

# ESTIMACIÓ DE VARIÀNCIES DE LES VARIABLES DE L'ENQUESTA DE SALUT DE BARCELONA

Carles Murillo Fort / Montserrat Guillén Estany

Departament d'Econometria, Estadística i Economia Espanyola. Universitat de Barcelona

## Resum

El càlcul de les variàncies en els estudis de disseny mostra complex (mostreig estratificat o multietàpic) resulta esbiaixat en no tenir en compte els efectes del disseny. En aquest article es presenta el càlcul de les variàncies dels estadístics de l'enquesta de salut de Barcelona de 1986 (estudi d'una mostra de 2.205 famílies —conglomerats— i estratificada per districte municipal i per grandària familiar). S'utilitza el mètode *Jackknife* i els resultats es comparen amb l'estimació obtinguda pel mètode estàndard (és a dir, suposant un mostreig aleatori simple d'individus).

El mètode *Jackknife* incorpora tot el disseny mostra en el càlcul

de les variàncies, en formar a posteriori pseudo-estrats que són en el seu interior homogenis. Aquest mètode conduce a resultats més acurats que el mètode estàndard, especialment en el càlcul de valors poblacionals totals. Les diferències, però, no són excessivament importants, mentre que el efecte del disseny per conglomerats és més gran per algunes variables. (*Gac Sanit* 1989; 12 (3): 409-20).

**Paraules clau:** Enquesta. Variància. Mostreig per conglomerats. Mostreig estratificat. Mètode *Jackknife*.

## VARIANCE ESTIMATION OF THE VARIABLES OF THE HEALTH INTERVIEW SURVEY OF BARCELONA

## Summary

Variance estimation of surveys with complex sampling designs (stratified or multistage design) is biased if design effects are not taken into account. In this article we estimate the variance of some of the variables included in the 1986 health interview survey of Barcelona (survey of 2,205 households —clusters— that were stratified by municipal district and by family size). We present a comparison of variance estimates using the *Jackknife* method and using the standard method (the one used for simple random samples).

*Jackknife* method incorporates sampling design effects for estimating the variance, as homogeneous pseudo-clusters are formed. This method leads to more accurate results than the other method especially when calculating global population estimates. Differences between these methods are not very important, whereas cluster design effects are more important for certain variables. (*Gac Sanit* 1989; 12 (3): 409-20).

**Key words:** Survey. Variance. Cluster sampling. Stratified sampling. *Jackknife* method.

## Introducció

L'Enquesta de Salut per entrevista de Barcelona del 1986 (ESB-86)<sup>1</sup> ha estat realitzada segons un disseny mostra estratificat per districtes i per grandària familiar. Per a avaluar la magnitud de la precisió en les estimacions deduïdes de les explotacions de les dades de l'ESB-86, cal tenir en compte tant la forma de l'es-

## ESTIMACIÓN DE LAS VARIANZAS DE LAS VARIABLES DE LA ENQUESTA DE SALUD DE BARCELONA

## Resumen

El cálculo de las varianzas en los estudios de diseño muestral complejo (muestreo estratificado o multietápico) resulta sesgado al no tener en cuenta los efectos de ese diseño. En este artículo se presenta el cálculo de las varianzas de los estadísticos de la encuesta de salud de Barcelona de 1986 (estudio de una muestra de 2.205 familias —conglomerados— estratificadas por distrito y tamaño familiar). Se utiliza el método *Jackknife* y sus resultados se comparan con la estimación obtenida utilizando el método estándar (es decir, suponiendo un muestreo aleatorio simple de individuos).

El método *Jackknife* incorpora todo el diseño muestral al cálculo de las varianzas, al formar a posteriori pseudoestratos que son en su interior homogéneos. Este método conduce a resultados más precisos que el método estándar, especialmente en el cálculo de los valores poblacionales totales. Las diferencias entre ambos métodos no son, sin embargo, muy importantes, mientras que el efecto del diseño por conglomerados es más grande para algunas variables. (*Gac Sanit* 1989; 12 (3): 409-20).

**Palabras clave:** Encuesta. Varianza. Muestreo por conglomerados. Muestreo estratificado. Método *Jackknife*.

## Introducción

La encuesta de salud por entrevista de Barcelona de 1986 (ESB-86)<sup>1</sup> ha sido realizada según un diseño muestral estratificado por distritos y por tamaño familiar. Para evaluar la magnitud de la precisión de las estimaciones deducidas de la explotación de los datos de la ESB-86, se necesita tener en cuenta tanto la forma

Correspondencia: Carles Murillo Fort. Departament d'Econometria, Estadística i Economía Espanyola. Avgda. Diagonal, 690. 08034 BARCELONA  
Este artículo fue recibido el 27 de septiembre de 1988 y fue aceptado, tras revisión, el 15 de marzo de 1989.

tadístic d'interès com la natura del disseny de la mostra. La mesura utilitzada per a donar compte de la precisió dels resultats ha estat la variància de l'estimador i, en conseqüència, el seu error estàndard. El coneixement de l'estadístic i del seu error estàndard ens donarà l'opció de la construcció dels intervals de confiança al nivell de significació elegit.

En general, els casos en què el disseny mostral presenta estratificació de la població, accés a les unitats mostraies mitjançant processos multietàpics, les ponderacions necessàries per al càlcul de les variàncies dels estadístics d'interès (mitjanes, proporcions, raons,...) fan molt complicada l'aproximació analítica habitual. Si, en un afany simplificador, fem un càlcul directe dels estimadors de les variàncies suposant que la mostra és aleatòria simple encara que sigui complexa, aleshores obtindrem inferències esbiaixades de les veraderes variàncies. A més a més, si les unitats mostraies no han estat seleccionades de manera independent, el biaix augmenta notablement. Un problema addicional el constitueix l'existència de no-resposta, que té com a conseqüència l'aparició de biaix àdhuc en les estimacions.

#### *Mètodes alternatius per al càlcul de les variàncies*

En presència d'un disseny mostral complex es presenten, almenys, tres camins alternatius per a valorar la qualitat de les estimacions<sup>2</sup>. En primer lloc, hi ha la possibilitat de calcular una estimació de la variància mitjançant la fórmula clàssica de mostra aleatòria simple, ignorant l'efecte del disseny. Aquesta estimació requereix fer una mitjana dels quadrats de les desviacions respecte a la mitjana de totes les observacions. Alternativament, i en segon lloc, l'estratificació de la mostra i, fins i tot, altres efectes del disseny com poden ser la presència de conglomerats (*clusters*), es poden incorporar als càlculs. En aquest cas, cal que la mitjana de les desviacions que s'utilitza per a estimar la variància sigui ponderat per factors de diversa naturalesa d'acord amb el disseny mostral, els quals poden arribar a assolir una dificultat i complicació considerables<sup>2</sup>.

El primer procediment dels esmentats és el més senzill, tan conceptualment com computacionalment. Malgrat que tenim l'avantatge de la simplificació dels càlculs, els efectes ignorats del mostratge fan que l'estimació de la variància es distorsioni i s'allunyi del valor real del paràmetre. D'altra banda, el problema que sorgeix en la utilització del segon procediment és que els estimadors de la variància esdevenen excessivament complicats. Un altre inconvenient addicional apareix quan, sovint, es desconeixen les característiques del mostratge i de la població. Aquests elements són imprescindibles per a l'aplicació correcta de la fórmula de l'estimador de la variància.

Pero encara podem recórrer a la utilització d'un tercer mètode d'estimació que incorpora una metodologia nova. Es tracta de fer servir mètodes d'estimació de les variàncies

del estadístic de interès com la natura del disseny de la muestra. La medida utilizada para expresar la precisión de los resultados ha sido la varianza del estimador y, en consecuencia, su error estándar. El conocimiento del estadístico y de su error estándar nos dará la opción de la construcción de los intervalos de confianza al nivel de significación elegido.

En general, en los casos en que el diseño muestral presenta estratificación de la población, o acceso a las unidades muestrales mediante procesos multietápicos, las ponderaciones necesarias para el cálculo de las varianzas de los estadísticos de interés (medias, proporciones, razones,...) hacen muy complicada la aproximación analítica habitual. Si, en un afán simplificador, se realiza un cálculo directo de los estimadores de las varianzas suponiendo que la muestra es aleatoria simple aunque sea en realidad compleja, entonces se obtienen inferencias sesgadas de las verdaderas varianzas. Además, si las unidades muestrales no han sido seleccionadas de manera independiente, el sesgo aumenta de forma importante. Un problema adicional lo constituye la existencia de no-respuesta que tiene como consecuencia la aparición de sesgo en las estimaciones de los parámetros de interés.

#### *Métodos alternativos para el cálculo de las varianzas*

En presencia de un diseño muestral complejo se presentan, al menos, tres formas alternativas para valorar la calidad de las estimaciones<sup>2</sup>. En primer lugar existe la posibilidad de calcular una estimación de la varianza mediante la fórmula clásica de muestra aleatoria simple ignorando el diseño. Esta estimación se obtiene sencillamente mediante el cálculo del promedio de los cuadrados de las desviaciones. En segundo lugar, pueden incorporarse a los cálculos tanto la estratificación de la muestra como otros efectos del diseño, como pueden ser la presencia de conglomerados (*clusters*). En este caso, es necesario que el promedio de las desviaciones que se utiliza para estimar la varianza esté ponderado por pesos de diversa naturaleza en función del diseño muestral. El resultado puede suponer en algunas ocasiones una dificultad y complicación realmente considerables<sup>2</sup>.

El primero de los procedimientos citados es el más sencillo tanto a nivel conceptual como computacional. Aunque se tiene la ventaja de la simplificación de los cálculos, los efectos ignorados del muestreo provocan que la estimación de la varianza se distorsione y se aleje del valor real del parámetro. Por otro lado, el problema que surge en la utilización del segundo procedimiento es que el cálculo de los estimadores de la varianza alcanza demasiada complicación. Otro inconveniente adicional aparece cuando, a menudo, se desconocen las características del muestreo y de la población, puesto que estos elementos son imprescindibles para la correcta aplicación de la fórmula del estimador de la varianza.

Finalmente, podemos recurrir a la utilización de métodos de estimación de las varianzas de estadísticos de una muestra realizada con un diseño complejo, los cuales tienen como

d'estadístics provinents d'una mostra amb disseny complex, els quals tenen com a virtut principal la capacitat d'incorporació dels efectes de: l'estratificació, la formació de conglomerats (*clusters*), l'existència de no-respostes, els ajustaments per estratificació a posteriori, etc... La idea bàsica és la formació de molts «grups aleatoris», que fan possible l'extracció de «mostres artificials» de la mostra de què disposem (pseudo-replicació dels grups aleatoris).

En poques paraules, el procediment consisteix a aconseguir més mostres, però com que habitualment només se'n té una i és difícil fer més sondeigs aleshores es treuen submostres de mida més petita a partir de la mostra inicial. L'existència d'un conjunt de submostres permet mesurar la variabilitat dels estadístics estudiats, que es calcula buscant la variància de la distribució dels estadístics obtinguts en cada submostra o mostra artificial.

En situacions de moderada complexitat en el disseny (estratificacions múltiples, polietàpiques, etc.), els càlculs de manual ja no són teòricament ni pràcticament aconsellables, mentre que els procediments derivats de les pseudorépliques de grups aleatoris no tenen altra complicació que la dimensió del nombre de càlculs i no pas la complexitat analítica, que es pràcticament menyspreable.

#### *El procediment «Jackknife» d'estimació de la variància*

Existeixen diversos mètodes d'estimació de les variàncies a partir de la idea de la construcció artificial de grups aleatoris. En aquest treball hem utilitzat l'anomenat mètode *Jackknife*<sup>3-6</sup>. El principi inspirador d'aquest mètode és la formació de mostres artificials que serveixen d'aproximació a l'existència real de mostres repetides: a partir d'una mostra de mida  $n$  (nombre d'unitats primàries de mostreig) el *Jackknife* consisteix en la selecció de mostres de mida més reduïda. Les noves mostres s'obtenen senzillament per l'omissió d'un element o grup d'elements de la mostra total. Per obtenir aquestes submostres s'haurà dividit prèvialement la mostra original en  $k$  grups de mida  $m$  cadascun d'ells. L'exigència de precisió dels estimadors de les variàncies i el cost computacional dels càlculs permeten fer una determinació del nombre  $k$  adequat de grups que es formin d'entre els  $n$  elements que constitueixen la mostra inicial<sup>7</sup>. Si la mostra s'ha generat d'un disseny amb estratificació prèvia de la població, aleshores aquest fet s'ha de reflectir també en la formació dels grups abans de la selecció de submostres pel mateix procediment ja esmentat. El mateix cal dir per a altres característiques del disseny mostral inicial.

En una mostra estratificada, el mètode consisteix a situar-se dins de cada estrat i allà fer tantes rèpliques de la mostra com elements hi hagi, eliminant a tal fi cada cop un element. En totes aquestes mostres es calcula l'estimador dels paràmetres desitjats (mitjanes i proporcions, per exemple). La idea prové de Quenouille<sup>8</sup>, que proposa estimar la mit-

virtud principal la capacitat de incorporació de los efectos de: la estratificación, la formación de conglomerados (*clusters*), la existencia de no-respuesta, los ajustes por estratificación a posteriori, etc... La idea básica de dichos métodos es la formación de muchos «grupos aleatorios» que hacen posible la extracción de «muestras artificiales» de la muestra disponible (pseudoreplicación de grupos aleatorios).

En pocas palabras, el procedimiento consiste en conseguir más muestras, pero como habitualmente sólo se dispone de una única muestra y es difícil realizar más sondeos, entonces se extraen submuestras de tamaño más pequeño a partir de la muestra inicial. La existencia de un conjunto de submuestras permite medir la variabilidad de los estadísticos estudiados, la cual se calcula buscando la varianza de la distribución de los estadísticos obtenidos en cada submuestra o muestra artificial.

En situaciones de moderada complejidad en el diseño (estratificaciones múltiples, polietápicas, etc,...) los cálculos de manual ya no son teórica ni prácticamente aconsejables, mientras que los procedimientos derivados de las pseudoréplicas de grupos aleatorios no tienen otra complicación que la dimensión del número de cálculos y no tanto la complejidad analítica, que en este caso es prácticamente despreciable.

#### *El procedimiento «Jackknife» de estimación de la varianza*

Existen diversos métodos de estimación de la varianza a partir de la idea de la construcción artificial de grupos aleatorios. En este trabajo hemos utilizado el llamado método *Jackknife*<sup>3-6</sup>. El principio inspirador de este método es la formación de muestras artificiales que sirven como aproximación de la existencia real de muestras repetidas: a partir de una muestra de tamaño  $n$  (número de unidades primarias de muestreo) el *Jackknife* consiste en la selección de muestras de tamaño más reducido. Las nuevas muestras se obtienen sencillamente por la omisión de un elemento o un grupo de elementos de la muestra total. Para la obtención de estas submuestras se habrá dividido previamente la muestra original en  $k$  grupos de tamaño  $m$  cada uno de ellos. La exigencia de precisión de los estimadores de las varianzas y el coste computacional de los cálculos permite realizar una determinación del número adecuado  $k$  de grupos a formar de entre los  $n$  elementos que constituyen la muestra inicial<sup>7</sup>. Si esa muestra se ha generado a partir de un diseño con estratificación previa de la población entonces este hecho debe reflejarse también en la formación de los grupos antes de la selección de submuestras por el mismo procedimiento citado anteriormente y lo mismo debe aplicarse para otras características del diseño muestral inicial.

Para una muestra estratificada el método consiste en situarse dentro de cada estrato y allí hacer tantas réplicas de la muestra como elementos o grupos de elementos se hayan formado, eliminando a tal fin cada vez un elemento o grupo de elementos. En todas estas muestras se calcula el estimador de los parámetros deseados (medias y propor-

jana poblacional calculant una mitjana de les mitjanes obtingudes en cada réplica. Agafant les estimacions i aplicant la fórmula de mostra aleatòria simple, es calcula la variància de l'estimador dins l'estrat. Després es fa una mitjana de totes les estimacions de la variància dels diferents estrats per obtenir una mesura de la variància global. Està demostrat que aquest procediment es un estimador bastant conservador de la variància desconeguda de la distribució mostral de l'estadístic. En relació a altres tipus d'estimadors (raons, coeficients de regressió, etc.) els resultats del mètode *Jackknife* tenen, en condicions generals, validesa asimptòtica<sup>9</sup>.

Les variàncies poden ésser estimades de manera esbiaixada en les situacions particulars de funcions lineals<sup>6</sup>, encara que en mostres finites i en el cas d'estimadors no-lineals, hi ha una tendència a produir estimacions esbiaixades positivament<sup>3</sup>.

Hem dit abans que podem suposar que la mostra de grandària  $n$  està dividida en  $k$  grups de  $m$  elements cadascun d'ells, és a dir, que  $n=km$ . Si eliminem el  $k$ -èsim grup obtenim una rèplica de la nostra mostra. En l'ordre pràctic, el principal problema en la utilització del mètode *Jackknife* no és altre que la selecció de  $k$ , el nombre de grups en què dividim la mostra. Els costos associats al càlcul estan en relació inversa a l'eficiència del procediment, per a cada possible elecció de  $k$ . La precisió més elevada, l'assolirem amb  $k=n$ , és a dir, amb tants grups com elements té la mostra (i, en conseqüència, un element a cada grup). Les estimacions dels estimadors *Jackknife* no són fàcilment generalitzables. En el cas de  $H$  estrats es proposa un estimador<sup>10</sup> anomenat *Jackknife* de primer ordre.

Wolter<sup>3</sup> descriu els principis metodològics i alguns dels mètodes d'estimació de la variància. En Murillo i Guillén<sup>11</sup> es presenten també els resultats de l'estimació de les variàncies pel mètode de les «semimostres equilibrades». Aquest procediment alternatiu es basa també en la idea de replicar la mostra però difereix del *Jackknife* en la manera de construir les submostres; en particular, és adequat quan es pot suposar que la mostra és constituïda per estrats que tenen només dues unitats mostrals cadascun. Cal remarcar que quan s'ha utilitzat el mètode de les «semimostres equilibrades», els resultats obtinguts han estat molt sensibles a l'elecció dels grups aleatoris en què cal dividir la mostra, és a dir, a la manera com es formen les dues unitats dins dels estrats, la qual cosa es tradueix en un clar desvantatge en relació al mètode *Jackknife*.

L'objectiu del treball consisteix en la utilització d'un algoritme per a calcular les estimacions de les variàncies dels estadístics resultants de la recollida d'informació per mètodes d'enquesta que provenen de dissenys mostrals complexos. Aquests resultats es comparen amb els càlculs realitzats amb les fórmules d'estàndard.

ciones, por ejemplo). La idea proviene de Quenouille<sup>8</sup> que propone estimar la media poblacional calculando una media de las medias obtenidas en cada réplica. Tomando las estimaciones y aplicando la fórmula de muestra aleatoria simple se calcula la varianza del estimador dentro de cada estrato. Después se hace un promedio de todas las estimaciones de la varianza de los diferentes estratos para obtener una medida de la varianza global. Está demostrado que este procedimiento es un estimador bastante conservador de la varianza desconocida de la distribución muestral del estadístico. En relación a otros tipos de estimadores (razones, coeficientes de regresión, etc.) los resultados del mètode *Jackknife* tienen, en condiciones generales, validez asintótica<sup>9</sup>.

Las varianzas pueden ser estimadas de forma sesgada en las situaciones particulares de funciones lineales<sup>6</sup>, aunque en muestras finitas y en el caso de estimadores no lineales, hay una tendencia a producir estimaciones sesgadas positivamente<sup>3</sup>.

Como hemos dicho antes podemos suponer que la muestra de tamaño  $n$  está dividida en  $k$  grupos de  $m$  elementos cada uno de ellos, es decir, que  $n=km$ . Si eliminamos el  $k$ -ésimo grupo obtenemos una réplica de nuestra muestra. En la práctica, el principal problema en la utilización del mètode *Jackknife* no es otro que la selección de  $k$ , el número de grupos en que se divide la muestra. Los costes asociados al cálculo están en relación inversa a la eficiencia del procedimiento, para cada posible elección de  $k$ . La precisión más elevada se alcanza cuando  $k=n$ , es decir, con tantos grupos como elementos tiene la muestra (y en consecuencia un elemento en cada grupo). Las expresiones de los estimadores *Jackknife* no son fácilmente generalizables. En el caso de tener  $H$  estratos se propone un estimador<sup>10</sup> llamado *Jackknife* de primer orden.

Wolter<sup>3</sup> describe los principios metodológicos y algunos de los mètodes de estimación de la varianza. Murillo y Guillén<sup>11</sup> presentan también los resultados de la estimación de las varianzas por el mètode de las «semimuestras equilibradas». Este procedimiento alternativo está basado también en la idea de replicar la muestra pero difiere del de *Jackknife* en la forma como se constituyen las submuestas y, en particular, es adecuado cuando se puede suponer que la muestra está constituida por estratos que tienen únicamente dos unidades de muestrales cada uno. Debemos remarcar que cuando se ha utilizado este mètode de las «semimuestras equilibradas» los resultados obtenidos han sido muy sensibles a la elección de los grupos aleatorios en que se debe dividir la muestra, es decir, la manera como se forman las dos unidades dentro de los estratos, lo cual se traduce en una clara desventaja en relación al mètode *Jackknife*.

El objetivo del trabajo consiste en la utilización de un algoritmo para calcular las estimaciones de las varianzas de los estadísticos resultantes de la recogida de información por métodos de encuesta que provienen de diseños muestrales complejos. Estos resultados se comparan con los cálculos realizados con las fórmulas estándar.

## Material i mètodes

### Característiques de la mostra

L'enquesta de salut de Barcelona de 1986 (ESB-86) va ser realitzada per a famílies residents a Barcelona. Per triar una mostra que reflectís al màxim les característiques dels habitants de la ciutat i que, per tant, reproduís fidelment el comportament de tota la població, es varen fer dues estratificacions. Primerament es van tenir en compte els 10 districtes que hi ha a Barcelona i després es va agafar com a segona estratificació la grandària de les famílies, prenent quatre patrons de grandària (famílies d'un o dos membres, de tres o de quatre membres, de cinc o de sis membres i finalment famílies de set membres o més). Aleshores, la selecció es va fer de forma proporcional per a ambdues estratificacions, basant-se en dades censals. Un cop triada la família, tots els seus membres havien de respondre el qüestionari.

Tal com ja indicàvem, en el càlcul de la variància amb el procediment *Jackknife* s'ha de tenir en compte que els estrats han d'ésser independents. Per a la construcció dels estrats, en l'obtenció de les unitats de la mostra, s'han utilitzat criteris (districtes i grandària familiar, tal com hem vist) que condueixen a la pràctica, amb tota probabilitat, a classes independents. Els objectius de l'anàlisi de les dades de l'ESB-86 fan referència principalment a l'estimació de paràmetres relativs a individus per grups d'edat i sexe. Per això, cal considerar que la independència dels elements que componen els diferents estrats —les unitats primàries d'estudi, és a dir, les famílies— no implica necessàriament la independència dels elements finalment observats —els individus—. Malgrat que dues famílies, en un mateix estrat, hagin estat seleccionades independentment, el fet de definir la família com un conglomerat i d'haver observat tots els seus membres, condueix a situacions en les quals és possible pensar en un comportament relacionat. És a dir, podem evidenciar la manca d'independència entre alguns membres d'una mateixa família per algunes característiques observades (disposar de cobertura sanitària per la seguretat social, hàbits de comportament, nivell educacional...).

### Càlcul de les variàncies

A continuació es tracta d'analitzar els resultats obtinguts en utilitzar cadascun dels mètodes d'estimació de les variàncies que hem presentat en la introducció: càlcul com si les dades provinguessin d'una mostra aleatòria simple, càlcul de la variància amb ponderació dels resultats segons l'estratificació i, en tercer lloc, variàncies estimades pel procediment *Jackknife*.

En el primer procediment s'ignora totalment com ha estat dissenyada la mostra i la variància es calcula fent una mitjana de les desviacions respecte a la mitjana:

$$\text{Var SRS} = \sum_i \frac{(x_i - \bar{x})^2}{n-1}$$

## Material y métodos

### Características de la muestra

La encuesta de salud de Barcelona (1986) estuvo dirigida a familias residentes en Barcelona. Para seleccionar una muestra que reflejara al máximo las características de los habitantes de la ciudad y que, por tanto, reprodujese fielmente el comportamiento de toda la población, se hicieron dos estratificaciones. Primeramente se tuvo en cuenta los 10 distritos que hay en Barcelona y después se tomó como segunda estratificación el tamaño de las familias tomando cuatro patrones de medida (familias de uno o dos miembros, de tres o cuatro miembros, de cinco o seis miembros y finalmente familias de 7 miembros o más). Entonces, la selección se hizo de forma proporcional para ambas estratificaciones en base a datos censales. Una vez escogida la familia, todos sus miembros debían responder al cuestionario.

Como ya indicábamos, para el cálculo de la varianza mediante el procedimiento *Jackknife* debe tenerse en cuenta que los estratos deben ser independientes. Para la construcción de los estratos, en la obtención de las unidades de la muestra, se han utilizado criterios (distrito y tamaño familiar) que conducen en la práctica con toda probabilidad a clases independientes. Los objetivos del análisis de los datos de la ESB-86 hacen referencia principalmente a la estimación de parámetros relativos a individuos por grupos de edad y sexo. Por ello debe considerarse que la independencia de los elementos que componen los diferentes estratos —las unidades primarias de estudio, es decir, las familias— no implica necesariamente la independencia de los elementos finalmente observados —los individuos—. A pesar de que dos familias, en un mismo estrato, hayan sido seleccionadas independientemente, el hecho de definir la familia como un conglomerado y haber observado a todos sus miembros conduce a situaciones en las que posiblemente existe un comportamiento relacionado. Es decir, podemos evidenciar la falta de independencia entre algunos miembros de una misma familia para ciertas características observadas (poseer cobertura sanitaria por la seguridad social, hábitos de comportamiento, nivel educacional).

### Cálculo de las varianzas

En el presente trabajo se analizan los resultados obtenidos al aplicar a la ESB-86 cada uno de los métodos de estimación de las varianzas que hemos presentado en la introducción: cálculo como si los datos provinieran de una muestra aleatoria simple, cálculo de la varianza con ponderación de los resultados según la estratificación, y en tercer lugar, varianzas estimadas por el método *Jackknife*.

En el primer procedimiento se ignora totalmente cómo ha sido diseñada la muestra y la varianza se calcula haciendo un promedio de las desviaciones respecto a la media:

$$\text{Var SRS} = \sum_i \frac{(x_i - \bar{x})^2}{n-1}$$

En el segon cas el disseny mostral s'incorpora parcialment ja que només es té en compte l'estratificació i es menyspreuen els efectes dels conglomerats. En aquesta situació es fa una mitjana de les desviacions respecte a la mitjana dins de cada estrat i finalment es fa una mitjana ponderada ( $W_h$ ) dels estrats, segons la seva grandària.

$$Var\ STR = (1/n) \sum_h W_h \sum_i \frac{(x_{ih} - \bar{x})^2}{n_h - 1}$$

Abans de continuar, cal remarcar que si volguéssim incorporar la totalitat del disseny mostral de l'ESB-86 en la fórmula precedent, caldría incloure-hi també el fet que els individus s'agrupen en famílies (les unitats seleccionades) que constitueixen els conglomerats. Per tant, s'hauria de tenir en compte la correlació entre els individus d'un mateix conglomerat. Suposant també que la correlació entre els individus d'una família és anàloga en totes les famílies d'un mateix estrat tindriem:

$$Var = \sum_h (1/n) W_h \sum_i \frac{(x_{ih} - \bar{x})^2}{n_h - 1} (1 + (m_h - 1) P_h)$$

on  $m_h$  és el nombre d'individus en cada família i  $P_h$  la correlació entre ells. (Recordem que els estrats estan formats per famílies de grandària semblant).

El mètode *Jackknife*, la tercera possibilitat, que incorpora tot el disseny mostral i evita la formulació anterior, ha estat utilitzat per a tractar l'ESB-86. La idea és formar, a posteriori, pseudo-estrats que en el seu interior siguin homogenis i que estiguin poc correlacionats amb la resta de pseudo-estrats. Per a aconseguir aquest fenomen, es realitza una agrupació de districtes mitjançant una anàlisi factorial. Es prenen les dades dels districtes de la ciutat, publicades en *L'Estat de Salut de Barcelona*<sup>12</sup>, relatives a indicadors de morbi-mortalitat, d'utilització de serveis sanitaris i de dades demogràfiques. La projecció sobre el pla factorial format pels dos primers eixos factorials, que recull el 55% de la variació global, permet fer una agrupació temptativa dels estrats. Així doncs, aquesta anàlisi factorial va suggerir mantenir els districtes I i V sols en sengles pseudo-estrats, agrupar per proximitat els districtes VII, VIII i IX i posar en una altra agrupació la resta dels districtes. Fent això, s'aconsegueixen quatre «pseudo-districtes» amb quatre tipus de família en cadascun d'ells, que van donar lloc als setze pseudo-estrats finals.

Com que l'ESB-86 es basava en la tria de famílies i en l'enquesta a tots els seus membres, hem de tenir en compte que les unitats mostrals primàries no són els individus sinó les famílies. Per eliminar un element o grup d'elements de la mostra, per calcular —segons el procediment *Jackknife*— l'estadístic sense aquell element o grup d'elements, hem separat tots els membres de la família o grup de famílies involucrades. Cal remarcar que és en aquest punt on introduïm en els càlculs aquells efectes que poden causar els conglomerats.

En el segundo caso el diseño muestral se incorpora parcialmente ya que tan sólo se tiene en cuenta la estratificación y se desprecian los efectos de los conglomerados. En esta situación se hace un promedio de las desviaciones respecto a la media dentro de cada estrato y finalmente se hace un promedio ponderado ( $W_h$ ) de los estratos según su tamaño.

$$Var\ STR = (1/n) \sum_h W_h \sum_i \frac{(x_{ih} - \bar{x})^2}{n_h - 1}$$

Antes de continuar cabe destacar que si se quisiese incorporar la totalidad del diseño muestral de la ESB-86 en la fórmula precedente se debería tener en cuenta que los individuos se agrupan en familias (las unidades seleccionadas) que constituyen los conglomerados. Por tanto se debería tener en cuenta la correlación existente entre individuos de un mismo conglomerado. Suponiendo también que la correlación entre los individuos de una familia es análoga para todas las familias de un mismo estrato se tendría:

$$Var = \sum_h (1/n)_h W_h \sum_i \frac{(x_{ih} - \bar{x})^2}{n_h - 1} (1 + (m_h - 1) P_h)$$

donde  $m_h$  es el número de individuos en cada familia y  $P_h$  la correlación entre ellos (recordemos que los estratos están formados por familias de tamaño semejante).

El método *Jackknife*, la tercera posibilidad, incorpora la totalidad del diseño muestral que ha sido utilizado para tratar la ESB-86. La idea es formar, a posteriori, pseudoestratos que en su interior sean homogéneos y que estén poco correlacionados con el resto de pseudoestratos. Para conseguir este resultado se realizó una agrupación de distritos mediante un análisis factorial. Se tomaron los datos de los distritos de la ciudad, publicados en *L'Estat de Salut de Barcelona*<sup>12</sup>, relativos a indicadores de morbi-mortalidad, utilización de servicios sanitarios y datos demográficos. La proyección sobre el plano factorial formado por los dos primeros ejes factoriales, que recogió el 55% de la variación global, permitió hacer una agrupación tentativa de los estratos. Así pues, este análisis factorial sugirió mantener los distritos I y V en sendos pseudoestratos, agrupar por proximidad los distritos VII, VIII y IX, y poner en otra agrupación al resto de distritos. Con todo ello se consiguieron cuatro «pseudo-distritos» con cuatro tipos de familia en cada uno de ellos, que dieron lugar a los dieciséis pseudoestratos finales.

Como la ESB-86 se basaba en la elección de familias y en la encuesta a todos sus miembros, debemos tener en cuenta que las unidades muestrales primarias no son los individuos sino las familias. Para eliminar un elemento o grupo de elementos de la muestra, para calcular —según el procedimiento *Jackknife*— el estadístico sin aquel elemento o grupo de elementos, hemos separado todos los miembros de la familia o grupo de familias involucradas. Cabe destacar que los efectos que pueden causar los conglomerados sobre el cálculo de las varianzas se introducen al tener presente la consideración anterior.

A continuació es presenten les taules de creuaments que hem tractat en aquest treball. Els resultats són陪伴nys de les estimacions de la variància d'aquesta mitjana o proporció. Les tres estimacions corresponen a cadascun dels mètodes assenyalats, de manera que: *Var SRS* correspon al cas de suposar en els càlculs que la mostra és aleatoria simple; *Var STR* indica que en el càlcul de la variància s'ha inclòs l'efecte de l'estratificació feta en el disseny mostral inicial però ignorant l'efecte conglomerat d'aquest disseny. Finalment, *Var JKN* fa referència a l'estimació feta amb el mètode *Jackknife* que incorpora tot el disseny mostral. Al costat d'aquest últim resultat es presenta l'error estàndard que correspon a l'arrel quadrada de *Var JKN*. En totes les taules es proporcionen també els marginals per sexe, si escau, i els totals.

Los resultados se presentan mediante tablas que incluyen las medianas o las proporciones de las variables seleccionadas para este estudio acompañadas de las estimaciones de sus varianzas según los tres métodos descritos. Las varianzas analizadas son las siguientes: *Var SRS* corresponde al caso de suponer en los cálculos que la muestra es aleatoria simple; *Var STR* indica que en el cálculo de la varianza se ha incluido el efecto de la estratificación del diseño muestral inicial pero ignorando el efecto conglomerado de este diseño. Finalmente, *Var JKN* hace referencia a la estimación realizada por el método *Jackknife* que incorpora la totalidad del diseño. Junto a este último resultado se presenta el error estándar que corresponde a la raíz cuadrada de *Var JKN*. Para todas las tablas se proporcionan también los marginales por sexo, en su caso, y los totales.

**Taula 1. Mitjana del nombre de dies amb restricció de les activitats habituals per persona i any**

**Tabla 1. Media del número de días con restricción de las actividades habituales por persona y año**

EDAT / EDAD		HOMES / HOMBRES	DONES / MUJERES
< 15	valor	12,63	11,97
	var srs	3,77	3,68
	var str	3,75	3,66
	var jkn	4,42 e.s. 2,10	5,11 e.s. 2,26
15-44	valor	5,90	9,54
	var srs	1,06	1,58
	var str	1,07	1,59
	var jkn	1,11 e.s. 1,05	1,53 e.s. 1,27
45-64	valor	10,78	15,75
	var srs	3,72	4,42
	var str	3,72	4,43
	var jkn	3,57 e.s. 1,89	4,34 e.s. 2,08
≥ 65	valor	19,03	25,21
	var srs	14,43	12,66
	var str	14,43	12,69
	var jkn	13,55 e.s. 3,68	12,32 e.s. 3,51
TOTES / TODAS	valor	10,12	14,03
	var srs	0,75	0,99
	var str	0,80	0,99
	var jkn	0,81 e.s. 0,91	1,13 e.s. 1,06
TOTAL	valor	12,20	
	var srs	0,32	
	var str	0,45	
	var jkn	0,48 e.s. 0,69	

var srs = variància com a mostreig aleatori simple

varianza como muestreo aleatorio simple

var str = variància com a mostreig estratificat

varianza como muestreo estratificado

var jkn = variància pel mètode Jackknife

varianza por el método Jackknife

e.s. = error estàndard

error estándar

**Taula 2. Percentatge de persones que declaren algun trastorn crònic dels presents a l'enquesta**

**Tabla 2. Porcentaje de personas que declaran algún trastorno crónico de los incluidos en la encuesta**

EDAT / EDAD		HOMES / HOMBRES	DONES / MUJERES
< 15	valor	25,33	20,93
	var srs	2,77	2,34
	var str	2,78	2,34
	var jkn	2,93 e.s. 1,71	2,46 e.s. 1,57
15-44	valor	39,70	51,22
	var srs	1,80	1,70
	var str	1,80	1,66
	var jkn	1,83 e.s. 1,35	1,74 e.s. 1,32
45-64	valor	70,02	80,95
	var srs	2,48	1,70
	var str	2,45	1,63
	var jkn	2,36 e.s. 1,54	1,49 e.s. 1,22
≥ 65	valor	84,22	90,34
	var srs	3,56	1,50
	var str	3,60	1,50
	var jkn	3,43 e.s. 1,85	1,49 e.s. 1,22
TOTES / TODAS	valor	49,75	58,94
	var srs	0,72	0,66
	var str	0,74	0,60
	var jkn	0,79 e.s. 0,89	0,68 e.s. 0,82
TOTAL	valor	54,62	
	var srs	0,25	
	var str	0,33	
	var jkn	0,43 e.s. 0,66	

var srs = variància com a mostreig aleatori simple

varianza como muestreo aleatorio simple

var str = variància com a mostreig estratificat

varianza como muestreo estratificado

var jkn = variància pel mètode Jackknife

varianza por el método Jackknife

e.s. = error estàndard

error estándar

## Resultats

Les taules 1 a 6 presenten les estimacions de les variàncies dels estadístics que apareixen en les corresponents capçaleres. Les taules inclouen les estimacions pels tres mètodes esmentats en l'apartat metodologia del treball.

Tal com indicàvem, la variància estimada pel mètode *Jackknife* és acompañada del seu corresponent error estàndard, que facilita el càlcul immediat dels intervals de confiança. Així, per exemple, un interval al 95% de confiança per la mitjana del nombre de dies amb restricció de les activitats habituals (taula 1) per persona i any en les dones menors de 15 anys, serà donat per:

$$11,97 \pm 1,96 \times 2,26 = (7,54, 16,40)$$

En relació a aquesta mitjana podem notar que si hagués-

**Taula 3. Percentatge de persones que tenen cobertura sanitària amb la Seguretat Social**

**Tabla 3. Porcentaje de personas que tienen cobertura sanitaria con la Seguridad Social**

EDAT / EDAD					
< 15	valor	91,56			
	var srs	0,55			
	var str	0,55			
	var jkn	1,26	e.s. 1,12		
15-44	valor	90,73			
	var srs	0,28			
	var str	0,30			
	var jkn	0,55	e.s. 0,74		
45-64	valor	93,12			
	var srs	0,37			
	var str	0,36			
	var jkn	0,51	e.s. 0,71		
≥ 65	varlos	89,39			
	var srs	1,00			
	var str	0,99			
	var jkn	1,34	e.s. 1,16		
TOTES / TODAS	valor	91,32			
	var srs	0,081			
	var str	0,115			
	var jkn	0,336	e.s. 0,580		

var srs= variància com a mostreig aleatori simple

varianza como muestreo aleatorio simple

var str= variància com a mostreig estratificat

varianza como muestreo estratificado

var jkn= variància pel mètode Jackknife

varianza por el método Jackknife

e.s.= error estàndard

error estándar

## Resultados

En las tablas 1 a 6 se presentan las estimaciones de las varianzas de los estadísticos que aparecen en las correspondientes cabeceras. Las tablas incluyen las estimaciones por los tres métodos mencionados en el apartado metodológico del trabajo.

Tal como indicábamos, la varianza estimada por el método *Jackknife* se acompaña de su correspondiente error estandar lo que facilita el cálculo inmediato de los intervalos de confianza. Así, por ejemplo, un intervalo al 95% de confianza para la media del número de días con restricción de las actividades habituales por persona y año (tabla 1) en las mujeres menores de 15 años vendrá dado por:

$$11,97 \pm 1,96 \times 2,26 = (7,54, 16,40)$$

En relación a esta media podemos resaltar que tanto si

**Taula 4. Mitjana de visites mèdiques per persona i any**

**Tabla 4. Media de visitas médicas por persona y año**

EDAT / EDAD		HOMES / HOMBRES		DONES / MUJERES	
< 15	valor	3,23		3,18	
	var srs	0,063		0,041	
	var str	0,062		0,039	
	var jkn	0,061	e.s. 0,247	0,043	e.s. 0,207
15-44	valor	1,68		2,52	
	var srs	0,012		0,012	
	var str	0,012		0,012	
	var jkn	0,012	e.s. 0,110	0,012	e.s. 0,119
45-64	valor	3,46		4,52	
	var srs	0,070		0,083	
	var str	0,073		0,080	
	var jkn	0,073	e.s. 0,270	0,079	e.s. 0,281
≥ 65	valor	6,02		6,01	
	var srs	0,288		0,149	
	var str	0,274		0,148	
	var jkn	0,253	e.s. 0,503	0,146	e.s. 0,382
TOTES / TODAS	valor	2,97		3,69	
	var srs	0,013		0,012	
	var str	0,014		0,012	
	var jkn	0,015	e.s. 0,122	0,013	e.s. 0,114
TOTAL		valor	3,36		
		var srs	0,005		
		var str	0,007		
		var jkn	0,008	e.s. 0,089	

var srs= variància com a mostreig aleatori simple

varianza como muestreo aleatorio simple

var str= variància com a mostreig estratificat

varianza como muestreo estratificado

var jkn= variància pel mètode Jackknife

varianza por el método Jackknife

e.s.= error estàndard

error estándar

**Taula 5. Percentatge de persones que declaren haver estat visitades pel metge en l'últim any**

**Tabla 5. Porcentaje de personas que declaran haber sido visitadas por el médico en el último año**

EDAT / EDAD	HOMES / HOMBRES	DONES / MUJERES
< 15	valor 79,29 var srs 2,43 var str 2,28 var jkn 2,50 e.s. 1,58	79,55 2,30 2,14 2,37 e.s. 1,54
15-44	valor 55,49 var srs 1,88 var str 1,89 var jkn 2,03 e.s. 1,42	68,46 1,46 1,46 1,52 e.s. 1,23
45-64	valor 65,48 var srs 2,69 var str 2,72 var jkn 2,59 e.s. 1,61	76,20 2,02 2,02 1,96 e.s. 1,40
≥ 65	valor 78,44 var srs 4,56 var str 4,60 var jkn 4,41 e.s. 2,10	79,93 2,77 2,73 2,66 e.s. 1,64
TOTES / TODAS	valor 65,80 var srs 0,64 var str 0,64 var jkn 0,70 e.s. 0,91	74,31 0,52 0,52 0,59 e.s. 0,78
TOTAL	valor 70,34 var srs 0,21 var str 0,30 var jkn 0,43 e.s. 0,66	

var srs= variància com a mostreig aleatori simple

varianza como muestreo aleatorio simple

var str= variància com a mostreig estratificat

varianza como muestreo estratificado

var jkn= variància pel mètode Jackknife

varianza por el método Jackknife

e.s.= error estàndard

error estándar

sim utilitzat les estimacions corresponents al càlcul com si la mostra hagués estat aleatòria simple, o estratificada, els intervals de confiança obtinguts serien, respectivament:

$$11,97 \pm 1,96 \times 1,92 = (8,21, 15,73)$$

$$11,97 \pm 1,96 \times 1,91 = (8,22, 15,72)$$

Com es pot apreciar amb la lectura de les taules, les diferències entre les variàncies estimades per un o altre mètode no sempre tenen la mateixa magnitud ni el mateix sentit. Aquest fet no ha de sorprendre si tenim en compte que els efectes del cluster són desiguals segons en quina casella actuem i en relació a quina variable ens estem referint. Així, per exemple, les variàncies obtingudes pel mètode *Jackknife* són sensiblement menors que les calculades com si fos una mostra aleatòria simple —Var SRS— o amb

**Taula 6. Mitjana dels anys d'educació per als majors de 15 anys**

**Tabla 6. Media de años de educación para los mayores de 15 años**

EDAT / EDAD	HOMES / HOMBRES	DONES / MUJERES
15-44	valor 12,15 var srs 0,016 var str 0,015 var jkn 0,017 e.s. 0,130	11,59 0,014 0,013 0,015 e.s. 0,128
45-64	valor 9,07 var srs 0,036 var str 0,034 var jkn 0,034 e.s. 0,184	7,45 0,023 0,022 0,020 e.s. 0,141
≥ 65	valor 7,97 var srs 0,075 var str 0,072 var jkn 0,065 e.s. 0,255	5,87 0,039 0,039 0,037 e.s. 0,192
TOTES / TODAS	valor 10,51 var srs 0,011 var str 0,011 var jkn 0,70 e.s. 0,110	9,20 0,008 0,009 0,009 e.s. 0,095
TOTAL	valor 9,81 var srs 0,005 var str 0,005 var jkn 0,007 e.s. 0,084	

var srs= variància com a mostreig aleatori simple

varianza como muestreo aleatorio simple

var str= variància com a mostreig estratificat

varianza como muestreo estratificado

var jkn= variància pel mètode Jackknife

varianza por el método Jackknife

e.s.= error estàndard

error estándar

hubiésemos utilizado las estimaciones correspondientes al cálculo como si la muestra hubiese sido aleatoria simple, o estratificada, los intervalos de confianza serían, respectivamente:

$$11,97 \pm 1,96 \times 1,92 = (8,21, 15,73)$$

$$11,97 \pm 1,96 \times 1,91 = (8,22, 15,72)$$

Como se puede apreciar de la lectura de las tablas, las diferencias entre las varianzas estimadas por uno u otro método no siempre tienen la misma magnitud ni el mismo sentido. Este hecho no debe sorprendernos si tenemos en cuenta que los efectos de los conglomerados son desiguales según en qué casilla nos encontramos y en relación a qué variable nos estemos refiriendo. Así, por ejemplo, las varianzas obtenidas por el método *Jackknife* son sensiblemente menores que las calculadas como si tuviésemos una mues-

l'expressió de manual per a una estratificació —*Var STR*—, en l'estimació que correspon a homes i dones de 45 a 64 anys i de 65 anys o més, per a les variables «mitjana del nombre de dies amb restricció de les activitats habituals» (taula 1), «percentatge del nombre de persones que declaren algun trastorn crònic» (taula 2), «mitjana del nombre de visites mèdiques per persona i any» (taula 4), i «percentatge del nombre de persones que declaren haver estat visitades pel metge en l'últim any» (taula 5). D'altra banda, hem trobat notables diferències en estimar les variàncies del percentatge del nombre de persones cobertes per la Seguretat Social (taula 3): la variància estimada pel mètode *Jackknife* és, segons els casos, d'un 30% a un 60% més elevada que la calculada pels mètodes simplificats. La raó d'aquestes diferències no és altra que les conseqüències conegeudes i esperades dels efectes dels conglomerats<sup>7</sup>. En les caselles de les taules de creuament es veu com varien aquests efectes. Quan es miren totals i marginals és quan les conseqüències del procés de formació de conglomerats en el disseny de la mostra són més fortes. En efecte, en aquest cas tractem individus que pertanyen al mateix conglomerat, mentre que en els diferents grups d'edat i sexe, és molt plausible pensar que els conglomerats (famílies) han quedat desagregats. Per exemple, en el grup de dones de més de 65 anys, és difícil que hi hagi famílies que tinguin un nombre elevat de membres d'aquesta categoria i per tant l'efecte dels conglomerats és menor i àdhuc inexistente.

## Discussió

La configuració de l'enquesta de salut de l'Ajuntament de Barcelona-1986 aconsella l'estimació de les variàncies dels paràmetres estimats (mitjanes, proporcions, totals, etc.) per mètodes que tinguin en compte el disseny de la mostra i garanteixin les propietats desitjables en tot bon estimador. En aquest treball es presenten els resultats de les variàncies estimades per un mètode basat en la formació artificial de grups aleatoris, juntament amb els que proporcionen altres mètodes d'aplicació directa de fórmules de manual que no recullen precisament els possibles efectes del disseny mostral. El primer d'aquests procediments, és a dir, el mètode *Jackknife* conduce a resultats més acurats amb un cost addicional de computació assumible en una enquesta de grans dimensions.

Hem trobat algunes diferències substancials en emprar aquest mètode de càcul en relació al que podria ésser una expressió més senzilla per a l'obtenció de les variàncies de proporcions i mitjanes. Aquestes diferències són molt més acusades en algunes caselles de les taules de doble entrada que s'ofereixen en el text i acostumen a coincidir amb col·lectius en què les conseqüències dels efectes del disseny de la mostra són més acusats. Per exemple, en els totals, on tenim la mostra sencera és on es veuen més cla-

tra aleatoria simple —*Var SRS*— o con estratificació —*Var STR*—, en la estimación que corresponde a hombres y mujeres de 45 a 64 años y de 65 años o más, para las variables «media del número de días con restricción de las actividades habituales» (tabla 1), «porcentaje del número de personas que declaran algún trastorno crónico» (tabla 2), «media del número de visitas médicas por persona y año» (tabla 4) y «porcentaje del número de personas que declaran haber sido visitadas por un médico en el último año» (tabla 5). Por otro lado, hemos encontrado notables diferencias al estimar las varianzas del porcentaje del número de personas que tienen cobertura por la Seguridad Social (tabla 3): la varianza estimada por el método *Jackknife* es de un 30% a un 60% más elevada que la calculada por los métodos simplificados. La razón de estas diferencias no es otra que las consecuencias conocidas y esperadas de los efectos de los conglomerados<sup>7</sup>. En las casillas de las tablas de cruzamiento se observa cómo varían estos efectos. Cuando se observan los totales o los marginales es cuando las consecuencias del proceso de formación de conglomerados en el diseño de la muestra son más fuertes. En efecto, en este caso tratamos individuos que pertenecen al mismo conglomerado, mientras que para los distintos grupos de edad y sexo es muy plausible pensar que los conglomerados (familias) hayan quedado desagregados. Por ejemplo, para el grupo de las mujeres de más de 65 años, es difícil que existan muchas familias que tengan un número elevado de miembros de esta categoría y por lo tanto el efecto de los conglomerados es menor e incluso inexistente.

## Discusión

La configuración de la encuesta de salud del Ayuntamiento de Barcelona —1986— aconseja la estimación de las varianzas de los parámetros estimados (medias, proporciones, totales, etc.) por métodos que tengan en cuenta el diseño de la muestra y garanticen las propiedades deseables en todo buen estimador. En este trabajo se presentan los resultados de las varianzas estimadas por un método basado en la formación artificial de grupos aleatorios, juntamente con los que proporcionan otros métodos de aplicación directa de fórmulas de manual que no recogen precisamente los posibles efectos del diseño muestral. El primero de estos procedimientos, es decir, el método *Jackknife* conduce a resultados más precisos con un coste adicional de computación asumible en una encuesta de grandes dimensiones.

Hemos hallado algunas diferencias sustanciales empleando este método de cálculo en relación a lo que podría ser una expresión más sencilla para la obtención de las varianzas de proporciones y medias. Dichas diferencias son mucho más acusadas en algunas casillas de las tablas de doble entrada que se ofrecen en el texto y vienen a coincidir con colectivos donde las consecuencias de los efectos del diseño muestral son más acusados. Por ejemplo, para los totales, donde se tiene la muestra entera, es cuando se reflejan

rament aquestes diferències entre els mètodes. Aquí es produeix el dilema, per altra banda sempre present en tot protocol per a la realització d'una enquesta per mostreig, entre la reducció del cost d'obtenció de la informació i l'afany de garantir un cert nivell de precisió en l'estimació dels paràmetres. Un cop fixada una determinada grandària muestral, el procés d'estratificació permet, entre altres objectius, millorar la precisió en l'estimació dels paràmetres poblacionals. D'altra banda, la decisió de fer un disseny muestral que consisteixi en la definició de clusters (les unitats familiars en el cas de l'ESB-86) i en l'observació de tots els elements d'aquells clusters que hagin resultat seleccionats (entrevistar tots els membres de les famílies escollides), significa el convenciment que aquest procediment reduirà el cost de l'obtenció de la informació, malgrat que això suposi també una pèrdua de variabilitat, és a dir, de riquesa informativa.

Els resultats insinuen dues conclusions que cal tenir en compte: en àmbits de recollida d'informació com el de l'ESB-86, els efectes de l'estratificació no són excessivament importants en la mesura que no apreciem reduccions considerables en les variàncies estimades. Les diferències entre *Var SRS* i *Var STR*, casella a casella, són efectivament reduïdes, és a dir, que les conseqüències de l'estratificació per districte i grandària familiar no s'han traduit en estimacions de les mitjanes i de les proporcions amb intervals de confiança molt més reduïts. Per altra banda, el fet que les unitats primàries de mostreig (famílies) no coincideixin amb les unitats estudiades (individus) si bé pot comportar una disminució del cost del treball de recollida d'informació, comporta que els efectes del conglomerat són més apreciables en tractar variables en les quals s'espera un comportament homogeni en totes les persones que pertanyen al conglomerat. En qualsevol cas es fa difícil, i seria una pràctica poc recomanable, anticipar apriorísticament el sentit i la magnitud del biaix que en l'estimació de les variàncies es produiria si utilitzéssim una expressió que no tingués en compte l'efecte del conglomerat. Com ja hem esmentat, en presència de dissenys mostrals complexos, el mètode *Jackknife* permet estimacions de les variàncies amb més cura, la qual cosa permet d'analitzar les característiques estadístiques dels paràmetres poblacionals estimats amb més precisió. Aquest fet és prou important en la interpretació que pot fer-se dels resultats d'una taula de freqüències obtingudes amb dades mostrals provinents de dissenys complexos.

más claramente estas diferencias entre los distintos métodos. Aquí es donde se presenta el dilema, por otro lado siempre latente en todo protocolo para la realización de una encuesta por muestreo, entre la reducción del coste de obtención de la información y el afán de garantizar un cierto nivel de precisión en la estimación de los parámetros. Fijado un determinado tamaño muestral, el proceso de estratificación permite, entre otros objetivos, mejorar la precisión en la estimación de los parámetros poblacionales. Por otra parte, la decisión de hacer un diseño muestral que consista en la definición de conglomerados (las unidades muestrales en el caso de la ESB-86) y en la observación de todos los elementos de aquellos conglomerados que hayan sido seleccionados (entrevistar a todos los miembros de las familias elegidas) significa el convencimiento de que este procedimiento reducirá el coste de la obtención de la información, aunque ello suponga también una pérdida de la variabilidad, es decir, de riqueza informativa.

Los resultados insinúan dos conclusiones a tener en cuenta: en ámbitos de recogida de información como el de la ESB-86, los efectos de la estratificación no son excesivamente importantes en la medida en que no se aprecian reducciones considerables en las varianzas estimadas. Las diferencias entre *Var SRS* y *Var STR*, casilla a casilla, son efectivamente reducidas, es decir, que las consecuencias de la estratificación por distrito y tamaño familiar no se han traducido en estimaciones de las medias y de las proporciones con intervalos de confianza mucho más reducidos. Por otra parte, el hecho de que las unidades primarias de muestreo (familias) no coincidan con las unidades estudiadas (individuos) si bien puede comportar una disminución del coste del trabajo de recogida de la información implica, en el peor de los casos, una pérdida de precisión y la necesidad de utilizar procedimientos de cálculo más complejos. Cabe destacar que los efectos de los conglomerados son más apreciables al tratar variables en las que se espera un comportamiento homogéneo para todas las personas que pertenecen a un mismo conglomerado. En cualquier caso se hace difícil, y sería una práctica poco recomendable, anticipar apriorísticamente el sentido y la magnitud de sesgo que en la estimación de las varianzas se produciría al utilizar una expresión que no tuviese en cuenta el efecto de los conglomerados. Como ya hemos dicho, en presencia de diseños muestrales complejos, el método *Jackknife* permite realizar estimaciones de las varianzas con mayor rigor, lo cual permite analizar las características estadísticas de los parámetros poblacionales estimados con mayor precisión. Este hecho es suficientemente importante en la interpretación que puede hacerse de los resultados de una tabla de frecuencias obtenidas con datos obtenidos a partir de un diseño muestral complejo.

#### Bibliografia

1. Alonso J, Antó J M. *Enquesta de Salut de Barcelona 1986*. Barcelona: Area de Salut Pública, Ajuntament de Barcelona, 1989.
2. Cochran W G. *Sampling Techniques*. New York: John Wiley and Sons, 1977.

3. Wolter K M. *Introduction to Variance Estimation*. New York: Springer-Verlag, 1985.
4. Brillinger D R. The Assymptotic Behaviour of Tukey's General Method of Setting Approximate Confidence Intervals (the Jackknife) when Applied to Maximum Likelihood Estimates. *Rev Int Stat Institute* 1964; 32: 202-206.

5. Frankel M R. *Inference from Survey Samples*. Ann Arbor: Institute for Social Research, University of Michigan, 1971.
6. Efron B. *The Jackknife, the Bootstrap and Other Resampling Plans*. Philadelphia: Society for Industrial and Applied Mathematics, 1982.
7. Kish L, Frankel M R. Balanced Repeated Replications for Standard Errors. *J Am Stat Ass* 1970; 65: 1.071-94.
8. Quenouille M H. Approximate Tests of Correlation in Time Series. *J Roy Stat Soc* 1949; b 11: 68-84.
9. Mulry M H, Wolter K M. The effects of Fisher's Z-transformation on Confidence Intervals for the Correlation Coefficient. En: *Proceedings of the Survey Research Section*, American Statistical Association, 1981.
10. Jones H L. Jackknife Estimation of Functions of Strata Means. *Biometrika* 1974; 61: 343-348.
11. Murillo C, Guillén M. *Mètodes de construcció de grups aleatoris en l'estimació de la variància dels paràmetres de mitjanes i proporcions de les variables de l'ESB (86)*. Mimeo. Facultat d'Econòmiques, Universitat de Barcelona, 1988.
12. Alonso J, Ruigómez A, Antó JM. *La Salut a Barcelona 1986. Informe del Regidor de Sanitat al Consell Plenari 23 de desembre de 1986*. Barcelona: Àrea de Salut Pública, Ajuntament de Barcelona, 1987.

