

Estabilidad dinámica de un modelo factorial para la pobreza multidimensional en Argentina

Dynamic stability of a factorial model for
multidimensional poverty in Argentina
*Estabilidade dinâmica de um modelo fatorial
para pobreza multidimensional na Argentina*

Ana Paula Satorres Bechara

*Universidad Nacional de Córdoba,
Argentina*

E-mail: anapaulasatorres@gmail.com

Resumen

Fecha de recepción: 01/12/2020
Fecha de aceptación: 28/01/2021

Este trabajo examina la invarianza factorial longitudinal de un modelo para la pobreza multidimensional en Argentina hallado a través de métodos robustos de Análisis Factorial Exploratorio (AFE) y Análisis Factorial Confirmatorio (AFC).

Se utilizan los microdatos de la Encuesta Permanente de Hogares (EPH) de los cuartos trimestres de los años pertenecientes a dos periodos —2003 a 2006 y 2016 a 2019— seleccionados por ser representativos de fases diferentes del ciclo económico: recuperación y recesión. Se pretende de esta manera evaluar la invarianza factorial en dos sentidos: tanto para años consecutivos dentro un mismo contexto económico, como para periodos enmarcados en coyunturas diametralmente opuestas.

A través del AFE y el AFC se hallan, para ambos periodos, tres dimensiones que subyacerían a la pobreza en Argentina, que fueron denominados ingresos, vivienda y entorno.

El nivel máximo de invarianza alcanzado para años consecutivos dentro de un mismo contexto fue la invarianza débil, nivel que asegura que las cargas factoriales sean constantes año a año. Por su parte, la evaluación entre periodos alcanzó como máximo nivel la invarianza configuracional, asegurándose únicamente la igualdad en la estructura factorial de un periodo a otro.

Palabras clave

- Pobreza Multidimensional
- Invarianza Longitudinal
- Análisis Factorial
- Argentina

Estos resultados no son triviales ya que condicionan los estudios dinámicos de pobreza multidimensional, restringiendo las conclusiones a las que pueden arribarse al comparar los resultados de la misma de un año a otro, y más aún entre contextos diferentes.

Abstract

This paper examines the longitudinal factor invariance of a model for analyzing multidimensional poverty in Argentina, found by using robust methods of exploratory factor analysis (EFA) and confirmatory factor analysis (CFA).

We used microdata from the fourth trimesters of the nationwide survey Encuesta Permanente de Hogares (EPH), gathered for two time intervals (from 2003 to 2006 and from 2016 to 2019), specifically chosen because they represent two different stages of the economic cycle: recovery and recession. By studying this, we attempt to evaluate factor invariance in two ways: both for consecutive years in the same economic context and for time frames in entirely different contexts.

Through EFA and CFA, for both time frames, three dimensions were found to underlie poverty in Argentina: income, housing and environment.

The highest level of invariance achieved for consecutive years in the same context was weak invariance, a level that assures that factor loadings will remain constant year after year. On the other hand, the evaluation of invariance among different time frames, in its highest level, got to configural invariance, where equality was only present in the factor structure from one time frame to another.

These results are not trivial as they condition the dynamic studies of multidimensional poverty, restricting the possible conclusions when comparing results from one year to the other and, moreover, in different time frames.

Keywords

- Multidimensional Poverty
- Factorial Analysis
- Longitudinal Factorial Invariance
- Argentina

Resumo

O presente trabalho examina a invariância fatorial longitudinal de um modelo para a pobreza multidimensional na Argentina achado através de métodos robustos de análise fatorial exploratória (AFE) e análise fatorial confirmatória (AFC).

São utilizados os microdados da Encuesta Permanente de Hogares (EPH)¹ dos quartos trimestres dos anos pertencentes a dois períodos - de 2003 a 2006 e de 2016 a 2019 - escolhidos por serem representativos de diferentes fases do ciclo econômico: recuperação e recessão Assim,

(1) NdT: Programa Nacional de produção sistemática e permanente de indicadores sociais feita pelo INDEC (Instituto Nacional de Estadística y Censos de la República Argentina) que permite conhecer as características sócio-demográficas e socioeconômicas da população.

pretende-se avaliar a invariância fatorial em dois sentidos: tanto para anos consecutivos dentro de um mesmo contexto econômico quanto para períodos enquadrados em conjunturas diametralmente opostas.

Através da AFE e da AFC encontram-se, para ambos períodos, três dimensões que fundamentam a pobreza na Argentina, que foram denominados: renda, moradia e meio ambiente.

O nível máximo de invariância alcançado para anos consecutivos dentro do mesmo contexto foi a invariância fraca, nível que garante que as cargas fatoriais sejam constantes ano a ano. Por sua vez, a avaliação entre períodos atingiu como máximo nível a invariância configuracional, garantindo apenas a igualdade na estrutura fatorial de um período para o outro.

Esses resultados não são triviais, pois condicionam os estudos dinâmicos de pobreza multidimensional, restringindo as conclusões às que pode se chegar comparando os resultados de um ano para o outro, e ainda mais entre diferentes contextos.

Palabras-chave

- Pobreza Multidimensional
- Invariância Longitudinal
 - Análise Fatorial
 - Argentina

1. Introducción

El estudio de la pobreza concierne a investigadores de todas las áreas desde tiempos remotos. Su comprensión y medición son esenciales a la hora de llevar a cabo políticas públicas destinadas a erradicarla. Sin embargo, a pesar de ser un concepto tan estudiado, no se ha llegado aún a un acuerdo respecto de su definición estricta.

Si bien todas las definiciones relacionan el concepto a cierta situación de desventaja de las personas que la padecen, en esta discusión han surgido distintos enfoques. Uno de ellos ha estudiado la pobreza como un concepto absoluto, entendido como la falta de los medios indispensables para la subsistencia, independientemente del contexto. Otro, en cambio, ha comprendido a la misma como algo relativo al lugar y tiempo en que se esté midiendo. En este sentido, Townsend (1979) define a una persona pobre como aquella excluida de las actividades, costumbres y patrones de vida comunes en la sociedad a la que pertenece.

La discusión no termina allí. No solo hay falta de consenso respecto a su definición, sino también a

su medición. La forma más difundida de medir la pobreza (quizá por su simplicidad y facilidad de comprensión) ha sido mediante su entendimiento en términos monetarios: una persona es pobre si su ingreso no supera cierto nivel mínimo necesario para adquirir una canasta básica de bienes.

Sin embargo, existen convincentes argumentos que sugieren comprender la pobreza como una noción que va más allá del aspecto monetario y considerar (por lo tanto también medir) otras dimensiones del concepto.

La principal línea argumentativa que se utiliza para justificar la pobreza multidimensional es el enfoque de las capacidades de Amartya Sen. El premio Nobel propone medir la pobreza en términos de las *capacidades* que las personas poseen para elegir la vida que desean. Esas capacidades se ven reflejadas en la práctica en lo que denomina *funcionamientos*, que incluyen estar bien alimentado, bien vestido, sentirse integrado a la sociedad, tener libertad para moverse, entre otras. Sen define de este modo a la pobreza como

la falta de capacidades para alcanzar esos funcionamientos. Ahora bien, el ingreso monetario es solo una de esas capacidades, pero se requieren otras: salud, educación, vivienda. De esta manera, la definición de la pobreza se vuelve necesariamente multidimensional.

Al adoptar este último enfoque, la discusión toma un nuevo rumbo: ¿cuáles son esas dimensiones que caracterizan a la pobreza? El primer objetivo de este trabajo es hallarlas. La tarea no es sencilla dada la naturaleza no observable de lo que se quiere estudiar. Sin embargo, se puede asumir que dichas dimensiones se manifiestan a través de ciertos indicadores que sí podemos observar. Basándonos en este supuesto, la metodología propuesta para alcanzar tal fin es el Análisis Factorial (AF), técnica reductora de datos que permite justamente determinar si detrás de una serie de variables observables existe en realidad una variable latente, no observable, que las explica.

Al proponer una medición multidimensional de la pobreza como una alternativa a la actual medición monetaria, debemos aseverar su efectiva utilidad. Si se logra encontrar un modelo de medida para la pobreza y se desea comenzar a utilizarlo para medirla, debemos asegurarnos que ese modelo no varíe en el tiempo. Si las variables latentes y sus indicadores halladas para un corte transversal determinado no permanecen constantes para otros cortes, el seguimiento de la pobreza en el tiempo se obstaculiza. Si de un momento a otro el valor que se encuentra para alguna dimensión cambia, ¿estamos seguros que el cambio se debe a un cambio en la pobreza? ¿o puede deberse, en su lugar, a cambios en la forma de medir ese constructo?

El segundo objetivo del trabajo está influido por la noción relativa de la pobreza. La línea argumentativa liderada por Townsend sugiere que, con el paso del tiempo, el nivel de vida que una persona debe alcanzar para no ser pobre puede cambiar debido a que se modifique el contexto en que está envuelto. Cabe preguntarse entonces: ¿pueden las dimensiones de la pobreza y sus indicadores ir

variando de acuerdo con los cambios en las condiciones económicas y sociales?

El análisis que se llevará a cabo para responder a esa pregunta es la verificación de *invarianza factorial longitudinal*. Si la invarianza longitudinal no se verifica, entonces los cambios observados a lo largo del tiempo pueden estar reflejando cambios en *lo que está siendo medido*, en lugar de en el *nivel* de ese constructo. La evaluación de la invarianza se vuelve crítica para poder derivar conclusiones válidas al estudiar la pobreza de manera dinámica y realizar recomendaciones de política económica correctamente fundamentadas.

Este trabajo es innovador en distintos sentidos. Por un lado, la gran mayoría antecedentes bibliográficos sobre pobreza multidimensional en Argentina ponen el foco en la agregación de distintos indicadores en un índice que los sintetice y permita la medición de la misma, como son los de Alkire–Foster y Bourguignon–Chakravarty. Sin embargo, poca es la importancia que se otorga a la selección de los indicadores que conforman ese índice, careciendo en su mayoría de un análisis estadístico y realizándose de manera *ad hoc*. Este trabajo presta la debida atención a dicha selección de indicadores y dimensiones, acompañando la teoría con el correspondiente análisis estadístico, y teniendo en consideración los supuestos que se violan y haciendo las correcciones necesarias.

Por otro lado, este trabajo analiza la estabilidad en el tiempo de dichas dimensiones, condición necesaria para hacer comparaciones válidas de las mediciones de la pobreza a lo largo del tiempo. Si bien Conconi (2011) realiza cierto estudio longitudinal de la pobreza multidimensional ya que selecciona cuatro años distintos para llevar a cabo el análisis, lo hace aplicando el análisis de componentes principales (ACP). A pesar de que esta, al igual que el AF, es una técnica reductora de datos, los supuestos subyacentes a cada una de ellas difieren, y por lo tanto también las conclusiones a las que se arriban. Mientras que para el ACP las variables observables son las variables indepen-

dientes del modelo, para el AF son las dependientes. Esto implica que la dirección de las relaciones indicador–dimensión es opuesta.

Por último, si bien Fagnola & Moneta (2019) realizan una correcta aplicación de AF para la determinación de las dimensiones, este análisis es estático ya que considera una única onda de la Encuesta Permanente de Hogares (EPH) para llevar a cabo el mismo. El presente trabajo puede considerarse una extensión de la metodología aplicada por dichos autores, ampliando el análisis para tener en cuenta el aspecto dinámico del fenómeno bajo estudio.

El trabajo se estructurará de la siguiente manera. En primer lugar, se realizará una breve revisión de los principales enfoques para estudiar la pobreza. A continuación, nos centraremos en el enfoque multidimensional, en donde se propondrá una serie de posibles dimensiones de la pobreza con sus correspondientes indicadores observables. Las secciones posteriores se centrarán en el análisis estadístico. Se introducirán los datos que se utilizarán, la metodología que se llevará a cabo y los resultados obtenidos.

2. Enfoques para estudiar la pobreza

La pobreza es uno de aquellos conceptos que, aun siendo fácil de reconocer y comprender intuitivamente, no así de sencillo es definirlo. A pesar de ser un fenómeno presente desde los inicios de la vida en sociedad, los investigadores no han llegado aún a un acuerdo respecto a la definición estricta del mismo. La búsqueda de este consenso conceptual es una tarea primordial, ya que la forma en que se defina el fenómeno tendrá implicancias en las políticas públicas destinadas a erradicarlo.

La forma más extendida de estudiar y medir la pobreza es entendiéndola como el estado de aquellas personas que no pueden alcanzar cierto nivel de vida medido en términos monetarios mediante un umbral conocido como línea de pobreza. La

línea de pobreza se define en como aquel ingreso mínimo necesario para cubrir las necesidades básicas de consumo de una persona. Este consumo incluye, además de una canasta de alimentos, otros bienes y servicios que hacen a ese nivel de vida mínimo.

Esta es la manera en que actualmente es medida la pobreza en Argentina por el Instituto Nacional de Estadísticas y Censos (INDEC). El INDEC define dos umbrales: una línea de indigencia y una línea de pobreza. La primera está dada por la Canasta Básica Alimentaria (mínimo consumo alimentario para cubrir las necesidades energéticas básicas), mientras que la segunda adiciona a la anterior otros bienes y servicios de consumo básicos, y se denomina Canasta Básica Total. Así, aquellos hogares cuyos ingresos no superen dichos umbrales son considerados indigentes o pobres respectivamente.

Este enfoque es unidimensional: considera que el único indicador del nivel de vida de una persona es su capacidad económica, dado por su ingreso monetario. Además, es también un enfoque absoluto. Es decir, la regla para decidir quién es pobre y quién no, no varía junto con las condiciones económicas generales. Haciendo alusión al carácter absoluto de la medida monetaria de la pobreza, Cicowiez, Gasparini & Sosa Escudero explican que «un individuo pobre es aquel con un conjunto de carencias monetarias específicas: la definición de ese conjunto es invariante al nivel de desarrollo de la sociedad en la que se miden las privaciones. De acuerdo con esta concepción, la línea de la pobreza permanece fija en términos reales en el tiempo» (2013:189).

En contraste, el enfoque relativo de la pobreza no considera que dicha regla sea constante, sino que es función del contexto que la envuelve. Townsend define la pobreza relativa de la siguiente manera: «Individuos, familias y grupos en la población pueden ser considerados en la pobreza cuando no poseen los recursos para obtener los tipos de dieta, participar en actividades y tener las condiciones de vida y comodidades que son comunes en la sociedad a la que pertenecen» (1979:31).

Es decir, esta perspectiva considera la pobreza como un concepto relativo a las condiciones de la sociedad en la que está siendo medida. Así, el concepto puede también cambiar con el tiempo, a medida que la sociedad se va desarrollando y el contexto cambia.

Un tercer enfoque es el de las capacidades, propuesto por Amartya Sen, que rompe con la dicotomía absoluta–relativa, y será la línea argumentativa que se tomará para fundamentar el presente trabajo.

Dos son los conceptos claves para entender el enfoque de Sen: las *capacidades* y los *funcionamientos*.² Las capacidades son todo aquello que un individuo es capaz de hacer o ser. Son las verdaderas libertades u oportunidades que posee una persona. Los funcionamientos, por su parte, son las realizaciones de esas capacidades. Son los «ser/estar» o «hacer». Las capacidades son todas las combinaciones alternativas de funcionamientos que son factibles de ser elegidas. Los funcionamientos son la combinación efectivamente elegida.

Con este planteo, la definición de pobreza toma otro rumbo. Sen define entonces la pobreza como la escasez de un conjunto básico de capacidades necesarias para alcanzar el nivel de vida que se desea, mientras que la riqueza se entiende en cambio como un conjunto de capacidades muy extenso.

En esta nueva manera de entender a la pobreza, la unidimensionalidad con que se la mide a través de la línea de pobreza se torna insuficiente. El ingreso monetario es una de las tantas capacidades que un individuo puede tener para alcanzar los funcionamientos básicos, pero no es el único. Una persona puede, aun teniendo los medios económicos, estar privado en otras capacidades que le impidan alcanzar ciertos funcionamientos, como estar integrado en la sociedad, tener una buena educación, tener libertades y derechos cívicos, etcétera.

3. Explorando la multidimensionalidad del fenómeno

La premisa de la multidimensionalidad de la pobreza impone un nuevo desafío consistente en determinar cuáles son estas dimensiones y mediante qué indicadores se manifiesta cada una.

El marco más extendido en América Latina para captar dicha multidimensionalidad es el enfoque de las Necesidades Básicas Insatisfechas (NBI) desarrollado por la CEPAL a comienzos de los años ochenta. El organismo propuso una serie de indicadores de privaciones en necesidades básicas que pudieran ser medidas en los países de América Latina, por lo que se restringió la selección de los mismos a la información censal disponible en esos países.

Otro de los avances teórico–metodológicos de medición multidimensional de la pobreza que destaca es la propuesta elaborada por OPHI (*Oxford Poverty & Human Development Initiative*) que es ampliamente reconocida y utilizada a nivel mundial. A nivel más local, por su parte, el Observatorio de la Deuda Social Argentina (ODSA) de la Universidad Católica Argentina (UCA) realiza su propia encuesta para elaborar un análisis multidimensional incorporando también indicadores de derechos sociales.

Todos estos estudios y mediciones, no obstante, llevan a cabo una selección de indicadores y dimensiones de manera arbitraria y sin ningún análisis estadístico que la respalde. Es tarea del presente trabajo aunar toda la teoría que dichos estudios han desarrollado con técnicas estadísticas que doten de mayor rigurosidad a dicha selección.

Dado que el marco teórico que respalda este trabajo es el enfoque de las capacidades de Sen, debe hacerse cierta aclaración antes de comenzar con la selección de indicadores. Este enfoque puede ser abordado de dos maneras: estudiando lo que un individuo *puede hacer o ser*, u observando aquello que *no puede hacer o ser*. De esta manera, la primera perspectiva centra

(2) En el idioma inglés original de las publicaciones de Sen, *capabilities and functionings*.

la atención en el espacio de capacidades y funcionamientos de un individuo. La segunda, en cambio, pone el foco en las privaciones que sufre una persona. Esta última forma de entender el enfoque es el que guiará la selección de indicadores en este trabajo.

La siguiente cuestión es decidir qué indicadores elegir. Al proponer el enfoque de Sen como norte del trabajo, se comienza a pensar en un gran universo de capacidades y privaciones de las mismas que se quisieran medir. Sin embargo, existe una gran restricción a ese universo: la disponibilidad de datos.

No existe en Argentina una encuesta enfocada en una medición multidimensional del bienestar que incluya indicadores relacionados con las distintas libertades constituyentes de las capacidades de una persona. La principal fuente de monitoreo de los aspectos socioeconómicos del país la constituye la EPH llevada a cabo por el INDEC trimestre a

trimestre. Es esta la fuente de información a la que se restringirá la selección de indicadores.

Continuando y ampliando la propuesta de Fagnola & Moneta (2019), se han seleccionado en este trabajo 18 indicadores, manifestaciones de 5 dimensiones que, en principio, se consideraban subyacentes a la pobreza multidimensional en Argentina.³ Estas dimensiones son: capacidad económica, infraestructura adecuada, ambiente, salud e inclusión social. La selección de las mismas está fuertemente guiada por lo expresado en los Objetivos de Desarrollo Sostenible por el Programa de Naciones Unidas para el Desarrollo.

La siguiente tabla detalla cada una de estas dimensiones, junto con las capacidades que se ven privadas dentro de ellas, los indicadores que representan esas privaciones y las variables de la EPH que se utilizan para construir cada indicador.

Tabla 1. Selección preliminar de dimensiones e indicadores

DIMENSIÓN	DESCRIPCIÓN ⁴	INDICADOR	VARIABLES EPH
Capacidad económica	Contar con capacidad para generar ingresos propios, estables y suficientes	ITF menor a CBT	P47T, ITF
		Jefe de hogar con primaria incompleta	CH03, NIVEL_ED
		Recibe ayuda externa	V5, V6, V7
Infraestructura adecuada	Tener vivienda adecuada y saneamiento básico	Piso de baja calidad	IV3
		Techo de baja calidad	IV4, IV5
		Vivienda no apta para habitar	IV1
		Sin cocina	II4_1
		Hacinamiento crítico ⁵	IX TOT, II2
		Falta de agua	IV6, IV7
Ambiente	Estar en un ambiente seguro	Sin baño adecuado	IV8, IV9, IV10, IV11
		Zona de basural	IV12_1
		Zona inundable	IV12_2
		Villa de emergencia	IV12_3

[Cont. pág. sgte.]

(3) Esta selección y clasificación es meramente preliminar, ya que es el AF lo que confirmará o rechazará esta propuesta.

(4) La forma en que se plantea sigue el enfoque de Sen: son aquellos «ser/estar» que conforman el universo de las capacidades.

(5) Se sigue el criterio de la OMS. Sea $i_{hacinam} = (\text{personas habitando una vivienda}) / (\text{número de dormitorios en la vivienda})$, se considera hacinamiento crítico cuando $i_{hacinam} \geq 5$.

DIMENSIÓN [CONT.]	DESCRIPCIÓN	INDICADOR	VARIABLES EPH
Salud	Gozar de buena salud	Sin cobertura médica	CH08
Inclusión social	Pertener a la institución social correspondiente al ciclo de vida al que se pertenece	Niño entre 5 y 17 años que no asiste a la escuela	CH06, CH10
		Joven entre 18 y 24 años que no estudie ni trabaje	CH06, CH10, ESTADO
		Adulto de entre 25 y 64 años que no trabaje	CH06, ESTADO
		Persona de tercera edad que no trabaje ni esté jubilada	CH06, ESTADO, CAT_INAC

Fuente: *Elaboración propia*

Las primeras cuatro dimensiones y sus indicadores son aquellas cuyo monitoreo cuenta con cierta tradición en Argentina y América Latina, ya que corresponden a los ingresos insuficientes (base de la definición de la pobreza monetaria) y a las Necesidades Básicas Insatisfechas.

La quinta dimensión es un tanto más novedosa y surge de la propuesta de Arévalo & Paz (2015). La idea directriz es que la vida de una persona puede dividirse en cuatro grandes etapas: la niñez, la juventud, la adultez y la tercera edad. Cada una de estas etapas del ciclo de vida tiene alguna institución clave a la que los individuos que transitan por la misma deberían pertenecer. Estas son: escolaridad, mercado laboral y seguridad social. De esta manera, puede entenderse a una persona excluida socialmente como aquella que no pertenece a la institución correspondiente a la fase del ciclo de vida por la que está transitando.

4. Datos

Como se mencionó, la fuente de datos a la que se restringe el presente trabajo son los microdatos de la EPH. Las ondas seleccionadas para el análisis fueron los cuartos trimestres de los años 2003–2006 y 2015–2019. La razón de los años seleccionados tiene origen en la naturaleza de la investigación: se quiere evaluar la invarianza del modelo

en el tiempo. Esta invarianza será testeada en dos sentidos. Primero se quiere estudiar la estabilidad del modelo en el tiempo para años consecutivos, sin grandes cambios estructurales. Luego, si la invarianza se cumple para años inmediatos, se quiere evaluar si se cumple también para periodos con contextos económicos diametralmente distintos. Es esta la justificación de los dos periodos seleccionados, que son representativos de fases de recuperación (2003–2006) y recesión económica (2015–2019).

Las variables de la EPH que han sido utilizadas se detallaron en la Tabla 1. Sin embargo, las mismas han sido trabajadas para transformarlas en variables dicotómicas. Dado que el enfoque que se toma es el de las privaciones, una variable toma el valor de 1 si el hogar estudiado está privado de esa capacidad, y 0 caso contrario.

Por otro lado, la unidad de análisis del estudio no son los individuos, sino el hogar. Como bien explican Fagnola & Moneta: «Utilizar el hogar como foco de estudio es de suma utilidad bajo el enfoque teórico que subyace la investigación: las personas viven en hogares, el sufrimiento de un miembro del hogar afecta al resto, y de igual manera las habilidades de uno a veces ayudan a los otros» (2019:10).

Para tal propósito se debió extrapolar a nivel hogar las privaciones individuales. Se consideró para ello que un hogar está privado en alguna capacidad si al menos uno de sus miembros lo está. Es

decir, si cualquier miembro del hogar tiene alguna variable con valor 1, todo el hogar debe tenerlo. Este criterio es especialmente útil cuando las variables estudiadas pertenecen a la base individual de la EPH. Estas son: jefe de hogar con primaria incompleta, falta de cobertura médica y todas aquellas pertenecientes a la dimensión «Inclusión social». El emparejamiento con la base hogares fue llevada a cabo mediante un código único disponible en la EPH que identifica a cada hogar.

El resultado de este procedimiento fueron ocho matrices (una por año seleccionado) de ceros y unos que muestra la situación de privación de los hogares en cada una de las variables estudiadas.

5. Metodología

La técnica estadística que sigue el presente trabajo es el análisis factorial (AF). El mismo se llevará a cabo en distintas etapas: una etapa exploratoria, una confirmatoria y otra de evaluación de invarianza. Todo el procedimiento será realizado con el programa estadístico Stata 16.

Los datos se dividirán, en primera instancia, en dos subgrupos: una matriz con los indicadores para los años 2003–2006 y otra para 2016–2019. Para cada uno de los grupos se realizará el mismo procedimiento.

El objetivo principal del AF es determinar la cantidad y la naturaleza de variables latentes o factores que explican las variaciones de un conjunto de variables observables denominadas indicatoras. Es una técnica reductora de datos que pretende encontrar en una variable no observable la causa común de las correlaciones entre ciertas variables observables. Claro está que en el presente trabajo las variables indicatoras son aquellas recolectadas de la EPH y las variables latentes serían las distintas dimensiones de la pobreza.

Si bien la Tabla 1 da un norte a la selección de indicadores de la investigación, antes de adentrarnos a la confirmación de la estructura factorial

allí propuesta mediante un análisis factorial confirmatorio (AFC), este trabajo llevará a cabo previamente un análisis factorial exploratorio (AFE).

A pesar de que tanto el AFE como el AFC comparten el mismo propósito, estos difieren en las restricciones impuestas a la forma del modelo. Mientras el AFE es una técnica *data-driven* que no requiere especificaciones a priori sobre el número de factores ni indicadores que saturan en cada uno, en el AFC el investigador debe establecer previamente la estructura factorial del modelo. Este último, por lo tanto, requiere un fuerte respaldo teórico que fundamente dicha especificación (Lloret–Segura et al., 2014).

La forma en que estos procedimientos se ejecutarán será sobre cada uno de los dos periodos (expansivo y recesivo) bajo análisis, sin separar entre los años que los componen. La descomposición por año será luego realizada en el análisis de invarianza. Para este propósito se ha dividido la muestra en dos partes: 50 % para el AFE y 50 % para el AFC, asegurando que dentro de esa división para cada periodo se retengan también 50 % de los datos de cada año que los componen.

5.1. Análisis Factorial Exploratorio

El método más habitual para aplicar el análisis factorial exploratorio es el que utiliza la matriz formada por los coeficientes de correlación de Pearson, siendo este el método aplicado por defecto en los softwares estadísticos. Sin embargo, este método está destinado a ser utilizado con variables continuas, por lo que cuando se dispone de variables dicotómicas su uso genera resultados distorsionados y menos precisos que los deseables.

Es por ello que el insumo a utilizar para este AFE es la matriz de correlaciones tetracóricas, apropiada para la naturaleza binaria de los indicadores. Esta matriz se construye haciendo uso de la totalidad de indicadores de la Tabla 1.

El método utilizado para la extracción de factores, debido a la naturaleza categórica de las variables del análisis, será el de Ejes Principales,

que es un método iterativo robusto a violaciones del supuesto de normalidad (Lloret–Segura et ál., 2014).

La decisión sobre el número adecuado de factores a retener será tomada a partir de dos criterios conjuntos: la clásica regla de Kaiser–Guttman que retiene aquellos factores con *eigenvalues* mayores a uno, junto con el gráfico de sedimentación, que es analizado para determinar la última caída substancial en el valor de los *eigenvalues*. Estos criterios irán acompañados por la intepretabilidad y la relevancia conceptual de los factores.

Luego de seleccionar el número de factores adecuados, la solución será rotada mediante el método Promax para una mejor interpretación de los resultados. Este método de rotación oblicua permite que los factores estén correlacionados y es el adecuado en este caso dada la premisa de que todos ellos están explicados por un constructo aun mayor que sería la pobreza. Con esta nueva solución, se eliminaron aquellos indicadores con bajas cargas factoriales, reteniendo aquellos con cargas mayores a 0.40.

Por último, se llevará a cabo la posestimación, en donde se estudiará la adecuación del modelo. La validez discriminante se analiza observando la matriz de correlaciones entre los factores, debiendo estas ser moderadas. Si las correlaciones entre los factores son muy elevadas, es probable que existan factores redundantes. Si, en cambio, son demasiado bajas y en similar magnitud, quizá sea mejor un modelo con más factores. La adecuación de los datos se examinará mediante el índice Kaiser–Meyer–Olkin (KMO), buscando un valor mayor a 0.70 para ser considerado aceptable.

Por último, la consistencia interna de las escalas será estudiado mediante el coeficiente alfa ordinal que, a diferencia del mayormente difundido alfa de Cronbach, utiliza la matriz de correlaciones tetracóricas para su cálculo y es por tanto una medida más adecuada dada la naturaleza binaria de los datos utilizados (Gadermann, Guhn, & Zumbo, 2012).

5.2. Análisis Factorial Confirmatorio

La estructura factorial hallada será validada mediante el AFC haciendo uso de la mitad de la muestra reservada para tal propósito, nuevamente sobre ambos periodos. Como se mencionó, a la hora de llevar a cabo el AFC es de suma importancia la fundamentación teórica de las relaciones propuestas, y no solo la guía proporcionada por el AFE.

Si se han logrado hallar factores e indicadores con apropiado sustento conceptual, el siguiente paso es construir ese modelo de medida y estimar sus parámetros: cargas factoriales, varianzas únicas, varianzas y covarianzas factoriales. Las cargas factoriales se interpretan como las pendientes de una regresión en la que la variable independiente es el factor y la dependiente la indicadora. La varianza única es aquella parte de la varianza de un indicador que no es explicado por la variable latente. Las varianzas factoriales muestran la dispersión del factor en la muestra, y las covarianzas la relación entre los distintos factores.

La naturaleza binaria de las variables dificulta la aplicación de los métodos tradicionales de estimación del modelo de medida tal como Máxima Verosimilitud (MV) que asume continuidad y normalidad de las variables. Si bien algunos trabajos intentan sortear este obstáculo haciendo uso de la corrección de Satorra–Bentler para conseguir errores robustos ante la ausencia de normalidad, dicho método no corrige por falta de continuidad y por lo tanto no debería ser usado en este caso. Brown (2015) y Finney & DiStefano (2006) consideran más apropiado utilizar estimadores como Mínimos Cuadrados Ponderados (también conocido como métodos de Distribución Asintótica Libre) o Mínimos Cuadrados Ponderados Robustos. Este último da mejores resultados cuando la muestra es pequeña, lo cual no será un problema en este caso. Dada la disponibilidad de herramientas del software a utilizar, se procederá a aplicar el Método de Distribución Asintótica Libre (ADF por sus siglas en inglés).

Este método, no obstante, tiene cierta limitación a la hora de evaluar la bondad de ajuste del modelo, ya que solo reporta los coeficientes asociados a los residuos: SRMR (*Standardized Root Mean–Square Residual*) y CD (*Coefficient of determination*).

El foco estará puesto más bien en el primer indicador y, siguiendo las recomendaciones de Schermelleh–Engel et ál. (2003), se considerará un ajuste aceptable cuando el SRMR sea menor a 0.10 y bueno cuando sea menor a 0.5.

5.3. Invarianza longitudinal del modelo

El objetivo en esta etapa es verificar si las propiedades de medida de las variables latentes son estables en el tiempo para así evitar confundir cambios en la forma de medir el constructo con cambios en el constructo mismo.

En el contexto de la medición de pobreza, la propiedad de invarianza longitudinal se vuelve crítica si se desea hacer un correcto seguimiento del fenómeno en el tiempo. El principal aporte de este trabajo se encuentra justamente en este punto y responde a la pregunta: ¿es efectivamente útil el enfoque multidimensional propuesto para medir la pobreza?

El AF permite realizar comparaciones entre distintos subgrupos de la muestra bajo estudio para evaluar si el mismo modelo es adecuado para cada uno de ellos. Los test de invarianza entre grupos se realizan comparando modelos anidados que van agregando restricciones en ciertos parámetros cuya estabilidad se desea poner a prueba. El estudio de la invarianza en el tiempo se llevará a cabo de la misma manera que cualquier otro análisis multi-grupo, pero en donde los grupos serán los distintos años seleccionados (Newsom, 2015).

Seguiremos la clasificación propuesta por Meredith (1993) de los diferentes tipos de invarianza longitudinal, cuyo nivel va creciendo a medida que se imponen más restricciones de estabilidad en los parámetros.

La figura 1 es de utilidad para entender mejor las sucesivas restricciones que se irán imponiendo sobre el modelo. Para ello se supondrá un modelo

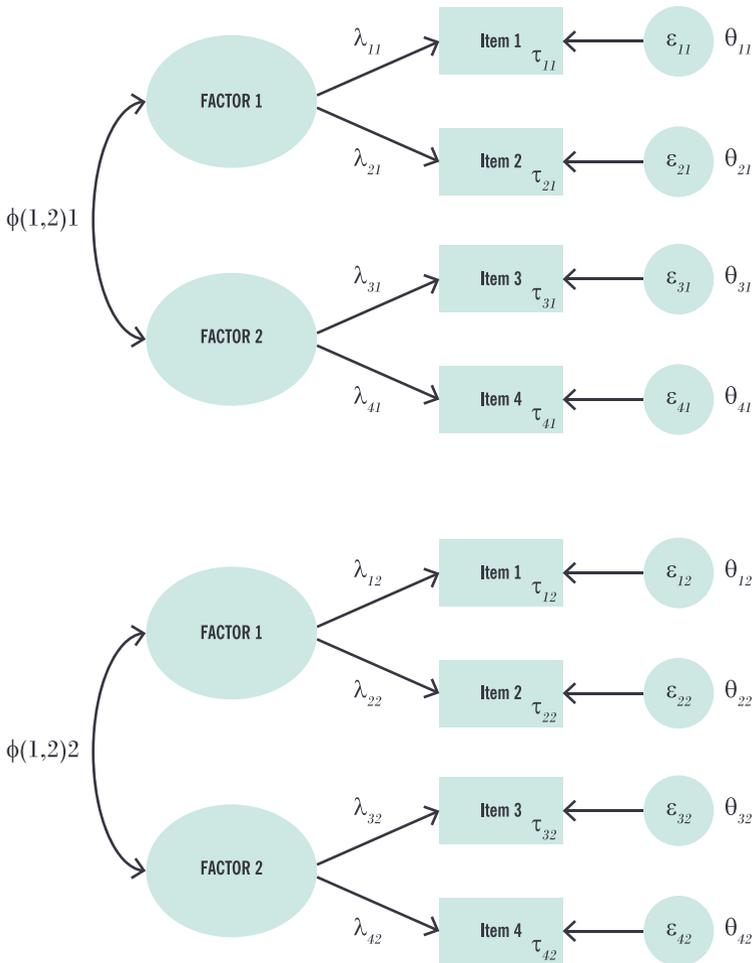
simple con dos factores y dos ítems saturando en cada uno de ellos. También se supondrán dos unidades temporales para las cuales se desea verificar la invarianza longitudinal.

El nivel más bajo de invarianza es la *invarianza configuracional*, también llamada de forma, y resulta fundamental para poder avanzar en los siguientes. Este nivel exige que la misma estructura factorial sea adecuada para todos los años bajo análisis. Esto es, para cada onda seleccionada se debe hallar la misma cantidad de factores y los mismos indicadores saturando en cada uno de ellos. Este nivel de invarianza asegura que el constructo tenga el mismo significado en todas las unidades estudiadas. Más específicamente, certifica que las dimensiones de la pobreza y la forma en que estas se manifiestan no varían en el tiempo. En la Figura 1 la invarianza configuracional se está verificando ya que la estructura factorial es la misma en ambas unidades de tiempo.

El siguiente nivel es la *invarianza factorial débil*, también denominada invarianza métrica, que exige que las cargas factoriales sean iguales en todas las unidades temporales (es decir $\lambda_{11} = \lambda_{12}$, $\lambda_{21} = \lambda_{22}$, $\lambda_{31} = \lambda_{32}$ y $\lambda_{41} = \lambda_{42}$), pero los demás parámetros pueden variar en el tiempo. Este nivel de invarianza implica que un incremento de una unidad en un constructo tiene el mismo impacto en cada indicador que lo conforma en todos los años. Cuando además de las cargas factoriales también se exige que los interceptos sean constantes (esto es, $\tau_{11} = \tau_{12}$, $\tau_{21} = \tau_{22}$, $\tau_{31} = \tau_{32}$ y $\tau_{41} = \tau_{42}$), se alcanza la *invarianza factorial fuerte o escalar*. Este nivel asegura que cambios en las medias de los indicadores de un año a otro sean manifestaciones de cambios en las medias de las variables latentes entre esos años.

Por último, el nivel más alto de invarianza es la *invarianza factorial estricta*, en el que cargas factoriales, interceptos y varianzas residuales deben ser invariantes (es decir, se agregan las restricciones $\theta_{11} = \theta_{12}$, $\theta_{21} = \theta_{22}$, $\theta_{31} = \theta_{32}$ y $\theta_{41} = \theta_{42}$).

Figura 1. Invarianza longitudinal para un modelo simple



Nota. En esta representación gráfica los óvalos contienen a los factores, los rectángulos a los ítems y los círculos a los errores. Por su parte, los λ representan las cargas factoriales, los τ los interceptos, los θ las varianzas de los errores y ϕ la covarianza entre los factores. Además, cada parámetro tiene dos subíndices: el primero refiere al número de parámetro en el modelo, y el segundo refiere a la unidad temporal en que se lo está midiendo. Fuente: *Elaboración propia*

La manera de llevar a cabo la evaluación de los distintos niveles de invarianza presentados es de forma jerárquica. Es decir, en primer lugar se evaluará la invarianza configuracional. Solo si esta se verifica se puede pasar al siguiente nivel y testear la invarianza débil. De igual manera, si esta última se cumple, se evalúa el siguiente nivel y así sucesivamente.

En este punto, no obstante, surge una gran limitación. Dado que los niveles de invarianza estudiados de manera jerárquica no son otra cosa que modelos anidados, se requiere una regla de decisión para poder establecer que el modelo más restrictivo no es significativamente peor que el menos restrictivo, y así confirmar un nuevo nivel de invarianza. Dado que el método ADF solo reporta los indicadores de

bondad de ajuste SRMR y CD, pocas son las conclusiones que pueden derivarse de comparar dichos estadísticos para modelos anidados.

El método ADF, por lo tanto, no es el más adecuado para esta etapa del análisis. Es por eso que se optará por realizar las estimaciones mediante Máxima Verosimilitud aplicando *bootstrap*. Esta técnica es una de las estrategias que Brown (2006) sugiere ante la falta de normalidad de las variables indicadoras, ya que la distribución que utiliza es una distribución empírica obtenida a partir de remuestreos sobre la muestra original. Este método permitirá obtener más estadísticos de bondad de ajuste y por lo tanto realizar las comparaciones necesarias para arribar a mejores conclusiones.

La técnica más tradicional para comparar modelos anidados es analizando las diferencias del estadístico chi-cuadrado. Sin embargo, para muestras grandes y falta de normalidad, este estadístico presenta problemas y tiende a ser demasiado elevado, llevando siempre al rechazo de la hipótesis nula de buen ajuste. Además, estudios previos (Cheung & Rensvold, 2002; Davidov et ál., 2014; Yuan & Chan, 2016) han criticado su uso alegando que para análisis multigrupo dicho indicador es demasiado sensible a la más mínima muestra de invarianza y por lo tanto no es especialmente útil para este propósito. Sokolov (2019) presenta una segunda alternativa consistente en utilizar varios índices de bondad de ajuste alternativos, tales como CFI, TLI, RMSEA y SRMR, para evaluar la bondad de ajuste *relativa* entre los distintos niveles de invarianza de manera jerárquica. Esa bondad de ajuste relativa no es más que la diferencia en valor absoluto de los índices de bondad de ajuste de cada uno de los modelos, que no debe exceder cierto límite propuesto por el autor.⁶ Si esa diferencia no supera dicho umbral, se puede concluir que el modelo más restringido es al menos tan bueno como el menos restrictivo y de esa manera avanzar a un nuevo nivel de invarianza. De acuerdo con las recomendaciones del autor, compartidas también por Chen (2007), si la

muestra en cada grupo es de tamaño similar y mayor a 300, los umbrales de cambios en los indicadores de bondad de ajuste son de -0.01 para el CFI, 0.015 para el RMSEA y 0.03 para el SRMR.

Esta será la manera en que se evaluarán las invarianzas débil a estricta. La invarianza configuracional, por su parte, será estudiada llevando a cabo un AFE sobre cada uno de los años del análisis.

6. Resultados

6.1. Análisis factorial exploratorio

Los resultados del AFE para cada uno de los dos periodos bajo análisis se presentan en las Tablas 2 y 3. Los mismos ya han sido rotados mediante el método de rotación oblicua Promax. Se puede observar que, de los 18 indicadores inicialmente propuestos, solo se han retenido 10, que son aquellos cuyas cargas factoriales resultaron mayores a 0.4.

La forma en que los indicadores se han agrupado en tres factores permite una clara interpretación de los resultados. El primer factor agrupa indicadores todos ellos alusivos a cuestiones de la infraestructura del hogar: piso de baja calidad, techo de baja calidad, falta de agua corriente y falta de baño adecuado. Esta dimensión hallada se denominará «vivienda».

El segundo factor está conformado por indicadores que refieren a la capacidad económica del hogar: Ingreso Total Familiar (ITF) menor a la Canasta Básica Total (CBT), recepción de algún tipo de ayuda económica externa y falta de cobertura médica. Esta dimensión de la pobreza recibirá el nombre de «ingresos» y está estrechamente relacionada con la pobreza monetaria. Esto permite inferir que la unidimensionalidad con que se mide actualmente la pobreza en Argentina es insuficiente ya que se han hallado otras dos dimensiones, además de la monetaria, que la componen.

(6) Dichas recomendaciones no son arbitrarias, sino que surgen de una serie de estudios y simulaciones realizados por el autor, que arriba a conclusiones similares a otros autores tales como Chen (2007).

Tabla 2. Análisis factorial exploratorio para el periodo 2003–2006

VARIABLE	FACTOR1	FACTOR2	FACTOR3	UNIQUENESS
Piso baja ~1	0,7399			0,5336
Techo baja~1	0,7084			0,3548
Sinagua	0,9405			0,1200
Sin bano	0,8656			0,1342
Basural			0,7069	0,5319
Inundable			0,6638	0,5962
Villa			0,4971	0,4726
Ayuda ex		0,5068		0,6403
Hogar sin ~b		0,6766		0,4569
ITFCBT		0,7057		0,4080

Fuente: *Elaboración propia*

Por último, el tercer factor agrupa tres indicadores relacionados con el ambiente en que está inserto el hogar. Se llamará a esta última dimensión «entorno».

Se observa además que, para ambos periodos, a pesar de sus contextos económicos completamente diferentes, se ha encontrado la misma estructura factorial, lo cual es indicio de la verificación de la

Tabla 4. Matriz de correlaciones entre factores 2003–2006

FACTORS	FACTOR1	FACTOR2	FACTOR3
Factor1	1		
Factor2	.6396	1	
Factor3	.5519	.4854	1

Fuente: *Elaboración propia*

Por su parte, el índice KMO resultó meritorio para ambos periodos, siendo 0.83 para el primero y 0.71 para el segundo. Se demuestra así una buena adecuación de los datos para el AFE.

Por último, la fiabilidad interna fue evaluada con el alfa ordinal, cuyo cálculo fue realizado siguiendo

Tabla 3. Análisis factorial exploratorio para el periodo 2016–2019

VARIABLE	FACTOR1	FACTOR2	FACTOR3	UNIQUENESS
Piso baja ~1	0,6850			0,5522
Techobaja~1	0,5906			0,5045
Sinagua	1,0098			0,0581
Sin bano	0,8884			0,1254
Basural			0,7569	0,4859
Inundable			0,7631	0,4585
Villa			0,6614	0,4317
Ayuda ex		0,6720		0,5337
Hogar sin ~b		0,7583		0,3966
ITFCBT		0,7245		0,4515

Fuente: *Elaboración propia*

invarianza configuracional entre dichos periodos.

Las correlaciones entre los factores de cada una de las soluciones factoriales halladas denota validez discriminante, ya que dichas correlaciones son en ambos casos moderadas. Las mismas se reportan a continuación en las Tablas 4 y 5.

Tabla 5. Matriz de correlaciones entre factores 2016–2019

FACTORS	FACTOR1	FACTOR2	FACTOR3
Factor1	1		
Factor2	.4712	1	
Factor3	.4439	.4007	1

Fuente: *Elaboración propia*

a Dominguez–Lara (2018).⁷ Los valores obtenidos se detallan en la Tabla 6. Se puede observar una buena consistencia interna de las subescalas, concluyendo así que los instrumentos están efectivamente midiendo lo que pretenden medir.

(7) El autor facilitó un archivo Excel para poder realizar el cálculo, disponible en ResearchGate.

6.2. Análisis Factorial Confirmatorio

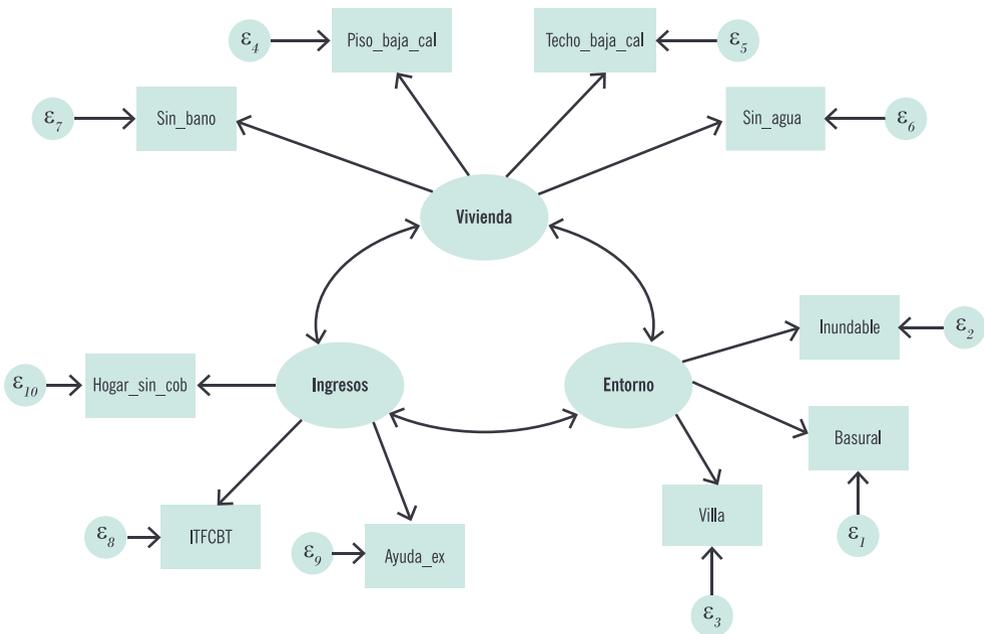
Siguiendo los resultados hallados en el paso anterior se construyó el modelo factorial a ser testeado con la muestra restante. Haciendo uso de la herramienta *SEM Builder* de Stata, se construyó la Figura 2 que muestra la estructura factorial a confirmar.

Tabla 6. Alfa ordinal para cada subescala

	2003–2006	2016–2019
Factor 1	0.88	0.87
Factor 2	0.66	0.76
Factor 3	0.65	0.77

Fuente: *Elaboración propia*

Figura 2. Modelo para el análisis factorial confirmatorio



Nota. Esta es la forma en que la herramienta SEM Builder de Stata 16 representa el modelo. Al igual que se presentó en la Figura 1, se simboliza con óvalos a las variables latentes, con rectángulos a las variables indicadoras y con círculos a los errores.

Fuente: *Elaboración propia*

El modelo fue estimado mediante el método ADF, y los resultados estandarizados para cada periodo se muestran a continuación.

Tabla 7. Análisis factorial confirmatorio con ADF para 2003–2006

STANDARDIZED		COEF.	STD. ERR.	Z	P> Z	[95% CONF. INTERVAL]	
Measurement							
Piso_baja_cal	Vivienda	.097213	.0101572	9.57	0.000	.0773052	.1171207
	cons	.0701475	.0045597	15.38	0.000	.0612106	.0796844
Techo_baja_cal	Vivienda	.5578005	.007625	73.15	0.000	.5428558	.5727452
	cons	.3342162	.0048532	68.87	0.000	.3247041	.3437283
Sin_agua	Vivienda	.6850545	.0067706	101.18	0.000	.6717844	.6983247
	cons	.2716936	.0043361	62.66	0.000	.263195	.2801922
Sin_bano	Vivienda	.7675635	.0029045	264.26	0.000	.7618707	.7732862
	cons	.4221023	.0045481	92.81	0.000	.4131882	.4310164
Basural	Entorno	.4781837	.0112775	42.40	0.000	.4566803	.5002872
	cons	.3059867	.0052025	58.81	0.000	.29579	.3161835
Inundable	Entorno	.4661214	.0116155	40.13	0.000	.4433554	.4888873
	cons	.2887008	.0051652	55.89	0.000	.2785772	.2988243
Villa	Entorno	.3528453	.0173222	20.37	0.000	.3188944	.3867962
	cons	.1067083	.0049559	21.53	0.000	.0969949	.1164216
ITFCBT	Ingresos	.6685577	.0034949	191.29	0.000	.6617078	.6754076
	cons	.8589399	.0067294	127.64	0.000	.8457505	.8721293
Ayuda_ex	Ingreses	.4317728	.006282	68.73	0.000	.4194604	.4446853
	cons	.5026242	.0053192	94.49	0.000	.4921988	.5130496
Hogar_sin_cob	Ingreses	.6344015	.0037574	168.84	0.000	.6270372	.6417657
	cons	.8524678	.0065671	129.81	0.000	.8395966	.8653391
	var(e.Piso_baja_cal)	.9905496	.0019748			.9866866	.9944278
	var(e.Techo_baja_cal)	.6888586	.0085065			.6723864	.7057344
	var (e. Sin_agua)	.5307003	.0092765			.5128266	.5491969
	var (e.Sin_bano)	.4108463	.0044588			.4021995	.419679
	var(e.Basural)	.7713403	.0107854			.7504883	.7927717
	var(e.Inundable)	.7827309	.0168285			.7617926	.8042446
	var(e.Villa)	.8755002	.0122241			.8518662	.8997899
	var(e.ITFCBT)	.5530306	.0046731			.5439469	.5622659
	var(e.Ayuda_ex)	.8135722	.0054248			.803009	.8242744
	var(e.Hogar_sin_cob)	.5975348	.0047673			.5882636	.606952
	var(Vivienda)	1	-			-	-
	var(Entorno)	1	-			-	-
	var(Ingresos)	1	-			-	-
	cov(Vivienda,Entorno)	.4256278	.0150585	28.26	0.000	.3961136	.4551419
	cov(Vivienda, Ingreses)	.5449827	.0074609	73.05	0.000	.5303596	.5596057
	cov(Entorno,Ingresos)	.3573603	.0112225	31.84	0.000	.3353647	.379356

Fuente: *Elaboración propia*

Tabla 8. Análisis factorial confirmatorio con ADF para 2016–2019

STANDARDIZED		COEF.	STD. ERR.	Z	P> Z	[95% CONF. INTERVAL]	
Measurement							
Piso_baja_cal	Vivienda	.8637618	.0105664	6.03	0.000	.0430519	.0844716
	cons	.048271	.0043949	10.98	0.030	.0396571	.0568849
Techo_baja_cal	Vivienda	.460349	.0092708	49.66	0.000	.4421785	.4785195
	cons	.2853247	.0046855	60.90	0.030	.2761414	.294 5081
Sin_agua	Vivienda	.5894233	.011567	50.96	0.000	.5667523	.6120942
	cons	.1653075	.0046325	35.68	0.030	.1562279	.1743871
Sin_bano	Vivienda	.7396833	.034685	157.88	0.030	.7305008	.74 8 8657
	cons	.3366347	.0043499	77.39	0.000	.3281091	.3451604
Basural	Entorno	.5391602	.0127716	42.22	0.030	.5141282	.5641921
	cons	.2722188	.004 8 769	55.82	0.000	.2626602	.2817773
Inundable	Entorno	.5126341	.0126328	40.58	0.030	.4878743	.5373939
	cons	.2762027	.0048618	56.81	0.030	.2666738	.2857315
Villa	Entorno	.2584072	.0198573	13.01	0.000	.2194875	.2973269
	cons	.081643	.0048234	16.93	0.030	.0721894	.0910965
ITFCBT	Ingresos	.6258283	.0042019	148.94	0.030	.6175928	.6340638
	cons	.6163116	.0052322	117.79	0.000	.6060566	.6265666
Ayuda_ex	Ingreses	.5524428	.0050807	108.73	0.000	.5424849	.5624008
	cons	.5408273	.0049729	108.75	0.000	.5310806	.550574
Hogar_sin_cob	Ingreses	.6542642	.0036388	179.80	0.030	.6471324	.661396
	cons	.7428399	.0058852	126.22	0.030	.7313052	.7543747
	var(e.Piso_baja_cal)	.9959344	.0013475			.9932969	.9985789
	var(e.Techo_baja_cal)	.7880788	.0085356			.7715256	.8049872
	var (e. Sin_agua)	.6525802	.0136357			.6263945	.6798606
	var (e.Sin_bano)	.4528687	.0069 309			.4394861	.4666587
	var(e.Basural)	.7093063	.0137719			.682821	.7368189
	var(e.Inundable)	.7372063	.012952			.7122529	.7630338
	var(e.Villa)	.9332257	.0102626			.9133267	.9535583
	var(e.ITFCBT)	.6083389	.0052593			.5981178	.6187348
	var(e.Ayuda_ex)	.6948069	.0056136			.6838912	.7058969
	var(e.Hogar_sin_cob)	.5719384	.0047614			.5626819	.5813471
	var(Vivienda)	1	-			-	-
	var(Entorno)	1	-			-	-
	var(Ingresos)	1	-			-	-
	cov(Vivienda,Entorno)	.2726133	.0148038	18.42	0.000	.2436044	.3016223
	cov(Vivienda, Ingreses)	.4263274	.0090224	47.25	0.000	.4086438	.4440111
	cov(Entorno,Ingresos)	.2596447	.0115092	22.56	0.030	.2370871	.2822023

Fuente: Elaboración propia

Como se mencionó, la gran restricción de este método de estimación, a pesar de ser el más adecuado dada la naturaleza binaria de los datos, es la poca cantidad de índices de bondad de

ajuste. Sin embargo, aquellos dos que permiten ser analizados arrojan en ambos casos muy buenos resultados. Estos pueden ser observados en las siguientes tablas.

Tabla 9. Índices SRMR y CD. 2003–2006

FIT STATISTIC	VALUE	DESCRIPTION
Size of residuals		
SRMR	0.068	Standardized root mean squared residual
CD	0.929	Coefficient of determination

Fuente: *Elaboración propia*

Tabla 10. Índices SRMR y CD. 2016–2019

FIT STATISTIC	VALUE	DESCRIPTION
Size of residuals		
SRMR	0.045	Standardized root mean squared residual
CD	0.928	Coefficient of determination

Fuente: *Elaboración propia*

6.3. Invarianza longitudinal del modelo

El primer paso de esta etapa es la verificación de la invarianza configuracional. Para ello se realizó un AFE sobre cada uno de los años que componen

los dos periodos estudiados, en busca de la misma estructura factorial. En total se realizaron 8 análisis, cuyos resultados se muestran a continuación.

Tabla 11. Análisis factorial exploratorio. Año 2003

VARIABLE	FACTOR1	FACTOR2	FACTOR3	UNIQUENESS
Piso baja ~1	0.6889			0.5761
Techo baja~1	0.6992			0.3594
Sinagua	0.9554			0.1031
Sin bano	0.8812			0.1501
Basural			0.6926	0.5566
Inundable			0.6397	0.6376
Villa			0.4828	0.5143
Ayuda_ex		0.5099		0.6812
Hogar sin ~b		0.6550		0.4796
ITFCBT		0.6648		0.4547

Fuente: *Elaboración propia*

Tabla 12. Análisis factorial exploratorio. Año 2004

VARIABLE	FACTOR1	FACTOR2	FACTOR3	UNIQUENESS
Piso baja ~1	0.6830			0.5565
Techo baja~1	0.6585			0.3776
Sinagua	0.9981			0.0907
Sin bano	0.8847			0.1261
Basural			0.6650	0.5880
Inundable			0.6640	0.6011
Villa			0.4105	0.4700
Ayuda_ex		0.4659		0.6586
Hogar sin ~b		0.7012		0.4499
ITFCBT		0.7298		0.4014

Fuente: *Elaboración propia*

Tabla 13. Análisis factorial exploratorio. Año 2005

VARIABLE	FACTOR1	FACTOR2	FACTOR3	UNIQUENESS
Piso baja ~1	0.7753			0.4845
Techo baja~1	0.6871			0.3363
Sinagua	0.9425			0.1145
Sin baño	0.8264			0.1327
Basural			0.6946	0.5377
Inundable			0.7330	0.5014
Villa			0.6373	0.3775
Ayuda ex		0.5228		0.6303
Hogar sin ~b		0.6387		0.4401
ITFCBT		0.7416		0.3718

Fuente: *Elaboración propia***Tabla 14.** Análisis factorial exploratorio. Año 2006

VARIABLE	FACTOR1	FACTOR2	FACTOR3	UNIQUENESS
Piso baja ~1	0.6282			0.5626
Techo baja~1	0.5921			0.5048
Sinagua	1.0179			0.0601
Sin baño	0.8972			0.1240
Basural		0.7189		0.5234
Inundable		0.7987		0.4034
Villa		0.6368		0.4937
Ayuda ex			0.6785	0.5208
Hogar sin ~b			0.7436	0.4101
ITFCBT			0.7154	0.4718

Fuente: *Elaboración propia***Tabla 15.** Análisis factorial exploratorio. Año 2016

VARIABLE	FACTOR1	FACTOR2	FACTOR3	UNIQUENESS
Piso baja ~1	0.6958			0.4633
Techo baja~1	0.7213			0.3422
Sinagua	0.9576			0.1290
Sin baño	0.9355			0.1206
Basural			0.7392	0.4949
Inundable			0.6941	0.5396
Villa			0.4195	0.4054
Ayuda ex		0.5590		0.5770
Hogar sin ~b		0.7101		0.4281
ITFCBT		0.7402		0.3902

Fuente: *Elaboración propia***Tabla 16.** Análisis factorial exploratorio. Año 2017

VARIABLE	FACTOR1	FACTOR2	FACTOR3	UNIQUENESS
Piso baja ~1	0.6380			0.4970
Techo baja~1	0.5948			0.4946
Sinagua	1.0229			0.0458
Sin baño	0.9450			0.1175
Basural			0.7918	0.4485
Inundable			0.7852	0.4360
Villa			0.6196	0.4819
Ayuda ex		0.6866		0.5228
Hogar sin ~b		0.7498		0.4118
ITFCBT		0.6979		0.4807

Fuente: *Elaboración propia*

Nótese que, aún siendo una técnica guiada meramente por los datos y sin ninguna especificación a priori sobre la estructura factorial buscada, se han hallado para todos los años los mismos tres factores con exactamente los mismos indicadores saturando en cada uno de ellos y todos con una carga factorial mayor a 0.4.

Si bien este es el nivel más básico de invarianza, este descubrimiento no es en absoluto trivial y conduce a la primera gran conclusión de este trabajo: las dimensiones de la pobreza y la manera en que estas se manifiestan son estables en el tiempo, tanto para años consecutivos como también para periodos enmarcados en contextos económicos diferentes.

Tabla 17. Análisis factorial exploratorio. Año 2018

VARIABLE	FACTOR1	FACTOR2	FACTOR3	UNIQUENESS
Piso baja ~1	0.5397			0.6328
Techo baja~1	0.5582			0.5038
Sinagua	1.0072			0.0768
Sin bano	0.9389			0.1011
Basural			0.8090	0.4204
Inundable			0.7081	0.5312
Villa			0.7381	0.3040
Ayuda ex		0.6880		0.5166
Hogar sin ~b		0.7901		0.3795
ITFCBT		0.7469		0.4032

Fuente: *Elaboración propia*

Tabla 18. Análisis factorial exploratorio. Año 2019

VARIABLE	FACTOR1	FACTOR2	FACTOR3	UNIQUENESS
Piso baja ~1	0.6064			0.6051
Techo baja~1	0.5481			0.5186
Sinagua	1.0292			0.0437
Sin bano	0.9175			0.1003
Basural			0.7880	0.4478
Inundable			0.6956	0.5480
Villa			0.7090	0.4015
Ayuda ex		0.6686		0.5162
Hogar sin ~b		0.7589		0.3999
ITFCBT		0.7326		0.4274

Fuente: *Elaboración propia*

Este nivel de invarianza puede ser tambien evaluado analizando la bondad de ajuste absoluta del modelo que surge de aplicar AFC multigrupo sin imponer ninguna restriccion de igualdad a los parámetros. Siguiendo a Browne & Cudeck (1992) y Hu & Bentler (1999), para afirmar que un modelo ajusta bien a los datos se debe observar valores de

CFI y TLI ambos mayores a 0.95 (o al menos 0.90), un valor de RMSEA menor a 0.05 (o al menos 0.08) y de SRMR menor a 0.08. Los resultados obtenidos mediante MV con *bootstrap* se muestran a continuacion y denotan para ambos periodos, como era de esperarse, un buen ajuste. Se confirma de esta manera la invarianza configuracional.

Tabla 19. Evaluación de la invarianza configuracional. 2003–2006

FIT STATISTIC	VALUE	DESCRIPTION
Population error		
RMSEA	0.044	Root mean squared error of approximation
90% CI, lower bound	0.043	
upper bound	0.046	
Baseline comparison		
CFI	0.959	Comparative fit index
TLI	0.943	Tucker–Lewis index
Size of residuals		
SRMR	0.031	Standardized root mean squared residual
CD	0.935	Coefficient of determination

Fuente: *Elaboración propia*

Tabla 20. Evaluación de la invarianza configuracional. 2016–2019

FIT STATISTIC	VALUE	DESCRIPTION
Population error		
RMSEA	0.034	Root mean squared error of approximation
90% CI, lower bound	0.033	
upper bound	0.036	
Baseline comparison		
CFI	0.967	Comparative fit index
TLI	0.953	Tucker-Lewis index
Size of residuals		
SRMR	0.027	Standardized root mean squared residual
CD	0.939	Coefficient of determination

Fuente: *Elaboración propia*

Una vez confirmada la invarianza configuracional se puede avanzar a los siguientes niveles anteriormente detallados.

Tabla 21. Evaluación de la invarianza débil. 2003–2006

FIT STATISTIC	VALUE	DESCRIPTION
Population error		
RMSEA	0.043	Root mean squared error of approximation
90% CI, lower bound	0.041	
upper bound	0.044	
Baseline comparison		
CFI	0.956	Comparative fit index
TLI	0.947	Tucker-Lewis index
Size of residuals		
SRMR	0.032	Standardized root mean squared residual
CD	0.933	Coefficient of determination

Fuente: *Elaboración propia*

Las Tablas 20 y 21 muestran la bondad de ajuste del modelo cuando las cargas factoriales se fuerzan a ser iguales entre años. El ajuste absoluto es muy bueno en ambos periodos. No obstante, el interés está en el ajuste relativo, es decir comparativo al ajuste del modelo que no impone ninguna restricción.

Para el periodo 2003–2006 el RMSEA no aumentó, el CFI disminuyó en 0.003 y el SRMR aumentó en 0.001. Por su parte, para el periodo 2016–2019 el RMSEA no se modificó, el CFI cayó en 0.004 y el SRMR aumentó en 0.002. Todas estas variaciones son menores a los límites establecidos por Chen (2007), confirmando así la invarianza débil para ambos periodos.

Tabla 22. Evaluación de la invarianza débil. 2016–2019

FIT STATISTIC	VALUE	DESCRIPTION
Population error		
RMSEA	0.034	Root mean squared error of approximation
90% CI, lower bound	0.032	
upper bound	0.035	
Baseline comparison		
CFI	0.963	Comparative fit index
TLI	0.956	Tucker-Lewis index
Size of residuals		
SRMR	0.029	Standardized root mean squared residual
CD	0.938	Coefficient of determination

Fuente: *Elaboración propia*

El siguiente paso es la evaluación de la invarianza fuerte, que impone, además de las restricciones sobre las cargas factoriales, restricciones

de igualdad entre años a los interceptos. Los resultados de la bondad de ajuste de dichos modelos se exhiben a continuación.

Tabla 23. Evaluación de la invarianza fuerte. 2003–2006

FIT STATISTIC	VALUE	DESCRIPTION
Population error		
RMSEA	0.045	Root mean squared error of approximation
90% CI, lower bound	0.044	
upper bound	0.047	
Baseline comparison		
CFI	0.941	Comparative fit index
TLI	0.941	Tucker-Lewis index
Size of residuals		
SRMR	0.032	Standardized root mean squared residual
CD	0.933	Coefficient of determination

Fuente: *Elaboración propia*

Para el periodo 2003–2006, el RMSEA aumentó en 0.002, el CFI disminuyó en 0.015 y el SRMR se mantuvo constante. Por su parte, para el periodo 2016–2019, el RMSEA aumentó en 0.011, el CFI cayó en 0.022 y el SRMR aumentó en 0.003.

Si bien ambos ajustes son considerablemente buenos, la caída en el indicador CFI para ambos

periodos supera el umbral tolerado, por lo que no es posible asegurar que el modelo sea al menos tan bueno como el anterior. No hay evidencia, por lo tanto, de que el modelo verifique la invarianza factorial fuerte.

El hecho de que el máximo nivel de invarianza alcanzado por el modelo sea el débil implica que,

Tabla 24. Evaluación de la invarianza fuerte. 2016–2019

FIT STATISTIC	VALUE	DESCRIPTION
Population error		
RMSEA	0.045	Root mean squared error of approximation
90% CI, lower bound	0.044	
upper bound	0.047	
Baseline comparison		
CFI	0.941	Comparative fit index
TLI	0.941	Tucker-Lewis index
Size of residuals		
SRMR	0.032	Standardized root mean squared residual
CD	0.933	Coefficient of determination

Fuente: *Elaboración propia*

si bien cambios en una unidad de cada uno de los constructos tiene el mismo impacto en cada indicador año a año, no necesariamente son iguales año a año los interceptos del modelo. Como se explicó en la sección 5.3, esto no permite hacer comparaciones entre las medias de los indicadores de un año a otro e inferir que cambios en las mismas se deban a cambios en la media de las variables latentes. Un correcto análisis dinámico de la pobreza multidimensional debe tener en cuenta este resultado.

Una vez estudiado el nivel máximo de invarianza alcanzado para años consecutivos, resta evaluar el que se alcanza entre periodos con diferentes contextos económicos. Dado que ya fue llevado a cabo un AFE sobre ambos periodos y la misma estructura factorial fue hallada (véase tablas 2 y 3), claro está que la invarianza configuracional se cumple entre periodos. Sin embargo, se debe también llevar a cabo un AFC sobre el modelo sin restricciones para poder comparar la bondad de ajuste con el siguiente modelo más restrictivo.

Tabla 25. Evaluación de invarianza configuracional entre periodos

FIT STATISTIC	VALUE	DESCRIPTION
Population error		
RMSEA	0.038	Root mean squared error of approximation
90% CI, lower bound	0.036	
upper bound	0.039	
Baseline comparison		
CFI	0.966	Comparative fit index
TLI	0.952	Tucker-Lewis index
Size of residuals		
SRMR	0.027	Standardized root mean squared residual
CD	0.938	Coefficient of determination

Fuente: *Elaboración propia*

Tabla 26. Evaluación de invarianza débil entre periodos

FIT STATISTIC	VALUE	DESCRIPTION
Population error		
RMSEA	0.043	Root mean squared error of approximation
90% CI, lower bound	0.042	
upper bound	0.044	
Baseline comparison		
CFI	0.950	Comparative fit index
TLI	0.937	Tucker-Lewis index
Size of residuals		
SRMR	0.038	Standardized root mean squared residual
CD	0.940	Coefficient of determination

Fuente: *Elaboración propia*

El ajuste del modelo sin ninguna restricción es muy bueno, lo cual era de esperarse dado que ya había sido confirmada la invarianza configuracional con el AFE para cada periodo.

Por su parte, el ajuste absoluto del modelo cuyos coeficientes han sido forzados a ser iguales entre periodos es igualmente bueno, pero no así el ajuste relativo. El coeficiente RMSEA aumentó en 0.005, el CFI disminuyó en 0.016 y el SRMR aumentó en 0.011. El valor de la caída del CFI supera el umbral tolerado, por lo que no puede asegurarse que el ajuste no haya empeorado.

El hecho de que el máximo nivel de invarianza que puede demostrarse haber alcanzado el modelo entre periodos sea el configuracional conduce a la siguiente conclusión: si bien las dimensiones y sus indicadoras no variaron en el tiempo, si pueden haberlo hecho el peso que cada indicador tiene dentro de cada dimensión. Una vez más, este resultado no es trivial, ya que puede invalidar todo análisis dinámico de la pobreza que no tenga en cuenta dichos cambios.

7. Conclusiones

Pese a las discusiones en torno a la manera de definir el concepto, hay un hecho innegable: la pobreza es un mal y debe ser erradicada. La forma de entender al fenómeno condiciona la dirección que los recursos públicos adopten para combatirlo. Es por eso que su correcta definición resulta una tarea primordial.

La forma indirecta de medir la pobreza a través del enfoque monetario ha comenzado a ser cuestionada en numerosos países, promoviendo un mayor estudio del fenómeno teniendo en cuenta más de una dimensión. Este trabajo es una contribución más al entendimiento multidimensional de la pobreza en Argentina que no se limita solo a hallar sus dimensiones e indicadores en que las mismas se manifiestan, sino también aseverar la estabilidad de dichos constructos en el tiempo.

Dada la naturaleza no observable del fenómeno a estudiar, la técnica estadística escogida para llevar a cabo este propósito fue el análisis factorial. Los microdatos de la EPH conformaron

la fuente de datos de la cual se obtuvieron las variables indicadoras sometidas a dicha técnica reductora de datos, con el objetivo de encontrar los factores detrás de las mismas que explicarían su correlación.

Se han encontrado, de esta manera, tres dimensiones que subyacerían a la pobreza en Argentina, dejando en claro que la unidimensionalidad con que la línea de pobreza detecta a los pobres resulta insuficiente. Dichas dimensiones se denominaron ingresos, vivienda y entorno, y son las variables latentes detrás de 10 variables observables obtenidas de la EPH.

Estos hallazgos son coincidentes con las dimensiones encontradas por Fagnola & Moneta (2019), aunque se adiciona el indicador «falta de agua corriente» a la dimensión vivienda. La similitud en los resultados, aun habiendo utilizado diferentes métodos de estimación, es muestra de la robustez de los mismos.

Fundamental a la hora de evaluar las políticas públicas destinadas a combatir este flagelo es el seguimiento del mismo a través del tiempo. Para ello, los resultados de la medición multidimensional propuesta deben poder ser comparables de un momento a otro. La propiedad que asegura dicha comparabilidad es la invarianza factorial longitudinal que, en sus distintos niveles, se vuelve crítica para poder arribar a conclusiones válidas.

La invarianza longitudinal se verificó en dos sentidos: en primer lugar, entre años consecutivos dentro de una misma fase del ciclo económico, y, luego, entre periodos con características económicas disimiles. Para tal propósito se trabajó sobre los cuartos trimestres de los años correspondientes a dos periodos: 2003 a 2006 y 2016 a 2019. El primero es representativo de una fase de recuperación, mientras el segundo está enmarcado por un contexto recesivo.

El máximo nivel de invarianza alcanzado al efectuar la comparación entre periodos fue la invarianza configuracional, que implica que la estructura factorial (cantidad de factores e indicadores saturando en cada uno) es la misma en ambas etapas. Este hallazgo no es trivial ya que permite concluir que las dimensiones de la pobreza y la forma en que estas se manifiestan son las mismas aun cuando la coyuntura económica sea fuertemente cambiante. Sin embargo, no es igual el peso que cada variable latente tiene sobre los indicadores, por lo que las varianzas, covarianzas y medias que podrían extraerse de las variables latentes no son comparables en el tiempo. Por su parte, al efectuar el análisis entre años dentro de un mismo periodo se alcanzó, en ambos casos, el nivel de invarianza factorial débil. Esto asegura que las cargas factoriales entre años se mantengan constantes, permitiendo que las varianzas y covarianzas de los factores sean comparables en el tiempo. Estos resultados deben ser tenidos en consideración cuando desee llevarse a cabo la medición misma de la pobreza año a año a partir de los *factor scores* obtenidos para cada dimensión.⁸

Los hallazgos de este trabajo están sujetos a una serie de limitaciones. La principal de ellas está relacionada con la fuente de datos utilizada. Dado que no existe en el país una fuente de monitoreo de la pobreza entendida de manera multidimensional, toda investigación sobre el fenómeno que desee realizarse debe restringirse a la disponibilidad de variables en la EPH. Esto condiciona seriamente la selección de indicadores a someter al análisis factorial, y por lo tanto también los resultados obtenidos. Es posible que pudieran encontrarse más dimensiones del fenómeno si se contara con un cuestionario específicamente diseñado para tal propósito.

(8) Un factor score es un valor numérico que indica la posición de una persona en un factor determinado según los valores que asumen los indicadores que lo componen. En el caso de esta aplicación responden a la pregunta: ¿qué tan pobre en esta dimensión es esta persona?

Además, no solo se limita la selección de indicadores sino también, como se experimentó en este trabajo, los métodos estadísticos a utilizar ya que al trabajar exclusivamente con variables binarias queda muy acotado el número de técnicas de estimación apropiadas y sus indicadores de bondad de ajuste. Una alternativa que podría resultar conveniente es el uso de la opción GSEM (*Generalized Structural Equation Model*) cuya particularidad es que permite estimar el modelo haciendo uso de una función enlace específica para datos binarios, tal como Logit o Probit. La razón por la que este trabajo

no hizo uso de tal método fue la falta de convergencia del modelo, pero resulta una interesante futura línea de investigación.

Con todas sus limitaciones, este trabajo es otro aporte para exhibir el largo camino que Argentina aún tiene por delante en el estudio de la pobreza multidimensional y la necesidad de contar con una encuesta que a nivel nacional busque capturar específicamente indicadores de bienestar y desarrollo (en sentido positivo) o de privaciones y pobreza (en sentido negativo).

Referencias bibliográficas

- Browne, M.W. & Cudeck, R. (1992). Alternative ways of assessing model fit. *Sociological methods & research*, 21(2), 230–258.
- Chen, F.F. (2007). Sensitivity of goodness of fit indexes to lack of measurement invariance. *Structural Equation Modeling: A Multidisciplinary Journal*, 14(3), 464–504.
- Cheung, G.W. & Rensvold, R.B. (2002). Evaluating goodness-of-fit indexes for testing measurement invariance. *Structural equation modeling*, 9(2), 233–255.
- Cicowiez, M., Gasparini, L. & Sosa Escudero, W. (2010). *Pobreza y desigualdad en América Latina. Conceptos, herramientas y aplicaciones*. Mimeo. CEDLAS–UNLP.
- Conconi, A. (2011). *Pobreza Multidimensional en Argentina: Ampliando las Medidas Tradicionales de Pobreza por Ingreso y NBI*. Documento de Trabajo Nro. 90
- Cupani, M. (2012). Análisis de ecuaciones estructurales: conceptos, etapas de desarrollo y un ejemplo de aplicación. *Tesis*, 1, pp. 186 – 199.
- Fagnola B. & Moneta Pizarro, A.M. (en prensa). *Identificación de la pobreza multidimensional en argentina con métodos robustos de análisis factorial*. Cuadernos del CIMBAGE, Facultad de Ciencias Económicas, Universidad de Buenos Aires.
- Finney, S.J. & DiStefano, C. (2006). Non-normal and categorical data in structural equation modeling. *Structural equation modeling: A second course*, 10(6), 269–314.
- Hu, L.T. & Bentler, P.M. (1999). Cutoff criteria for fit indexes in covariance structure analysis: Conventional criteria versus new alternatives. *Structural equation modeling*, 6(1), 1–55.
- Lloret–Segura, S., Ferreres–Traver, A., Hernández–Baeza, A. & Tomás–Marco, F. (2014). El análisis factorial exploratorio de los ítems: una guía práctica, revisada y actualizada. *Anales de Psicología*, 30(3), pp. 1151–1169.
- Moneta Pizarro, A.M. (2019). *Determinantes del desempeño académico en Educación a Distancia: aplicación de un modelo de ecuaciones estructurales*. Tesis de Maestría en Estadística Aplicada, Facultad de Ciencias Económicas, UNC.
- Meredith, W. (1993). Measurement invariance, factor analysis, and factorial invariance. *Psychometrika*, 58, 525–543.
- Newsom, J.T. (2015). *Longitudinal structural equation modeling: A comprehensive introduction*. New York, Routledge, Taylor and Francis Group.
- Sen, A. (1992). Functionings and Capability. *Inequality reexamined* (39–55). Oxford: Oxford University Press.
- Schermelleh–Engel, K., Moosbrugger, H. & Müller, H. (2003). Evaluating the Fit of Structural Equation Models: Tests of Significance and Descriptive Goodness-of-Fit Measures. *Methods of Psychological Research Online – Vol. 8 – No. 2*, 23–74.
- Sokolov, B. (2019). *Sensitivity of Goodness of Fit Indices to Lack of Measurement Invariance with Categorical Indicators and Many Groups*, HSE Working papers WP BRP 86/SOC/2019, National Research University Higher School of Economics.
- Yuan, K.H. & Chan, W. (2016). Measurement invariance via multigroup SEM: Issues and solutions with chi-square-difference tests. *Psychological methods*, 21(3), 405.

Registro bibliográfico

Satorres Bechara, A.P. (2020). Estabilidad dinámica de un modelo factorial para la pobreza multidimensional en Argentina. *Revista Ciencias Económicas*, 17 (02), 83–109.