes principales de la matriz de correlaciones de los nueve indicadores básicos



Cálculos propios mediante Minitab usando archivo de datos encontrado el 20 de noviembre de 2009 en www.conapo.gob.mx/publicaciones/margina2005/AnexoB.xls

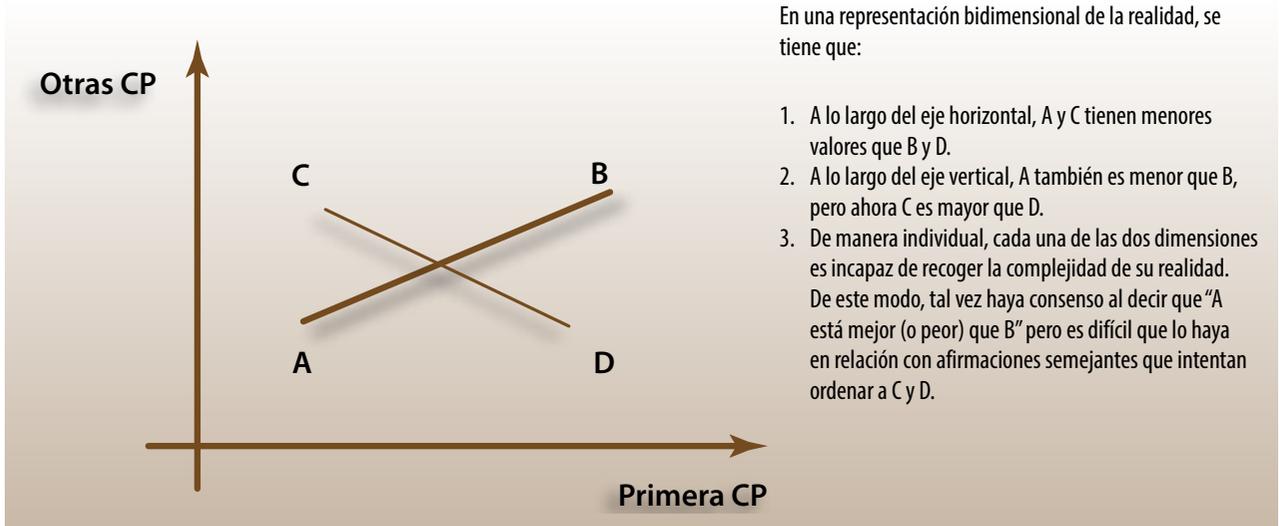
Cuadro 3

Tamaño de los estratos

Grado de marginación	Número de municipios
Muy bajo	279
Bajo	423
Medio	501
Alto	886
Muy alto	365

Cálculos propios mediante Minitab usando archivo de datos encontrado el 20 de noviembre de 2009 en www.conapo.gob.mx/publicaciones/margina2005/AnexoB.xls

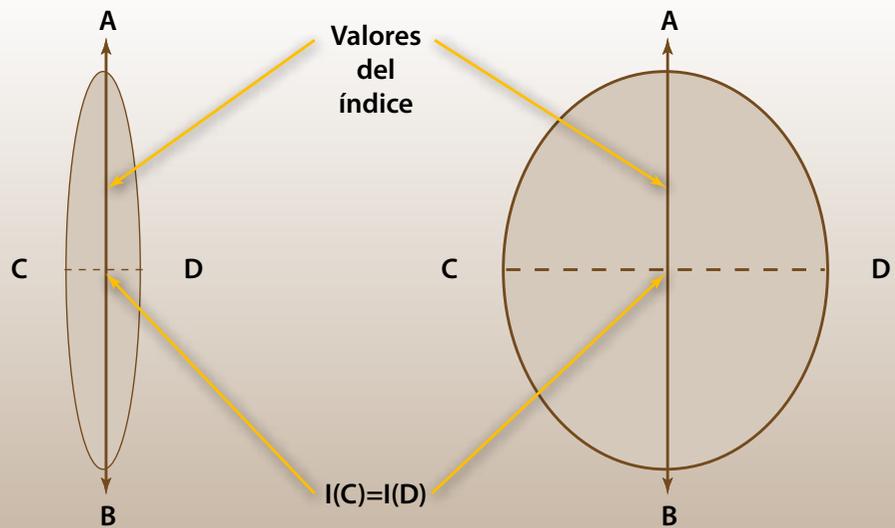
Ordenar lo que no es ordenable



Gráfica 3

Igualar lo diferente

El índice compuesto $I(X)$ iguala realidades diversas ya que les asigna iguales valores del índice. En las figuras, aunque las unidades C y D son diferentes, se tiene que $I(C)=I(D)$. En el lado izquierdo, pues la primera CP explica una proporción sustancial de la variabilidad total, el error cometido es menor. En cambio, en el lado derecho son *igualadas* por el índice a pesar de que su mutua distancia es del mismo orden de magnitud de la que hay entre A y B, a las que se considera diferentes sólo por encontrarse a lo largo del eje vertical.



Discusión crítica del procedimiento

La presente sección muestra una breve discusión de asuntos que, a nuestro juicio, deben ser tratados con mayor profundidad, pues afectan de manera significativa a los resultados obtenidos y, en consecuencia, pueden contribuir a que las políticas basadas en los mismos no abarque a la totalidad de los individuos a los que van dirigidas. Los temas que serán considerados son:

1. Uso de la primera componente principal solamente.
2. Uso de la matriz de correlaciones.
3. Uso del índice con fines de conglomeración.

Las dos primeras hablan de una limitada eficiencia del uso que se hace de la información disponible, la tercera (consecuencia de las anteriores) debe, también, mostrar un resultado inferior al óptimo por razones obvias.

Uso de la matriz de correlaciones

A nuestro juicio, el procedimiento lleva a cabo una doble e innecesaria estandarización. Los autores del documento explican sus motivos de la siguiente manera: "Aunque el recorrido de las nueve variables está acotado por la izquierda y la derecha, es necesario transformar las variables de tal manera que aquellas con **una mayor varianza** no predominen en la determinación del índice y vuelvan inoperante el análisis multivariado. Con el fin de eliminar los **efectos de escala** entre las variables, éstas se estandarizaron mediante el promedio aritmético y la desviación estándar de cada uno de los niveles de análisis (estados y municipios)...", según se muestra en la expresión (1).

En efecto, los índices básicos usados son expresados en porcentajes (de población, ocupantes o viviendas) por lo que las unidades originales (el efecto de escala, por ejemplo, centenares, millares o decenas de miles de personas o viviendas) ya no son un factor de preocupación en cuanto a la influencia indebida que puedan representar para el valor del índice. Es por esta razón que no resulta claro el porqué de volver a eliminar las unidades originales mediante su estandarización para llegar a las Z_{ij} . Si la única consecuencia de la anterior observación fuera sólo la crítica por excesiva cautela, no habría motivo de preocupación. Sin embargo, el propósito del análisis de componentes principales, que es el de *señalar direcciones de máxima varianza*, se pierde con esta estandarización, ya que se *esferiza* el problema de manera innecesaria. Pero, lo que es peor, al mismo tiempo se ocultan las inequidades, es decir, el objetivo principal del estudio.

Uso del índice con fines de conglomeración

Los métodos de conglomeración buscan conjuntar unidades lo más parecidas (homogéneas) entre sí. Los estratos homogéneos se forman a partir de los valores de una o más variables medidas en cada una de las unidades. El CONAPO usa las nueve variables de manera indirecta al conglomerar usando

sólo el valor del índice de marginación, en el cual se da, en todo caso, la homogeneidad. Sin embargo, cabe preguntarse si los estratos son similares en términos de los mismos nueve indicadores básicos.

Esta situación se ilustra en la gráfica 4, la cual muestra que los cinco estratos definidos por el CONAPO incluyen municipios con 0 y 100% de pobladores en localidades con menos de 5 mil habitantes. La desviación estándar poblacional para el indicador es igual a 34.713, los valores correspondientes a cuatro estratos se encuentran entre 22 y 33, la de un quinto está cerca de 11; en otras palabras, en términos de este indicador la conglomeración no logra su cometido.

Consecuencias

El procedimiento según ha sido descrito es tal que:

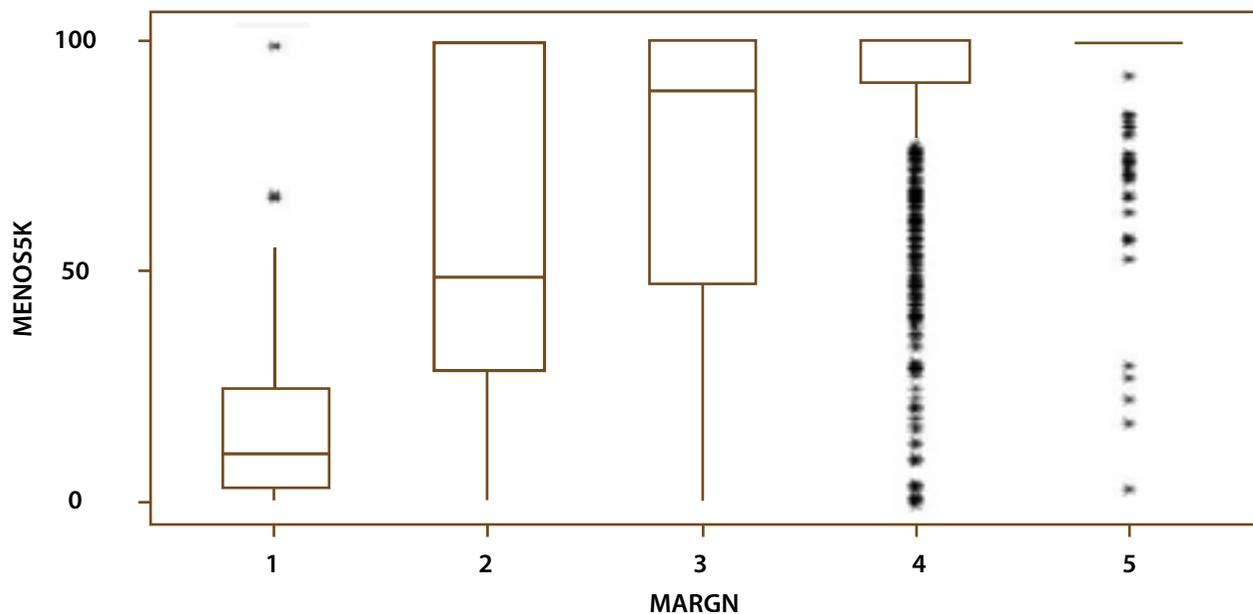
1. El orden es incierto.
2. Reduce la dimensión del problema, pero pierde información significativa sobre la dispersión de los indicadores y las relaciones entre éstos.
3. Y lo que es más importante, no resulta en estratos homogéneos en términos de todos los indicadores básicos.

Ya que la conglomeración es la base de numerosas políticas públicas dirigidas sobre todo a municipios y localidades con *alta y muy alta marginación*, existe el riesgo de que una clasificación inadecuada pueda evitar que recursos y apoyos necesarios alcancen a los sujetos de éstas.

Propuesta

A nuestro juicio, el problema multivariado de ordenamiento de unidades no tiene una solución satisfactoria, salvo cuando la primera CP *explica* una proporción sustancial de la variabilidad total. Por lo anterior, se sugiere atender el de conglomeración de la manera más adecuada:

Boxplots para el porcentaje de población en localidades con menos de 5 mil habitantes



Cálculos propios mediante Minitab usando archivo de datos encontrado el 20 de noviembre de 2009 en www.conapo.gob.mx/publicaciones/margina2005/AnexoB.xls

1. En primer lugar, se calculan las componentes principales basadas en la matriz de covarianzas, es decir, en los indicadores no estandarizados. De este modo, la estructura de covarianzas entre ellos habrá sido aprovechada y se evita la *esferización* del problema.
2. Enseguida, usando un procedimiento multivariado de conglomeración (k -medias), se clasifican las unidades de la población con base en los valores de las componentes. Para este fin, se procederá de manera incremental partiendo de una clasificación inicial que considera sólo la primera componente; la segunda toma en cuenta tanto a la primera como la segunda; la tercera, a las primeras tres y así sucesivamente hasta llegar a la que considera a todas las componentes principales.
3. Las clasificaciones alternativas son comparadas con base en un criterio a ser introducido y cuyo valor máximo determinará la clasificación formada por estratos internamente más homogéneos y, en consecuencia, la que ha conseguido unir a los parecidos y separar a los diferentes.

El uso de las componentes principales con fines de clasificación tiene tres motivaciones principales:

- El procedimiento de las k -medias (entre los de más sencilla utilización) ha sido criticado porque no aprovecha la estructura de correlación de los indicadores básicos. Su aplicación a las componentes principales resuelve de forma parcial esta crítica. En efecto, por construcción, las componentes principales no están correlacionadas, razón por la cual se prestan de mejor manera a la aplicación del mencionado método.
- La redundancia entre indicadores, implicada por sus correlaciones, hace temer que una clasificación pueda verse indebidamente influenciada por alguna de las dimensiones, en detrimento de las restantes. Tal redundancia es tomada en cuenta por el ACP y no está presente entre las componentes.
- La variabilidad residual explicada por las últimas componentes puede ser ignorada, dando lugar a una reducción de la dimensionalidad.

Propuesta de criterio resumen para evaluar conglomeraciones

Conglomeración

Sea Ω un universo formado por N individuos o unidades, es decir, $\Omega = \{u_1, u_2, \dots, u_N\}$. Una conglomeración multivariada S representa una partición de Ω , elaborada a partir de k mediciones realizadas en cada una de las unidades u_1, u_2, \dots, u_N (o k indicadores básicos) de modo que el universo es descompuesto en h clases o estratos disjuntos S_1, S_2, \dots, S_h (es decir, la conglomeración es excluyente, pues una unidad es clasificada sólo en uno de los estratos); en otras

palabras, se tiene que $\Omega = \sum_{l=1}^h S_l$. En consecuen-

cia, si N_l representa el número de unidades que componen el estrato S_l , $l=1, \dots, h$, y N denota el tamaño de la población, debe tenerse que $N = N_1 + N_2 + \dots + N_h$. En este caso, se dice que la conglomeración es también exhaustiva.

Bajo las anteriores circunstancias, es claro que aún es posible determinar un gran número⁶ de conglomeraciones alternativas. Según los fines para los que se realiza la conglomeración, algunas de ellas serán más favorables que otras, pero se hace necesario estar en condiciones de medir o evaluar cuando éste sea el caso.

Medida de homogeneidad

Como ya se indicó, el propósito más importante de los métodos de conglomeración consiste en formar estratos que sean tan homogéneos de manera interna como sea posible en términos de los valores de los indicadores considerados. Una comparación entre conglomeraciones diferentes puede basarse en resúmenes de la desigualdad para cada uno de los indicadores según cada conglomeración, definidas en la expresión (3) y los que serán denominados índices de desigualdad por indicador.

⁶ h^N cuando se permite que $N_l = 0$, para uno o más valores de l .

$$v_j^2(S) = \sum_{l=1}^h \left(\frac{N_l}{N}\right)^2 v_j^2(S_l), j=1, \dots, k; \quad (3)$$

donde:

$$v_j^2(S_l) = \frac{1}{N_l(N_l-1)} \sum_{i=1}^{N_l} (I_{i,j,l} - \bar{I}_{j,l})^2, l=1, \dots, h, \text{ es directa-}$$

mente proporcional al valor de la varianza del j -ésimo indicador básico al interior de la l -ésima clase e inversamente proporcional al número de unidades que la componen, tal como ocurre con la varianza del estimador del promedio dentro del estrato.

De este modo, una clase cuyas unidades muestran gran desigualdad en los valores del indicador correspondiente y cuyo tamaño es grande, contribuirá con un valor igualmente grande al anterior criterio, alejándose del propósito de definir clases formadas por unidades homogéneas. Así, valores pequeños de la medida indicarán una mejor conglomeración en vista de su mayor homogeneidad en términos del indicador al interior de las clases. En vista de que el número de unidades en la población es fijo, es claro que serán preferibles estratos muy heterogéneos pero poco numerosos, o numerosos pero homogéneos.

Cuando los k valores definidos en la expresión (3) para una conglomeración sean todos menores que los obtenidos para otra, se dirá que la primera es más favorable que la segunda. Sin embargo, las ganancias y las pérdidas que resultan de considerar conglomeraciones alternativas (en términos de homogeneidad de las unidades al interior de los estratos) son de sentido y magnitud diversos para los indicadores básicos, por lo que se hace difícil determinar una ganadora.

$$\begin{aligned} \sum_{l=1}^h \sum_{i=1}^{N_l} (I_{ijl} - \bar{I}_j)^2 &= \sum_{l=1}^h N_l (\bar{I}_{jl} - \bar{I}_j)^2 + \sum_{l=1}^h \sum_{i=1}^{N_l} (I_{ijl} - \bar{I}_{jl})^2 \Rightarrow \\ \Rightarrow v_j^2 &= \frac{1}{N} \sigma_j^2 = \frac{1}{N(N-1)} \sum_{l=1}^h \sum_{i=1}^{N_l} (I_{ijl} - \bar{I}_j)^2 = \\ &= \frac{1}{N(N-1)} \sum_{l=1}^h N_l (\bar{I}_{jl} - \bar{I}_j)^2 + \sum_{l=1}^h \frac{N_l(N_l-1)}{N(N-1)} \sum_{i=1}^{N_l} \frac{(I_{ijl} - \bar{I}_{jl})^2}{N_l(N_l-1)} = \\ &= \frac{1}{N(N-1)} \sum_{l=1}^h N_l (\bar{I}_{jl} - \bar{I}_j)^2 + \sum_{l=1}^h \frac{N_l(N_l-1)}{N(N-1)} v_j^2(S_l) \end{aligned} \quad (4)$$

donde:

I_{ijl} representa el valor del j -ésimo indicador para la i -ésima unidad en el l -ésimo estrato; \bar{I}_{jl} , al promedio del propio indicador dentro del mismo estrato; e \bar{I}_j , a su promedio poblacional.

Lo anterior obliga a buscar medidas que permitan evaluar de forma global los resultados alcanzados y que conduzcan a sugerir el uso de una u otra conglomeración. Jarque (1981)⁷ propuso una medida para obtener conglomeraciones multivariadas óptimas en el muestreo.

Un criterio semejante adecuado al presente contexto se obtiene a partir de la consideración de la expresión (4) hace uso de una descomposición de la suma de cuadrados de la distancia entre el valor del indicador para cada unidad y el de su promedio poblacional; en otras palabras, de un resumen de la heterogeneidad del indicador en la población. El lado izquierdo de la anterior expresión es proporcional a la varianza poblacional del i -ésimo indicador. Por su parte, el segundo término del lado derecho representa una suma ponderada, de acuerdo con el tamaño de cada estrato, de las varianzas del mismo indicador, pero esta vez dentro de cada estrato.

⁷ Jarque, C. M. (1981). *A Solution to the Problem of Optimum Stratification in Multivariate Sampling*. Series C (Applied Statistics). JRSS, 30 (2), 163-169, en www.jstor.org/stable/2346387.

Cuando la conglomeración multivariada no consigue formar grupos notoriamente diferentes para alguno de los indicadores, puede tenerse que la suma de cuadrados que involucra tanto a \bar{I}_{jl} como a \bar{I}_j tome valores pequeños. Ello traería como consecuencia que algunas de las varianzas dentro de los estratos tengan órdenes de magnitud similares a los de la varianza poblacional, es decir, $v_j^2 \approx v_j^2(S)$. En el otro extremo, cuando la conglomeración es exitosa para alguno de los indicadores, debe tenerse que las varianzas dentro de todos los estratos toman valores pequeños en relación con la varianza poblacional y, en consecuencia, lo mismo ocurre con la suma ponderada.

En general, se puede obtener una buena aproximación a la expresión (4), haciendo uso de la (3), como se muestra en la (5).

$$\begin{aligned} v_j^2 &\approx \frac{1}{N^2} \sum_{l=1}^h N_l (\bar{I}_{jl} - \bar{I}_j)^2 + \sum_{l=1}^h \frac{N_l^2}{N^2} v_j^2(S_l) \\ &= \frac{1}{N^2} \sum_{l=1}^h N_l (\bar{I}_{jl} - \bar{I}_j)^2 + v_j^2(S) \end{aligned} \quad (5)$$

Por lo anterior, con fines de comparación, se hará uso de la expresión (6).

$$H(S) = \sum_{j=1}^k \frac{v_j^2}{v_j^2(S)} \quad (6)$$

Ya que el valor de v_j^2 representa la cota máxima para el de $v_j^2(S)$, el valor del criterio debe ser mayor para estratos homogéneos por lo que se preferirá aquella conglomeración que proporcione el valor máximo. La medida a maximizar puede, además, ser expresada en términos de lo que se denominan precisiones:

$$H(S) = \sum_{j=1}^k \frac{v_j^2}{v_j^2(S)} = \sum_{j=1}^k \frac{1/v_j^2(S)}{1/v_j^2} = \sum_{j=1}^k \frac{P_j(S)}{P_j} \quad (7)$$

En concordancia con lo antes señalado, la mínima precisión se alcanza cuando el cálculo de la varianza no considera ninguna conglomeración. La conglomeración multivariada no debe hacer peor el valor de la precisión para ninguno de los indicadores básicos. Por lo anterior, el valor de la medida será siempre mayor o igual al número de indicadores.

Según ha sido descrita, la medida propuesta no toma en cuenta la estructura de correlación exhibida por los indicadores utilizados. Sin embargo, ha sido preferida ya que, para su cálculo, la medida requiere sólo de los resultados que aporta cualquier paquete estadístico comercial.

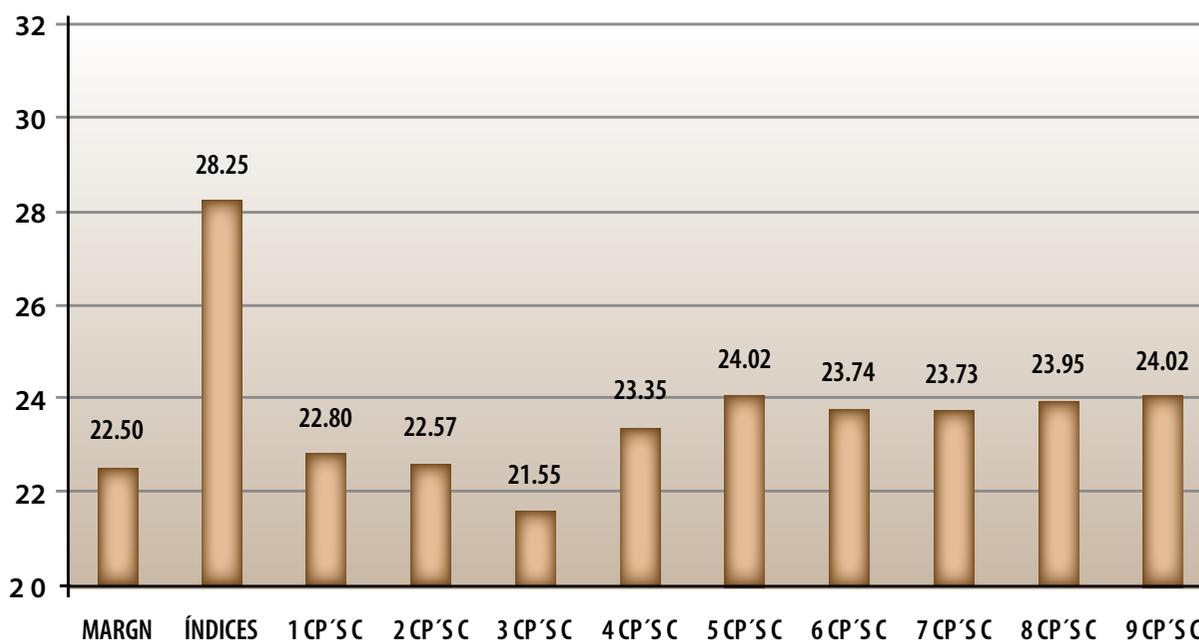
Ejemplo numérico

Con el doble fin de comparar resultados y aclarar la contribución de cada uno de los cambios sugeridos, se seguirá una estrategia incremental:

1. En primer lugar, se comparará el resultado de conglomerar tal cual fue obtenido por el CONAPO (MARGN) con el de usar **dos o más de las componentes principales** obtenidas a partir del uso de **indicadores estandarizados**; es decir, de la **matriz de correlaciones** (denotadas mediante nCP C). De forma adicional, se incluye el resultado de hacer uso de los nueve indicadores básicos contemplados (INDICES).
2. Por último, y con el fin de probar la posibilidad de reducir la dimensión del problema, se hará uso de **subconjuntos crecientes de las componentes principales** calculadas usando **indicadores sin estandarizar** o, lo que es lo mismo, la **matriz de covarianzas** (identificadas como nCP V).

Gráfica 5

Criterio resumen usando matriz de correlaciones



Cálculos propios mediante Minitab usando archivo de datos encontrado el 20 de noviembre de 2009 en www.conapo.gob.mx/publicaciones/margina2005/AnexoB.xls

Todas las clasificaciones obtenidas en los incisos anteriores son comparadas con base en el criterio introducido en la expresión (6). Este proceso permitirá ordenar clasificaciones alternativas y determinar la que conduce al mejor resultado.

Componentes principales a partir de la matriz de correlaciones

En esta instancia se mantienen como base de todos los cálculos los indicadores estandarizados pero, a diferencia del ejercicio llevado a cabo por el CONAPO, se obtienen conglomeraciones multivariadas partiendo de la aplicación del procedimiento de las k -medias a subconjuntos crecientes de las nueve componentes principales: en el lugar inicial, sólo la primera (1CP C); en segundo, la primera y la segunda (2CP C); en tercero, de la primera a la tercera (3CP C) y así sucesivamente hasta la que las considera a todas (9CP C). Se evalúa, también, la clasificación que usa los nueve indicadores básicos sin estandarizar ni tomar en cuenta las correlaciones existentes entre ellos (INDICES).

La gráfica 5 presenta los valores de $H(S)$ correspondientes a cada una de las 11 clasificaciones anteriores. A partir de tales valores se observa, en primer lugar, que las dos clasificaciones que se basan sólo en la primera componente muestran grados de homogeneidad similares, a pesar de ser obtenidas por el procedimiento de Dalenius, en un caso y por el de las k -medias, en el otro.

También, es notable y extraño el deterioro en el valor del criterio al pasar de una a tres CP, aunque se incorpora de forma gradual más información, así como su posterior mejoría al incluir CP adicionales. Se destaca, asimismo, la también cercana coincidencia de las conglomeraciones que usan cinco, ocho y nueve componentes.

De hecho, estas últimas conglomeraciones son las que resultan mejor calificadas de entre todas las que usan componentes de la matriz de correlaciones. A pesar de todo lo anterior, la mejor calificada de las mostradas en la referida gráfica es la que

recurre a los nueve indicadores sin estandarizar ni tomar en cuenta su estructura de correlación. De lo anterior se concluye que, con fines de estratificación, no se hace uso eficiente de la información disponible ni incluyendo todas las componentes principales, cuando se les calcula como combinaciones lineales de las versiones estandarizadas de los indicadores y cuyos coeficientes se obtienen del análisis espectral de la matriz de correlaciones.

Componentes principales a partir de la matriz de covarianzas

Enseguida, se aplica la metodología propuesta al mismo conjunto de datos: a) calcular las componentes principales a partir de la matriz de covarianzas y b) usar un procedimiento multivariado de conglomeración (k -medias) para ser aplicado a una o más de estas componentes principales. De resultar exitosa la estrategia, se alcanzaría el fin original y principal del CONAPO de **evaluar el impacto global de las carencias** a la vez que, por un lado, **se reduce el número original de dimensiones** y, por el otro, **se retiene y refleja al máximo posible la información referida a la dispersión de los datos**. Sin embargo, dicho propósito no se alcanzaría a través del medio establecido, es decir, de un único índice de marginación.

El ACP a partir de los indicadores básicos no estandarizados puede ser resumido en el cuadro 4. En este caso se observa que la primera componente principal aporta una explicación ligeramente mayor a la obtenida usando los indicadores estandarizados y que la suma de las dos primeras representa más de tres cuartas partes del mencionado total. Gracias a lo anterior, basta con cuatro componentes para rebasar 90% del total y la aportación de las cuatro últimas es menos significativa que las correspondientes calculadas a partir de la matriz de correlaciones.

Con base en los valores que toma cada una de las componentes principales en los elementos de la población de municipios, se obtuvieron nue-

Valores propios de la matriz de covarianzas

Valores propios	Proporción	Acumulada
1 846.1	58.20%	58.20%
583.1	18.40%	76.60%
265.5	8.40%	85.00%
168.6	5.30%	90.30%
119.9	3.80%	94.10%
80.5	2.50%	96.60%
55.6	1.80%	98.40%
36.8	1.20%	99.50%
14.7	0.50%	100.00%
Total = 3 170.8		

Cálculos propios mediante Minitab usando archivo de datos encontrado el 20 de noviembre de 2009 en www.conapo.gob.mx/publicaciones/margina2005/AnexoB.xls

ve clasificaciones adicionales para los municipios mexicanos. La gráfica 6 muestra los valores de $H(S)$ para 12 conglomeraciones diferentes: por un lado las ya comentadas MARGN, INDICES y las 9CP C, y por el otro las nueve que resultan al usar conjuntos crecientes de componentes principales, las que serán denotadas por 1CP V, 2CP V, ..., 9CP V, en notación similar a la usada antes.

La información resumida en la gráfica deja claro que las conglomeraciones basadas en el uso de una sola componente principal, sea ésta calculada a partir de la matriz de correlaciones o de la de covarianzas, resultan ser las peor clasificadas de acuerdo con el criterio utilizado. Más aún, aunque los resultados parecen mejorar de forma ligera, el uso de todas las componentes principales de la matriz de correlaciones también muestra un comportamiento deficiente.

Por otro lado, llama la atención que la implementación de Minitab para el algoritmo de las k -medias conduce a la misma conglomeración tanto cuando se usan los nueve indicadores básicos como cuando se emplean las nueve componentes principales. Lo anterior podría llevar a la conclusión de que no es necesario hacer nada más pues, al hacer uso de las componentes principales, se ha tomado en cuenta una de las más importantes objeciones a este procedimiento, es decir, el hecho de que no aprovecha la información sobre las correlaciones entre los indicadores. De hecho, podría encontrarse sustento adicional para alcanzar tal conclusión sobre la base de que se ha hecho uso de toda la in-

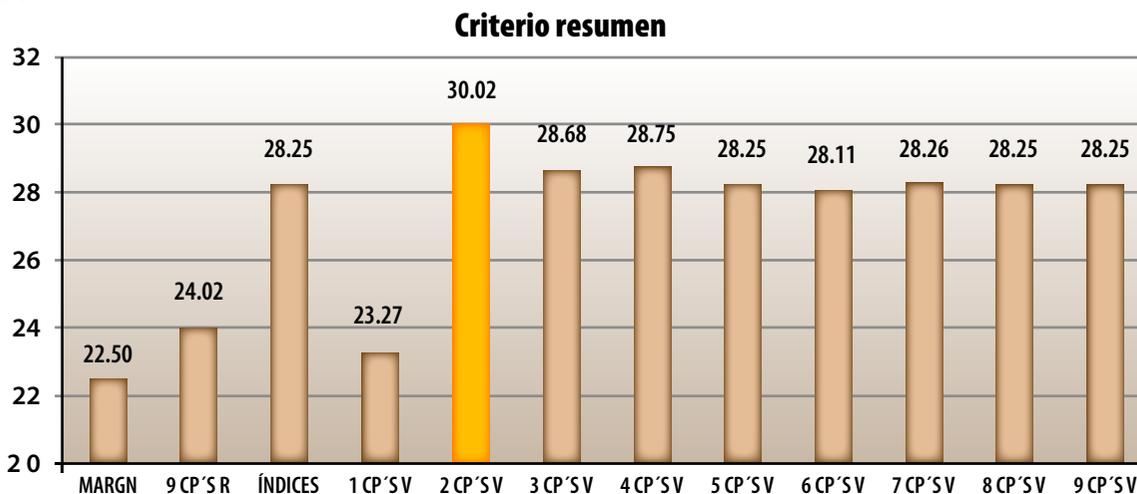
formación disponible pues hasta la intrascendente última componente principal habría sido tomada en cuenta.

Sin embargo, la evaluación a través del criterio propuesto de todas las conglomeraciones elaboradas lleva de inmediato a concluir que el mejor valor de dicho criterio se alcanza con la conglomeración basada en el uso de sólo las dos primeras componentes principales. Los resultados parecen indicar que la información restante contenida en cualesquiera indicadores adicionales no correlacionados con las dos primeras componentes principales, las dos influencias más importantes, tiene más bien un comportamiento ruidoso o aleatorio, por lo que no contribuyen a mejorar posteriores clasificaciones de municipios.

Por su parte, además de los tamaños en los estratos, la gráfica 7 muestra la que es, sin duda, la ganancia más importante en términos de los indicadores básicos al pasar de MARGN a la estratificación óptima: el indicador de *ruralidad* tiene un comportamiento más homogéneo al interior de los nuevos estratos. Como se observa, la conglomeración MARGN da lugar a estratos, todos los cuales contienen unidades con valores muy pequeños o muy grandes para este indicador.

A partir de este resultado es también posible ver que los nuevos estratos con grado de marginación medio (3) y muy alto (5) están formados casi en su totalidad por municipios *rurales*, en tanto que el que se identificaría con alto grado de marginación

Gráfica 6



Cálculos propios mediante Minitab usando archivo de datos encontrado el 20 de noviembre de 2009 en www.conapo.gob.mx/publicaciones/margina2005/AnexoB.xls

(4) tiene una composición más bien mixta. Ello conduce a evitar la conclusión, tal vez errónea, que se extraería de la conglomeración MARGN, en el sentido de que un grado alto o muy alto de marginación parece estar ligado a una mayor ruralidad.

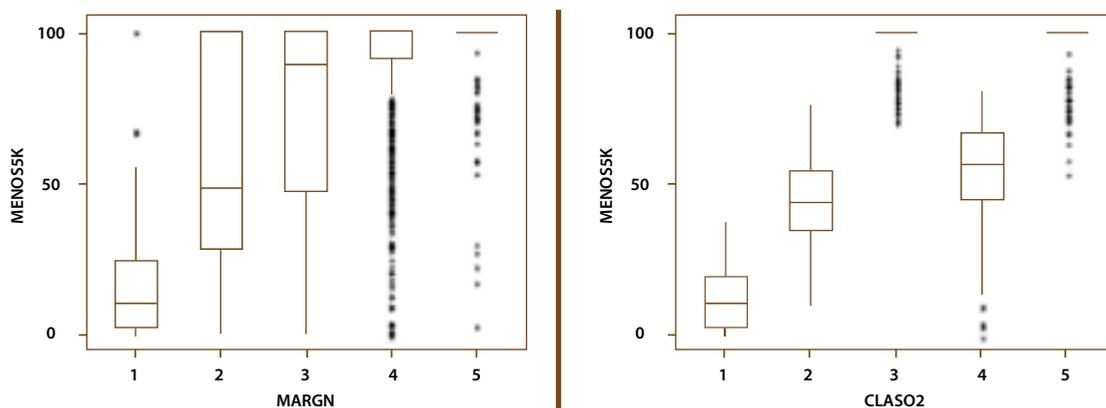
El cuadro 5 permite, a su vez, comparar el resultado de conglomerar municipios a partir de, por un lado, los valores del índice de marginación y, por el otro, los de las primeras dos componentes principales calculadas usando la matriz de covarianzas, cruzando la forma en que cada municipio es clasificado en cada caso. Se destaca en particular el importante

desplazamiento de municipios entre clases alternativas. Por su número, sin duda, el efecto más importante de pasar de una clasificación a la otra es la salida de 470 municipios de las clases con alto y muy alto grado de marginación. En sentido contrario, sólo 37 municipios que tenían una clasificación diversa ingresan en alguna de estas dos clases.

El efecto de lo anterior en términos poblacionales puede ser visto usando la información del Censo 2005. En los 470 municipios que abandonan las categorías de muy alto y alto grado de marginación en el 2005 habitaban 4 339 251 personas. Por su

Gráfica 7

Boxplots para MENOS5K según las conglomeraciones marginación vs. óptima



Grado de marginación: 1. Muy bajo; 2. Bajo; 3. Medio; 4. Alto; 5. Muy alto.

	Muy bajo	Bajo	Medio	Alto	Muy alto		Muy bajo	Bajo	Medio	Alto	Muy alto
N_i	279	423	501	886	365	N_i	370	395	871	207	611

Cálculos propios mediante Minitab usando archivo de datos encontrado el 20 de noviembre de 2009 en www.conapo.gob.mx/publicaciones/margina2005/AnexoB.xls

Cuadro 5

Conglomeraciones: marginación vs. óptima

	1	2	3	4	5	Total
1	248	93	22	7	0	370
2	19	189	169	18	0	395
3	12	141	273	441	4	871
4	0	0	37	162	8	207
5	0	0	0	258	353	611
Total	279	423	501	886	365	2 454
Renglones:2CP V			Columnas: MARGN			

Cálculos propios mediante Minitab usando archivo de datos encontrado el 20 de noviembre de 2009, en www.conapo.gob.mx/publicaciones/margina2005/AnexoB.xls

parte, en los 37 que son ahora clasificados dentro de la categoría de alto grado de marginación residían, en aquel año, 1 287 197.

Conclusión

Se presentó una estrategia a seguir para lograr la conglomeración de unidades de una población. Partiendo de las componentes principales basadas en la matriz de covarianzas, se clasifican las unidades de la población con base en los valores de las componentes. Se procede de manera incremental obteniendo la primera clasificación que considera sólo a la primera componente; la segunda clasificación que considera tanto a la primera como la segunda componentes; la tercera, a las primeras tres y así sucesivamente hasta llegar a la que considera a todas las componentes principales. Las clasificaciones alternativas son comparadas con base en el criterio introducido en este trabajo y cuyo valor máximo determina la clasificación formada por estratos más homogéneos en su forma interna.

De esta manera, se alcanza el fin original y principal del CONAPO de evaluar "...el impacto global de las carencias..." a través de un medio que, para "...facilitar el análisis de la expresión territorial de la marginación, reduzca la dimensionalidad original y, al mismo tiempo, se retenga y refleje al máximo posible la información referida a la dispersión de los datos (...) así como las relaciones entre ellos..."; sin embargo, dicho propósito no se alcanza a través del medio establecido por esta institución, es decir, de un único índice de marginación. De cualquier modo, bajo condiciones excepcionales que se dan cuando la primera componente principal explica una proporción sustancial de la suma de las

varianzas de los indicadores originales, no se impide que ésta sea una posibilidad, en cuyo caso se podrá además "...establecer una ordenación entre las unidades de observación: estados, municipios o localidades."

Es preciso reiterar que el propósito de este artículo no es el de sugerir el uso de un conjunto u otro de indicadores cuando se realiza un ejercicio de clasificación. Es por ello que el significado de la variable que tiene mayor influencia en la conglomeración óptima alcanzada no es relevante para la discusión que se presenta. Sin embargo, ya que para el caso de ejemplo éste no es sino un sucedáneo para medir las condiciones de ruralidad de un municipio, se sugiere evitar el trabajar con variables resumen para una o más de las dimensiones que se estudian e incluir de manera explícita tantas variables como se considere necesario para lograr una buena conglomeración.

Ésta es la estrategia seguida por el ejercicio denominado *niveles de bienestar*, desarrollado por el INEGI con base en la información de los censos de 1990 y del 2000. Por supuesto, tampoco se aboga por la aplicación de tal ejercicio en las mismas condiciones en que fue realizado ya que, como se ha visto, puede conducir a una solución subóptima. En efecto, por así decirlo, permite que el ruido y la redundancia en los indicadores afecten el resultado. Una vez que se considera el uso de dos o más componentes principales como insumo al procedimiento multivariado de conglomeración y que se dispone de un criterio adecuado que permite identificar el resultado más adecuado, la dimensión del problema alcanzará un tamaño razonable y conducirá a conglomeraciones adecuadas.