

**LATAM Revista Latinoamericana de Ciencias
Sociales y Humanidades, Asunción, Paraguay.**

ISSN en línea: 2789-3855, 2025, Volumen VI

**Desarrollo de un indicador compuesto de propensión
perceptual a la adopción de biomasa forestal en pellets en el
segmento residencial**

Development of a composite indicator of perceptual propensity to adopt
forest biomass pellets in the residential sector

Gustavo Schweickardt

gaocerin@gmail.com

<https://orcid.org/0000-0002-0843-2946>

CONICET-Universidad Tecnológica

Nacional, Concepción del Uruguay

Concepción del Uruguay – Argentina

DOI: <https://doi.org/10.56712/latam.v6i6.5073>

Artículo recibido: 22 de agosto de 2025.

Aceptado para publicación: 24 de diciembre
de 2025.

Conflictos de Interés: Ninguno que declarar.


Redilat
Red de Investigadores
Latinoamericanos

NÚMERO

DOI: <https://doi.org/10.56712/latam.v6i6.5073>

Desarrollo de un indicador compuesto de propensión perceptual a la adopción de biomasa forestal en pellets en el segmento residencial

Development of a composite indicator of perceptual propensity to adopt forest biomass pellets in the residential sector

Gustavo Schweickardt

gaocerin@gmail.com

<https://orcid.org/0000-0002-0843-2946>

CONICET-Universidad Tecnológica Nacional, Concepción del Uruguay
Concepción del Uruguay – Argentina

Artículo recibido: 22 de agosto de 2025. Aceptado para publicación: 24 de diciembre de 2025.
Conflictos de Interés: Ninguno que declarar.

Resumen

El presente trabajo presenta el desarrollo y aplicación de un indicador compuesto, que refleja la propensión a la adopción de biomasa forestal pelletizada (BFP), como energético sustituto del empleado habitualmente para calefacción en hogares residenciales. Este indicador es de origen perceptual, pues su construcción parte de la percepción que una muestra de usuarios residenciales, manifiestan sobre un conjunto de variables relacionadas con tres dimensiones centrales de la BFP: calidad energética, comercialización y logística, y dificultades operativas de uso. El procedimiento de construcción sigue un enfoque metodológico mixto, en etapas secuenciales, que emplea: técnicas del análisis estadístico multivariado (análisis factorial exploratorio -AFE-, análisis factorial confirmatorio -AFC- Multi-grupo), optimización soportada en análisis envolvente de datos -DEA-IC-, y simulación para configuraciones estables de mínima dispersión del indicador compuesto adoptado como operativo (método de Montecarlo). El indicador compuesto operativo queda, entonces, validado conforme las métricas exigidas para cada etapa, tanto por la literatura como por las buenas prácticas sugeridas por expertos. El estudio se realizó a partir de una encuesta a individuos jefes de hogar, pertenecientes al segmento residencial suburbano (considerado de alto potencial de penetración para la BFP), en una región de las provincias de Córdoba y Santa Fe, Argentina, cuyos perfiles de consumo energético tienen similares características. Los resultados resultaron de gran utilidad para la definición de políticas de incentivos que favorezcan la penetración de la BFP en forma segmentada por región.

Palabras clave: biomasa forestal pelletizada, indicador compuesto, análisis estadístico multivariado, optimización DEA-IC, simulación de Montecarlo

Abstract

This paper presents the development and application of a composite indicator that reflects the propensity to adopt Biomass from Forest Residue Pelletizing (BFRP) as a substitute energy source for heating in residential homes. This indicator is perceptual in origin, as its construction is based on the perceptions expressed by a sample of residential users regarding a set of variables related to three core dimensions of BFRP: energy quality, marketing and logistics, and operational difficulties of use. The construction procedure follows a mixed-methods approach, in sequential stages, employing multivariate statistical analysis techniques (exploratory factor analysis -EFA-, confirmatory factor

analysis -CFA- Multi-group), optimization supported by data envelopment analysis -DEA-IC-, and simulation for stable parameters of minimum dispersion of the composite indicator adopted as operational (Montecarlo method). The operational composite indicator is then validated according to the metrics required for each stage, both by the literature and by best practices suggested by experts. The study was based on a survey of heads of households in the suburban residential segment (considered to have high potential for BFRP penetration) in a region encompassing the provinces of Córdoba and Santa Fe, Argentina, whose energy consumption profiles share similar characteristics. The results proved highly useful for defining incentive policies that promote BFRP penetration in a segmented manner by region.

Keywords: biomass from forest residue pelletizing, composite indicator, multivariate statistical analysis, DEA-CI optimization, Montecarlo simulation

Todo el contenido de LATAM Revista Latinoamericana de Ciencias Sociales y Humanidades, publicado en este sitio está disponibles bajo Licencia Creative Commons.



Cómo citar: Schweickardt, G. (2025). Desarrollo de un indicador compuesto de propensión perceptual a la adopción de biomasa forestal en pellets en el segmento residencial. *LATAM Revista Latinoamericana de Ciencias Sociales y Humanidades* 6 (6), 2485 – 2509.
<https://doi.org/10.56712/latam.v6i6.5073>

INTRODUCCIÓN

La Biomasa Forestal Pelletizada (BFP). Generalidades

Dentro de los denominados recursos energéticos renovables, la biomasa constituye uno de los más antiguos empleados por la humanidad. A lo largo de la historia, logró constituirse en un pilar emergente sobre el cual se sustentan las actuales estrategias de la referida como 'transición energética', término que indica un proceso de sustitución de fuentes: desde las energías predominantemente fósiles, con elevados y acumulativos efectos que impactan ambientalmente (emisiones de CO₂ y efecto invernadero, fundamentalmente), hacia fuentes renovables y limpias, más sostenibles. En términos generales, la biomasa puede definirse como el 'conjunto de materiales orgánicos de origen biológico (vegetal o animal) susceptibles de ser aprovechados como fuente primaria de energía, o bien como 'un insumo para ciertos procesos productivos que tiene lugar en el marco de la bioeconomía', entendida, tomando el todo por la parte, como la disciplina que aborda el estudio de la producción/prestación de bienes/servicios, utilizando recursos biológicos de carácter renovable (McKendry, 2002; Bridgwater, 2006; Bonechi et al., 2017). Actualmente, la biomasa representa una fracción significativa del total de energía renovable utilizada a nivel mundial (matriz energética renovable), y desempeña un rol central como energético sustituto de las fuentes primarias fósiles. En mayor grado en países más industrializados respecto de las economías en desarrollo; particularmente en lo que respecta a usos finales en ámbitos residenciales, tales como la calefacción y cocción de alimentos (Hall et al., 1993; Field et al., 2008; Antar et al., 2021).

Considerando un enfoque de mayor alcance y amplitud, la relevancia de la biomasa, en general, no se vincula únicamente con su carácter renovable, sino también con su abundancia respecto a otras fuentes limpias o no carbónicas. Diferentes estudios en la literatura especializada, focalizados en el análisis de la distribución de la biomasa a escala planetaria, muestran que la biomasa de origen vegetal constituye una de las principales reservas en la Tierra, lo cual subraya su potencial como fuente energética si es gestionada de manera sostenible (Bar-On et al., 2018). En este sentido, ocupa un lugar destacado en los debates contemporáneos sobre descarbonización, seguridad y sustentabilidad energética, y desarrollo territorial sostenible, razón por la cual se integra, con mayor énfasis, en la concepción de estrategias para la transición energética, así como en los enfoques de la bioeconomía, ambos dependientes de cada región o país (Rosillo-Calle & Woods, 2012; Antar et al., 2021).

La importancia del recurso energético biomásico, no sólo estriba en su renovabilidad sino, además, en su abundancia en términos relativos con otras fuentes no carbónicas y cuya disponibilidad no tiene regímenes intermitentes (como el recurso solar o el eólico). La biomasa de origen vegetal constituye una de las principales reservas (Bar-On et al., 2018), (Rosillo-Calle & Woods, 2012; Antar et al., 2021). Específicamente, la biomasa forestal ha sido, históricamente, de particular importancia, en especial bajo la forma de combustible sólido, pues su composición química la torna especialmente adecuada para usos térmicos directos, y, muy importante en el contexto de esta investigación, para someterla a procesos que aumenten su eficiencia energética (Thek & Obernberger, 2012).

Los denominados 'pellets' de biomasa forestal, emergen como una forma de biomasa forestal (BFP), que le permite superar las limitaciones referidas. Para este caso, son biocombustibles sólidos obtenidos a partir de la compactación de biomasa previamente procesada (generalmente residuos forestales o subproductos de la industria maderera) en pequeñas unidades cilíndricas, de alta densidad energética y características relativamente homogéneas (Thek & Obernberger, 2012; Garcia-Maraver & Pérez-Jiménez, 2015). De esta manera, la biomasa forestal pelletizada, BFP, incrementa la eficiencia en aspectos centrales vinculados a su logística y comercialización (transporte, almacenamiento y uso final de la biomasa), en aras de la necesaria estandarización para facilitar su penetración en mercados de energéticos sustitutos.

El proceso de 'pelletizado', puede ser definido como de forma simple como 'un conjunto de operaciones que se inician con la reducción del volumen de la materia prima en 'bruto' (por caso, residuos de forestación, astillas, sobrantes de descarte provenientes de un aserradero), que se continúa con un secado de la misma hasta obtener un grado de humedad aceptable, y finaliza con su compactación, aplicando presión mecánica'. El resultado son unos cilindros combustibles denominados 'pellets'. En ese proceso, subyacen mecanismos físico-químicos fundamentales para asegurar la calidad del final de los 'pellets' obtenidos (Anukam et al., 2021). Conforme la literatura especializada, se ha demostrado que las propiedades esenciales de los pellets, (densidad, resistencia mecánica y poder calorífico), dependen tanto de las características de la materia prima utilizada como de las condiciones del pelletizado (Miranda et al., 2015; Anukam et al., 2021).

Por último, desde una perspectiva no tecnológica, el aspecto relevante a destacar para el presente trabajo, estriba en que el pelletizado permite transformar un recurso primario originalmente disperso, de complicada logística, y heterogéneo, en un combustible estandarizado, fácilmente comercializable y compatible con sistemas modernos de calefacción. La formulación de estándares para la BFP resulta un objeto actual de estudio y propuestas normativas, orientadas a garantizar una elevada eficiencia energética en diferentes usos finales, tanto domésticos como industriales. La definición de estándares, contribuiría, sin duda, a un aumento en la confiabilidad de la BFP como combustible sustituto, y a la reducción de la inevitable incertidumbre asociada a su empleo, condiciones esenciales para su penetración en mercados energéticos, fundamentalmente minoristas-residenciales (Thek & Obernberger, 2012; Garcia-Maraver & Pérez-Jiménez, 2015). En este sentido, la BFP se diferencia de otras formas tradicionales de biomasa -por caso, la leña en 'bruto'-, no solo por sus características físicas, sino también por exhibir una mayor integración en cadenas de valor reguladas. Este contexto de trabajo, resulta particularmente relevante para un estudio cuyo objetivo sea medir y explicar la propensión de los hogares a adoptar sistemas de calefacción basados en BFP, ya que permite situar en un marco más amplio de transición energética por sustitución de fuentes, reconociendo su complejidad en múltiples dimensiones más allá de los aspectos tecnológicos de su producción.

Adopción de tecnologías de BFP para uso residencial. Antecedentes

La adopción de tecnologías de BFP para usos finales domésticos de calefacción y cocción residencial, ha sido objeto de estudios empíricos desde etapas relativamente tempranas de su difusión. Existen trabajos pioneros (Nyrud et al., 2010; Sopha et al., 2011), focalizados en diferentes regiones de Europa, que analizaron las diferencias entre hogares adoptantes y no adoptantes de sistemas de calefacción, e identificaron que la adopción se encontraba asociada a una combinación de factores económicos, estructurales, actitudinales y de conocimiento tecnológico. La decisión de adoptar o no la BFP como energético sustituto, no podía ser explicada a partir de un único factor determinante (por caso, eficiencia desde la tecnología), sino que su respuesta dependía de múltiples dimensiones. En particular, el trabajo de Nyrud et al. (2010), referido a la adopción de BFP a nivel residencial en Noruega, mostró que tal adopción no finaliza en una única decisión inicial pre-adoptiva, sino que involucra una fase post-adoptiva que resulta crítica, donde influyen de manera significativa, sobre la satisfacción y el uso sostenido, la confiabilidad del sistema, la calidad del equipamiento, la estabilidad del suministro y las exigencias de mantenimiento. En este marco, Jagger et al. (2019) en regiones urbanas de África, analizaron la adopción (que refieren como 'temprana') de sistemas energéticos de BFP domésticos, estudiando los factores que la impulsan y las asociaciones existentes entre la adopción y la intervención de una empresa perteneciente al sector privado, proveedora tanto de equipos como de pellets. Utilizando técnicas de estratificación de hogares y análisis de diferencias en diferencias, evidenciaron que los beneficios percibidos en términos de salud y bienestar, se condicionan a restricciones económicas y sociales.

Desde una perspectiva que considera el interés por la BFP, en particular, Triani et al. (2025) estudiaron la implementación exitosa de proyectos de energía de la biomasa, identificando, y luego midiendo, los factores que motivan a las personas para la participación en los mismos. Analizan cuáles son aquellos que incrementan, desde un enfoque perceptivo, la intención que los individuos efectivamente tienen para involucrarse. Los autores proponen un modelo teórico integrando el Modelo de Aceptación de Tecnología (Davis, 1989) y la Teoría del Comportamiento Planificado (Ajzen, 1991). Toman en cuenta otras variables pertinentes, como la escolaridad, la preocupación ambiental, la experiencia, la información y los valores de autotrascendencia.

Existen numerosos aspectos para definir diferentes enfoques con los cuales la literatura especializada ha abordado perceptualmente los procesos sustitutivos de diferentes energéticos, empleados para los mismos usos finales (cocción y calefacción), por la biomasa (en particular, la BFP). Se observan enfoques desde la caracterización de perfiles y factores determinantes de la adopción residencial de BFP (García-Maroto et al., 2020; 2021); enfoques sociodemográficos que consideran barreras y dinámicas facilitadoras de los procesos sustitutivos (Seguin et al., 2018), (Boso et al., 2019) y (Álvarez et al., 2024); y enfoques centrados en la evaluación técnica y la viabilidad sostenible de la BFP frente a otras fuentes convencionales para los mismos usos (Dickinson et al., 2019), (Pardo et al., 2020), (Mawusi et al., 2023), (García et al., 2024), y (Gómez-Gil et al., 2024), entre los de mayor relevancia. No obstante, y en términos generales, tales enfoques tienden a ser de carácter post-adoptivo, considerando hogares que ya han incorporado la BFP, o bien, existiendo un cierto grado de penetración de este energético, se encuentran próximos a hacerlo.

Si bien la literatura existente ha realizado aportes valiosos en la identificación de factores relevantes para la adopción BFP y sus tecnologías aprovechamiento, los estudios revisados comparten una limitación común: los factores identificados suelen analizarse de manera post-adoptiva, mediante modelos explicativos parciales o análisis descriptivos y que abarcan regiones muy amplias en sus casos.

A diferencia de estos enfoques, el marco de trabajo subyacente en la presente investigación, considera que, en estadios de pre-adopción de la BFP, la segmentación regional integrando hogares con similares patrones de consumo energético (para calefacción, sin pérdida de generalidad), proporciona un contexto de mayor validez de contenido que el análisis sobre regiones amplias y heterogéneas. En tal contexto, el presente manuscrito busca operacionalizar, mediante una rigurosa metodología, un indicador perceptual que mida la propensión pre-adoptiva de los individuos, cuestión de fundamental importancia que no se observa tratada en el estado del arte.

METODOLOGÍA

La metodología se sustenta en un enfoque metodológico mixto, el cual involucra técnicas estadísticas multivariadas, obtención de indicadores simples que formarán el compuesto mediante modelos de optimización, y estabilización del mismo para operaciones. Sus Etapas se sintetizan a continuación:

Etapla I: Adecuación Muestral, Fiabilidad del Instrumento y Análisis Factorial Exploratorio sobre la muestra obtenida de hogares potencialmente adoptantes de la BFP. Identificación de la Estructura Factorial Latente y número de Factores retenidos.

Etapla II: Análisis Factorial Confirmatorio Multi-Grupo: Comprobación del Nivel de Invarianza de Medida. Comparación de medias latentes inter-grupo.

Etapla III: Construcción de los Indicadores Simples asociados a cada Factor.

Etapla IV: Construcción del Indicador Compuesto (IC): Método DEA-IC con restricciones de proporción y modificación en dos niveles de optimización para el IC de Mínima Dispersión. Definición operativa de

los valores finales para el empleo del IC como el Indicador Perceptual de propensión a la adopción de BFP.

Las mismas se desarrollan a continuación. Para seguir la ‘marcha de cálculo’ de la metodología propuesta, se optó por presentar también los resultados pertinentes de cada etapa, dado que son secuenciales e insumo de la siguiente.

Etapas I: Adecuación Muestral, Fiabilidad del Instrumento y Análisis Factorial Exploratorio

En la Tabla 1, se presentan las preguntas que componen el cuestionario administrado a los jefes de hogares residenciales suburbanos, potencialmente adoptantes de BFP como energético sustituto del utilizado de forma habitual (gas de red, gas en garrafa o leña), así como los estadísticos descriptivos para cada uno de los ítems asociados a las mismas. También se muestran los resultados de los principales indicadores utilizados para evaluar la fiabilidad de la escala y la adecuación del instrumento de medida. La muestra considerada tiene 301 observaciones (199 de la provincia de Córdoba y 102 de la provincia de Santa Fe). Se utilizó una puntuación Likert de 7 puntos [1 a 7], en la cual: 1 □ completamente en desacuerdo; 2 □ muy en desacuerdo; 3 □ en desacuerdo; 4 □ ni en desacuerdo ni de acuerdo; 5 □ de acuerdo; 6 □ muy de acuerdo; y 7 □ completamente de acuerdo. Para los casos en que un ítem se asocia a una puntuación invertida, se recodifica a un nuevo valor dado por: [puntaje nuevo = 8 – puntaje original]. Estos ítems se indican en la Tabla 1 mediante una (I), al final de la pregunta. Tal recodificación, permite obtener puntuaciones que faciliten la obtención de los indicadores, tanto los simples como el compuesto, en las etapas correspondientes, pues los valores más altos reflejan de forma consistente una percepción más favorable del ítem medido. Para cada ítem, se observan la medida de adecuación muestral de Kaiser-Meyer-Olkin (KMO) (Kaiser, 1974), la correlación $r(\text{ítem-test})$ (Hair et al., 2019) y, al final de la Tabla, el KMO y el α de Cronbach (Cronbach, 1951) globales. Se utilizó el software STATA 16.

La prueba de esfericidad de Barlett fue significativa: $\chi^2 = 3909.670$; $gl = 66$; $p < 0.001$, rechazándose la hipótesis nula de no correlación entre las variables. En cuanto a la idoneidad muestral, la medida Kaiser-Meyer-Olkin (KMO) global fue de 0.808, valor meritorio para proceder con un AFE. A nivel individual por ítem, los valores KMO fueron mayormente superiores al valor mínimo recomendado o (0.60). Solo se identificaron dos ítems débiles (señalados en rojo en la Tabla 1): ADOMB3 (KMO = 0.599) y COMSERV4 (KMO = 0.392). Por su parte, las correlaciones $r(\text{ítem-test})$, que indican el grado de asociación entre las puntuaciones obtenidas de cada ítem con la puntuación global del instrumento, resultaron moderadas (> 0.3) – altas (> 0.5), excepto para los ítems que se identificaron como problemáticos dada su baja adecuación: COMSERV4, con un $r(\text{ítem-test}) = 0.162$, y ADOMB3 con un $r(\text{ítem-test}) = 0.241$, lo cual supone con una pobre contribución de ambos a la consistencia interna global. El alfa de Cronbach para todo el instrumento fue de 0.706, valor aceptable.

Una vez que se validó la fiabilidad del instrumento y su adecuación muestral para la identificación de factores latentes, se procedió con el Análisis Factorial Exploratorio (AFE). Se utilizó el método de factores principales (Principal Factor Analysis – PFA), con una rotación (ortogonal) Varimax y, de forma complementaria, una rotación (oblicua) Oblimin, para contrastar la estabilidad de la estructura factorial resultante. Estimada con los 12 ítems originales, la solución sin rotación exhibe claramente una estructura simple interpretable: se tienen tres factores bien definidos y un cuarto factor cuyas características son residuales, espurio y carente de sustento teórico. Siguiendo el criterio de Kaiser para la retención de factores latentes, el gráfico de sedimentación mostró un ‘codo’ a partir del cuarto autovalor. Los tres primeros factores explican el 72.600% de la varianza total, mientras que el cuarto factor, de características residuales y compuesto sólo por los ítems COMSERV4 (carga I = -0.720) y ADOMB3 (carga I = $+0.720$), elevaba el porcentaje acumulado al 81.400%, pero sin aportar una interpretación teórica que resultase consistente.

Tabla 1

Fiabilidad del Instrumento de Medida: Estadísticos Descriptivos y): Medida de Adecuación (KMO), Correlación r (ítem-test) y α de Cronbach

Descriptivos – Adecuación Muestral y Fiabilidad del Instrumento							Cuestionario
Ítem	Media	Std. Dev.	Min	Max	KMO	r(ítem-test)	Pregunta [si adoptara BFP]
FPCAL1	3.512	1.969	1	7	0.858	0.715	Podría calentar mi hogar de forma más eficaz
COMSERV1	4.409	1.981	1	7	0.721	0.508	Me resultaría más fácil conseguirla cuando la necesitara
ADOMB1	5.166	1.741	1	7	0.657	0.369	Instalar y poner en marcha las estufas sería más simple
FPCAL4	4.399	1.946	1	7	0.833	0.720	Se generaría más humo y suciedad en el interior de la vivienda (I)
COMSERV3	3.229	2.063	1	7	0.780	0.493	Los puntos de venta en mi zona no serían suficientes (I)
ADOMB2	5.545	1.729	1	7	0.611	0.362	El encendido, limpieza y reposición de combustible en las estufas de calefacción requerirían mucho tiempo y esfuerzo (I)
FPCAL2	4.093	1.983	1	7	0.885	0.718	La temperatura se podría regular, logrando ambientes confortables
COMSERV2	4.907	2.108	1	7	0.788	0.499	Los proveedores podrían brindar un servicio de venta rápido y garantizado
ADOMB3	4.000	2.003	1	7	0.599	0.241	Encender y operar una estufa llevaría más tiempo y resultaría difícil (I)

ADOMB4	5.402	1.776	1	7	0.719	0.325	El almacenamiento o y mantenimiento del combustible me resultarían tareas manejables
FPCAL3	4.724	1.807	2	7	0.878	0.719	La seguridad de calefaccionar de forma estable a lo largo del día sería igual o mejor
COMSERV4	4.000	2.003	1	7	0.392	0.162	Los proveedores no responderían en tiempo y forma cuando existiese mucha demanda (I)
				Overall	0.808	$\alpha = 0.706$	

Fuente: elaboración propia.

Las cargas factoriales (I) indican en qué medida la variabilidad de un ítem es explicada por un factor común al cual se asocia. Valores absolutos superiores a 0.50, se consideran elevados, entre 0.30 y 0.49, moderados, y valores inferiores a 0.30 débiles. Como se presenta en la Tabla 2, los ítems asociados a los tres primeros factores, presentan cargas I muy elevadas: sólo un ítem, ADOMB4, con una carga I = 0.776, siendo superiores a 0.820 para el resto. Esta situación evidencia la saturación en un único factor, con una estructura bien definida. Sobre el cuarto factor, sin interpretación conceptual clara, sólo cargan los ítems problemáticos: COMSERV4 y ADOMB3.

Las unicidades reflejan la proporción de la varianza total de cada ítem que no es explicada por los factores comunes extraídos (unicidad = 1 – comunalidad). Valores ≤ 0.30 , implican una unicidad muy buena (el factor explica $\geq 70\%$ de la varianza del ítem); entre 0.31 – 0.50, aceptable; entre 0.51 – 0.70, débil; y > 0.7 , inaceptable. Se observa que los dos ítems problemáticos son los de unicidades mayores, cercanas a la condición de débiles.

Dado que el PFA sugiere la retención de cuatro factores latentes, cuyos autovalores (u_i) resultan mayores o igual a 1: (Factor 1, $u_1 = 3.938$; Factor 2, $u_2 = 2.717$; Factor 3, $u_3 = 2.059$; Factor 4, $u_4 = 1.056$), se realizó complementariamente el Análisis Paralelo de Horn (Horn, 1965), utilizando 500 iteraciones. Este método compara los autovalores obtenidos de la matriz de correlaciones observada, con la correspondiente a una matriz de datos, con el mismo número de variables y tamaño muestral, derivados desde un gran número de matrices generadas aleatoriamente. Se conservan aquellos factores cuyos autovalores superan el umbral del percentil 95 de los valores generados aleatoriamente, lo cual expresa que no se deben al azar.

Tabla 2

Factorial Exploratorio (AFE, método de Factores Principales, sin rotación): Cargas factoriales y unicidades del análisis. (Se reportan únicamente las cargas factoriales con valor absoluto igual o superior a 0.15)

Ítem	Factor 1	Factor 2	Factor 3	Factor 4	Unicidad
FPCAL1	0.984				0.024
FPCAL2	0.985				0.022
FPCAL3	0.983				0.027
FPCAL4	0.989				0.016
COMSERV1		0.949			0.090
COMSERV2		0.937			0.112
COMSERV3		0.941			0.107
COMSERV4				-0.721	0.462
ADOMB1			0.822		0.312
ADOMB2			0.868		0.227
ADOMB3				0.720	0.467
ADOMB4			0.776		0.364

Fuente: elaboración propia.

Los resultados mostraron que solo los tres primeros autovalores observados, superaron a los esperados por azar (autovalores ajustados: $u1aju = 3.560$, $u2aju = 2.490$ y $u3aju = 1.950$, respectivamente), mientras que el cuarto ($u4aju = 0.960$) no alcanzó el umbral $\geq$ percentil 95.

De manera que, por todo lo analizado sobre las métricas obtenidas, son retenidos 3 Factores Latentes, coincidentes con la estructura de diseño del cuestionario administrado a los encuestados, sobre las tres dimensiones fundamentales que ratifica la literatura: calidad energética, comercialización y logística, y dificultades operativas de uso. Son referidos como: Favorabilidad en la Percepción de la Calidad (FPCAL), con cuatro ítems (FPCAL1, FPCAL2, FPCAL3 y FPCAL4); Comercialización y Servicio (COMSERV), con tres ítems (COMSERV1, COMSERV2 y COMSERV3); y Adaptabilidad y Dificultad Operativa para el Mantenimiento Básico (ADOMB), con tres ítems (ADOMB1, ADOMB2 y ADOMB4). Al correr un nuevo AFE – PFA con los 10 ítems finales, los mismos tres factores obtenidos explican el 86.930% de la variabilidad de los datos. Esto indica que el modelo factorial final, con el cual se trabaja en las etapas siguientes, exhibe una mayor capacidad para captar la estructura de variabilidad de los datos, reduciendo notablemente la proporción de varianza residual no explicada.

Etapas II: Análisis Factorial Confirmatorio Multi-Grupo. Comprobación del Nivel de Invarianza de Medida


En la Figura 1, se representa conceptualmente el Modelo de Medida a estimar. Los dos grupos (Grupo 1: hogares de Córdoba; Grupo 2: hogares de Santa Fe) para la región analizada, son considerados ante a posibles impactos debido a la existencia de políticas diferentes, referidas al fomento para el uso de la BFP. En Argentina, los Entes que regulan la energía en general, son autárquicos para cada provincia. Esta condición podría afectar la percepción de los individuos jefes de hogar encuestados, conforme la provincia donde residen, más allá de la relativa homogeneidad en los patrones de consumo que exhiba la región considerada.

En primer término, se lleva a cabo un Análisis Factorial Confirmatorio (AFC) para el Modelo de Medida completo, sin considerar los dos grupos en los cuales se divide la muestra. Los resultados de la estimación se presentan en la Tabla 3 y 4, siguiendo a Aldás y Uriel (2017). Luego, a efectos de

comprobar la Invarianza Factorial del Modelo, se siguen los pasos que son detallados en Schweickardt (2024), con el mismo sustento teórico que proporciona la literatura, principalmente: Joaquín Aldás en su capítulo del libro de Sarabia Sánchez (2013), (Meredith, 1993), (Cheung y Rensvold, 2002; Byrne, 2012), Koufteros y Marcoulides (2006). Los resultados se presentan en las Tablas 5, 6 y 7.

Figura 1

Modelo Conceptual de Medida. Constructos e Ítems



Fuente: elaboración propia.

Tabla 3

Propiedades Psicométricas del Modelo de Medida

Cargas Factoriales, Fiabilidad y Validez					
Factores, Ítems y Cargas Factoriales			Fiabilidad y Validez Convergente		
Factor	Ítem	λ (z-valor)	α- Crombach	RC	AVE
FPCAL	FPCAL1	0.985 (40.010***)	0.992	0.993	0.971
	FPCAL2	0.984 (37.453***)			
	FPCAL3	0.980 (40.111***)			
	FPCAL4	0.991 (39.081***)			
COMSERV	COMSERV1	0.946 (31.476***)	0.944	0.944	0.848
	COMSERV2	0.905 (36.957***)			
	COMSERV3	0.914 (30.065***)			
ADOMB	ADOMB1	0.709 (10.436***)	0.776	0.781	0.547
	ADOMB2	0.861 (12.671***)			
	ADOMB4	0.637 (9.0800***)			
Indicadores de Bondad de Ajuste (S-B o Robustos)					
S-Bχ² (32 df)	S-B CFI	S-B TLI	S-Bχ²/df	SRMR	S-B RMSEA (90% CI)
59.670 (p-Chi2 = 0.002)	0.993	0.990	1.0864	0.021	0.053(0.031 0.073)

Nota: λ = Cargas Factoriales estandarizadas; α = Alfa de Crombach (Crombach, 1951) -Fiabilidad Simple-; RC = Fiabilidad Compuesta (Bagozzi & Yi, 1998); (Fornell & Larker, 1981); (Sarabia Sánchez, 2013); AVE = Average Variance Extracted (Fornell y Larker, 1981); $S-B\chi^2 = \chi^2$ Satorra-Bentler (Satorra y Bentler, 1994); df = Grados de Libertad; S-B CFI = Comparative Fit Index (Bentler, 1990); S-B TLI = Tucker-Lewis Index (Tucker & Lewis, 1973) Robusto; (Bentler & Bonett, 1980); $S-B\chi^2/df = S-B\chi^2$ ratio de (Wheaton et al., 1977) Robusto; SRMR = Standarized Root Mean Residual (Jöreskog & Sörbom, 1981), (Pavlov et al., 2021); S-B RMSEA = Root Mean Square of Approximation (Steiger, 1990); (Steiger & Lind, 1980); (Kenny & McCoach, 2003) Robusto; CI = Confidence Interval; *** $\rightarrow p < 0.001$.

Fuente: elaboración propia.

Tabla 4

Propiedades Psicométricas del Modelo de Medida. Validez Discriminante. Ratio HT/MT

Validez Discriminante: Ratio HT/MT (Henseler et al., 2015)			
	FPCAL	COMSERV	ADOMB
FPCAL	1.000		
COMSERV	0.026	1.000	
ADOMB	0.064	0.040	1.000

Nota: La ratio HT/MT resulta < 1 entre pares de Factores distintos: < 0.900 .

Fuente: elaboración propia.

Tabla 5

Indicadores de Ajuste para los Modelos de Invarianza por Nivel

Nivel	S- $B\chi^2$	df	S- $B\chi^2/df$	S-B CFI	S-B TLI	S-B RMSEA (90% CI)	SRMR
Configural	97.678	64	1.526	0.992	0.988	0.058 (0.033–0.080)	0.030
Métrica	101.480	74	1.371	0.993	0.992	0.048 (0.021–0.070)	0.035
Escalar	112.275	81	1.386	0.993	0.992	0.049 (0.024–0.070)	0.036
Estricta	115.807	91	1.273	0.994	0.994	0.041 (0.009–0.062)	0.038

Fuente: elaboración propia.

Tabla 6

Tests de Diferencia Chi2 Robusta ($\Delta S-B\chi^2$) por Comparación entre Niveles de Invarianza Factorial

Comparación	Restricción añadida	$\Delta S-B\chi^2$ (df)	p	Decisión
Métrica vs. Configural	Igualdad de cargas (λ)	2.640 (10)	0. 989	Invarianza Métrica
Escalar vs. Métrica	Igualdad de interceptos (λ, τ)	9.940 (7)	0. 192	Invarianza Escalar
Estricta vs. Escalar	Igualdad de residuos (λ, τ, θ)	3.290 (10)	0. 974	Invarianza Estricta

Fuente: elaboración propia.

Tabla 7

Tests de Diferencia (Δ) de Indicadores de Ajuste (SRMR - S-B CFI - S-B RMSEA) entre Niveles de Invarianza Factorial

Comparación	Δ SRMR	Δ S-B CFI	Δ S-B RMSEA	Decisión
Métrica vs. Configural	0.005	+0.001	-0.010	Invarianza Métrica
Escalar vs. Métrica	0.001	0.000	+0.001	Invarianza Escalar
Estricta vs. Escalar	0.002	+0.001	-0.008	Invarianza Estricta

Nota: Umbrales satisfactorios adoptados para los valores Δ : Δ S-B CFI $\leq$ 0.01; Δ SRMR $\leq$ 0.03; Δ S-B RMSEA $\leq$ 0.015 (Cheung & Rensvold, 2002) y (Chen, 2007).

Fuente: elaboración propia.

En cuanto al AFC, Tabla 3, las cargas factoriales para los factores FPCAL y COMSERV son muy elevadas, y los valores de α -Crombach, RC y AVE muy satisfactorios. El factor ADOMB presenta dos ítems fuertes: ADOMB2, con $\lambda = 0.861$, y ADOMB1, con $\lambda = 0.709$. El tercero puede considerarse adecuado: ADOMB4, con $\lambda = 0.637$, dado que se trata de un factor con un número reducido de ítems. El α -Crombach (= 0.776), fiabilidad simple, y la fiabilidad compuesta, RC (= 0.781), son aceptables. La varianza promedio extraída, AVE (= 0.547), no obstante ser menor que la correspondiente a los dos primeros factores, supera el umbral límite (≥ 0.5). El ajuste general del Modelo, observando los valores de los indicadores reportados, es muy bueno. Adicionalmente, cumple con la validez discriminante, Tabla 4, muy satisfactoriamente.

En cuanto al Análisis Multigrupo, la Invarianza Factorial fue comprobada mediante dos enfoques: a) Pruebas de diferencia de χ^2 , y b) Diferencias (Δ) entre Indicadores de Ajuste SRMR, S-B CFI y S-B RMSEA. La Tabla 5, muestra los indicadores de ajuste para los Modelos de Invarianza por Nivel. Las Tablas 6 y 7, presentan los resultados del enfoque a) y b), respectivamente. El ajuste en todos los casos fue muy satisfactorio, y se comprobó que el Modelo alcanza el nivel de Invarianza Estricta.

El nivel de Invarianza Escalar, es el suficiente para la comparación de medias latentes entre los dos grupos considerados (Córdoba y Santa Fe). Este paso, final y fundamental para la Etapa II, está orientado, como se dijo, a evaluar si existen diferencias estadísticamente significativas en la percepción de los encuestados, según residan en una u otra provincia, como potenciales adoptantes de la BFP. Como se explicó, podrían existir e influir políticas diferenciadas de incentivos para el fomento de este energético, dado que cada provincia es autárquica respecto de las normativas reguladora de energía. Esta comparación se presenta en la Tabla 8. Si bien es suficiente reportar la comparación de medias latentes para el nivel Escalar, dado que el Modelo alcanzó Invarianza Estricta tales estimaciones son también reportadas en este nivel. Se observa que, en ambos niveles, las estimaciones arrojan resultados prácticamente idénticos.

Tabla 8

Comparación de Medias Latentes por constructo y Nivel de invarianza (Escalar y Estricta)

Constructo	Nivel de Invarianza	$\Delta\mu$ (SF-Cba)	EE	z	p	IC 95%
FPCAL	Escalar	-0.115	0.122	-0.94 1	0.347	[-0.354; 0.124]
	Estricta	-0.114	0.122	-0.93 5	0.350	[-0.353; 0.125]

COMSERV	Escalar	-0.038	0.124	-0.310	0.757	[-0.281; 0.205]
	Estricta	-0.040	0.124	-0.322	0.747	[-0.283; 0.203]
ADOMB	Escalar	+0.019	0.132	+0.144	0.886	[-0.240; 0.278]
	Estricta	+0.024	0.132	+0.183	0.855	[-0.236; 0.284]

Nota: EE: error estándar; $\Delta\mu(\text{SF}-\text{Cba})$: diferencia de medias latentes estimada entre los grupos (Grupo 1, Córdoba, es el de referencia); z: estadístico de contraste ($\Delta\mu/\text{EE}$); p: p-valor. IC 95%: todos incluyen el valor 0.

Fuente: elaboración propia.

La Tabla 8 muestra que en la comparación inter-grupo de medias latentes para cada factor de Modelo no se evidencian diferencias estadísticamente significativas. Esta condición se sostiene, inclusive, en el nivel de Invarianza Estricta. De modo que la percepción de los potenciales adoptantes se considera equivalente en ambas provincias. Los resultados no excluyen la existencia de políticas de incentivo diferenciadas entre Córdoba y Santa Fe sino que sugieren, no obstante aquellas puedan existir, que sus diferencias no se traducen en percepciones significativamente distintas por parte de los encuestados. De haber existido evidencia que avalen medias latentes significativamente distintas, una razón podría sostenerse en políticas de fomento diferentes para ambas provincias, relativas a la penetración de la BMP. Pero no puede, en tal caso, establecerse como una relación de carácter causal.

Etapla III: Construcción de los Indicadores Simples asociados a cada Factor

En base a los resultados de la Etapa II, se adoptan los puntajes factoriales, $\hat{\eta}_{ij}$, (factor j para cada individuo i) como ‘insumo’ o entradas para construir tres índices simples. Las razones de tal adopción estriban en que:

Constituyen la síntesis de mayor simplicidad para captar la información inherente a los ítems de cada factor del Modelo. El pasaje de: ítems $\rightarrow$ factor latente $\rightarrow$ índice simple, preserva la estructura confirmada por el AFC.

Al haber probado Invarianza Estricta, los puntajes $\hat{\eta}_{ij}$ se encuentran en una misma escala latente entre provincias. Esto asegura que cualquier transformación monótona posterior de $\hat{\eta}_{ij}$, mantenga el orden relativo y no introduzca sesgos de escala por grupo.

El método de agregación de los índices simples en uno compuesto aquí empleado, DEA-IC, requiere entradas homogéneas, no negativas y de ‘beneficio’. Por ello, cada puntaje $\hat{\eta}_{ij}$ se transforma de forma simple en un índice normalizado en $[0, 1]$ orientado a un criterio ‘cuanto más, mejor’, lo cual evita sesgos por heterogeneidad de ‘unidades’ (empleando la terminología DEA, las observaciones resultan ser las unidades de análisis), facilitando, a su vez, la interpretación y el agregado para obtener el indicador compuesto.

Operativamente: para cada Factor $j \in \{\text{FPCAL}, \text{COMSERV}, \text{ADOMB}\}$ y cada individuo i , se calcula un índice simple, IS como:

$$IS_{ij} = G\left(\hat{\eta}_{ij}\right) \tag{1}$$

donde $G(\cdot)$ es una transformación monótona que mapea los puntajes latentes a $[0,1]$. Como $G(\cdot)$, se consideran dos transformaciones equivalentes: por intervalo Min–Max directo y Min–Max robusto (winsorizado por percentiles). La expresión general, en ambos casos, resulta:

$$IS_{ij} = \frac{\hat{\eta}_{ij} - \text{Min}_k \hat{\eta}_{kj}}{\text{Max}_k \hat{\eta}_{kj} - \text{Min}_k \hat{\eta}_{kj}} \tag{2}$$

El winsorizado, propuesto por Tukey (1962), supone una versión ‘robusta’ de la transformación Min–Max directa, en la cual los puntajes factoriales se recortan por percentiles (1%–99%) antes de la normalización. Teniendo los resultados para el método directo, expresión (2), y los de esta versión robusta (winsorizada), se compararon ambas transformaciones mediante diversas métricas de concordancia y distancia. Los resultados se presentan en las Tablas 9 y 10.

En la Tabla 9, se observa que los estadísticos descriptivos de los índices directos y winsorizados son prácticamente idénticos. En la comparación de las dos transformaciones monótonas, Tabla 10, se tienen también resultados de equivalencia conforme las métricas empleadas.

Tabla 9

Estadísticos descriptivos y diferencias absolutas entre índices simples directos y winsorizados

I-Factor	n	Media (Directo)	SD (Directo)	Media (Winsor)	SD (Winsor)	Dif. media	Dif. Mediana	Max. dif. abs.
I-FPCAL	301	0.5184	0.3289	0.5184	0.3290	0.00005	0.00004	0.00016
I-COMSERV	301	0.5336	0.3224	0.5334	0.3225	-0.00019	-0.00017	0.00051
I-ADOMB	301	0.7349	0.2484	0.7356	0.2489	0.00068	0.00082	0.00122

Nota: I-Factor: indicador resultante, según la transformación, asociado a cada factor; n: N° observaciones; SD: desviación estándar; Dif.: diferencia; Max. Dif. Abs: máxima diferencia absoluta entre el índice winsorizado y el índice directo, observada a nivel individual.

Fuente: elaboración propia.

El coeficiente de correlación r de Pearson resultó la unidad para los tres indicadores asociados a sendos factores, y los coeficientes de correlación ρ de Spearman confirman una concordancia monótona perfecta ($= 0.999$);

El estadístico de Kolmogorov-Smirnov ($KS-D \leq 0.056$) indica que las distribuciones empíricas para la transformación directa y winsorizada no presentan diferencias significativas en forma ni dispersión (en ningún punto del conjunto $[0, 1]$, la diferencia acumulada entre las distribuciones de los índices directos y winsorizados supera el 5.6%); y

Los tamaños del efecto inter-grupal (d de Cohen) no se modifican entre ambas transformaciones, lo cual sugiere que el winsorizado no modifica la relación entre los grupos considerados.

Tabla 10

Correlación, equivalencia distributiva y efecto inter-grupo de los índices simples

I-Factor	r	ρ	KS-D	d (Directo)	d (Winsor)
I-FPCAL	1.000	0.999998	0.056	0.114	0.114

I-COMSERV	1.000	0.999998	0.043	0.038	0.038
I-ADOMB	1.000	0.999998	0.043	-0.023	-0.023

Nota: I-Factor: indicador resultante, según la transformación, asociado a cada factor; r: coeficiente de Pearson; p: coeficiente de Spearman; KS-D: estadístico de Kolmogorov-Smirnov (Stephens, 1992); d: d de Cohen (Cohen, 1988).

Fuente: elaboración propia.

Se concluye, de esta manera, que la transformación winsorizada no introduce beneficios adicionales respecto de la normalización directa por intervalo, dada por la expresión (2), cuyos valores son los operativos para las etapas siguientes.

Etapla IV: Construcción del Indicador Compuesto (IC): Método DEA-IC con restricciones de proporción y modificación en dos niveles de optimización para el IC de Mínima Dispersión

El modelo de agregación de indicadores simples (o subindicadores, IS) en un indicador compuesto (IC) DEA-IC, constituye un enfoque sustentado programación lineal eficiencia no paramétrica, que resuelve de forma conjuntamente los esquemas de ponderación y agregación, evitando imponer, a priori, pesos fijos (Lovell & Pastor, 1999). Para cada unidad de análisis, el modelo elige aquellos pesos que maximizan su propio desempeño relativo, dentro de restricciones de equidad y participación mínima por componente. Esto confiere al índice compuesto obtenido, una estructura endógena empíricamente fundada, libre de arbitrariedades y coherente con la heterogeneidad de las percepciones (Zhu, 2014) y Zhou et al. (2007, 2021). De esta forma, su elección para la presente etapa se sintetiza en los siguientes puntos:

Como se sustenta en una técnica DEA (Data Envelopment Analysis – Análisis Envolvente de Datos), tiene un esquema de ponderación que carece de subjetividad por parte del tomador de decisiones, ya que los pesos de los ISs son determinados a través un proceso de optimización iterativo.

Las tareas de ponderación y agregación se realizan al mismo tiempo.

El esquema de ponderación tiene una estructura de ponderación simple, SAW - Simple Additive Weighting –, pero con la diferencia de que los pesos SAW son fijos y exógenos, mientras que los obtenidos mediante DEA-IC son variables (para cada unidad) y endógenos.

El único aspecto rígido que presenta este enfoque, estriba en que todos los subindicadores deben ser de 'beneficio' – criterio 'cuanto más, mejor'-. Como se ha visto en las secciones anteriores, tal condición no implica ninguna limitación para este estudio, pues los índices simples factoriales, por construcción, cumplen con ese criterio. En general, si algún subindicador fuese de 'costo', -criterio 'cuanto menos, mejor' - 'tendrá que ser transformado en uno de 'beneficio', lo cual no entraña dificultades, salvo casos específicos.

El método DEA-IC como lo formulan Zhou et al. (2007, 2021), formalmente requiere de tres pasos que arriban a sendos modelos operacionales:

1er Paso: Modelo (I): Son considerados m ISs, y n unidades-observaciones de la muestra, cuyos valores son designados como: I_{ij} , i en $[1, n]$, j en $[1, m]$. Resolviendo iterativamente n veces, una por cada unidad, se obtiene el conjunto de índices, $\{I_1, I_2, \dots, I_m\}$. w_{ij}^I , es el peso del indicador j , asignado a la por el modelo a la unidad i , en el agregado de su indicador, I_i :

$$I_i = \text{Max} \sum_{j=1}^n w_{ij}^I I_{ij} \quad (3)$$

Sujeto a:

$$\sum_{j=1}^n w_{ij}^l I_{kj} \leq 1, k = 1, 2, \dots, m \quad w_{ij}^l \geq 0, j = 1, 2, \dots, n \quad (4)$$

Se trata de un modelo DEA multiplicador, que maximiza la eficiencia, con salidas múltiples y entradas constantes. Mide 'cuán lejos' está la entidad evaluada de la entidad de mejor práctica, 'bajo los mejores pesos posibles' (desde aquí la 'l' en II_i). Los valores de II_i , resultarán en el intervalo $[0, 1]$.

Si fuese considerado únicamente el Modelo (I) en la construcción del indicador compuesto (IC), se presentarían dos inconvenientes: a) si una unidad tuviese un valor para determinado subindicador, que domina a las otras unidades siempre obtendrá una puntuación de 1, aun teniendo valores muy pobres en los otros subindicadores; b) puede conducir a una situación en la que una gran cantidad de unidades tengan una puntuación de desempeño igual a 1, y cualquier diferenciación o clasificación entre las mismas resulte dificultosa. El Modelo (I) por sí mismo carece, entonces, de una cualidad imprescindible para un indicador compuesto, que es referida como 'poder o capacidad de discriminación'. Los autores introducen un segundo modelo de programación lineal, que resuelve estos dos inconvenientes.

2do Paso: Modelo (II): Con la misma estructura en la notación, se expresa como:

$$cI_i = \text{Min} \sum_{j=1}^n w_{ij}^c I_{ij} \quad (5)$$

Sujeto a:

$$\sum_{j=1}^n w_{ij}^c I_{kj} \geq 1, k = 1, 2, \dots, m \quad w_{ij}^c \geq 0, j = 1, 2, \dots, n \quad (6)$$

Este modelo mide 'cuán cerca está la entidad evaluada de la entidad de peor práctica', bajo 'los peores pesos posibles' (desde aquí la 'c' en cI_i y en los pesos w_{ij}^c). Los valores obtenidos para cI_i , serán mayores o iguales a 1. Por esta razón, se normalizan ambos indicadores por intervalo min-max, y se los agrega en el tercer paso.

3er Paso: Modelo (III): Se integran los dos aspectos complementarios de la eficiencia para cada unidad, sintetizados por los valores II_i y cI_i , en un modelo de operación (no de optimización) que genera los valores individuales para el indicador compuesto,

$$IC_i(\lambda) = \lambda \cdot \frac{II_i - II^-}{II^+ - II^-} + (1 - \lambda) \cdot \frac{cI_i - cI^-}{cI^+ - cI^-} \quad (7)$$

Los valores II^- , II^+ y cI^- , cI^+ , corresponden al máximo y mínimo de los indicadores parciales obtenidos desde los Modelos (I) y (II), respectivamente, para la normalización por intervalo referida. Los autores introducen el parámetro λ , que toma valores discretos con incrementos de 0.1 en el intervalo $[0.1, 0.9]$. Su función es permitir una ponderación hacia una de las dos métricas de eficiencia, pero en las aplicaciones que presentan establecen $\lambda = 0.5$, lo cual equivale a promediar los dos componentes. Los valores que asume $IC_i(\lambda)$, independientemente del valor fijado para λ , siempre estarán en el intervalo $[0, 1]$. También consideran lo que denominan 'restricciones de proporción' en la participación de cada indicador simple en su agregado para obtener el compuesto, con iguales límites inferior, Inf_j , y superior, Sup_j , para cada indicador j . Estas restricciones se expresan como:

$$Inf_j \leq \frac{w_{ij}^l I_{ij}}{\sum_{j=1}^n w_{ij}^l I_{ij}} \leq Sup_j, j = 1, 2, \dots, m \quad Inf_j \leq \frac{w_{ij}^c I_{ij}}{\sum_{j=1}^n w_{ij}^c I_{ij}} \leq Sup_j, j = 1, 2, \dots, m \quad (8)$$


De forma que pueden ser considerados dos indicadores compuestos en la ecuación (7): Sin y Con restricciones de proporción. Se describen sus simulaciones, utilizando los software R y Python.

Solución DEA-IC para el Indicador de Propensión Perceptual a la adopción de BFP, Sin restricciones de Proporción

Los valores de los subindicadores, en este caso, son los puntajes factoriales normalizados que arroja la ecuación (2). Dado que el parámetro λ , adopta valores discretizados en $[0.1, 0.9]$ con saltos de 0.1, para cada unidad se tendrá dispersión en los valores de $IC_i(\lambda)$. Como no es posible, por cuestiones de espacio, presentar valores individuales, se optó por reportar un gráfico box-plot para 50 unidades-observaciones, elegidas aleatoriamente desde los 301 totales que tiene la muestra, gráfico 1.

Gráfico 2

Gráficos Box-Plot del $IC_i(\lambda)$ para 50 individuos de la muestra elegidos aleatoriamente



Fuente: elaboración propia.

En esta figura se observa dónde se ubica la mediana (coincidente con $\lambda = 0.5$) del valor de $IC_i(\lambda)$, y la muy elevada dispersión que tiene, en general, el indicador compuesto al variar el parámetro (λ). No podría garantizarse la misma clasificación u ordenamiento para $IC_i(\lambda)$ en esta submuestra, que resulte independiente del valor asignado al parámetro. En indicador compuesto carece de robustez, y no tiene mucho sentido 'colapsar' sus valores en $\lambda = 0.5$.

Solución DEA-IC para el Indicador de Propensión Perceptual a la adopción de BFP, Con restricciones de Proporción

En este caso, la propuesta para el presente estudio es novedosa y constituye un aporte respecto a la formulación del método DEA-IC en su forma original. La estrategia consiste en incorporar restricciones de proporción, respecto a la participación de los subindicadores factoriales, proponiendo una optimización en dos niveles, que se realiza en forma conjunta. Los pasos operativos se presentan a continuación:

Límites Inferior y Superior de las restricciones de proporción para cada subindicador factorial: Se define un intervalo en el que pueden variar las restricciones para cada subindicador j , conjunto indicado en las Tablas 9 y 10 como $\{I-FPCAL, I-COMSERV \text{ e } I-ADOMB\}$, $[L_j, U_j]$, cuyos valores límite inferior (L_j ; $\sum_j L_j < 1$) y superior (U_j ; $\sum_j U_j > 1$) se fijan en proporción a la varianza media extraída para cada factor, AVE, mediante dos multiplicadores, ML y MU , con $ML < MU$:

$$L_j = ML \cdot wAVE_j, U_j = MU \cdot wAVE_j, wAVE_j = \frac{AVE_j}{\sum_j AVE_j} \rightarrow \sum_j wAVE_j = 1 \quad (9)$$

Optimización en dos Niveles: Se define, primeramente, el Rango Intercuartílico para cada individuo i -ésimo, como:

$$IQR_i(ML, MU) = Q_{0.75}\{IC_i(\lambda)\} - Q_{0.25}\{IC_i(\lambda)\} \quad (10)$$

Como se observa en la expresión (10), este valor será una función de los multiplicadores ML y MU . Luego, la función objetivo de nivel superior que ingresa en un contexto de minimización, es el el Rango Intercuartílico Promedio Global (u objetivo de Mínima Dispersión), $J(ML, MU)$, definido como:

$$J(ML, MU) = \frac{1}{n} \sum_{i=1}^n IQR_i(ML, MU) \quad (11)$$


La minimización de $J(ML, MU)$, permite identificar los valores óptimos de (ML^*, MU^*) :

$$(ML^*, MU^*) = \arg \min_{ML, MU} J(ML, MU) \quad (12)$$

Y con ello los valores óptimos para las restricciones óptimas para cada subindicador factorial (L_j^*, U_j^*) , desde la expresión (9). Los resultados, al igual que en la Figura 2 y para los mismos 50 individuos seleccionados aleatoriamente sobre los 301 de la muestra, se presentan en el gráfico 2.

Gráfico 2

Gráficos Box-Plot del $IC_i(\lambda)_{(ML^*, MU^*)}$ de Mínima Dispersión para los 50 individuos de la muestra elegidos aleatoriamente



Fuente: elaboración propia.


Los valores de AVE (Tabla 3), resultaron: FPCAL, AVE = 0.971; COMSERV, AVE = 0.848; ADOMB, AVE = 0.547. Consecuentemente, desde la ecuación (9), los correspondientes pesos wAVE, resultaron: FPCAL, wAVE = 0.410; COMSERV, wAVE = 0.358; ADOMB, wAVE = 0.232. En cuanto a los intervalos de búsqueda para (ML, MU) , se adoptó: ML en $[0.95, 0.99]$ y MU en $[1.10, 1.20]$. Para ejecutar la optimización en dos niveles (nivel superior $\min_{ML, MU} J(ML, MU)$ y nivel inferior $IC_i(\lambda)$) se aplicó el método de Montecarlo. Se consideraron Bmax = 1000 réplicas, repitiendo cada simulación para cuatro semillas estocásticas: [127, 3597, 978 y 98765]. Como se presenta en la Figura 4, las cuatro trayectorias convergen hacia el mismo valor, con diferencias 6to decimal, y un valor de B = 250 réplicas es suficiente para alcanzar el umbral práctico de mínima dispersión. En esta situación tiene sentido colapsar el $IC_i(\lambda)_{(ML^*, MU^*)}$ al valor $\lambda = 0.5$, mediana de cada box-plots i -ésimo. Este resultará el valor operativo del Indicador de Propensión Perceptual a la adopción de BFP.

Análisis Estabilidad del Índice Compuesto Operativo: El coeficiente de congruencia de Tucker–Tukey (ϕ) resulta la métrica más adecuada para evaluar la robustez estructural o estabilidad del índice compuesto operativo. El proceso final de agregación del IC operativo no guarda linealidad con los subindicadores factoriales. (ϕ), al medir el coseno del ángulo entre los vectores no centrados, no depende de la linealidad, sino de la semejanza direccional entre los patrones de variación. Los valores obtenidos: I-FPCAL, $\phi = 0.868$; I-COMSERV, $\phi = 0.886$; I-ADOMB, $\phi = 0.856$, evidencian una congruencia muy alta entre el IC ($\lambda = 0.5$) y sus subindicadores factoriales. En términos geométricos, se tienen ángulos de 29.773° , 27.625° y 31.130° , respectivamente, inferiores a 32° , indicando que los vectores asociados al índice compuesto operativo y a cada subindicador factorial, mantienen una orientación prácticamente coincidente dentro del espacio de percepción, con muy alta alineación geométrica.

Comparación de Medias inter-grupo de (IC ($\lambda = 0.5$)): Dado el tamaño muestral desigual entre grupos y la ausencia de evidencia de diferencias, se optó por la prueba t de Welch como contraste, por ser robusta ante posibles heterocedasticidades. Los resultados se presentan en la Tabla (11).

Gráfico 3

Curvas ‘Best-so-far’ – ‘Mejor hasta Ahora’, $J = f(B)$ ($B_{max} = 1000$; 4 semillas)



Fuente: elaboración propia.

Tabla 11

Diferencia de medias inter-grupo para IC ($\lambda = 0.5$) el evaluada mediante prueba t de Welch

Provincia	n	Media IC ($\lambda = 0.5$)	Δ Media (SF–Cba)	IC 95%	p (Welch)	Tamaño de efecto
Córdoba	199	0.403	-0.024	[-0.086 ; 0.039]	0.453	g = -0.09
Santa Fe	102	0.427				

Nota: n: número de observaciones para cada grupo-provincia; g de Hedges (tamaño del efecto).


Fuente: elaboración propia.

No existen diferencias significativas en las medias del IC ($\lambda = 0.5$), como Indicador de Propensión Perceptual a la adopción de BFP operativo, IPP-BFP, entre ambos grupos. Se confirma, de esta manera,

que las propiedades perceptuales se sostienen a lo largo de toda la metodología propuesta para su construcción. Finalmente, si los hogares cuyos IPP-BFPi superan o igualan al promedio del indicador fuesen identificados como adoptantes de BFP, se tendría la distribución del gráfico 4.

Gráfico 4

Distribución del IPP-BFP con grupos de adopción



Fuente: elaboración propia.

CONCLUSIONES

Son sintetizados los siguientes puntos como conclusiones finales del trabajo de investigación abordado:

Se ha presentado una novedosa metodología de cuatro etapas, que permite, partiendo de un cuestionario afín aplicado en una región argentina, obtener un indicador perceptual de propensión a la adopción de biomasa forestal pelletizada como energético sustituto a nivel residencial. Esta región integra individuos que residen en las provincias de Córdoba y Santa Fe, y cuyos patrones de consumo energético para calefacción tienen características similares (hogares del segmento suburbano).

El enfoque metodológico es mixto (o multi-instrumental) y riguroso, incorporando técnicas del análisis estadístico multivariante (AFE, AFC, pruebas de invarianza factorial y de comparación de medias inter-grupo), Optimización (DEA IC) y Estabilización por optimización en dos niveles (simulación de Montecarlo), como instrumentos centrales de la estrategia operacional propuesta.

Los resultados, si bien se corresponden con el caso de estudio particular, no quitan generalidad al la metodología propuesta, la cual puede ser replicada en otros contextos, siempre que incorporen las tres dimensiones que respalda la literatura en los estudios de pre-adopción de BFP, aquí representadas por los tres factores latentes confirmados: Favorabilidad en la Percepción de la Calidad (FPCAL), Comercialización y Servicio (COMSERV), y Adaptabilidad y Dificultad Operativa para el Mantenimiento Básico (ADOMB). Es de importancia, en potenciales replicaciones de esta metodología, considerar que la segmentación regional, integrando hogares con similares patrones de consumo energético (para calefacción, sin pérdida de generalidad), proporciona un contexto de mayor validez de contenido que el análisis sobre regiones amplias y heterogéneas. Asimismo, el Indicador obtenido resultó de gran

utilidad para la definición de políticas de incentivos que favorezcan la penetración de la BFP en forma para la región considerada.

REFERENCIAS

- Ajzen, I. (1991). The theory of planned behavior. *Organizational behavior and human decision processes*, 50(2), pp. 179-211. [https://doi.org/10.1016/0749-5978\(91\)90020-T](https://doi.org/10.1016/0749-5978(91)90020-T)
- Aldás, J., Uriel, E. (2017). *Análisis Multivariante Aplicado con R*. 2da Edición. Paraninfo.
- Álvarez, B., Boso, À., Rodríguez-Rodríguez, I., & Espluga-Trenc, J. (2024). Engaging communities in energy transitions: A study on attitudes towards sustainable heating technologies and the role of peer effects in Southern Chile. *Sustainability*, 16(20), 9115. <https://doi.org/10.3390/su16209115>
- Antar, M., Lyu, D., Nazari, M., Shah, A., Zhou, X., & Smith, D. L. (2021). Biomass for a sustainable bioeconomy: An overview of world biomass production and utilization. *Renewable and Sustainable Energy Reviews*, 139, 110691. <https://doi.org/10.1016/j.rser.2020.110691>
- Anukam, A., Berghel, J., Henrikson, G., Frodeson, S., & Ståhl, M. (2021). A review of the mechanism of bonding in densified biomass pellets. *Renewable and Sustainable Energy Reviews*, 148, 111249. <https://doi.org/10.1016/j.rser.2021.111249>
- Bagozzi, R.P., Yi, Y. (1998). On the Evaluation of Structural Equation Models. *JAMS* 16, pp. 74–94.
- Bar-On, Y. M., Phillips, R., & Milo, R. (2018). The biomass distribution on Earth. *Proceedings of the National Academy of Sciences*, 115(25), pp. 6506–6511. <https://doi.org/10.1073/pnas.1711842115>
- Bentler, P. M. (1990). Comparative fit indexes in structural models. *Psychological Bulletin*, 107, pp. 238–246. <https://doi.org/10.1037/0033-2909.107.2.238>
- Bentler, P.M., Bonett, D. G. (1980). Significance tests and goodness of fit in the analysis of covariance structures. *Psychological Bulletin*, 88, pp. 588–606. <https://doi.org/10.1037/0033-2909.88.3.588>
- Bonechi, C., Consumi, M., Donati, A., Leone, G., Magnani, A., Tamasi, G., & Rossi, C. (2017). Biomass: An overview. In *Bioenergy systems for the future* (pp. 3–42). Academic Press. <https://doi.org/10.1016/B978-0-08-101031-0.00001-6>
- Boso, À., Oltra, C., & Hofflinger, Á. (2019). Participation in a programme for assisted replacement of wood-burning stoves in Chile: The role of sociodemographic factors, evaluation of air quality and risk perception. *Energy Policy*, 129, pp. 1220–1226. <https://doi.org/10.1016/j.enpol.2019.03.038>
- Bridgwater, T. (2006). Biomass for energy. *Journal of the Science of Food and Agriculture*, 86(12), pp. 1755–1768. <https://doi.org/10.1002/jsfa.2605>
- Byrne, B. M. (2012). *Structural Equation Modeling with Mplus: Basic Concepts, Applications, and Programming*. New York, NY: Routledge. <https://doi.org/10.4324/9780203807644>
- Chen, F. F. (2007). Sensitivity of goodness of fit indexes to lack of measurement invariance. *Structural Equation Modeling*, 14(3), 464-504. <https://doi.org/10.1080/10705510701301834>
- Cheung, G. W., & Rensvold, R. B. (2002). Evaluating goodness-of-fit indexes for testing measurement invariance. *Structural Equation Modeling*, 9(2), pp. 233–255. https://doi.org/10.1207/S15328007SEM0902_5
- Clifton, J. D. W. (2020). Managing Validity versus Reliability Trade-offs in Scale Building Decisions. *Psychological Methods*, 25(2), pp. 259–270. <https://doi.org/10.1037/met0000226>

Cohen, J. (2013). *Statistical power analysis for the behavioral sciences*. Routledge. <https://doi.org/10.4324/9780203771587>.

Cronbach, L. J. (1951). Coefficient alpha and the internal structure of tests. *Psychometrika*, 16 (3): pp. 297-334.

Davis, F. D. (1989). Technology acceptance model: TAM. Al-Suqri, MN, Al-Aufi, AS: *Information Seeking Behavior and Technology Adoption*, 205(219), 5.

Dickinson, K. L., Piedrahita, R., Coffey, E. R., Kanyomse, E., Alirigia, R., Molnar, T., ... & Wiedinmyer, C. (2019). Adoption of improved biomass stoves and stove/fuel stacking in the REACCTING intervention study in Northern Ghana. *Energy Policy*, 130, pp. 361–374. <https://doi.org/10.1016/j.enpol.2019.04.021>

Field, C. B., Campbell, J. E., & Lobell, D. B. (2008). Biomass energy: The scale of the potential resource. *Trends in Ecology & Evolution*, 23(2), pp. 65–72. <https://doi.org/10.1016/j.tree.2007.12.001>

Fornell, C., Larcker, D. F. (1981). Evaluating Structural Equation Models with Unobservable Variables and Measurement Error. *Journal of Marketing Research*, 18(1), 39. <https://doi.org/10/cwp>

García, R. C., Galán, G., & Martin, M. (2024). Multiscale analysis for the valorization of biomass via pellets production towards energy security. *Journal of Cleaner Production*, 461, 142663. <https://doi.org/10.1016/j.jclepro.2024.142663>

Garcia-Maraver, A., & Pérez-Jiménez, J. A. (Eds.). (2015). *Biomass pelletization: Standards and production*. WIT Press.

García-Maroto, I., Muñoz-Leiva, F., Higuera-Castillo, E., & Liébana-Cabanillas, F. (2020). The main determinants of adopting domestic biomass heating systems: An integrating model. *Sustainability Accounting, Management and Policy Journal*, 11(2), pp. 409–428. <https://doi.org/10.1108/SAMPJ-03-2019-0133>

García-Maroto, I., Muñoz-Leiva, F., Higuera-Castillo, E., & Liébana-Cabanillas, F. (2021). Characterisation of potential adopters of domestic biomass heating. *International Journal of Green Energy*, 18(3), pp. 219–230. <https://doi.org/10.1080/15435075.2020.1854262>

Gómez-Gil, M., Etxebarria-Mallea, M., Arbulu, M., Grijalba-Aseguinolaza, O., Espinosa-Fernández, A., & Monzón-Chavarrías, M. (2024). Indicators and data in Spain regarding evidence-based estimate of expected energy savings and of reduction of costs for health systems from buildings renovation. In *Assessing Progress in Decarbonizing Spain's Building Stock: Indicators and Data Availability* (pp. 245–259). Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-51829-4_9

Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2019). *Multivariate Data Analysis* (8th ed.). Cengage.

Hall, D. O., Rosillo-Calle, F., Woods, J., & Williams, R. H. (1993). Biomass for energy: Supply prospects. *Renewable Energy*, 3(4–5), pp. 487–497. [https://doi.org/10.1016/0960-1481\(93\)90064-C](https://doi.org/10.1016/0960-1481(93)90064-C)

Henseler, J., Ringle, C.M. and Sarstedt, M. (2015). A new criterion for assessing discriminant validity in variance-based structural equation modeling. *Journal of the Academy of Marketing Science*, Vol. 43 No. 1, pp. 115-135. <https://doi.org/10.1007/s11747-014-0403-8>

Jagger, P., Das, I., Handa, S., Nylander-French, L. A., & Yeatts, K. B. (2019). Early adoption of an improved household energy system in urban Rwanda. *EcoHealth*, 16(1), pp. 7–20. <https://doi.org/10.1007/s10393-018-1382-4>

Jöreskog, K. G., y Sörbom, D. (1981). LISREL V: Analysis of linear structural relationships by maximum likelihood and least squares methods (Research Report 81-8). Uppsala, Sweden: University of Uppsala, Department of Statistics.

Kaiser H. (1974). An index of factorial simplicity. *Psychometrika*, Vol. 39, pp 31–36.

Kenny, D. A., McCoach, D. B. (2003). Effect of the number of variables on measures of fit in structural equation modeling. *Structural Equation Modeling*, 10(3), pp. 333–351. https://doi.org/10.1207/S15328007SEM1003_1

Koufteros, X., & Marcoulides, G. A. (2006). Product development practices and performance: A structural equation modeling-based multi-group analysis. *International Journal of Production Economics*, 103(1), 286–307. <https://doi.org/10.1016/j.ijpe.2005.08.004>

Lasker, J. (2024). Measurement Invariance Testing Works. *Applied Psychological Measurement*, 48(6), pp. 257–275. <https://doi.org/10.1177/01466216241261708>

Lovell, C. A. K., & Pastor, J. T. (1999). Radial and non-radial measures of productivity change. *European Journal of Operational Research*, 117(2), pp. 262–271. [https://doi.org/10.1016/S0377-2217\(98\)00274-7](https://doi.org/10.1016/S0377-2217(98)00274-7)

Marsh, H. W., Hau, K. T., & Wen, Z. (2004). In search of golden rules: Comment on hypothesis-testing approaches to setting cutoff values for fit indexes and dangers in overgeneralizing Hu and Bentler's (1999) findings. *Structural Equation Modeling: A Multidisciplinary Journal*, 11(3), pp. 320–341. https://doi.org/10.1207/s15328007sem1103_2

Mawusi, S. K., Shrestha, P., Xue, C., & Liu, G. (2023). A comprehensive review of the production, adoption and sustained use of biomass pellets in Ghana. *Heliyon*, 9(6), e16652. <https://doi.org/10.1016/j.heliyon.2023.e16652>

McKendry, P. (2002). Energy production from biomass (Part 1): Overview of biomass. *Bioresource Technology*, 83(1), pp. 37–46. [https://doi.org/10.1016/S0960-8524\(01\)00118-3](https://doi.org/10.1016/S0960-8524(01)00118-3)

Meade, A. W., Johnson, E. C., & Braddy, P. W. (2008). Power and sensitivity of alternative fit indices in tests of measurement invariance. *Journal of Applied Psychology*, 93(3), pp. 568–592. <https://doi.org/10.1037/0021-9010.93.3.568>

Meredith, W. (1993). Measurement invariance, factor analysis and factorial invariance. *Psychometrika*, 58(4), pp. 525–543. <https://doi.org/10.1007/BF02294825>

Miranda, T., Montero, I., Sepúlveda, F. J., Arranz, J. I., Rojas, C. V., & Nogales, S. (2015). A review of pellets from different sources. *Materials*, 8(4), pp. 1413–1427. <https://doi.org/10.3390/ma8041413>

Nyrud, A. Q., Roos, A., & Sopha, B. M. (2010). Wood-pellet heating in Norway: Early adopters' satisfaction and problems that have been experienced. *Biomass and Bioenergy*, 34(12), pp. 1840–1848. <https://doi.org/10.1016/j.biombioe.2010.07.001>

Pardo, J. E., Mejías, A., & Sartal, A. (2020). Assessing the importance of biomass-based heating systems for more sustainable buildings: A case study based in Spain. *Energies*, 13(5), 1025. <https://doi.org/10.3390/en13051025>

Pavlov, G., Maydeu-Olivares, A., Shi, D. (2021). Using the Standardized Root Mean Squared Residual (SRMR) to Assess Exact Fit in Structural Equation Models. *Educational and Psychological Measurement*, 81(1), pp. 110–130. <https://doi.org/10.1177/0013164420926231>

Rosillo-Calle, F., & Woods, J. (2012). The biomass assessment handbook (Vol. 4). Taylor & Francis.
<https://doi.org/10.4324/9780203121442>

Sarabia Sánchez, F. J. (2013). Métodos de Investigación Social y de la Empresa. Ediciones Pirámide.

Satorra, A., Bentler, P. M. (1994). Corrections to test statistics and standard errors in covariance structure analysis. In A. von Eye & C. C. Clogg (Eds.), Latent variables analysis: Applications for developmental research (pp. 399–419). Thousand Oaks, CA: Sage.

Schweickardt, G. (2024). Percepción de la calidad de servicio técnico en distribución eléctrica: un análisis multi-grupo entre clientes residenciales urbanos y suburbanos. LATAM Revista Latinoamericana De Ciencias Sociales Y Humanidades, 5(6), pp. 2658 – 2683.
<https://doi.org/10.56712/latam.v5i6.3190>

Seguin, R., Flax, V. L., & Jagger, P. (2018). Barriers and facilitators to adoption and use of fuel pellets and improved cookstoves in urban Rwanda. PLOS ONE, 13(10), e0203775.
<https://doi.org/10.1371/journal.pone.0203775>

Sopha, B. M., Klöckner, C. A., & Hertwich, E. G. (2011). Adopters and non-adopters of wood pellet heating in Norwegian households. Biomass and Bioenergy, 35(1), pp. 652–662.
<https://doi.org/10.1016/j.biombioe.2010.10.005>

Steiger, J. H. (1990). Structural model evaluation and modification: An interval estimation approach. Multivariate Behavioral Research, 25, pp. 173–180.

Steiger, J. H., Lind, J. C. (1980). Statistically based tests for the number of common factors. Paper presented at the Annual Meeting of the Psychometric Society, Iowa City, IA.

Thek, G., & Obernberger, I. (2012). The pellet handbook: The production and thermal utilization of biomass pellets. Routledge. <https://doi.org/10.4324/9781849775328>

Tucker, L. R., Lewis, C. (1973). A reliability coefficient for maximum likelihood factor analysis. Psychometrika, 38, pp. 1–10.

Wheaton, B., Muthen, B., Alwin, D. F., Summers, G. (1977). Assessing Reliability and Stability in Panel Models. Sociological Methodology, 8 (1), pp. 84-136.

Zhou, P., Ang, B. W., & Poh, K. L. (2007). A mathematical programming approach to constructing composite indicators. Ecological Economics, 62(2), pp. 291–297.
<https://doi.org/10.1016/j.ecolecon.2006.12.020>

Zhou, P., Ang, B. W., & Zhou, D. Q. (2021). Weighting and aggregation in composite indicators: A comparative review and unifying framework. Omega, 101, 102261.
<https://doi.org/10.1016/j.omega.2020.102261>

Todo el contenido de **LATAM Revista Latinoamericana de Ciencias Sociales y Humanidades**, publicados en este sitio está disponibles bajo Licencia [Creative Commons](https://creativecommons.org/licenses/by/4.0/) 