

Universidad de la República

Facultad de Ciencias Sociales

Departamento de Sociología

**TESIS DE MAESTRÍA BIMODAL EN ESTUDIOS
CONTEMPORÁNEOS DE AMÉRICA LATINA**

Programas de transferencias condicionadas en la región

Mecanismos de focalización desde una perspectiva
comparada entre Uruguay y Costa Rica

Autora: Elina Gómez Bonaglia

Tutores: Alberto Riella (DS-FCS-Udelar)

& Natalia da Silva (Iesta-FCEA-Udelar)

Resumen

El trabajo tiene como objetivo contextualizar y analizar los mecanismos de focalización que utilizan los Programas de Transferencias Condicionadas (PTC) en América Latina para seleccionar sus beneficiarios/as. Desde una perspectiva comparada se realiza una caracterización y evaluación de los desempeños de la focalización en dos casos de PTC de la región: el programa Asignaciones Familiares del Plan de Equidad (AFAM-PE) de Uruguay y el programa Avancemos de Costa Rica.

A partir de evidencia reciente sobre la ventaja comparativa en términos de reducción de errores de exclusión e inclusión que demuestran los modelos con base en Inteligencia Artificial (IA) y Aprendizaje Estadístico (AE) para el caso de Costa Rica, se presentan resultados asociados y se problematiza acerca de las implicancias prácticas y éticas que tiene su utilización en la toma de decisiones con alto impacto social, como es el caso de los criterios de elegibilidad de los PTC.

Se realizan ensayos para el caso de AFAM-PE, a partir del procesamiento de la Encuesta Continua de Hogares (ECH) de 2018, y se comparan rendimientos de los modelos basados en AE (Random Forest y Stochastic Gradient Boosting) con respecto al método econométrico (Probit) que sirven construir el Índice de Carencias Críticas (ICC) del Ministerio de Desarrollo Social (Mides) y definir la elegibilidad. Así también, se analiza y compara la importancia de las variables incluidas y se exploran modelos alternativos considerando otras variables predictoras posibles.

Entre los resultados presentados se halla que los modelos de AE ensayados para el caso de AFAM-PE, al igual que lo indicaba la evidencia para el caso de Costa Rica, presentan ventajas significativas en cuanto a reducción de errores de exclusión e inclusión entre los menores de edad, logrando mayores niveles de exactitud en la clasificación de la población objetivo. En el caso del Random Forest, el cual presenta mejor rendimiento, se logra una reducción de 11,3% de los errores con respecto al modelo Probit utilizado para la construcción del ICC.

Palabras clave: Transferencias monetarias condicionadas - Focalización - Aprendizaje estadístico - América Latina

Abstract

The work aims to contextualize and analyze the targeting mechanisms, used by Conditional Cash Transfer (CCT) programs, in Latin America with the purpose of selecting their beneficiaries. From a comparative perspective, a characterization and evaluation of the performance of the targeting is carried out in two cases of PTC in the region: the Family Allowances program of the Equity Plan (AFAM-PE) of Uruguay and the Avancemos program in Costa Rica.

Based on recent evidence on the comparative advantage, in terms of reduction of exclusion and inclusion errors, provided by the models based on Artificial Intelligence (AI) and Statistical Learning (SL) for the case of Costa Rica, associated results are presented and problematized in relation to the practical and ethical implications of its use in decision-making with high social impact, as is the case with the eligibility criteria of the PTC programs.

Tests are conducted for the case of AFAM-PE, based on the processing of the Continuous Household Survey (ECH) of 2018, and performances of the models based on SL (Random Forest and Stochastic Gradient Boosting) are compared with respect to the econometric method (Probit) that serve to build the Critical Deficiency Index (ICC) of the Uruguayan Ministry of Social Development (Mides) and define eligibility. Likewise, the importance of the included variables is analyzed, compared and alternative models are explored considering other possible predictor variables.

Among the results presented it is found that the models of SL tested for the case of AFAM-PE, as indicated by the evidence for the case of Costa Rica, have significant advantages in terms of reducing exclusion and inclusion errors among underage populations, achieving higher levels of accuracy in the classification of the target population. In the case of the Random Forest, which has better performance, an 11.3% reduction in errors is achieved with respect to the Probit model used for the construction of the ICC.

Keywords: Conditional Cash Transfers - Targeting - Statistical Learning - Latin America

Agradecimientos

En primer lugar, agradezco a la Facultad de Ciencias Sociales y a la Universidad de la República por los conocimientos brindados en el transcurso de la Maestría, y por fomentar siempre una educación gratuita y de calidad.

Así también, a la Agencia Nacional de Investigación e Innovación (ANII) por otorgarme la Beca de Maestría Nacional en Áreas estratégicas, que me permitió desarrollar la investigación.

Agradezco a los/as colegas del Mides por brindarme los datos, apoyo constante y asistencia metodológica en el transcurso del trabajo, especialmente a Gabriela Mathieu, Richard Detomasi y Mariana Tenenbaum, así como a Andrea Vigorito del Iecon.

A mis compañeros/as de la UMAD por el apoyo y la posibilidad de dedicación al trabajo.

A los tutores, Alberto Riella y Natalia da Silva, por el tiempo, la orientación y recomendaciones que nutrieron la tesis.

A Graciela y Sofía por la corrección de estilo.

A mis padres, hermanos, suegra y, en especial, a mi esposo Adrián por acompañarme amorosamente en todo este camino, apoyando en los cuidados y posibilitando el tiempo para culminar esta etapa.

A mis hijas, Emilia y Juliana, por comprender mis ausencias, y dejarles como legado mantener viva la curiosidad, el interés por el conocimiento y la importancia de seguir aprendiendo siempre.

Índice

Introducción	1
1. Los sistemas de protección social y las transferencias monetarias condicionadas en América Latina	4
1.1. Los programas de transferencias monetarias condicionadas en la región	6
1.2. Los mecanismos de focalización de los PTC	9
2. Las transferencias monetarias condicionadas y mecanismos de focalización en Uruguay y Costa Rica	14
2.1. Transferencias monetarias condicionadas en Uruguay	16
2.1.1. Programa Asignaciones Familiares del Plan de Equidad (AFAM-PE)	17
2.1.2. Mecanismos de focalización	19
2.1.3. Proceso de implementación de la prestación	23
2.2. Transferencias monetarias condicionadas en Costa Rica	25
2.2.1. Programa Avancemos	26
2.2.2. Mecanismos de focalización	28
2.2.3. Proceso de implementación de la prestación	32
3. Mecanismos alternativos de focalización usando AE	34
3.1. IA: definiciones e implicancias en la política pública	34
3.2. La IA aplicada a los PTC	36
3.3. El caso de Costa Rica: programa Avancemos	38

4. Ensayo de focalización utilizando IA y AE en el programa AFAM-PE	42
4.1. Introducción	42
4.2. Modelos utilizados	43
4.2.1. Probit	43
4.2.2. Random Forest	43
4.2.3. Stochastic Gradient Boosting	46
4.3. Fuente de datos y consideraciones previas	46
4.4. Estrategia metodológica	48
4.5. Pre-procesamiento	49
4.6. Modelado y calibraciones	52
4.6.1. Probit	52
4.6.2. Random Forest	53
4.6.3. Stochastic Gradient Boosting	54
4.7. Evaluación de resultados	56
4.7.1. Exactitud en muestra de testeo	56
4.7.2. Rendimiento general	57
4.7.3. Estimación de errores de focalización	63
4.8. Análisis de importancia de variables	67
4.9. Análisis exploratorio de diseños alternativos	69
5. Conclusiones	72
6. Bibliografía	77
7. Apéndice	84

Índice de figuras

1.1. Cantidad de PTC en América Latina y el Caribe por año (1996-2015)	
Nota: En este gráfico se presenta el número total de programas de transferencias condicionadas operativos en cada año.	
Fuente: Cecchini y Atuesta, 2017, sobre la Base de datos de programas de protección social no contributiva en América Latina y el Caribe de la Cepal, Programas de transferencias condicionadas.	
En: http://dds.cepal.org/bdptc/	7
2.1. Indicadores comparados AFAM-PE (Uruguay) y Avancemos (Costa Rica) - Año 2018	
Fuente: Elaboración propia a partir de Base de datos de programas de protección social no contributiva en América Latina y el Caribe - Cepal	15
2.2. Tipo de beneficiarios/as AFAM-PE	
Fuente: Informe Mides 2017-2018, Dinem-Mides	18
2.3. Evolución cobertura de AFAM-PE, total país, 2008-2018	
Fuente: Elaboración propia con base en datos extraídos de Informe Mides 2017-2018, Dinem-Mides.	19
2.4. Variables incluidas en el Índice de Carencias Críticas (ICC)	
Fuente: Mides - ICC rev. 2012	21
2.5. Proceso de ingreso de AFAM-PE	
Fuente: Elaboración propia con base en documentos oficiales del programa AFAM-PE (Mides).	24

2.6.	Evolución de cobertura de Avancemos, total país (2010-2018) Fuente: Elaboración propia a partir de Base de datos de programas de protección social no contributiva en América Latina y el Caribe - Cepal https://dds.cepal.org/bpsnc/	28
2.7.	Factores, subfactores y variables que componen el Modelo SIPO-2005 Fuente: Extraído de Delgado Jiménez (2017)	30
2.8.	Proceso de ingreso de Avancemos Fuente: Elaboración propia con base en Hernández Romero (2016)	32
3.1.	Extraído de Noriega-Campero, et al. (2020) - Section A. Supplementary Material (SM)	40
4.1.	Esquema de la estructura del algoritmo Random Forest Fuente: Elaboración propia con base en Riebesell, J.	45
4.2.	Esquema de la estrategia metodológica para la construcción y evaluación de modelos Fuente: Elaboración propia	48
4.3.	Exploración predictiva de variables cualitativas Fuente: Fuente: Elaboración propia con base en ECH (2018) . . .	50
4.4.	Exploración predictiva de variables cuantitativas Fuente: Elaboración propia con base en ECH (2018)	51
4.5.	Estimaciones puntuales y SE del modelo Probit Montevideo e interior Fuente: Elaboración propia con base en ECH 2018 (INE)	53
4.6.	Evolución de la exactitud del modelo Random Forest Fuente: Elaboración propia con base en ECH 2018 (INE)	54
4.7.	Evolución de la exactitud del modelo Gradient Boosting Fuente: Elaboración propia con base en ECH 2018 (INE)	55

4.8. Curvas ROC con base en la clasificación de primeros dos quintiles de ingreso - total país Fuente: Elaboración propia con base en ECH 2018 (INE)	59
4.9. Curvas ROC con base en la clasificación de primeros dos quintiles de ingreso - Montevideo e interior Fuente: Elaboración propia con base en ECH 2018 (INE)	60
4.10. Curvas ROC con base en la clasificación de Población Objetivo - total país Fuente: Elaboración propia con base en ECH 2018 (INE)	61
4.11. Curvas ROC con base en la clasificación de Población Objetivo - Montevideo e interior Fuente: Elaboración propia con base en ECH 2018 (INE)	62
4.12. Importancia de variables predictoras en Probit, RF y GBM - Montevideo e interior Fuente: Elaboración propia con base en ECH 2018 (INE)	68
4.13. Importancia de variables predictoras modelo exploratorio Random Forest (N=20) - Montevideo e interior Fuente: Elaboración propia con base en ECH 2018 (INE)	70
4.14. Curvas ROC con base en la clasificación RF de modelo reducido - Montevideo e interior Fuente: Elaboración propia con base en ECH 2018 (INE)	71
7.1. Matriz de confusión y métricas de modelo GBM fuera de la muestra - Montevideo e interior	85
7.2. Matriz de confusión y métricas de modelo RF fuera de la muestra - Montevideo e interior	86
7.3. Matriz de confusión y métricas de modelo GBM fuera de la muestra - Montevideo e interior	88

7.4. Matriz de confusión y métricas de modelo RF (análisis exploratorio) fuera de la muestra - Montevideo e interior	88
7.5. Matriz de confusión y métricas de modelo RF en modelo reducido (análisis exploratorio) fuera de la muestra - Montevideo e interior	89

Índice de cuadros

4.1. Exactitud de modelos en muestra de testeo - Montevideo e interior	57
4.2. Métrica AUC con base en la clasificación de primeros dos quintiles de ingreso - total país	59
4.3. Métrica AUC con base en la clasificación de primeros dos quintiles de ingreso - Montevideo e interior	60
4.4. Métrica AUC con base en la clasificación de Población Objetivo - total país	62
4.5. Métrica AUC con base en clasificación de Población Objetivo - Montevideo e interior	63
4.6. Umbrales de elegibilidad - Montevideo e interior	64
4.7. Estimación de errores de focalización de Población Objetivo AFAM- PE - modelo Probit	65
4.8. Estimación de errores de focalización de Población Objetivo AFAM- PE - modelo RF	66
4.9. Estimación de errores de focalización de Población Objetivo AFAM- PE - modelo GBM	66
7.1. Estimaciones del modelo Probit - Montevideo e Interior	84
7.2. Resultados calibración modelo RF - Montevideo	85
7.3. Resultados calibración modelo RF - Interior	86

7.4. Resultados calibración modelo GBM - Montevideo 87

7.5. Resultados calibración modelo GBM - interior 87

Introducción

Los programas de transferencias monetarias condicionadas (PTC) tienen su origen en América Latina hacia fines de los años noventa, momento en que se identifica un cambio de rumbo en los programas tendientes a reducir la pobreza. Tenían como objetivo «aliviar la pobreza corriente, apoyando el consumo de los hogares más pobres mediante transferencias otorgadas principalmente a las madres de familia, y contribuir a romper la transmisión intergeneracional de la pobreza con esquemas de condicionalidades dirigidos a fomentar la acumulación de capital humano entre los niños» (Ibarrarán et al., 2017). Inicialmente aplicados en países como Brasil y México, luego se expandieron por toda la región con características particulares según la estructura social y poblacional, así como el contexto político de implementación. Asimismo, ha implicado nuevas conceptualizaciones en cuanto a la noción de protección social, y el rol del Estado como garante de ciertos derechos a través del diseño y ejecución de políticas sociales universales y focalizadas, combinando componentes contributivos tradicionales con nuevos programas de corte no contributivo como son los PTC.

Por su parte, los PTC tuvieron la particularidad de desarrollar diversos mecanismos de focalización tendientes a una asignación eficiente de los recursos destinados a estos en toda América Latina. Este hecho ha instalado necesariamente el debate sobre la coexistencia de políticas universales y focalizadas en la región, su carácter gradual y su inserción en una noción, como fue mencionado, más amplia de protección social con combinación de instrumentos de distinto nivel. Por lo tanto, el carácter focalizado de los PTC ha implicado el desarrollo de sistemas de monitoreo y evaluación sin precedentes, lo cual ha permitido dar cuenta de su cobertura e impactos, así como de sus limitaciones y necesidad de ajuste en el tiempo (BID, 2017). Este hecho permite contar con gran cantidad de datos, indicadores y series históricas, que se complementan con los sistemas nacionales de estadísticas, y que los configuran como objetos de estudio valioso para el

análisis y evaluación desde las ciencias sociales.

En este marco, el presente trabajo se plantea tres objetivos principales que serán detallados a continuación.

En primer lugar, contextualizar y realizar una caracterización de los PTC en América Latina, con especial énfasis en los mecanismos de focalización desplegados. Para ello se ha realizado una revisión bibliográfica sobre la temática que ha permitido, en el Capítulo 1, presentar las principales discusiones y tensiones que han conocido los PTC en la región en sus más de veinte años de existencia. El segundo cometido se vincula con la presentación de dos casos de estudio de PTC de la región que serán analizados desde una perspectiva comparada: el programa Asignaciones Familiares del Plan de Equidad (AFAM-PE) de Uruguay y el programa Avancemos de Costa Rica. Cómo se verá, ambos representan ejemplos comparables en término de antigüedad, inversión y cobertura de las prestaciones, así como cuentan con un desarrollo amplio de sistemas de monitoreo de indicadores de procesos y resultados que permiten su comparabilidad en lo que refiere a los mecanismos de focalización. Al respecto, en el Capítulo 2, el trabajo busca realizar una sistematización a partir de análisis documental y posterior caracterización de los métodos para definir la elegibilidad de los/as beneficiarios/as en ambos casos, identificando similitudes y diferencias a partir tanto de los objetivos específicos definidos por ambos programas, así como por decisiones metodológicas que resultan en desempeños diferenciales de los mecanismos ejecutados en ambos países. En este sentido se verá cómo, a pesar de que el diseño para aproximarse a las situaciones de vulnerabilidad socioeconómica es similar, utilizando métodos extendidos en los países en desarrollo a partir de las carencias en información directa sobre ingresos (Coady et al., 2004) como es la prueba sustitutiva de medios, los resultados en términos de filtración y subcobertura se alejan entre sí.

En tercera instancia el trabajo se propone indagar acerca de mecanismos alternativos de focalización basados en Aprendizaje Estadístico (en adelante AE) o *Statistical Learning*, con el fin de mejorar la capacidad predictiva de las técnicas y

modelos de focalización tradicionales. Con dicho fin, en el Capítulo 3, se buscará presentar y problematizar la integración de nuevas tecnologías en el ámbito de la denominada ciencias de datos y su posible aporte en la mejora de desempeños de las políticas públicas en general y de las políticas sociales en particular. De este modo, se presentan algunos antecedentes en ese sentido, haciendo énfasis tanto en sus potencialidades como en las limitaciones y tensiones que presentan. En particular, en lo que respecta a los PTC y los mecanismos de focalización, existen algunas aplicaciones específicas recientes de modelos predictivos que utilizan el aprendizaje estadístico como trasfondo (Aiken et al., 2022; Noriega-Campero et al., 2020; McBride, et al., 2018) y que podrían mejorar el desempeño y eficiencia en términos de reducción de errores de inclusión y exclusión en la selección con respecto a los modelos tradicionales. Dichos trabajos representan antecedentes directos para los mecanismos que se ensayarán, aplicando diferentes algoritmos de clasificación, evaluando desempeños y adecuaciones en función de sus resultados en términos de reducción de errores de subcobertura y filtración en los casos estudiados. Así también, en este capítulo, el interés particular se centrará en los resultados obtenidos para el caso de Costa Rica que realiza Noriega-Campero et al. (2020), los cuales serán retomados y detallados, ya que servirán de referencia en el procesamiento que se realizará posteriormente para el caso de Uruguay.

Por último, en el Capítulo 4, se toma el caso de AFAM-PE en Uruguay y se ensayan modelos basados en AE (Random Forest y Stochastic Gradient Boosting) comparando desempeños con el modelo tradicional (Probit) a partir del cual se calcula el ICC como criterio para la selección de beneficiarios/as en el PTC. Para ello se procesan los datos de la Encuesta Continua de Hogares (INE) del año 2018, se detallan las características de los modelos y decisiones tomadas en su construcción, para luego presentar resultados en términos de rendimiento y calculo de errores de focalización.

1. Los sistemas de protección social y las transferencias monetarias condicionadas en América Latina

Los sistemas de protección social en América Latina han ido variando sus características y enfoques a lo largo del tiempo en estrecho vínculo con el rol del Estado en la atención de situaciones de pobreza y desigualdad cada vez más profundas. La historización de su evolución requiere remitir a los modelos de desarrollo subyacentes y el papel de las políticas sociales en cada etapa histórica. En este sentido, siguiendo a Cecchini y Martínez (2011), se identifican cuatro grandes momentos. El primero se extiende desde el siglo XIX hasta principios del XX y se caracteriza por un modelo de desarrollo liberal en el cual la noción de caridad y las incipientes instituciones de protección social vinculadas al trabajo son centrales; luego, hacia mediados del siglo pasado, se da paso a un modelo económico de industrialización por sustitución de importaciones, consolidándose un Estado planificador, proveedor de un orden social, y donde se fortalecen los mecanismos de protección contributiva, principalmente centrados en la masa asalariada, con un rol activo de los sindicatos en reivindicaciones asociadas a los derechos laborales. Luego, la llamada crisis de la deuda en la región inaugura una etapa signada por un enfoque neoliberal en el cual cobran fuerza las políticas sociales focalizadas y descentralizadas, centradas en el aseguramiento de niveles mínimos de bienestar, así como la reestructura de los fondos de jubilaciones y pensiones orientados en la capitalización individual, dejando atrás los enfoques universalistas precedentes (Cecchini y Martínez, 2011). Por último, en la primera década del siglo, con las crisis económicas y el agotamiento del modelo neoliberal, así como la consecuente profundización de situaciones de pobreza y vulnerabilidad en toda la región, se renueva el debate acerca del rol del Estado en los sistemas de protección social, particularmente en lo que refiere al vínculo entre el denominado *enfoque de derechos* como rector en el diseño de políticas sociales y las estrategias de desarrollo (Abramovich, 2006).

De este modo, el debate plantea un pasaje de la noción de *asistencia social* a la de *sujetos de derechos*, no únicamente económicos, y un Estado que se concibe como garante de dichos derechos básicos. Esto implica necesariamente un replanteo de la tensión entre políticas universales/focalizadas en las matrices de protección social. La Cepal ha tenido un rol central en las conceptualizaciones en ese sentido, proponiendo la noción de *protección como garantía de ciudadanía*, a partir de la cual existe una orientación prioritaria a la atención de situaciones de pobreza y vulnerabilidad, sin embargo, el enfoque considera que el alcance de la protección debe extenderse al conjunto de la ciudadanía desde una perspectiva inclusiva, integral y universalista (Cepal, 2016). Desde esta orientación, las políticas sociales representan un elemento más de una concepción de protección social más amplia que debe dialogar con un entramado institucional, acuerdos políticos y sociales, diseños de programas y disponibilidad de recursos específicos para cada uno de los países de la región. Se identifica, por tanto, una división entre tres grandes componentes de dicho sistema de protección social tendiente a abarcar todo el entramado social: contributivo, no contributivo y vinculado a la regulación del mercado laboral (Cecchini y Martínez, 2011). Cabe mencionar que los autores identifican disparidades entre los enfoques vinculados a los sistemas de protección social entre los países latinoamericanos, en los cuales los énfasis entre los componentes e instrumentos, que se traducen en diseños programáticos concretos, se encuentran en algunos casos centrados en la *asistencia y acceso a la promoción* y en otras como efectiva *garantía de ciudadanía*, con situaciones intermedias entre ambas perspectivas de la protección.

Los instrumentos que corresponden al componente no contributivo de la matriz de protección social son los tradicionalmente asociados a la *asistencia social*, y buscan una cobertura básica de necesidades a poblaciones en situación de pobreza y extrema vulnerabilidad. Estos cobran fuerza en América Latina ante un creciente debilitamiento de los mecanismos contributivos de aseguramiento futuro tradicionales, vinculado al empleo formal y acrecentamiento de las *brechas de*

bienestar, entendidas como la capacidad de una sociedad de lograr el sustento de sus integrantes a través de los ingresos provenientes del mercado laboral, así como de proteger a aquellos que no alcanzan niveles de ingresos mínimos (Cecchini et al., 2014).

1.1. Los programas de transferencias monetarias condicionadas en la región

Los programas de transferencias monetarias condicionadas (PTC) corresponden el principal, aunque no único, instrumento del componente no contributivo y se caracterizan por la entrega de recursos monetarios a hogares, generalmente con menores a cargo, aunque también se consideran otros tipos de arreglos, cuyo objetivo fundamental es el de «aliviar la pobreza corriente, apoyando el consumo de los hogares más pobres mediante transferencias otorgadas principalmente a las madres de familia, y contribuir a romper la transmisión intergeneracional de la pobreza con esquemas de condicionalidades dirigidos a fomentar la acumulación de capital humano entre los niños» (Ibarrarán et al., 2017).

Si atendemos a la génesis y evolución de los PTC, el primer antecedente de alcance nacional se ubica en México hacia el año 1997 con la implementación del Programa de Educación, Salud y Alimentación (Progresá), así como en Brasil surgen en la misma época diferentes iniciativas de programas enfocados en la reducción de la pobreza, cuyo instrumento principal era una prestación económica, y que en el año 2003 se unificaron en el programa Bolsa Familia. En ambos casos las condicionalidades o corresponsabilidades formaban parte del diseño de los programas, orientadas a áreas como la educación, la salud y la nutrición. De este modo, durante la primera década del siglo XX los PTC se expandieron por toda América Latina, incrementándose a lo largo de los años y contabilizándose treinta programas operativos en 2015 (ver Figura 1.1), así como registrando un aumento sostenido en términos de cobertura de hogares y personas (Cecchini y Atuesta, 2017).




Figura 1.1: Cantidad de PTC en América Latina y el Caribe por año (1996-2015)

Nota: En este gráfico se presenta el número total de programas de transferencias condicionadas operativos en cada año.

Fuente: Cecchini y Atuesta, 2017, sobre la Base de datos de programas de protección social no contributiva en América Latina y el Caribe de la Cepal, Programas de transferencias condicionadas. En: <http://dds.cepal.org/bdptc/>

La definición de las poblaciones objetivo de los PTC es heterogénea entre los países de la región, e incluso coexisten programas con diferentes orientaciones en un mismo país. Existe una vasta literatura que compara los diferentes PTC de la región, principalmente analizando los criterios de elegibilidad (Lavalleya y Tenembaum, 2020; Ibarrarán et al., 2017; Cecchini y Martínez, 2011; Cecchini y Madariaga, 2011). Las unidades en las que intervienen generalmente se asocian con los hogares en situación de pobreza o indigencia, aunque hay casos de prestaciones individuales, y en su mayoría se prioriza la presencia de menores de edad como forma de promover la escolarización, así como, en algunos casos, se consideran otras categorías específicas de acuerdo con los objetivos planteados por el programa (discapacidad, adultos mayores, inmigrantes, entre otros). Las personas receptoras de la prestación son en general jefas de hogar o madres, vinculado a la noción de una mayor optimización del gasto por parte de estas (Cecchini y Madariaga,

2011).

Por su parte, un aspecto clave al momento de caracterizar los PTC es distinguir entre los tipos de prestaciones que ofrecen, ya que en muchos casos se consideran únicamente aquellas transferencias de ingresos monetarios orientadas a la demanda, es decir a que los hogares efectúen un gasto, libre o predeterminado. Sin embargo, existen otros tipos que se centran en la oferta y resultan en transferencias monetarias dirigidas a determinados proveedores de servicios. Desde esta tipología que ilustra la diversidad de PTC en la región (Cecchini y Madariaga, 2011), incluso dentro de las prestaciones cuya unidad de intervención son los hogares, es posible distinguir entre aquellas monetarias y no monetarias, en muchos casos combinadas en términos de diseño, y según el uso que se le da en aquellas comprendidas en la primera categoría, mediante subsidios al consumo o compras directas con diferentes medios de pago.

Como fue mencionado, uno de los objetivos primordiales de los PTC implementados en la región es el incremento del capital humano de niños/as y adolescentes, así como la capacidad de los hogares para enfrentar los *riesgos sociales*. Para ello, las condicionalidades aparecen como el instrumento para incentivar el cumplimiento de ciertas conductas o requerimientos generalmente vinculados al ámbito educativo o sanitario. Estas difieren según las características de los programas en los diferentes países de América Latina, así como sus procesos de verificación, elemento este fundamental para, por ejemplo, evitar conductas clientelares. Al respecto, en la bibliografía reciente sobre los PTC, se ha revisado el término *condicionalidad* y se ha propuesto migrar hacia la noción de *corresponsabilidad* atendiendo a la necesidad de incluir el componente de la oferta, es decir, del Estado y su responsabilidad en garantizar el acceso a servicios básicos vinculados a dichos compromisos (Ibarrarán et al., 2017). Cabe mencionar que las condicionalidades también son cuestionadas por algunos enfoques que discuten el problema ético de establecer ciertas exigencias e incluso su incompatibilidad con un enfoque de derechos (Minujinet al., 2007). Asimismo, es puesto en debate

incluso la *legitimidad* de dicho componente de los PTC en un sistema democrático, ya que, según esta perspectiva, las argumentaciones asociadas a las condicionalidades se montan sobre vínculos desiguales entre los ciudadanos y los perpetúan (García Valverde, 2017). Otro aspecto acerca del debate de la pertinencia de las condicionalidades se vincula con su evaluación y la falta de evidencia sobre el impacto de los PTC asociada a la dificultad de *aislar* o *separar* el efecto de la condicionalidad y de las transferencias (Hanlon et al., 2010; Cecchini y Madariaga, 2011). Por último, otro elemento que se ha puesto en cuestión en los últimos trabajos sobre los PTC en la región es el vinculado al rol de la mujer en estos, que, como se ha mencionado, generalmente ocupan un lugar prioritario en el vínculo entre el hogar y el programa. Esto ha tenido una lectura dual, ya que mientras que podría significar un empoderamiento y visibilidad de estas fortaleciendo los lazos comunitarios, también implica una recarga en término de cumplimiento de condicionalidades y reproducción del papel tradicional asociado a lo doméstico y tareas de cuidado (Molyneux, 2009, Cookson, 2018).

1.2. Los mecanismos de focalización de los PTC

Al igual que cuando nos referimos a las condicionalidades como característica central de los programas de transferencias monetarias, los métodos de focalización también representan un elemento distintivo. Este hecho no se encuentra exento de debate y se enmarca, como fue mencionado al inicio, en una concepción más amplia de sistemas de protección social que combinan instrumentos universales y focalizados. Sin embargo, existen desarrollos teóricos, ya desde los años noventa, que ponen en duda el carácter redistributivo de los programas focalizados, específicamente atendiendo a las transferencias monetarias, en el entendido de que los programas de corte universalista, propio de los estados de bienestar, tienen mejores resultados en términos de distribución del ingreso y equidad (Korpi y Palme, 1998). Estudios posteriores han puesto en duda dichos postulados, a través de una actualización de datos y mejoras en términos de metodología y alcance,

por ejemplo, incluyendo en el análisis a países no desarrollados y no solo las denominadas *democracias ricas* (Brady y Bostic, 2015). Desde este enfoque, se reevalúa el vínculo entre el universalismo y la redistribución, sostenido por Korpi y Palme, y se incorporan elementos vinculados a las “preferencias de redistribución” asociadas a la opinión pública y su relación con la pobreza y la focalización de ingresos. Más recientemente, Jacques y Noël (2018) replantean la discusión, proponiendo una nueva forma de acercarse al debate universalismo/focalización, no ya centrandolo en los resultados (impactos en los ingresos de los hogares, por ejemplo), sino en los diseños institucionales de los programas en cuestión para medir su “universalismo”, considerando, para esto, indicadores tales como el porcentaje de transferencias que tienen alguna prueba de medios o directamente de ingresos. Esta postura refuerza la noción de *paradoja de la redistribución* que ponen en cuestión, aunque sin aplicaciones concretas para la región latinoamericana, los mecanismos de focalización como mejor instrumento para la reducción de la pobreza, frente a programas de transferencias con pretensión universalista (Jacques y Noël, 2018). Al respecto, para el caso de América Latina, aparecen varios elementos que complejizan la discusión asociados al contexto socio-económico, niveles de pobreza más profundas y recursos más limitados, lo cual hace que se sostenga una visión de progresividad hacia la universalidad de derechos, y la necesidad de adaptar los métodos de selección de los PTC según las realidades concretas de los países de la región (Cecchini y Madariaga, 2011). Asimismo, un último elemento, que sí ha sido analizado recientemente para el caso de Brasil, es el asociado al vínculo entre la focalización y la estigmatización en relación con la necesidad de las pruebas de medios, lo cual si bien podría interpretarse en una primera instancia desde un punto de vista contrario, es decir como una garantía para los/as participantes vinculada a un enfoque de derechos, también podría implicar una reproducción de *estereotipos sociales negativos* y discriminación entre receptores/as y no receptores/as (Layton, 2020).

El cometido primordial de los métodos de focalización es orientar la asignación

de recursos destinados a los PTC de forma eficiente hacia personas/hogares en situación de mayor vulnerabilidad, a partir de la aplicación de mecanismos que definan criterios de elegibilidad. Para ello, en un contexto de restricción presupuestal, implican decisiones político-administrativas sobre cómo realizar dicha asignación atendiendo a realidades particulares y cómo se aplican los mecanismos operativamente en el entramado institucional de un determinado país. Para el caso de los países en desarrollo, Coady et al.(2004) aportan una tipología específica de tipos de focalización, que luego es retomada por varios trabajos posteriores, y remarcan la importancia de considerar en los diseños los costos asociados a dichos mecanismos. En primer lugar, aquellos *administrativos*, sosteniendo que, a pesar de que existen costos fijos, cuanto mejor focalizada se encuentre una población, disminuyen los costos de este tipo; los costos *privados* que son los que incurren los hogares al ser beneficiarios de una transferencia (ej. trámites, declaraciones); y los costos de *incentivo* o *indirectos* vinculados a los cambios de comportamiento de un hogar para llegar a ser beneficiario (oferta de trabajo, cambios en pautas de consumo, declaración errónea). Luego, se menciona el costo *social*, asociado al estigma generado por pertenecer a una categoría de pobre monetario, lo cual ya fue abordado anteriormente; por último, el costo *político* de incluir/excluir con ciertos criterios puede acarrear costos en términos de adhesión en los partidos que diseñan y ejecutan el programa social (Coady et al., 2004). A la hora de definir un método de focalización, es fundamental delimitar la población objetivo de un PTC, considerando criterios socioeconómicos, demográficos o una combinación de ambos (Ibarrarán et al., 2017). De este modo, los tipos de mecanismos de focalización que se apliquen deben dialogar con los criterios de elegibilidad definidos al establecer la población objetivo.

Los tipos de focalización se consideran, según la tipología de Coady et al. (2004), son la evaluación de tipo individual o familiar a través de la *comprobación de medios de vida* simples, es decir, basados en autodeclaraciones de ingresos o sustitutivos, en los cuales se relevan características del hogar que dan cuenta de

un nivel de bienestar determinado. Dentro de este tipo individual o familiar se encuentra también la focalización comunitaria, la cual asigna a sus miembros la responsabilidad de definir los/as beneficios/as de un PTC. Por su parte, la focalización categórica se vincula con el requisito de pertenencia a un grupo específico, delimitado en término de edad o género, por ejemplo, que son sencillamente comprobables, y que generalmente se encuentran correlacionados con situaciones de pobreza. Por último, la focalización geográfica refiere a la elegibilidad de los hogares que pertenecen a determinado territorio atendiendo a características como la incidencia de la pobreza (Ibarrarán et al., 2017; Coady et al., 2004).

Al analizar los mecanismos utilizados en los diferentes PTC de América Latina, se observa que en la gran mayoría de los casos se utilizan métodos combinados y en etapas, siendo el de comprobación sustitutiva de los medios de vida, uno de los más extendidos en la última década (Ibarrarán et al., 2017). En esta línea, según un relevamiento reciente de veintinueve programas de veinte países de América Latina y el Caribe, el 71 % de estos utiliza dicho mecanismo, seguido por la focalización categórica en el 38 % de los casos, atendiendo a variables como la edad, sexo u otras relevantes, y geográfico en el 36 % (Lavallega y Tenenbaum, 2020). Al respecto, en el caso de la comprobación sustitutiva de medios de vida, generalmente se construyen índices que buscan predecir el ingreso o nivel de bienestar de los hogares, utilizando diferentes métodos estadísticos para tal fin. Por su parte, un aspecto relevante a la hora de diseñarlos, siguiendo a Coady et al. (2004), es la no inclusión de variables manipulables por los posibles beneficiarios/as o de dimensiones que tengan relación directa con los objetivos del programa. La evaluación de los mecanismos de selección descritos se realiza estimado la *subcobertura* del PTC vinculada al error de exclusión o aquellos hogares o personas que cumpliendo los criterios de elegibilidad no son beneficiarios, y la *filtración* o error de inclusión, es decir aquellos hogares que son beneficiarios aun no cumpliendo con los requisitos definidos. Como lo afirman Cecchini y Madariaga (2011), en muchos casos de PTC de la región, existe una preocupación mayor por

atender las situaciones vinculados al error de exclusión a través de fortalecer los mecanismos de fiscalización y control, mientras que el énfasis debería estar puesto en la disminución de los errores de inclusión. Otro aspecto relevante vinculado a la mejora de las evaluaciones de los mecanismos de focalización se centra en el manejo de la información en el marco de un sistema de monitoreo y evaluación que necesita ser dinámico y rever sistemáticamente los criterios y metodologías asociadas a la elegibilidad. Como mencionan los autores Coady et al., (2004) según sus hallazgos en el estudio de algunos casos de PTC, la clave en lograr buenos resultados en términos de focalización se asocia fundamentalmente a la *eficacia de la implementación* y a la *capacidad administrativa*, más que a el o los métodos utilizados. En términos operativos esto implicará, en los casos de la región estudiados, relevamientos de información de forma activa (territorio) o pasiva (oficinas) en consonancia con los métodos de focalización definidos, así como también la inclusión de sus resultados en sistemas informáticos que permitan verificar la elegibilidad y realizar la inscripción de los/as beneficiarios/as correspondiente (Ibarrarán et al., 2017).

2. Las transferencias monetarias condicionadas y mecanismos de focalización en Uruguay y Costa Rica

Como fue mencionado, los PTC se han expandido por todo América Latina en las últimas décadas, con variados diseños y formas de implementación adaptadas a las múltiples realidades nacionales y contextos socioeconómicos, así como mediadas por estructuras técnico-políticas diversas. Este trabajo se centrará en dos países: Uruguay y Costa Rica, y en sus principales programas de transferencias monetarias como son las Asignaciones Familiares del Plan de Equidad (AFAM-PE) y Avancemos.

En primera instancia debemos hacer foco en la historicidad de las matrices de protección que subyacen a los PTC en ambos países. Como lo sostienen Cecchini y Martínez (2011), Uruguay y Costa Rica pertenecen a un grupo de países en los que la implementación de programas de tipo contributivo y no contributivo se implementan desde las primeras décadas del siglo XX. Así también, comparten una misma visión en términos del rol central del Estado en garantizar un sistema de protección social frente a otras instituciones sociales, que es caracterizado por los autores como un régimen tempranamente “estatal-proteccionista” en las que la regulación de los mercados laborales en situaciones de informalidad y el diseño de instrumentos no-contributivos resultan centrales (Cecchini y Martínez, 2011). Asimismo, si se comparan los enfoques sobre la protección social de principio de siglo también se observan coincidencias no solo en lo que refiere a la protección social no-contributiva, sino que también a los instrumentos contributivos asociados, por ejemplo, a las modificaciones en la elegibilidad de la cobertura en salud o subsidios en ese sentido, implementado mediante reformas tanto en Uruguay como en Costa Rica en la primera década del siglo (Cecchini et al., 2014). De este modo, todos estos elementos hacen que, al momento de establecer una tipología de enfoques de protección social, Cecchini y Martínez (2011) caractericen a estos países como parte de un conjunto que involucra también a Argentina, Brasil y

Chile, y que lo denominen como *protección social como garantía de ciudadanía*, a partir de la existencia de un sistema integrado de protección con diálogo entre instrumentos y componentes de corte contributivo con no contributivos. Así también, se identifican algunas diferencias y singularidades de cada país, como es la institucionalidad rectora en lo que refiere a la gestión de los PTC. Mientras en el caso de Uruguay desde su creación en el año 2005 estos son llevados adelante por parte del Ministerio de Desarrollo Social (Mides), en el caso de Costa Rica el organismo encargado es el Instituto Mixto de Ayuda Social (IMAS), el cual cuenta con financiación múltiple, pública y privada, y una amplia trayectoria en la atención de situaciones de pobreza y vulnerabilidad en el país desde su creación en el año 1971.

Desde un punto de vista comparativo, atendiendo a los indicadores seleccionados que se incluyen en la [Base de datos de programas de protección social no contributiva en América Latina y el Caribe de la Cepal](#), AFAM-PE y Avancemos tienen características similares en términos de diseño y cobertura (ver Figura 2.1).

		AFAM-PE	Avancemos
Presupuesto	USD\$	195.116.342	121.523.859
	%PBI	0,33%	0,19%
Cobertura	Hogares	139.342	154.738
	Personas	372.231	201.631
	Personas en hogares	640.237	588.004
	% Población	18,46%	11,76%
Montos per cápita (USD\$)	Mínimo	48,7	52,0
	Máximo	69,6	69,3

Figura 2.1: Indicadores comparados AFAM-PE (Uruguay) y Avancemos (Costa Rica) - Año 2018

Fuente: Elaboración propia a partir de Base de datos de programas de protección social no contributiva en América Latina y el Caribe - Cepal

El año de inicio de estos se da en 2006 y 2008, representando en términos de presupuesto, para el año 2018, un 0,33 % y 0,19 % del PBI respectivamente. En cuanto a cobertura, si bien AFAM-PE registra un total de beneficiarios/as y personas en hogares beneficiarios sensiblemente mayor a Avancemos, la cantidad de hogares a los que llega la prestación es mayor para el programa de costarricense (154.738 frente a 139.342). Esto puede deberse a diferencias en la composición de los hogares, así como a cuestiones de diseño y elegibilidad a la interna del hogar que serán abordados posteriormente. Por último, los montos per cápita previstos como beneficio por parte de ambos PTC son similares, con un mínimo de U\$S 48,7 y U\$S 52, y un máximo de U\$S 69,6 y U\$S 69,3 en AFAM-PE y Avancemos respectivamente. Por último, una dimensión relevante que asemeja ambos programas, y que resulta central en el cometido del presente trabajo, refiere a los mecanismos de selección de beneficiarios/as y aproximación a las poblaciones vulnerables a través de criterios de focalización similares. La utilización de *proxy mean test* o comprobación sustitutiva de los medios de vida como método para definir la elegibilidad y las técnicas econométricas aplicadas para construir un indicador o índice de bienestar posee características similares que serán abordadas a continuación.

2.1. Transferencias monetarias condicionadas en Uruguay

El contexto en el que surgen los PTC en Uruguay se caracteriza por un período económico expansivo que inicia en 2003, luego de la crisis financiera y económica del 2002, una de las mayores que sufrió el país, con graves consecuencias sociales y deterioro de los indicadores de pobreza y vulnerabilidad. La llegada del Frente Amplio al gobierno significó un cambio de rumbo político y puesta en marcha de reformas estructurales de peso como el Sistema Integrado de Salud, la reforma de la Seguridad Social y el Plan de Equidad (Mordecki et al., 2015). En este marco económico y político, se creó el Ministerio de Desarrollo Social (Mides) y se implementó el Plan de Atención a la Emergencia Social (Panes) como el

primer conjunto de instrumentos, con componentes de corte no contributivo como el Ingreso Ciudadano (IC), que buscaban paliar las situaciones de emergencia y pobreza extrema, consecuencia de la recesión de principio de siglo. Dicho plan desde su diseño tenía un carácter temporal y transicional, y dio lugar, en el año 2008, al Plan de Equidad, cuya principal prestación es el programa AFAM-PE, que modifica el sistema tradicional de asignaciones que existía en el país, en términos de selección, montos y contraprestaciones (Informe Mides 2017-2018, Dinem-Mides). Dicho instrumento se combina con la Tarjeta Uruguay Social (TUS), surgida en 2006, y se centra en la atención a situaciones de pobreza extrema de sesenta mil hogares, a través de una transferencia monetaria en formato tarjeta electrónica dirigida a la adquisición de bienes básicos de alimentación e higiene.

2.1.1. Programa Asignaciones Familiares del Plan de Equidad (AFAM-PE)

El principal cometido del Plan de Equidad (2008) era «Asegurar el pleno ejercicio de los derechos ciudadanos de todas y todos los habitantes del territorio nacional, en especial de quienes se encuentran en una situación de vulnerabilidad social, a través de la nivelación de sus oportunidades de acceso en lo que refiere a servicios sociales universales, ingresos a través del trabajo digno y prestaciones sociales básicas» (Informe Mides 2017-2018, Dinem-Mides). En este marco, la Ley 18.227¹ crea un sistema de asignaciones familiares que será gestionado por parte del Banco de Previsión Social (BPS) y el Mides, la cual define la población objetivo y los criterios de elegibilidad de la prestación. Así también, la normativa precisa que la cobertura de la transferencia sería de forma gradual, comenzando con 330.000 beneficiarios/as en el primer año, y alcanzando los/as 500.000 beneficiarios/as en el año 2009. Por tanto, las AFAM-PE se constituyen, desde la promulgación de la ley y hasta el presente como la principal transferencia

¹Ver en: <https://legislativo.parlamento.gub.uy/temporales/leytemp3968086.htm>

monetaria no contributiva del país² orientada a atender a los hogares vulnerables. La población objetivo son los/as niño/as y adolescentes menores de 18 años, embarazadas y personas en situación de discapacidad que viven en hogares con mayores niveles de vulnerabilidad socioeconómica (Figura 2.2). Uno de los cometidos de la prestación se corresponde con la permanencia de los/as menores en el sistema educativo y promover los controles regulares de salud, por lo cual ambas dimensiones representan las condicionalidades que deben cumplir los/as beneficiarios/as para su permanencia en el programa (Informe Mides 2017-2018, Dinem-Mides).

Tipos de Beneficiarios	Descripción
Prenatales	Mujeres embarazadas pertenecientes a hogares en situación de vulnerabilidad socioeconómica
Menores en edad pre-escolar	Menores en edad pre-escolar, que deberán acreditar controles periódicos de salud y la tenencia de cédula de identidad a partir de los 45 días de su nacimiento
Menores en educación inicial y educación primaria	Menores que deberán estar cursando educación inicial o educación primaria
Menores en educación media o superior (complemento)	Menores que deberán acreditar estar cursando educación media o superior
Menores bajo la tutela del INAU	Menores en tiempo completo en establecimientos del Instituto del Niño y Adolescente del Uruguay (INAU e instituciones en convenio con el mismo)
Personas con discapacidad	Personas con discapacidad, así cobren o no pensión por ella.

Figura 2.2: Tipo de beneficiarios/as AFAM-PE

Fuente: Informe Mides 2017-2018, Dinem-Mides

En lo que refiere a lo operativo, las formas de ingreso al programa AFAM-PE puede darse mediante declaración jurada o visita en territorio por parte del equipo técnico del Mides, mediante ambas vías se registra información necesaria para evaluar la elegibilidad del hogar, así como desde BPS se controla ciertos umbrales de ingreso per-cápita del hogar que no deben ser superados. Los beneficiarios/as cobran la transferencia monetaria de forma mensual, a través de un mayor de edad responsable, y los montos se calculan a partir de la conformación del

²Cabe aclarar que dicho régimen coexiste con el componente contributivo definido por la Ley 15.084 de 1943, que reglamenta las Asignaciones Familiares destinada a trabajadores/as de la actividad privada.

hogar, un monto básico según cantidad de integrantes, aplicando una escala de equivalencia³ (0,6), y un complemento para aquellos integrantes que asistan a educación secundaria. La revisión del monto es de carácter mensual y se ajusta según el Índice de Precios al Consumo (IPC) (Lavalleja y Tenembaum, 2020).

En términos de cobertura, en la Figura 2.3 se presenta la evolución para la década 2008-2018. En el año 2011 la prestación alcanza su mayor valor en cuanto a cantidad de beneficiarios/as, 413.619 menores de edad, valor que disminuye sostenidamente y alcanza los 372.231 en 2018. Así también, cabe destacar que, si se analiza la evolución por tipo de beneficio para el mismo rango temporal, se registra un aumento sostenido de los/as beneficiarios/as que asisten a educación media, pasando de 16,8 % en 2008 a 24,1 % en 2018. Sin embargo la gran mayoría de las prestaciones (70,5 %) continúan siendo destinadas a escolares y menores de 5 años (Informe Mides 2017-2018, Dinem-Mides).

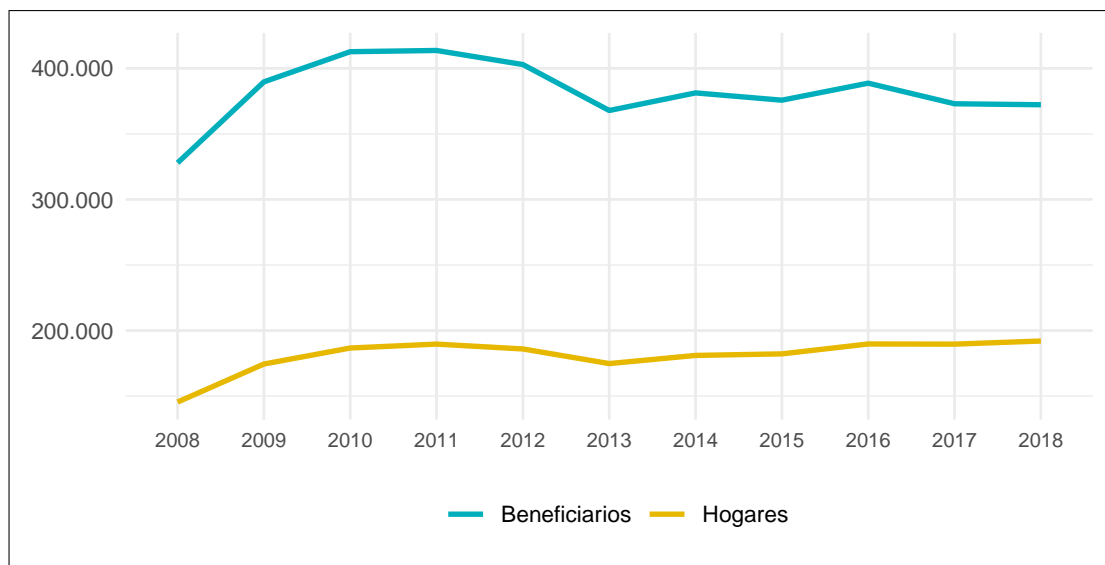


Figura 2.3: Evolución cobertura de AFAM-PE, total país, 2008-2018

Fuente: Elaboración propia con base en datos extraídos de Informe Mides 2017-2018, Dinem-Mides.

³La aplicación de una escala de equivalencia según cantidad de menores de edad se basa en la noción de economías de escala en la gestión del gasto a nivel del hogar, el cual no es proporcional según número de integrantes.

2.1.2. Mecanismos de focalización

Como ha sido mencionado, el programa AFAM-PE define como método de selección de sus beneficiarios/as la comprobación sustitutiva de medios de vida. El instrumento que se utiliza para dar cuenta del nivel de vulnerabilidad de los hogares y evaluar si estos forman parte de la población objetivo, definida por el programa en la ley que lo crea, es el Índice de Carencias Críticas (ICC)⁴. Este fue creado en el año 2008 en convenio entre el Mides y la Udelar, y como se menciona en un informe interno que detalla su diseño (DAES-Dinem y Mides, 2013): «La metodología propuesta para captar a la población objetivo combina un abordaje multidimensional de la situación socioeconómica de los hogares, con la concepción más clásica de pobreza asociada a los ingresos. Como resultado surge el ICC, un indicador que sintetiza información respecto a la situación de los hogares en distintas dimensiones entre las que no se incluye el ingreso, aunque este sí se utiliza como referencia en la elaboración de dicha síntesis». Por lo tanto, a partir de definir como población objetivo a los hogares con menores de edad que pertenecen al primer quintil⁵ de ingreso, para la construcción del ICC, se estima un modelo *probit* que predice la probabilidad de que un determinado hogar pertenezca a dicha categoría, considerando variables incluidas en la Encuesta Continua de Hogares (ECH-INE) asociadas a la educación, la vivienda, la composición del hogar y el confort (Amarante et al., 2008). Al respecto cabe mencionar que la selección de las variables utilizadas para el cálculo del ICC, como se observa en la Figura 2.4, se orienta a atributos que poseen una alta correlación con la variable dependiente y que se consideran como de difícil manipulación, lo cual le aporta estabilidad a la medición.

⁴Su uso trasciende el programa AFAM-PE y es aplicado para focalizar otros programas de transferencias como TUS y otros de diferente naturaleza como Cercanías o Uruguay Trabaja.

⁵La decisión de definir el primer quintil de ingreso como variable dependiente forma parte del diseño inicial del ICC que, dado el carácter general de la definición de población objetivo incluida en la ley, opta por operacionalizarla utilizando el 20% de los hogares de menores ingresos.

Variables	Detalle
Hacinamiento	Variable binaria que indica si el hogar está en condiciones de hacinamiento (más de dos personas por habitación para dormir).
Arrendatario	Variable binaria que indica si el hogar es arrendatario.
Ocupante	Variable binaria que indica si el hogar es ocupante.
Servicio sanitario sin descarga instantánea de agua o vivienda sin baño	Variable binaria que indica si el servicio sanitario con el que cuenta el hogar no tiene descarga automática de agua o el hogar no cuenta con servicio sanitario
Servicio sanitario entubado u otro	Variable binaria que indica si el hogar tiene evacuación del servicio sanitario por medio de un entubado hacia el arroyo u otro (superficie, etc.).
Índice compuesto de acceso a bienes durables y servicios	Variable construida por medio de un análisis factorial que aproxima al stock de riqueza del hogar.
Tamaño del hogar	Logaritmo del número de integrantes del hogar.
Techo planchada de hormigón sin protección	Variable binaria que indica que el material predominante del techo es hormigón sin protección.
Techo liviano con cielorraso	Variable binaria que indica que el material predominante del techo es liviano con cielorraso.
Techo liviano sin cielorraso o quincha o materiales de desecho	Variable binaria que indica que el material predominante del techo es liviano sin cielorraso o de quincha o materiales de desecho.
Piso de alisado de hormigón o solo contrapiso sin piso	Variable binaria que indica que el material predominante del piso es alisado de hormigón o contrapiso sin piso.
Tierra sin piso ni contrapiso	Variable binaria que indica que el material predominante del piso es de tierra sin piso ni contrapiso.

Figura 2.4: Variables incluidas en el Índice de Carencias Críticas (ICC)

Fuente: Mides - ICC rev. 2012

El resultado de dichas estimaciones es un conjunto de ponderadores para cada una de las variables consideradas, siendo diferentes para el caso de Montevideo como para los restantes departamentos del país, que son resumidos en un índice de variación entre 0 y 1 en términos de probabilidad de encontrarse en el primer quintil de ingreso. Inicialmente, el ICC fue construido con base en la ECH del año 2006, y años más tarde se llevó a cabo una revisión de las variables y ponderadores según ECH 2011, cuyos cambios se implementaron a partir del año 2013. Luego de contar con dicha estimación, se definen umbrales de elegibilidad para lograr una cobertura en consonancia con el mandato incluido en la ley que reglamenta las AFAM-PE, el cual se ubica en 500.000 menores luego de 2009. Sin embargo, en la actualidad permanecen vigentes los umbrales definidos en la revisión de 2013,

lo cual, en un contexto de crecimiento económico y mejora de las características de los hogares, implica una menor cobertura a partir de un aumento de los errores de exclusión y disminución del error de inclusión.

Si nos centramos en los resultados de la focalización desde su diseño existen múltiples documentos que lo evalúan⁶, no solo a partir de comparar la elegibilidad con captación en ECH o cobertura efectiva, sino que considerando otras medidas de vulnerabilidad como son la pobreza monetaria y las Necesidades Básicas Insatisfechas (NBI) o características poblacionales generales. A partir del método clásico para medir la focalización, como fue conceptualizado al inicio, se calculan los dos tipos de errores, de inclusión o filtración y de exclusión o subcobertura. Las estimaciones al respecto se realizan a partir de la ECH, lo cual tiene algunas dificultades asociadas a la captación de los/as beneficiarios/as⁷, que se ubica, según cálculos propios del Mides para el año 2018, en 87,4%⁸, así como la elegibilidad se estima solo mediante el método de ICC y sin considerar las condicionalidades previstas o los controles de topes de ingreso que realiza el BPS. Así también, la temporalidad considerada puede acarrear un desfase entre la situación socioeconómica del beneficiario/a al momento de definir su elegibilidad, según los medios previstos para la recolección de la información y su situación en las estimaciones de ECH (Informe 2017-2018, Dinem). Teniendo en cuenta las advertencias precedentes, para el año 2018 los errores asociados a la focalización de AFAM-PE se estiman en 35,8% (exclusión) y 23,4% (inclusión), contrastando la población elegible con la captación en ECH. En otro estudio reciente, Lavalleja y Tenembaum (2020) también realizan dicho ejercicio considerando no ya la

⁶Existe una serie de documentos denominada *Aportes a la conceptualización de la pobreza y la focalización de las políticas sociales en Uruguay*, publicada en el año 2013 por el Departamento de Análisis y Estudios Sociales de la Dirección Nacional de Evaluación y Monitoreo del Ministerio de Desarrollo Social (DAES-DESyTC-Dinem).

⁷Villatoro y Cecchini (2018) realizan un análisis exhaustivo acerca de las discrepancias entre los registros administrativos y las encuestas de hogares, en cuanto a la captación de beneficiarios/as de los programas de transferencias no contributivas de 13 países de la región. Concluye que, al igual que sucede en EE.UU. y Europa, dichas inconsistencias se vinculan más a una sub-captación de las encuestas que a falencias en los sistemas de registro de los PTC.

⁸Extraído del documento de trabajo *Captación de Asignaciones Familiares del Plan de Equidad (AFAM-PE) en las Encuestas Continuas de Hogares* (DAES-Dinem, 2019).

población elegible según ICC, sino la población objetivo de AFAM-PE definida como los quinientos mil menores de edad con ingresos per cápita más bajos (sin condicionalidades ni topes de ingreso), y encuentra que los errores en el año 2017 se ubican en 39 % (exclusión) y 10 % (inclusión). Así también, Coady et al. (2004) plantean que evaluar la focalización de los programas de transferencias monetarias centrando el análisis en la cobertura presenta carencias vinculadas a que aquellos hogares beneficiarios que se encuentran en los límites en cuanto a ingreso, ya que se consideran de igual modo que aquellos en situación opuesta, es decir que no se considera el factor distributivo de la prestación. En ese sentido es que plantean un enfoque alternativo que busca combinar la cobertura con la distribución del gasto según deciles o quintiles de ingreso. Para el caso de AFAM-PE el porcentaje de gasto destinado a los cuatro deciles inferiores de ingreso (40 %) asciende a 91 % en 2018 (Informe 2017-2018, Dinem).

2.1.3. Proceso de implementación de la prestación

En el presente apartado se busca dar cuenta sobre el proceso de implementación y obtención de la prestación en el programa AFAM-PE y los aspectos operativos que hacen a su funcionamiento (ver Figura 2.5). Como fue mencionado, la forma de ingreso al programa se da a partir de la demanda de los/as postulantes considerando dos vías posibles: visita del equipo técnico del Mides o declaración jurada en el BPS. En ambos casos se releva la misma información, y en el caso de contar con dos registros, se prioriza el más actual. Los datos necesarios para gestionar el ingreso al programa se encuentran en el Formulario de visita de Asignaciones Familiares del Plan de Equidad⁹, el cual incluye un módulo básico sobre la integración del hogar, datos geográficos y personales sobre los integrantes; otra sobre aspectos vinculados a la vivienda, alimentación, violencia doméstica y personas indocumentadas; por último, a nivel de persona, preguntas asociadas a la situación laboral, educativa, de salud y discapacidad de cada uno de los

⁹<https://www.gub.uy/ministerio-desarrollo-social/sites/ministerio-desarrollo-social/files/2019-06/FORMULARIO%20AFAM%202015.pdf>

integrantes del núcleo. Luego de relevados los datos, por ambos métodos, se realiza un chequeo de completitud y coherencia, y se lleva a cabo un control de las condicionalidades definidas, matriculación en el sistema educativo al ingresar y asistencia de forma anual. Posteriormente se calcula el ICC considerando la ubicación geográfica (Montevideo/interior) y se define la elegibilidad con base en los umbrales establecidos para cada caso, impactando dicho proceso y resultado en los sistemas informáticos y bases de datos de registro del Mides.




Figura 2.5: Proceso de ingreso de AFAM-PE

Fuente: Elaboración propia con base en documentos oficiales del programa AFAM-PE (Mides).

En lo que respecta a los criterios de salida del programa, no se establece un tiempo límite de permanencia, sino que el egreso se da al no cumplir con algún criterio de elegibilidad, ya sea a partir de re-visita del hogar y mejora de su situación o no cumplimiento de algunas de las condicionalidades educativas, de salud o con relación al tope de ingreso formal per cápita (Lavalleja et al., 2012).

2.2. Transferencias monetarias condicionadas en Costa Rica

El surgimiento de los PTC en Costa Rica debe enmarcarse en un sistema de protección social de larga data que, como ha sido remarcado en la introducción, combina políticas universalistas orientadas a la salud y la educación con selectivas o focalizadas de atención a situaciones de vulnerabilidad. Con el desarrollo de una institucionalidad temprana e innovadora en la región, como es el IMAS, el componente no contributivo estuvo presente en el país y, aunque con menor peso que las políticas universales, fueron importantes para paliar las consecuencias de la crisis de los ochenta y el deterioro en los indicadores sociales que conllevó incluso en la siguiente década (Román Vega, 2012). En esta línea, como lo analiza Román Vega (2012), si se atienden los indicadores de inversión social, desde los años noventa se registra un aumento sostenido de la inversión social pública (ISP) en Costa Rica, incluso en los períodos de contracción económica, y si se analiza por sectores se observa que los programas universales recogen la mayor parte de la inversión (58 % del ISP en 2010), mientras que los programas focalizados representan un 11 % y 2,5 % del PBI.

Además del IMAS, el Fondo de Desarrollo Social y Asignaciones Familiares (FODESAF) también representa un instrumento relevante en la comprensión de la génesis de las políticas no contributivas de alivio a la pobreza en Costa Rica, ya que constituye el principal mecanismo financiero que posibilita su existencia. El FODESAF se financia de fuentes impositivas, y ha experimentado variaciones al respecto desde su creación en los años setenta, existiendo leyes que reglamentan la distribución de los fondos entre los diferentes programas e instituciones. Entre esos destinos, y con algunos antecedentes similares, es que aparece Avancemos, el principal PTC actual del país, que, como afirma Román Vega (2012), «es la más importante iniciativa gubernamental desarrollada en los últimos 15 años para enfrentar el problema de la expulsión estudiantil en secundaria. Fue creado mediante decreto ejecutivo el 8 de mayo de 2006, con el

propósito promover la permanencia y reinserción en el sistema educativo formal de jóvenes pertenecientes a familias que tienen dificultades para mantener a sus hijos en el sistema educativo formal, por causas económicas. Su principal característica es la de funcionar como un subsidio a la demanda.» Como lo analiza Villalobos Álvarez (2012) al estudiar la genealogía y el proceso de formulación del programa en un contexto regional de expansión de los PTC con características similares y apoyo de organismos trasnacionales, Avancemos combina aspectos comunes de otros programas asociados a directrices de dichos organismos, pero que coexisten con los que denomina *factores domésticos* que resultan centrales para comprender la evolución y transformaciones que ha experimentado desde su creación y que serán abordadas a continuación.

2.2.1. Programa Avancemos

El programa Avancemos surge en el año 2006, inicialmente bajo la ejecución del Fondo Nacional de Becas (Fonbae) y el IMAS, y pasó a depender desde el año 2009, únicamente del segundo. Su cometido principal se asocia con «promover el mantenimiento y aprovechamiento en el sistema educativo de adolescentes miembros de familias en condición de pobreza, para que, con su compromiso, tengan oportunidad de superar a futuro la situación en que viven» (Decreto Ejecutivo n.o 33203-MP-Mideplan-Mivah-MEP-MTSS del 8 de junio de 2006). Contaba en su diseño inicial con tres componentes principales: una transferencia monetaria tradicional, un incentivo a crear un fondo de ahorro para la continuidad educativa o laboral, y un apoyo a la oferta educativa; así como las condicionalidades se vinculaban con control de asistencia y valoración de desempeño en lo educativo, y al menos una valoración de salud, cubriendo las dos áreas en que se buscaba impactar. Sin embargo, ya a partir de 2009, se experimentan cambios en ambos aspectos y el componente principal pasa a ser únicamente la transferencia monetaria y la asistencia educativa como la condicionalidad asociada (Hernández Romero, 2016).

La población objetivo del PTC son los/as adolescentes y jóvenes, entre 12 y 25 años, en familias¹⁰ que se encuentran en situación de pobreza (coyuntural o extrema), riesgo, vulnerabilidad y exclusión social, y que necesiten apoyo económico para sostener su participación en el sistema educativo o reinsertarse en él¹¹ (Informe Programa Avancemos, Viceministerio de Desarrollo Social, 2008). Con respecto al monto de la transferencia, lo reciben cada uno de los/as adolescentes y jóvenes estudiantes beneficiarios según el ciclo lectivo al que pertenecen, con valor diferencial entre tercer o cuarto ciclo. No existen límites en cantidad de beneficiarios por familia, pero si cumplimiento de los requisitos y condicionalidades previstas (Hernández Romero, 2016). El medio de pago de la transferencia es una tarjeta electrónica asociada a la persona encargada en caso de menores de edad o al estudiante si es mayor.

En términos de cobertura, según datos de Cepal¹², el programa Avancemos registra una estabilidad en la cantidad de estudiantes beneficiarios, con una leve caída en el período 2012-2016 que luego parece aumentar progresivamente (ver Figura 2.6). Las familias que son alcanzadas por el programa ascienden en promedio, considerando el período 2010-2018, a 138.517.

¹⁰La noción de *familia* difiere de la de *hogar*, ya que la primera corresponde a las personas con relación de parentesco o dependencia económica, mientras que el segundo puede no implicar relación de parentesco y se trata de un conjunto de personas que comparten el sustento económico (Hernández Romero, 2016).

¹¹Cabe señalar que han existido transformaciones en la definición de la población objetivo desde el año 2006, ya que se han flexibilizado y ampliado los criterios tanto en lo que respecta a la medición de pobreza y vulnerabilidad como a la edad considerada para el ingreso al programa.

¹²Base de datos de programas de protección social no contributiva en América Latina y el Caribe - Cepal (<https://dds.cepal.org/bpsnc/>)




Figura 2.6: Evolución de cobertura de Avancemos, total país (2010-2018)

Fuente: Elaboración propia a partir de Base de datos de programas de protección social no contributiva en América Latina y el Caribe - Cepal <https://dds.cepal.org/bpsnc/>

2.2.2. Mecanismos de focalización

La elegibilidad del programa Avancemos se da, además de por los requisitos formales de edad y condicionalidades, a partir la clasificación y puntajes obtenidos en el Sistema de Información sobre la Población Objetivo (SIPO). Este pertenece al Sistema de Información para la Acción Social (Sipas) y es el encargado de asistir al IMAS en lo referente a registro de información y focalización de los distintos programas que ejecuta. Es definido como un «registro computarizado de la población objetivo, que se alimenta principalmente de los datos obtenidos en la Ficha de información Social (FIS) (...) la cual reúne una serie de variables socio demográficas y económicas, a través de las cuales es posible identificar, caracterizar, seleccionar y clasificar a las personas y familias en situación de pobreza.» (IMAS, 2021).

A partir de la aplicación de la FIS, y la información surgida de esta se calcula un *indicador de bienestar* que ha sido construido, en su revisión denominada

SIPO-2005¹³, considerando seis dimensiones que se encuentran en la Encuesta de Hogares de Propósitos Múltiples (EHPM) y la FIS con el objetivo de poder realizar las estimaciones necesarias. Luego, para cada una de las dimensiones y subdimensiones, se calcula un puntaje vinculado a los deciles promedio de ingreso familiar per cápita de los hogares que tienen cada característica, distinguiendo entre urbano y rural. Posteriormente, se realiza un Análisis de Componentes Principales (ACP) para definir las variables más relevantes y que correlacionan más con el nivel de bienestar, y se definen las ponderaciones finales según zona. Las estimaciones del SIPO 2005 se realizan con base en la EHPM 2004 y, como se observa en la Figura 2.7, se consideran veintiocho variables que se desprenden de las seis dimensiones iniciales.

¹³El antecedente directo es el SIPO-2000, cuya metodología es explicitada en Elizondo (2000).

Factor	Subfactor	Variable
Vivienda	Protección Ambiental	Material De Paredes
		Material Del Piso
		Techo Con O Sin Cielo Raso
	Hacinamiento	Total De Personas En La Vivienda/Total De Cuartos Para Dormir En La Vivienda
	Saneamiento Y Confort	Abastecimiento De Agua
		Sistema Eliminación Excretas
		Disponibilidad Baño
		Suministro eléctrico
		Fuente De Energía Para Cocinar
Medio De Eliminación De Basura		
Educación	Escolaridad del jefe	Nivel Educativo Del jefe
	Escolaridad De Otros Miembros	Nivel Educativo De Otros Miembros Del Hogar Con Edad De 18 Años O Más
Ocupación	Ocupación del Jefe	Condición De Actividad Y Categoría Ocupacional Del Jefe
	Ocupación De Otros Miembros	Grupo De Ocupación De Otros Miembros Del Hogar Con Edad De 18 Años O Más
Patrimonio	Vivienda	Tenencia De La Vivienda
	Equipamiento 1	Posesión De Tv A Color
		Posesión De Refrigeradora
		Posesión De Lavadora
		Posesión De Teléfono Residencial
	Equipamiento 2	Posesión De Vhs
		Posesión De Teléfono Celular
		Posesión De Ducha Agua Caliente
		Posesión De Tanque Para Almacenar Agua
		Posesión De Computadora
		Posesión De Vehículo
		Posesión De Horno Microondas
	Aseguramiento	Categoría De Aseguramiento De Los Miembros Del Hogar
Ingreso	Ingreso Per-Cápita Del Hogar	

Figura 2.7: Factores, subfactores y variables que componen el Modelo SIPO-2005
Fuente: Extraído de Delgado Jiménez (2017)

Finalmente, se han definido en el SIPO-2000 los *umbrales de privación* a partir de un análisis de conglomerados para cada zona, y se establecen cuatro estratos que han sido utilizados para definir la población objetivo de las diferentes intervenciones que realiza el IMAS. Para la actualización metodológica SIPO-2005 no hay una definición clara en el criterio para establecer los puntos de corte

(Trejos y Sáenz, 2007; Viquez, 2005). En la actualidad, la clasificación SIPO se divide en los siguientes grupos: pobreza extrema (grupo 1), pobreza moderada (grupo 2), condiciones vulnerables (grupo 3) y no pobres (grupo 4). Aquellos que son priorizados para ser seleccionados como beneficiarios/as de Avancemos corresponden a los grupos 1, 2 y 3¹⁴, cuyos puntajes dan cuenta de mayores niveles de vulnerabilidad y pobreza (Hernández Romero, 2016).

Como forma de aproximar a los resultados de la focalización de Avancemos, se han ensayado algunos acercamientos utilizando diferentes enfoques. En primer lugar, Delgado Jiménez (2017) presenta una medida asociada a la distribución de los/as beneficiarios/as reales según grupos definidos en el SIPO a partir de datos administrativos del IMAS, y encuentra que un error de inclusión de 24,8 %, vinculada por el autor a la masividad inicial del programa que flexibilizó criterios de asignación de las prestaciones. Así también, cuando dicha estimación se realiza considerando la Encuesta Nacional de Hogares (Enaho), la filtración asciende a 28,8 %. En un segundo momento, se realiza la evaluación de la efectividad de la elegibilidad comparando su desempeño con dos medidas de vulnerabilidad como son la línea de pobreza y la pertenencia a los deciles más bajos de ingresos. Para ello, fue necesario estimar el índice de bienestar (SIPO-2005) en la Enaho del 2014 y comparar con la captación efectiva¹⁵ de beneficiarios/as de la prestación, para poder dar cuenta no solo de los errores de inclusión, sino también de los de exclusión. El autor halla problemas importantes de focalización vinculados a las medidas tradicionales de vulnerabilidad, ya que la proporción de estudiantes pertenecientes a la población objetivo y que no son cubiertos por el programa representa un 56,3 % según línea de pobreza y 57,9 % si se consideran los cuatro primeros deciles de ingreso. Por otra parte, la filtración según el primer método

¹⁴Inicialmente los grupos priorizados eran los correspondientes a pobreza extrema y moderada (grupos 1 y 2), sin embargo, en 2014 se extiende la cobertura de forma excepcional a estudiantes del grupo 3, mediados por una evaluación técnica por parte de un/a trabajador/a social y considerando que no se supere la línea de pobreza.

¹⁵Cabe señalar que en el estudio referido no se hacen menciones a la calidad y proporción de captación del programa Avancemos en la Enaho, lo cual puede significar un elemento importante para definir la fiabilidad de las estimaciones y errores calculados.

asciende a 58,9% y 33% si se considera el ingreso (Delgado Jiménez, 2017).

2.2.3. Proceso de implementación de la prestación

Cómo se observa en la Figura 2.8, que da cuenta del proceso para llegar a ser beneficiario/a, el primer paso para aplicar al programa Avancemos se da a partir de una entrevista en donde se recopila información incluida en la FIS¹⁶ que se origina como solicitud de los/as interesados/as y que se complementa con la presentación de documentación probatoria de lo declarado. Así también, existen experiencias recientes de captación en territorios con altos niveles de vulnerabilidad a partir de aplicación masiva de FIS en los hogares. Luego de obtener un puntaje en el SIPO como resultado de la información recabada en la FIS, se procesa la inscripción en el Sistema de Atención a Beneficiarios (Saben), el cual contiene el registro de la familia e información relevante sobre esta, asistiendo administrativamente el proceso. Posteriormente, la solicitud es derivada a las Asociaciones Regionales de Desarrollo Social (ARDS) que evalúan la fiabilidad de los datos y la documentación, así como proceden a dar una resolución al respecto considerando la disponibilidad presupuestal (Hernández Romero, 2016).



Figura 2.8: Proceso de ingreso de Avancemos

Fuente: Elaboración propia con base en Hernández Romero (2016)

Por su parte, luego de asignado el beneficio, también existe una verificación periódica, tres veces al año, del cumplimiento de las corresponsabilidades o condicionalidades del programa acerca de asistencia y desempeño educativo. Por último, las formas de egreso o salida del programa son tres: en primer lugar, la pérdida de elegibilidad asociada a una mejora en el nivel de bienestar de la familia o superación de la edad límite para la participación en el programa, en segunda

¹⁶Ver Ficha de Información Social (FIS) en Hernández Romero (2016).

instancia, el incumplimiento de las condicionalidades ya mencionadas, y en tercer caso, por falsa declaración o presentación de documentación fraudulenta, lo cual es corroborado por las oficinas encargadas y notificado a los/as participantes (Hernández Romero, 2016).

3. Mecanismos alternativos de focalización usando AE

El presente capítulo presenta una discusión teórica-conceptual general de la Inteligencia Artificial (IA) y el Aprendizaje Estadístico (AE) con especial énfasis en los desafíos que implica su utilización en las políticas públicas en general y en las políticas sociales en particular, destacando algunas conceptualizaciones y aportes para América Latina, así como antecedentes específicos de uso para la focalización de PTC en la región.

3.1. IA: definiciones e implicancias en la política pública

Desde hace cerca de dos décadas asistimos a la emergencia progresiva del dato y los algoritmos como elementos que atraviesa la vida social en sus diferentes ámbitos. En este marco, aparece como central la Inteligencia Artificial o *de máquinas*, cuya definición no es unívoca y representa un campo en disputa entre diferentes interpretaciones y matices al respecto de su alcance, pero que en términos generales refiere al conjunto de mecanismos computacionales que intentan emular la inteligencia humana a partir de un aprendizaje complejo. Los dos subtipos más extendidos son el aprendizaje estadístico (o *statistical learning*) y el aprendizaje profundo (o *deep learning*), el primero vinculado a algoritmos que *aprenden* de experiencias pasadas para poder predecir o tomar decisiones en el futuro, mientras que el segundo se basa en algoritmos que buscan la captación de relaciones profundas (redes neuronales) con el fin de hallar patrones en los datos (Giletta et al., 2020).

Cada vez más, los algoritmos con base en IA tienen mayores implicancias en diferentes áreas de la vida, potenciados por la creciente acumulación de datos que alimenta y acrecienta el llamado *big data*, como consecuencia de los procesos de digitalización de la vida cotidiana y de las interacciones humanas. Dichos impactos pueden verse desde la salud, la economía, la publicidad, el comercio electrónico, la política pública, entre otros (Giletta et al., 2020), lo cual abre

un debate necesario sobre los paradigmas subyacentes, la aparente neutralidad técnica o los dilemas éticos que se desprenden cuando se encuentra asociado a tomas de decisiones concretas de alto impacto. Este último aspecto cobra real importancia cuando los sistemas automatizados con base en IA y en AE son utilizados por los organismos públicos, ya que la posibilidad de existencia de zonas de incertidumbre o *cajas negras* en las herramientas desarrolladas para la toma de decisiones pueden escapar a la posibilidad de rendir cuentas a las personas o grupos de personas en los cuales se busca impactar, lo cual hace necesario un sistema regulatorio sólido (Reisman et al., 2018). Al respecto, existen desarrollos recientes que hacen énfasis en la necesidad de trabajar en la interpretabilidad de las predicciones resultantes de este tipo de modelos, especialmente relevante en algunos problemas específicos, con el objetivo de aportar equidad, privacidad, confiabilidad, causalidad y confianza (Doshi-Velez y Kim, 2017).

En particular, para el caso de América Latina existen trabajos recientes que dan cuenta de los desafíos que implica la inclusión de sistemas con base en IA para la toma de decisiones en el ámbito público (Gómez Mont et al., 2020; Cabrol et al., 2020; Alfonso Costa, 2019). Desde el Banco Interamericano de Desarrollo (BID) se ha acuñado el término *IA para el bien social*, que se utiliza para caracterizar y resaltar las potencialidades de la IA: «(...) Para abordar los retos más importantes de nuestro tiempo, aquellos que impactan directamente a los humanos y al medio ambiente en los más diversos campos como la salud, la educación, el empleo, la justicia, la disponibilidad de recursos, el cambio climático, la igualdad de género y la reducción de las desigualdades. Bajo el concepto de IA para el bien social tienen cabida distintos actores, incluyendo todas aquellas organizaciones o iniciativas que atiendan a dichos retos apoyándose en esta tecnología.» (Gómez Mont et al., 2020). A pesar de que se reconoce la IA y el AE como una herramientas que tienen la potencialidad de mejorar los impactos de las acciones tomadas por los organismos públicos de la región, se enfatiza en la necesidad de desarrollar sistemas auditables, explicables, transparentes y que eviten los *sesgos* y *efectos*

adversos que puedan terminar perjudicando a las poblaciones más desfavorecidas (Gómez Mont et al., 2020).

3.2. La IA aplicada a los PTC

Como fue detallado en capítulos anteriores, las políticas sociales implementadas en la región, en particular aquellas que pretenden un mayor impacto, tienen el carácter focalizado debido a las restricciones en los presupuestos asociados. En consecuencia, en las decisiones vinculadas a la selección de beneficiarios/as o criterios de elegibilidad de las políticas de alivio a la pobreza, como lo son los PTC, subyace la orientación algorítmica desde sus inicios, hace más de dos décadas. Los principales mecanismos utilizados, en ese sentido, se corresponden con modelos de predicción del nivel de pobreza o vulnerabilidad de los hogares a partir de pruebas sustitutivas de medios como consecuencia de las dificultades para relevar el ingreso de forma directa, que se construyen a partir de estadísticas oficiales nacionales con características diferentes según países.

La implementación de estrategias de focalización en los PTC con base en los modelos de IA y AE aún son escasas y se encuentran en una etapa de validación de los algoritmos en comparación con los métodos tradicionales. Se registran algunos antecedentes puntuales de aplicación vinculados a la situación de emergencia por covid-19, como es el caso de una transferencia monetaria de emergencia implementada en Togo, en la cual se utilizaron algoritmos de IA para definir la elegibilidad del programa a partir del uso de datos satelitales y de redes de telefonía móvil. Dada la carencia en los sistemas de registros oficiales en Togo la utilización de grandes volúmenes de datos como los mencionados, entrenados previamente modelos que captan los patrones de encuestas de riqueza y consumo del país, logran buenos resultados en términos de focalización de la pobreza (Aiken et al., 2022).

Para el caso de Estados Unidos, existen antecedentes sobre exploración de apli-

cación de modelos con base en IA para focalización de programas, donde se parte de un tipo de medición de pobreza desarrollada por el Centro IRIS (Universidad de Meryland) para la United States Agency for International Development (Usaid), que es utilizada para predecir la pobreza y definir la elegibilidad de programas implementados en diferentes países. El estudio realiza una comparación entre los modelos tradicionales y los que se basan en modelos de aprendizaje estadístico, considerando estas variables en ambos, y encuentra que los últimos mejoran significativamente los errores, tanto de exclusión como de inclusión, fuera de la muestra de entrenamiento (McBride et al., 2018).

En esta misma línea, el trabajo *Algorithmic Targeting of Social Policies: Fairness, Accuracy, and Distributed Governance* de Noriega-Campero et al. (2020) representa un antecedente directo del presente trabajo, ya que se centra específicamente en los PTC en América Latina. Plantea como hipótesis que la aplicación de modelos basados en IA mejoran la precisión predictiva con respecto a los modelos econométricos tradicionales, como el modelo *probit*, ya que logran captar relaciones no lineales presentes en datos de alta dimensión, y así reducir los errores de focalización, tanto de exclusión como de inclusión. A partir de dicha presunción, estudia dos casos de la región, Costa Rica y Colombia, comparando ambos modelos y mostrando evidencia de la mejora en la capacidad predictiva de aquellos con base en IA, lo cual conduce, según sus conclusiones, a un aporte sustantivo en términos de equidad. Así también, el autor indaga en los errores de focalización considerando subgrupos poblacionales específicos con el fin de dar cuenta de las disparidades subyacentes entre estos, y no solo confirma las diferencias entre ambos utilizando los dos métodos, sino que encuentra que los modelos construidos a partir de algoritmos de IA también logran reducir los errores con respecto a los modelos tradicionales (Noriega-Campero et al., 2020).

3.3. El caso de Costa Rica: programa Avancemos

A continuación se presentan los resultados comparativos de ambos métodos de focalización, econométricos y con base en IA, para el caso de Costa Rica y su programa de transferencias ya caracterizado Avancemos, los cuales son tomados del trabajo de Noriega-Campero et al. (2020), y que luego serán analizados de forma comparada en el capítulo siguiente con la aplicación de técnicas similares para el caso de AFAM-PE de Uruguay.

Como fue mencionado en el capítulo anterior, el puntaje SIPO que surge de la aplicación de modelos econométricos tradicionales representa el mecanismo utilizado por Avancemos, desde su comienzo, para definir la elegibilidad de los/as beneficiarios/as. Las técnicas utilizadas combinan la imputación del percentil promedio del ingreso per cápita de los hogares que cuentan con una de las múltiples categorías que se consideran, para luego establecer ponderaciones a partir de la técnica estadística ACP. Sin embargo, para ensayar la comparación entre modelos, el trabajo de referencia (Noriega-Campero et al., 2020) utiliza la regresión lineal cuantílica como método para predecir la pobreza, y que luego será contrastado en términos de resultados con modelos con base en IA. En ambos casos, se consideran las mismas variables de referencia definidas teóricamente a partir de conocimiento *experto* y que luego, con el fin de mejorar su capacidad predictiva, en los modelos con base en IA, serán complementadas con variables que resultan de la construcción de estadísticos individuales o agregados a nivel de hogar (medias, máximos, modas) y con variables *profundas* construidas a partir de aplicación de redes neuronales.

Los resultados de la comparación entre modelos son concluyentes en una ventaja comparativa de los modelos que aplican algoritmos de IA y aprendizaje estadístico frente a aquellos con base en técnicas econométricas tradicionales. El modelo con mejor nivel de precisión fuera de la muestra es el Gradient Boosting Classifier (GBM), que utiliza la validación cruzada para definir y ajustar los hiperparámetros

para su entrenamiento. Las métricas presentadas en el trabajo indican una mejora significativa tanto en los errores de exclusión como de inclusión en la selección de beneficiarios/as, considerando la línea de pobreza como *umbral de aceptación* fijo. En concreto, la reducción de ambos errores es de 25,9% si se comparan ambos métodos, lo cual implica una mejor clasificación tanto en incluir hogares que se encontraban mal clasificados como no beneficiarios (exclusión) según los métodos tradicionales, así como en evitar la filtración de beneficiarios que no lo son (inclusión). Dicha reducción se observa en la Figura 3.1¹⁷, en la cual se presentan las curvas exclusión-inclusión, indicando el balance o *trade-off* entre ambos tipos de errores de focalización y los puntos óptimos para cada uno de los modelos ensayados. Los mejores resultados en términos de precisión y exactitud se observan al incluir variables construidas, además de aquellas consideradas para integrar el modelo según consideraciones teóricas o *expertas* que las asocian a la variable dependiente (pobreza).

¹⁷«Estudio de ablación para los datos de Costa Rica. Se presentan cinco curvas de exclusión-inclusión diferentes para explicar las ganancias de precisión logradas por los métodos basados en IA. Estas curvas corresponden a diferentes combinaciones de variables basadas en conocimiento experto, estadísticos construídos y variables profundas descritas en el texto principal, así como a los diferentes estimadores utilizados: regresiones lineales cuantílica (QLR) y Gradient Boosting Classifier (GBM). Las barras grises alrededor de los puntos rojos indican intervalos de confianza del 95% calculados no paramétricamente a través de remuestreo bootstrap» (Noriega-Campero et al., 2020).




Figura 3.1: Extraído de Noriega-Campero, et al. (2020) - Section A. Supplementary Material (SM)

Los hallazgos del estudio sugieren que la utilización de estos modelos no sólo representan una ganancia en términos de precisión, lo cual redundaría en mayor equidad de la distribución de los recursos destinados a los PTC, sino que se presentan los errores de focalización desagregados por subgrupos con el fin de identificar posibles sesgos implícitos al considerar modelos unificados, es decir, con un mismo umbral para la totalidad de la población. De este modo, se consideran, para el caso de Costa Rica, grupos según zona (urbano/rural), región geográfica, sexo del jefe de hogar, presencia de hijos/as y tamaño del hogar. Para todos los casos se ensayan modelos diferenciales entre grupos y, si bien se hallan diferencias significativas entre los niveles de error entre estos, la precisión en todos los casos es mayor para aquellos modelos con base en IA (Noriega-Campero et al., 2020).

Por su parte, otro de los aspectos que es abordado en el trabajo refiere a la *explicabilidad* de los modelos, lo cual, como fue resaltado en apartados anteriores, resulta un requisito importante cuando se consideran modelos con base en técnicas de IA y AE que tienen un impacto social significativo como es el caso de los criterios de elegibilidad de un PTC. En este sentido, propone un análisis del peso relativo de cada una de las variables que son consideradas al momento de entrenar el modelo, la estimación de los errores y su presentación gráfica a través de *mapas de sensibilidad* que permitan visualizar y generar una validación experta de las ponderaciones o importancia de cada atributo considerado (Noriega-Campero et al., 2020).

4. Ensayo de focalización utilizando IA y AE en el programa AFAM-PE

4.1. Introducción

El presente capítulo tiene como objetivo ensayar estrategias alternativas de focalización para la selección de beneficiarios/as para el caso del PTC AFAM-PE de Uruguay a partir del uso de técnicas de aprendizaje estadístico.

El enfoque elegido, cómo fue esbozado en el capítulo anterior a partir de un antecedente concreto, pretende comparar modelos con base en conocimiento y análisis estadístico que, en términos de Breiman (2001), contraponen *dos culturas* en el tratamiento de datos orientado a la obtención de resultados. Por un lado, *la modelización de datos* en la que subyace la noción de que los datos son producidos por modelos estocásticos y buscan conectar variables predictoras (independientes) y variables resultado (dependientes), entre los cuales se encuentran los modelos econométricos *tradicionales*, regresiones lineales y sus derivados. Por otro lado, aquellos centrados en la *modelización algorítmica* que buscan captar relaciones complejas, no lineales, que no pueden ser captados por modelos de datos y cuyo interés fundamental se centra en la precisión predictiva (Breiman, 2001b). En esta última línea encontramos los modelos de aprendizaje estadístico, los cuales se dividen en dos tipos fundamentales: *supervisados*, cuando existe un conocimiento previo, y *no supervisado*, cuando se ajusta a los casos u observaciones.

A partir del marco de referencia precedente se buscará comparar ambos tipos de modelos, planteando la hipótesis que, como indican los antecedentes al respecto (Aiken et al., 2022; Noriega-Campero et al., 2020; McBride et al., 2018), aquellos basados con base en aprendizaje estadístico logran mejorar el desempeño predictivo y de esa forma ganar eficiencia al disminuir los errores de focalización. Para ello, en primera instancia, se detallarán técnicamente los modelos seleccionados (probit, Random Forest y Stochastic Gradient Boosting) a partir de antecedentes referidos, para luego presentar la estrategia metodológica y detallar su ejecución

en etapas. Por último, se presentan los resultados obtenidos, así como métricas y visualizaciones que acompañan el análisis.

4.2. Modelos utilizados

4.2.1. Probit

El *probit* es un tipo de modelo de regresión en el cual la variable dependiente es dicotómica, es decir que puede tomar dos valores (0 o 1). El modelo utiliza una Función de Distribución Acumulativa (FDA) normal bajo el supuesto de que la variable explicada depende de una *variable latente* se encuentra determinada por un conjunto de variables explicativas (Gujarati y Porter, 2010).

En el caso de que $Y = 1$, la fórmula asociada podría expresarse como:

$$Pr(Y = 1 / X_i) = \Phi(\beta_0 + \beta_1 X) \quad (1)$$

En la cual $\Phi(z)$ es la FDA normal evaluada en z , donde $z = \beta_0 + \beta_1 X$. Las X_i son i variables explicativas, en este caso socioeconómicas, y β_i son los índices o ponderadores de dichas variables.

4.2.2. Random Forest

El Random Forest (o *bosques aleatorios*) es un tipo de modelo que se encuentra entre los métodos ensamblados o agregados, que se basan en combinar las predicciones de distintos tipos de modelos, como es el caso de los métodos bagging, con el objetivo de reducir la varianza.

El algoritmo que subyace al modelo Random Forest se basa en los árboles de clasificación y regresión (CART) y, agrega al componente aleatorio de las observaciones, la selección aleatoria de variables en la partición de cada nodo en los árboles individuales, buscando superar la fuerte correlación (y mayor

varianza) que pueda existir entre variables predictoras (Hastie et al., 2001). A continuación se presenta el detalle del algoritmo para el subtipo de clasificación:

Algorithm 1 Random Forest de Clasificación

- 1: **for** $b \leftarrow 1, B$ **do**
 - 2: (a) Extraer una muestra bootstrap \mathbb{Z}^* de tamaño N de los datos de entrenamiento.
 - 3: (b) Hacer crecer un árbol del bosque aleatorio T_b sobre los datos de la muestra bootstrap, repitiendo recursivamente los siguientes pasos para cada nodo terminal del árbol, hasta que el tamaño mínimo de nodo n_{\min} sea alcanzado.
 - 4: (I) Seleccionar m variables aleatoriamente a partir de p variables.
 - 5: (II) Elegir la mejor variable/punto de corte entre las m .
 - 6: (III) Dividir el nodo en dos nodos secundarios.
 - 7: **end for**
 - 8: Resultado del ensamblado de árboles $\{T_b\}_1^B$
 - 9: Hacer la predicción en un nuevo punto x :
 - 10: Dejar que $\hat{C}_b(x)$ sea la predicción de la clase del b th árbol del bosque aleatorio. Luego $\hat{C}_r f^B(x) = \text{voto mayoritario } \{\hat{C}_b(x)\}_1^B$.
-

Fue propuesto por Breiman (2001b) y agrega, como se observa en el esquema de la Figura 4.1, que al momento de construir los árboles se definan «cortes binarios» o nodos a partir de un subconjunto de variables aleatorias que representan la mejor partición y no considerando todas las variables como en el caso de los árboles tradicionales CART. Es posible definir como hiperparámetros de calibración la profundidad de los árboles que componen el bosque, así como la cantidad de árboles. Como fue mencionado, el resultado será un promedio de las predicciones para el caso de la regresión, o el voto mayoritario en el caso de la clasificación. La probabilidad de la predicción resultante está dada por la proporción de clasificaciones de cada categoría (Hastie et al., 2001).

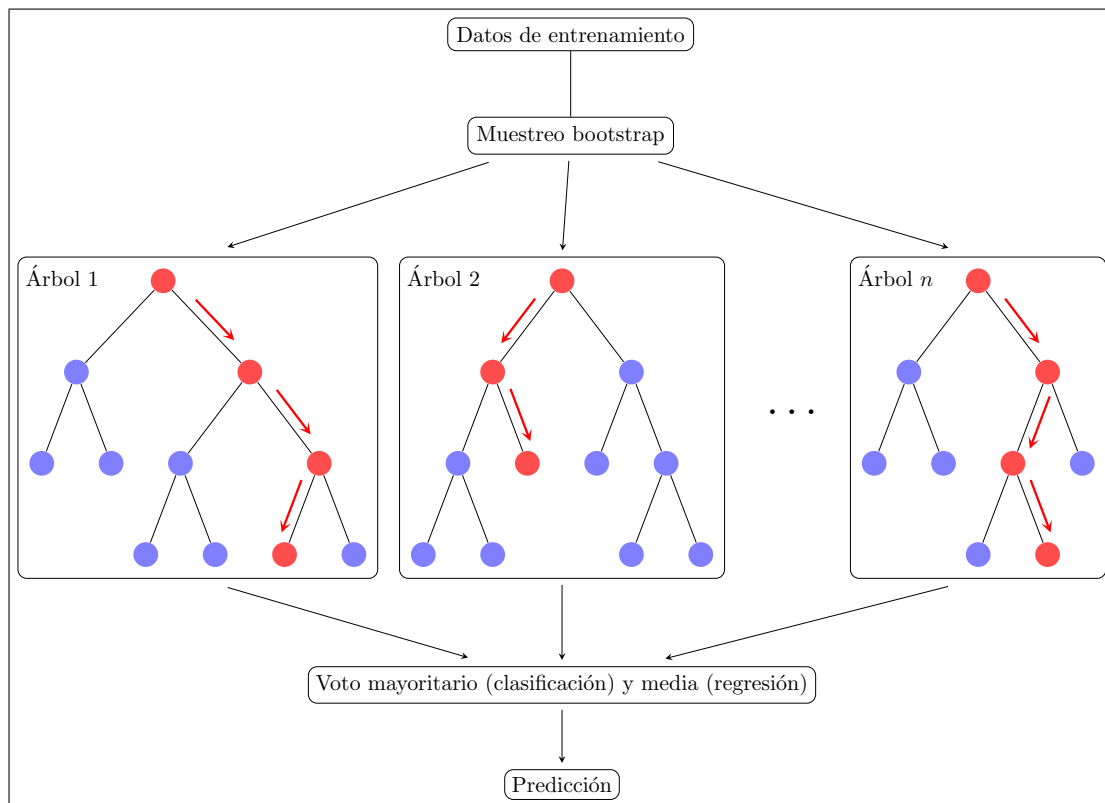


Figura 4.1: Esquema de la estructura del algoritmo Random Forest

Fuente: Elaboración propia con base en Riebesell, J.

La estimación del error del modelo se denomina estimación *out of bag* (OOB) o *fuera de la bolsa*, ya que el muestreo bootstrap en promedio toma en cuenta cerca de dos tercios de los datos, por lo que permite estimar el menor o mayor rendimiento de la predicción a partir de considerar las observaciones que quedaron por fuera en cada iteración. De este mismo modo, también el modelo random forest permite estimar la importancia de la variable observando cuánto aumenta el error de predicción a medida de que van cambiando los datos (OOB) de esa variable, mientras que todas las demás permanecen inalteradas (Breiman, 2001b). La implementación que se utiliza para el entrenamiento del modelo corresponde a la librería [ranger](#) (Wright, 2022).

4.2.3. Stochastic Gradient Boosting

El Gradient Boosting es otro tipo de modelo de ensamble en el que se combinan e *impulsan* modelos con baja capacidad predictiva ya que, como es en el caso de los árboles de decisión, hace que, de forma gradiente, el modelo aprenda de los errores del anterior y mejore el resultado. Es decir que el ajuste es secuencial y el peso de las observaciones va cambiando en cada iteración (Friedman, 2002).

La estrategia para disminuir el error difiere de los métodos de bagging, ya que estos trabajan con base en modelos con bajo sesgo y alta varianza, por lo que mediante la agregación buscan reducir la esta última, como fue mencionado en el caso del Random Forest. En cambio, los modelos de tipo boosting parten de modelos con poca varianza, pero alto sesgo, y el ajuste mediante hiperparámetros está orientado a reducir este último, por lo que el riesgo de sobreajuste es mayor.

En particular, el Stochastic Gradient Boosting es una variante del método general propuesta por Friedman (2002) en la que se agrega la aleatoriedad de las observaciones a la muestra de entrenamiento, al igual que el bagging, pero sin utilizar el muestreo bootstrap. Esto mejora el resultado final y permite estimar el error OOB (Friedman, 2002). La implementación que se utiliza para el entrenamiento del modelo corresponde a la librería *Generalized Boosted Regression Models* o [gbm](#) (Ridgeway, 2020).

4.3. Fuente de datos y consideraciones previas

La fuente de datos utilizada en el presente trabajo es la Encuesta Continua de Hogares (ECH) del Instituto Nacional de Estadística (INE) del año 2018, ya que representa, como fue mencionado en el Capítulo 2, la base para la construcción del ICC a partir de variables que se incluyen en la encuesta. Dicha información es relevada posteriormente en visitas de campo o declaraciones juradas por parte del equipo técnico del Mides, a partir de las cuales se calcula el índice a nivel de hogar y se define la elegibilidad para AFAM-PE. Para llevar a cabo el modelado

se ha trabajado con la base de datos de la ECH 2018 expandida a partir de los ponderadores anuales¹⁸ definidos por el INE según la metodología detallada en la Ficha técnica Encuesta Continua de Hogares 2018.

En lo que respecta a la variable de ingreso, se toma la decisión de utilizar el mismo criterio que se empleó en la construcción original del ICC (Amarante et al., 2008), es decir, considerar el ingreso a precios constantes, excluyendo el valor locativo, alquiler y los montos recibidos por concepto de transferencias AFAM-PE y TUS. A partir de este se construyen los quintiles de ingreso per cápita que servirán de variable dependiente para la estimación de los modelos.

Por último, cabe mencionar que la totalidad del procesamiento de datos fue realizado utilizando el software libre y abierto *R*¹⁹ (R Core Team, 2020) y la interfaz *RStudio* (RStudio Team, 2022)²⁰, empleando la librería *caret*²¹ (Classification And REgression Training) versión 6.0-92 (Max Kuhn, 2022), la cual contiene un conjunto de funciones que buscan hacer más eficiente el diseño e implementación de modelos predictivos. Para las visualizaciones se utiliza el paquete *ggplot2*²² (Wickham, 2016).

¹⁸«(...) la ECH expande a la población proyectada para el año de referencia para cada uno de los departamentos del país, y para la estructura de la población a nivel total país por sexo y cinco tramos de edad (0 a 14 años, 15 a 29 años, 30 a 49 años, 50 a 64 años y 65 años o más)» (INE, 2018).

¹⁹<https://www.R-project.org/>

²⁰<http://www.rstudio.com/>

²¹<https://cran.r-project.org/web/packages/caret/index.html>

²²<https://ggplot2.tidyverse.org>

4.4. Estrategia metodológica

A continuación se detallarán las etapas de la estrategia metodológica a seguir para la construcción y evaluación de los modelos descritos en la fuente de datos seleccionada, siguiendo las etapas que se presentan en el esquema de la Figura 4.2.

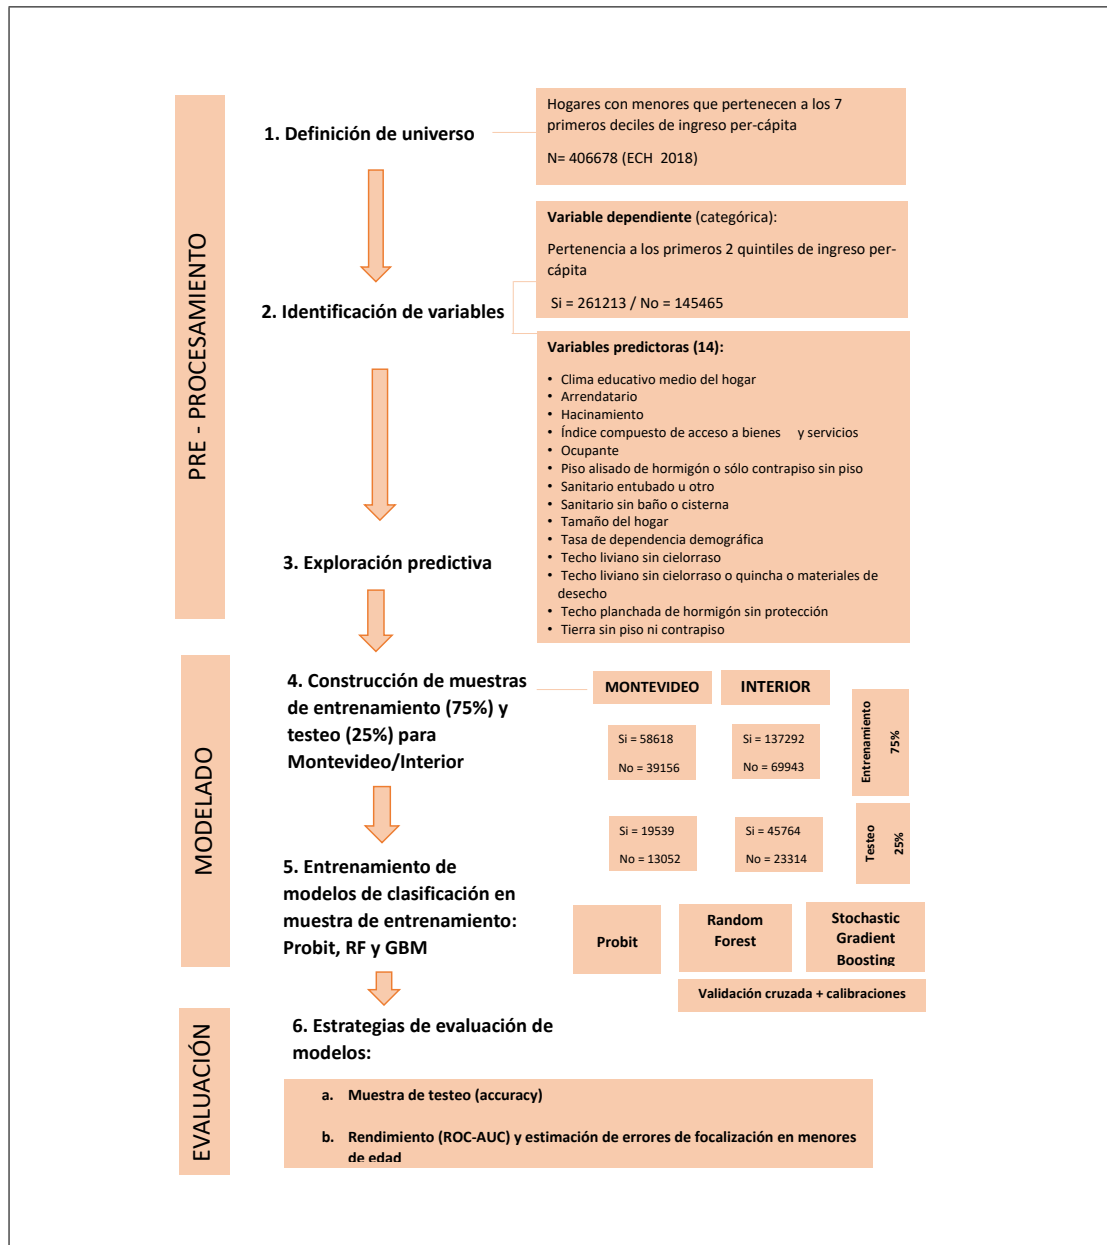


Figura 4.2: Esquema de la estrategia metodológica para la construcción y evaluación de modelos

Fuente: Elaboración propia

4.5. Pre-procesamiento

En primer lugar, como ha sido mencionado, se parte de los microdatos de la ECH 2018 y se opta por seleccionar como universo, en línea con el reciente trabajo de Lavalleja y Tenembaum (2020), los hogares con menores pertenecientes a los primeros siete deciles de ingreso²³.

En lo que refiere a la selección de variables que se utilizarán para entrenar el modelo, se considera como variable dependiente (categórica) la pertenencia a los dos primeros quintiles de ingreso per cápita y como variables predictoras se incluyen las mismas utilizadas por el modelo vigente del ICC (2012) presentado en el Capítulo 2, con una actualización de las variables que componen el Índice compuesto de acceso a bienes durables y servicios²⁴. Así también, al igual que el diseño original del ICC, se construyen modelos diferenciales para Montevideo e interior.

Como primer acercamiento a los datos se realiza una exploración de las variables predictivas a partir de gráficos de mosaico para las variables cualitativas (Figura 4.3) y se encuentra que la que refiere al hacinamiento del hogar y características precarias de techos (liviano o desecho) y pisos (hormigón, contrapiso o tierra) de la vivienda son aquellas que presentan mayor diferencia entre los hogares con menores que pertenecen a los dos primeros quintiles de ingreso per cápita y los que no.

²³Esta definición difiere del modelo probit original que predecía la probabilidad de pertenecer al primer quintil de ingreso, pero tiene ventajas en término de balance de clases y mejoras en la precisión (Lavalleja y Tenembaum, 2020).

²⁴Índice construido a partir de análisis factorial, en el cual se consideran los siguientes bienes: calefón, cable, lavarropas, microondas, computadora y automóvil.



Figura 4.3: Exploración predictiva de variables cualitativas

Fuente: Fuente: Elaboración propia con base en ECH (2018)

Al respecto de las variables cuantitativas²⁵, Figura 4.4, el clima educativo y el Índice compuesto de acceso a bienes durables y servicios son las que presentan distribuciones diferentes entre ambas poblaciones de referencia.

²⁵Las variables cuantitativas fueron agrupadas y factorizadas para optimizar la visualización.

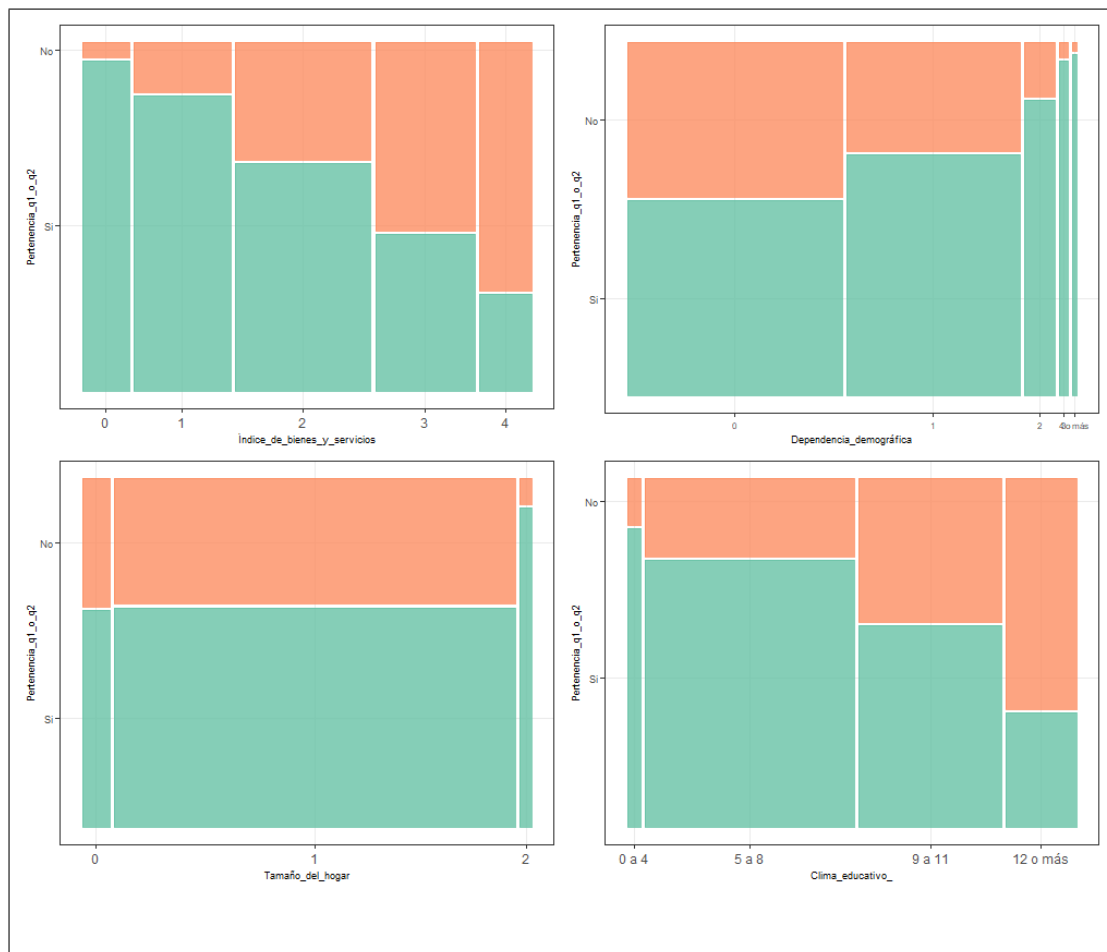


Figura 4.4: Exploración predictiva de variables cuantitativas

Fuente: Elaboración propia con base en ECH (2018)

4.6. Modelado y calibraciones

En segunda instancia se presentan detalles del entrenamiento de los modelos realizados en cada caso, así como de las técnicas aplicadas para lograr calibraciones óptimas de los hiperparámetros.

4.6.1. Probit

Con fines comparativos, se comienza reestimando el modelo Probit a partir del cual se construye el mecanismo vigente para definir la elegibilidad del programa AFAM-PE, el ICC. Para ello, tal como lo realiza el Mides, se estima para los hogares que cuentan con menores de edad de forma separada entre Montevideo y el interior. Con el objetivo de analizar su exactitud fuera de la muestra, al igual que los otros modelos que se ensayarán, se entrena sobre una muestra que abarca el 75 % de los casos, mientras que se evalúa en el restante 25 %.

En el siguiente Gráfico se presentan los estimadores puntuales del modelo en la muestra de entrenamiento tanto para Montevideo como para el interior (ver detalle en Tabla 7.1 del Apéndice). Se observa que las variables con signo negativo, clima educativo medio del hogar y el Índice compuesto de acceso a bienes durables y servicios²⁶, son aquellas que dan cuenta de mejores condiciones del hogar en términos de bienestar, mientras que las que tienen signo positivo indican mayores niveles de vulnerabilidad asociado principalmente a situaciones habitacionales precarias.

²⁶El signo negativo para la variable Servicio sanitario entubado u otro, se debe a los pocos casos que registra dicha categoría.




Figura 4.5: Estimaciones puntuales y SE del modelo Probit Montevideo e interior

Fuente: Elaboración propia con base en ECH 2018 (INE)

4.6.2. Random Forest

La aplicación del modelo Random Forest se realizó sobre una muestra de entrenamiento, considerando una partición de .75, y calibrando los hiperparámetros a partir de validación cruzada (k -fold). Dicha técnica consiste en dividir la muestra de entrenamiento en k subconjuntos que servirán de prueba del modelo y en cada iteración (definida también por el k) se tomarán, por lo tanto, muestras diferentes. Posteriormente, se calculan la exactitud, las precisiones y errores para cada modelo, y se elegirá el que tiene mejor capacidad predictiva y los hiperparámetros asociados.

Los hiperparámetros que fueron calibrados²⁷, considerando un $k=5$, corresponden al número de variables que se utilizarán al dividir cada nodo al construir los árboles ($mtry$) y el *min.node.size* que se asocia con el tamaño mínimo del nodo. Al respecto del número de árboles, se consideran 250 y para las restantes calibraciones se tomaron los valores por defecto. Como se observa en la Figura 4.6, tanto para Montevideo como para el interior, aumenta la exactitud al considerar más variables

²⁷Para entrenar el modelo se ha utilizado la librería ranger combinada con caret. <https://github.com/imbs-hl/ranger>

y mayor tamaño mínimo del nodo. Finalmente, $mtry=8$ y $min.node.size=20$ son los parámetros con los cuales se entrenó el modelo final para ambos casos²⁸.

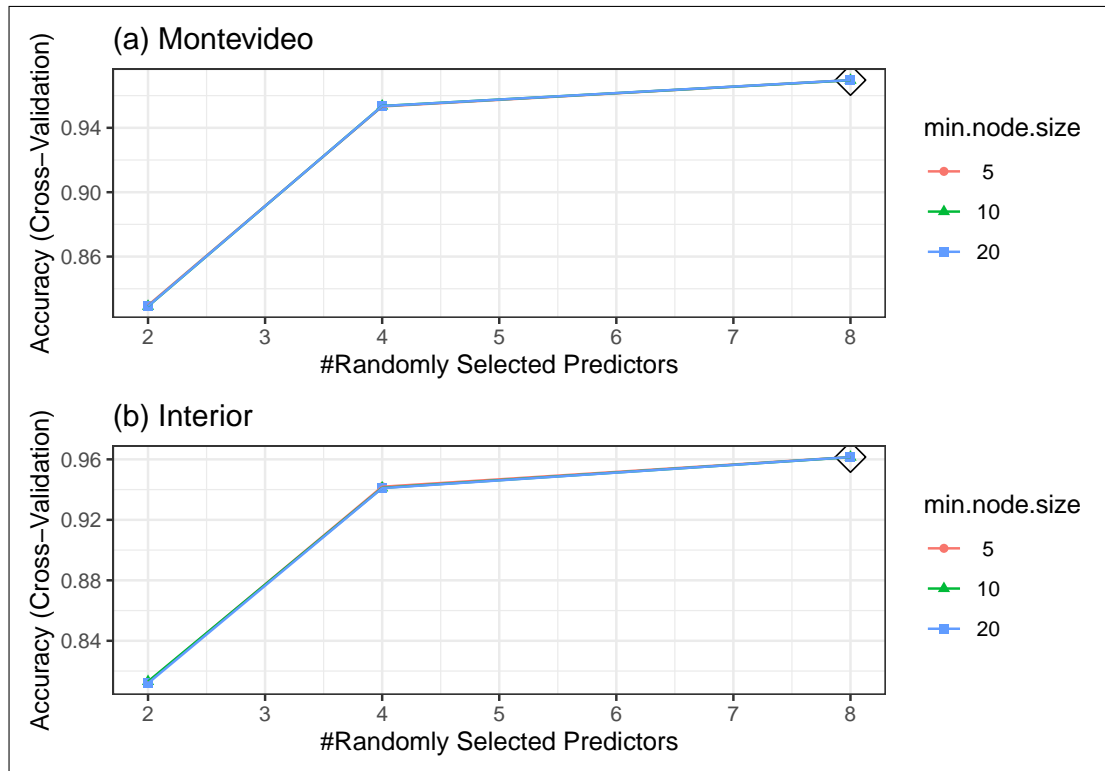


Figura 4.6: Evolución de la exactitud del modelo Random Forest

Fuente: Elaboración propia con base en ECH 2018 (INE)

4.6.3. Stochastic Gradient Boosting

El modelo Gradient Boosting²⁹ fue entrenado utilizando validación cruzada ($k=5$) y evaluando la exactitud a partir de los hiperparámetros *interaction.depth* el cual define la cantidad de divisiones que debe realizar en un árbol a partir de un solo nodo, y el *n.trees*, que se asocia con la cantidad de árboles a entrenar. Se considera, así también, una tasa de aprendizaje o de reducción del error (shrinkage) de forma gradiente, como fue explicado en el apartado anterior, de 0,1, y el número mínimo de observaciones a considerar en cada nodo (*n.minobsinnode*), como 20.

En la Figura 4.7 se observa que la mejor calibración en términos de exactitud,

²⁸Ver Apéndice para más detalles de calibración.

²⁹Para entrenar el modelo se ha utilizado la librería *gbm* combinada con *caret*. <https://github.com/gbm-developers/gbm>

para los dos modelos entrenados, se asocia con $n.trees = 1000$ y $interaction.depth = g^{30}$.

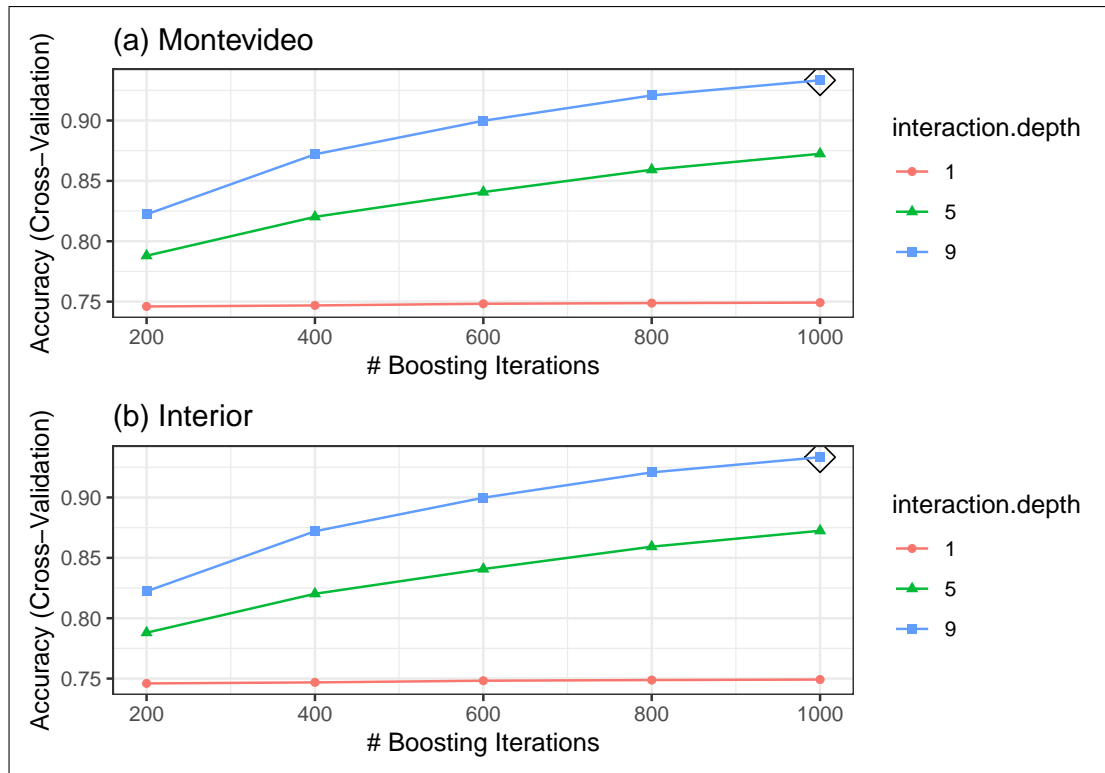


Figura 4.7: Evolución de la exactitud del modelo Gradient Boosting

Fuente: Elaboración propia con base en ECH 2018 (INE)

³⁰Ver Apéndice para más detalles de calibración

4.7. Evaluación de resultados

La estrategia utilizada para evaluar y comparar el desempeño de los tres modelos entrenados cuenta con dos etapas. En primer lugar se analizarán las métricas de exactitud (accuracy) de cada modelo en la muestra de testeo lo cual permite dar cuenta del nivel de acierto de cada uno al clasificar observaciones *nuevas*, es decir, fuera de la muestra en la cual fue entrenado. En segundo lugar, ateniendo al caso de estudio específico, se indagará acerca de la eficiencia de los modelos en clasificar correctamente la pertenencia o no a la población objetivo definida por el programa AFAM-PE. Para ello, se tomará como universo la totalidad de los menores de edad incluidos en le ECH y se compararán métricas y visualizaciones en ese sentido. En esta misma línea también se estimarán los errores de focalización para cada caso considerando umbrales de elegibilidad menos restrictivos que los que define el programa en la actualidad³¹ y de forma proporcional para cada zona geográfica, de modo que la *población elegible* incluya a los quinientos mil menores con menores ingresos per cápita.

4.7.1. Exactitud en muestra de testeo

Existen diversas métricas que dan cuenta del desempeño de los modelos fuera de la muestra de entrenamiento, en este caso presentaremos la exactitud que mide el porcentaje de acierto en la clasificación de cada modelo considerando la matriz de confusión resultante, cuya formula podría expresarse cómo:

$$Exactitud = \frac{VP + VN}{VP + VN + FP + FN} \quad (2)$$

En la Tabla 4.1 se observa como existe una diferencia entre el modelo Probit con

³¹No se consideran los umbrales que se utilizan en la actualidad para definir la población elegible de AFAM-PE ya que se encuentran desactualizados (para 2018 captaron, en términos absolutos, un 85,7% de la población objetivo), por lo que no permitirían la comparación certera entre modelos.

respecto a los modelos RF y GBM en el desempeño predictivo fuera de la muestra tanto para Montevideo como para el interior. En el caso del GBM, presenta mayores diferencias entre ambas regiones, mientras que en el RF tiene un nivel de acierto similar³².

Cuadro 4.1: Exactitud de modelos en muestra de testeo - Montevideo e interior

Modelos	Montevideo	Interior
Probit	74,2 %	75,8 %
RF	96,9 %	96,0 %
GBM	93,5 %	87,5 %

Fuente: Elaboración propia con base en ECH 2018 (INE)

4.7.2. Rendimiento general

El presente apartado tiene como objetivo comparar los resultados obtenidos a partir de la aplicación de los tres modelos estrenados para predecir la probabilidad de pertenencia a los primeros dos quintiles de ingreso per cápita entre los 879856 menores de edad que registra la ECH 2018.

En primer lugar, consideraremos el rendimiento general de los modelos a partir del análisis de las curvas ROC (Características de funcionamiento del receptor) y la métrica AUC (área bajo la curva). Las curvas ROC nos permiten evaluar el balance entre la proporción de *verdaderos positivos* (o sensibilidad) y los *falsos positivos* en las predicciones que realiza un modelo, por lo que una curva en la cual el clasificador se encuentre más cercano a la esquina superior izquierda indica un mejor rendimiento del modelo, es decir mayor proporción de verdaderos positivos y menor de falsos positivos. De esta forma, el área bajo la curva (AUC) refiere a la probabilidad que tiene el modelo de realizar una correcta clasificación, por lo que un valor de AUC correspondiente a 1 indicaría una clasificación perfecta por

³²Ver más detalles en Figuras 7.1, 7.2 y 7.3 del Apéndice

parte del modelo, 0,5 incapacidad de clasificar (aleatorio) y 0 una clasificación inversa.

Como fue mencionado, se presentarán las curvas ROC y métricas AUC en menores de edad considerando dos clases de referencia: la clasificación binaria para la cual fueron entrenados los modelos, pertenecer a los dos primeros quintiles de ingreso; y la pertenencia a la población objetivo definida por el programa. En ambos casos se considerarán las visualizaciones a nivel general y desagregado entre Montevideo e interior.

Quintiles de ingreso

La Figura 4.8 presenta las curvas ROC para los tres modelos ensayados, considerando la pertenencia a los primeros quintiles de ingreso como variable de clasificación. Se observa que el modelo Random Forest es el que presenta mejor rendimiento entre los tres considerados, ubicándose su valor AUC (Tabla 4.2) en 0,994 frente a 0,899 y 0,971 del modelos Probit y GBM respectivamente.




Figura 4.8: Curvas ROC con base en la clasificación de primeros dos quintiles de ingreso - total país

Fuente: Elaboración propia con base en ECH 2018 (INE)

Cuadro 4.2: Métrica AUC con base en la clasificación de primeros dos quintiles de ingreso - total país

Modelos	AUC
Probit	0.899
RF	0.994
GBM	0.971

Fuente: Elaboración propia con base en ECH 2018 (INE)

Al analizar el rendimiento desagregado por región es posible visualizar que, tal como señalaban antecedentes en este sentido (Noriega-Campero et al., 2020),

se observan diferencias en la capacidad predictiva entre ambos grupos para los modelos tradicionales (Probit) frente a los con base en AE, GBM y Random Forest. Este último es el que cuenta, al igual que a nivel país, mejor rendimiento (Tabla 4.3) y diferencias mínimas por región.




Figura 4.9: Curvas ROC con base en la clasificación de primeros dos quintiles de ingreso - Montevideo e interior

Fuente: Elaboración propia con base en ECH 2018 (INE)

Cuadro 4.3: Métrica AUC con base en la clasificación de primeros dos quintiles de ingreso - Montevideo e interior

Modelos	Montevideo	Interior
Probit	0.919	0.881
RF	0.996	0.993
GBM	0.986	0.958

Fuente: Elaboración propia con base en ECH 2018 (INE)

Población objetivo

En segunda instancia se analizaron las mismas visualizaciones y métricas pero considerando como variable de clasificación la pertenencia a la población objetivo, es decir, a los quinientos mil menores que viven en hogares con menores ingresos per cápita. Al igual que en el caso anterior, se observa una ventaja comparativa de los modelos con base en AE con respecto al modelo Probit y, aunque el valor AUC es menor que en el caso anterior, la probabilidad de una clasificación correcta por parte de ambos modelos es elevada (0,977 en RF y 0,959 en GBM).




Figura 4.10: Curvas ROC con base en la clasificación de Población Objetivo - total país

Fuente: Elaboración propia con base en ECH 2018 (INE)

Cuadro 4.4: Métrica AUC con base en la clasificación de Población Objetivo - total país

Modelos	AUC
Probit	0.896
RF	0.977
GBM	0.959

Fuente: Elaboración propia con base en ECH 2018 (INE)

En la misma línea, al desagregar por región, en la Tabla 4.5 se observa, en el caso del modelo Probit, una distancia mayor en las métricas AUC entre Montevideo e interior, registrando menos capacidad predictiva para el segundo caso, y que en los modelos con base en AE el desempeño al predecir la población objetivo es más homogéneo con altos niveles de acierto en las predicciones.

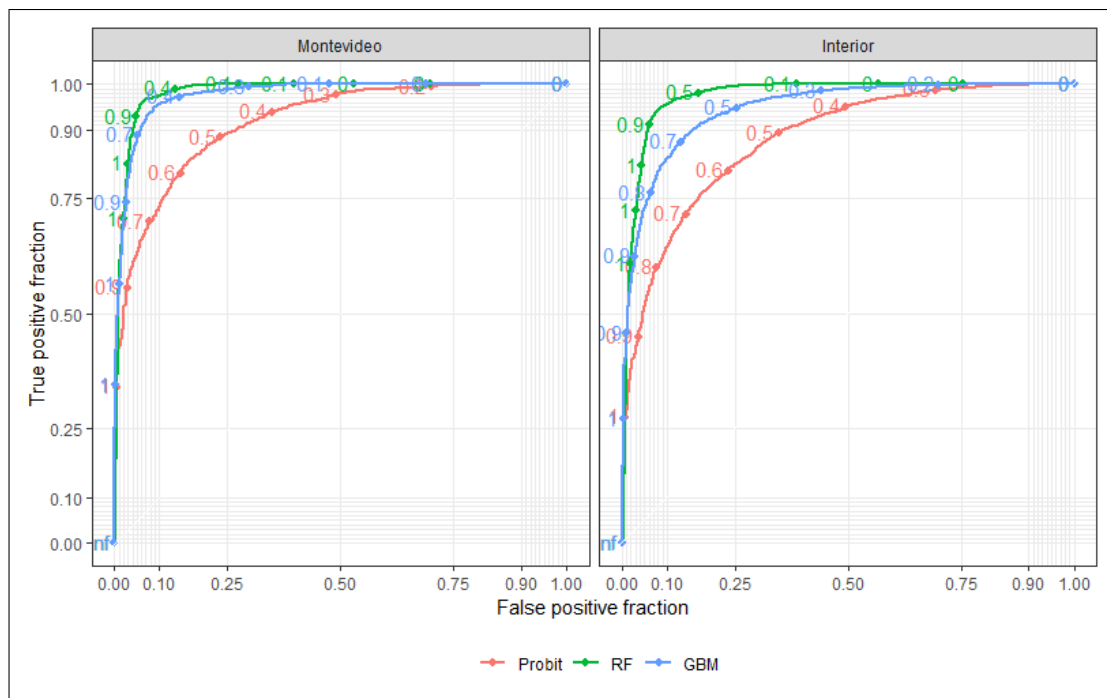


Figura 4.11: Curvas ROC con base en la clasificación de Población Objetivo - Montevideo e interior

Fuente: Elaboración propia con base en ECH 2018 (INE)

Cuadro 4.5: Métrica AUC con base en clasificación de Población Objetivo - Montevideo e interior

Modelos	Montevideo	Interior
Probit	0.917	0.878
RF	0.982	0.973
GBM	0.977	0.945

Fuente: Elaboración propia con base en ECH 2018 (INE)

4.7.3. Estimación de errores de focalización

Luego de probar un mejor rendimiento y exactitud de los modelos construidos a partir de AE, se estimaron los errores de focalización (exclusión e inclusión) de forma comparada entre los tres modelos con el objetivo de dimensionar y cuantificar las mejoras en términos de cobertura. Las estimaciones se realizarán, al igual que en las aplicaciones anteriores, sobre la totalidad de los/as menores de edad.

Como primer paso se identifica la *población elegible* a partir de la estimación de umbrales para cada uno de los modelos de forma de que incluyan a los quinientos mil menores en hogares con menores ingresos per cápita, de forma proporcional a la población de Montevideo e interior. Los umbrales se calculan a partir de la probabilidad de pertenencia a una clase determinada, en este caso pertenecer a los dos primeros quintiles de ingreso, y permitirán evaluar y comparar la eficiencia de los métodos para focalizar la población objetivo en igualdad de condiciones.

En la Tabla 4.6 se muestran los umbrales de elegibilidad resultantes para los tres modelos ensayados.

Cuadro 4.6: Umbrales de elegibilidad - Montevideo e interior

	Montevideo	Interior
Probit	0.5820	0.6096
RF	0.8670	0.7807
GBM	0.6608	0.6425

Fuente: Elaboración propia con base en ECH 2018 (INE)

Luego de identificar la población elegible para cada caso se calcularán ambos tipos de errores comparando con la población objetivo definida por el programa AFAM-PE, lo cual nos permitirá evaluar la eficiencia de cada uno de los modelos como criterio para seleccionar los/as beneficiarios/as.

La reestimación del modelo Probit que se usa para la construcción del ICC, y su comparación con la población objetivo, permite dar cuenta del escenario actual de focalización de AFAM-PE en el caso de que el umbral se fije de tal forma que incluya los quinientos mil menores en hogares con más bajos ingresos. Tal como se presenta en la Tabla 4.7, considerando a los menores de edad, implicaría un nivel de error de 16,7%, tanto de inclusión como de exclusión³³.

³³La magnitud de los errores son iguales, ya que se considera la misma cantidad de menores tanto en la población elegible como en la población objetivo.

Cuadro 4.7: Estimación de errores de focalización de Población Objetivo AFAM-PE - modelo Probit

	No población objetivo	Población objetivo	Total
No elegible	296034	83535	379569
Elegible	83652	416361	500013
Total	379686	499896	879582
Error de exclusión		16,70 %	
Error de inclusión		16,70 %	

Fuente: Elaboración propia con base en ECH 2018 (INE)

Si comparamos los errores del modelo actual con los modelos basados en AE ensayados para el año 2018, Tablas 4.8 y 4.9, se observa una reducción del error de 11,3 puntos porcentuales en el caso del modelo Random Forest, y 7,5 utilizando el Stochastic Gradient Boosting.

En términos de cobertura esto significa, tomando el Random Forest como referencia, ya que representa el modelo con mejor rendimiento, que 56.606 menores que pertenecían a la población objetivo pero que no eran considerados como elegibles en el modelo tradicional del ICC (Probit) pasan a serlo utilizando el modelo con base en AE.

Cuadro 4.8: Estimación de errores de focalización de Población Objetivo AFAM-PE - modelo RF

	No población objetivo	Población objetivo	Total
No elegible	352640	26929	379569
Elegible	26977	473036	500013
Total	379617	499965	879582
Error de exclusion		5,40 %	
Error de inclusión		5,40 %	

Fuente: Elaboración propia con base en ECH 2018 (INE)

Cuadro 4.9: Estimación de errores de focalización de Población Objetivo AFAM-PE - modelo GBM

	No población objetivo	Población objetivo	Total
No elegible	333731	45838	379569
Elegible	45939	454074	500013
Total	379670	499912	879582
Error de exclusion		9,20 %	
Error de inclusión		9,19 %	

Fuente: Elaboración propia con base en ECH 2018 (INE)

4.8. Análisis de importancia de variables

A continuación se cuantificará y visualizará la *importancia* de las variables predictoras en cada uno de los modelos con el objetivo de aportar a su explicabilidad³⁴ y comparar los funcionamientos.

En cada caso la estimación de la importancia difiere según las características de cada modelo, en el Probit se asocia con el valor absoluto del estadístico z estimado para cada parámetro considerado. Para el random forest, tal como fue detallado en apartados anteriores, se vincula con el cálculo del error OOB que permite estimar su incremento en cada iteración y definir la importancia de las variables en función de su inclusión (o no) en las diferentes muestras. En el gradient boosting se asocia con la reducción promedio de los errores al usar las diferentes variables para la construcción de los árboles y sus nodos o divisiones.

Siguiendo los conceptos precedentes, en la Figura 4.12 se presentan las estimaciones de la importancia de las diferentes variables predictoras para cada uno de los modelos, distinguiendo entre Montevideo e interior.

Se observa que las primeras cuatro variables son las mismas en términos de importancia para los tres modelos considerados, mientras que en aquellos con base en AE los restantes predictores tienen una menor importancia relativa si se lo compara con el modelo de regresión. Esto se encuentra en línea de lo hallado en la exploración de las variables predictivas inicial, en las cuales el Índice compuesto de acceso a bienes durables y servicios, el clima educativo medio del hogar y el hacinamiento eran las que registraban mayores diferencias entre los hogares que pertenecen a los dos primeros quintiles de ingreso per cápita y aquellos que no.

³⁴Otras técnicas vinculadas al aprendizaje estadístico interpretable que podría aplicarse con el objetivo de aportar a la explicabilidad de los modelos ensayados, ese es el caso de Partial Dependence Plot (PDP).

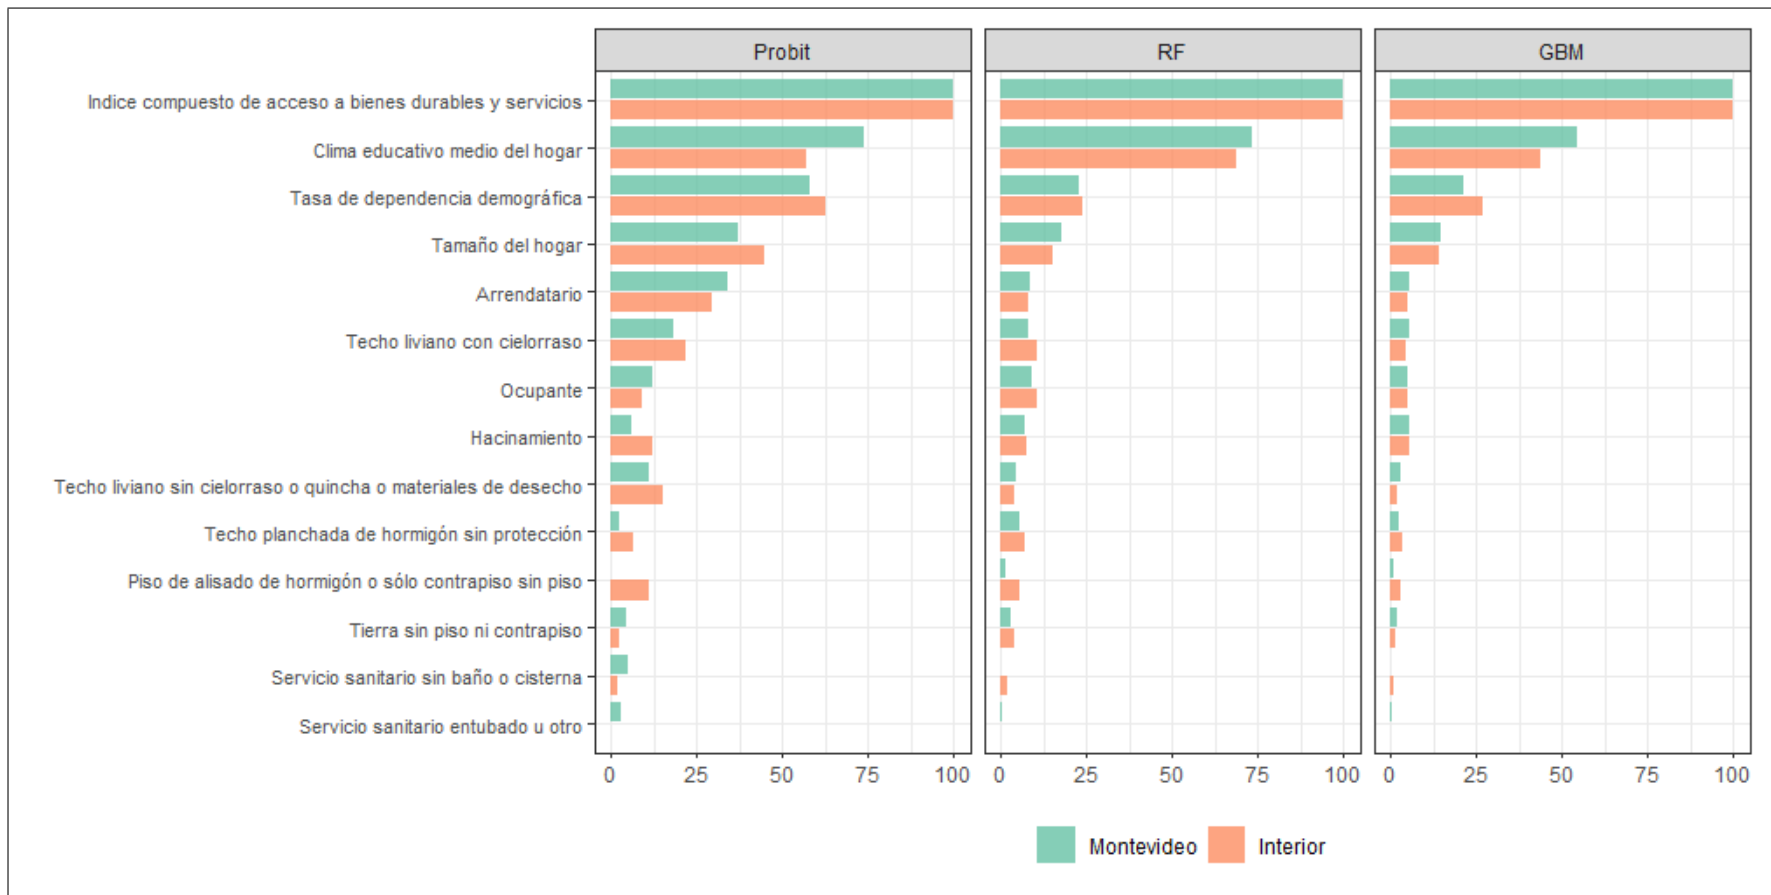


Figura 4.12: Importancia de variables predictoras en Probit, RF y GBM - Montevideo e interior

Fuente: Elaboración propia con base en ECH 2018 (INE)

4.9. Análisis exploratorio de diseños alternativos

Como último ensayo se ha realizado un análisis exploratorio de diseños alternativos en la construcción de los modelos incluyendo nuevas variables predictoras y no solo aquellas que son incluidas en el ICC en su versión actual como se ha hecho hasta el momento.

En primera instancia, se ha entrenado un modelo random forest considerando que es el que ha demostrado mejor rendimiento y, al igual que las pruebas ejecutadas hasta el momento, se predice la pertenencia a los dos primeros quintiles de ingreso en un universo de personas que pertenecen a los siete deciles de ingreso. En su construcción, se han utilizado sesenta y nueve variables predictoras incluidas en la ECH a nivel de hogar, y se ha realizado validación cruzada para la calibración de hiperparámetros, entrenando modelos diferenciales para Montevideo e interior.

Luego de su aplicación, el objetivo es comparar el rendimiento general del modelo fuera de la muestra de entrenamiento e indagar la importancia de las variables teniendo en cuenta, como fue presentado en apartados anteriores, la ventaja que tienen los modelos de AE en el tratamiento de datos de alta dimensionalidad.

La evaluación del modelo fuera de la muestra, a partir del análisis de las matrices de confusión, indica una exactitud casi perfecta de 99 % para ambas regiones (ver Figura 7.4 en Apéndice), lo cual se explica por el elevado número de variables utilizadas para entrenar el modelo. Si se analiza la importancia de las veinte variables consideradas con mayor valor (Figura 4.13) es posible visualizar que los bienes de confort y servicios, algunos de ellos incluidos en el Índice compuesto de acceso a bienes durables y servicios que forma parte del ICC, y la composición del hogar son los que tienen más relevancia en el modelo.




Figura 4.13: Importancia de variables predictoras modelo exploratorio Random Forest (N=20) - Montevideo e interior

Fuente: Elaboración propia con base en ECH 2018 (INE)

A partir de la identificación de las veinte variables con mayor importancia, se entrena un modelo reducido con las mismas características, pero incluyendo únicamente dichos predictores. Las métricas de evaluación fuera de la muestra para Montevideo indican una exactitud de 98 % y 97 % para el interior (Figura 7.5 en Apéndice). Si nos remitimos a la métrica AUC, tal cómo se observa en la Figura 4.14, el valor es de 99 % en ambos casos.

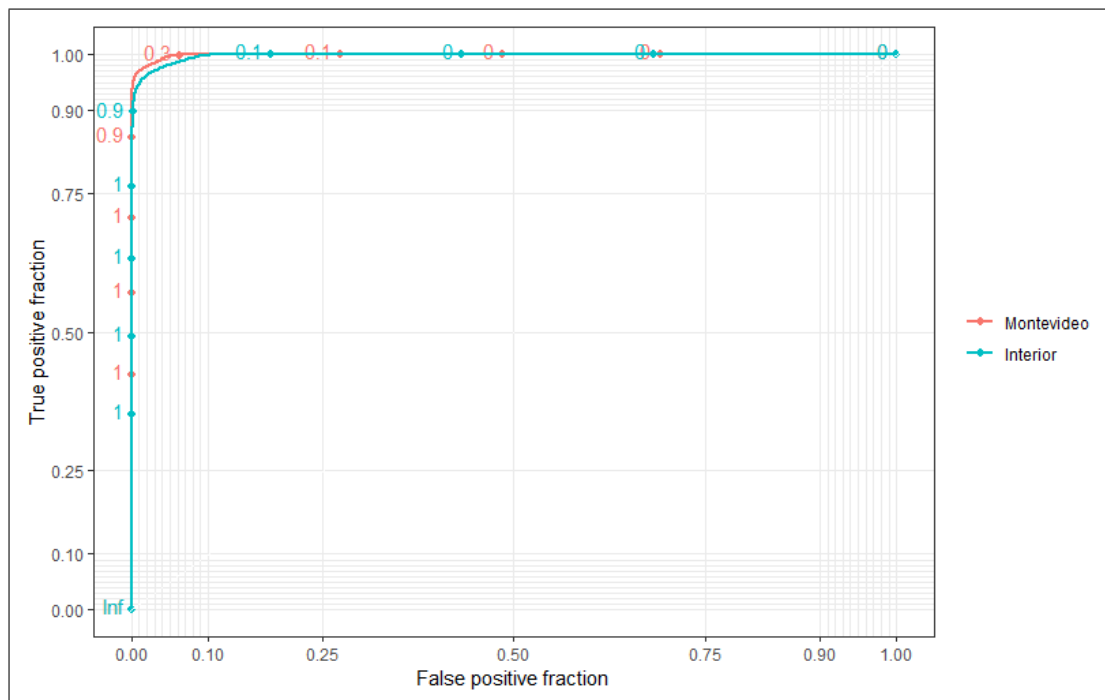


Figura 4.14: Curvas ROC con base en la clasificación RF de modelo reducido - Montevideo e interior

Fuente: Elaboración propia con base en ECH 2018 (INE)

Los resultados asociados al análisis exploratorio realizado nos indican que el rendimiento de los modelos con base en las métricas presentadas, es levemente superior utilizando variables alternativas a las incluidas en la herramienta de selección de beneficiarios/as que toma como referencia el programa AFAM-PE. En consecuencia, al respecto de la forma de construcción de los modelos con base en AE, la utilización de índices agregados, como lo es el que da cuenta del acceso a bienes durables y servicios, no tendría ventajas comparativas con respecto a la integración de dichas variables de forma unitaria.

5. Conclusiones

En las última décadas en América Latina los PTC se consolidan como el principal instrumento no contributivo de un sistema de protección social que se concibe más amplio, y en el cual se registra un creciente debilitamiento de los mecanismos de aseguramiento tradicionales vinculados al empleo formal. La proliferación de este tipo de programas tendientes a atacar situaciones de pobreza de los hogares ha implicado ciertas definiciones en términos de diseño y asignación de recursos, que adquieren particularidades según el país en el que se ejecutan. En particular, los tipos de transferencias monetarias orientadas a la demanda, aunque conviven con otro tipos de transferencias, se plantean como objetivo principal el de aumentar el capital humano de niños, niñas y adolescentes, y por ello conciben como unidad de intervención las familias u hogares, definiendo condicionalidades en consonancia con dicho cometido.

Como fue planteado a lo largo del trabajo, los mecanismos de focalización que definen los diferentes PTC en la región buscan un tipo de asignación eficiente de los recursos limitados a partir del establecimiento de ciertos criterios de elegibilidad de beneficiarios/as en diálogo con la definición de población objetivo inicial. En este marco, la comprobación sustitutiva de los medios de vida es el método actual más extendido en la región para seleccionar los/as beneficiarios/as, y se implementa a partir de relevamientos sistemáticos de información sobre las características y condiciones de los hogares para aproximar y predecir su ingreso y, en consecuencia, construir índices de vulnerabilidad/bienestar que definirán su inclusión o no en el PTC. Dentro de los programas que utilizan este tipo de focalización para seleccionar a sus beneficiarios/as se encuentran el PTC AFAM-PE, en Uruguay, y Avancemos en Costa Rica, utilizando técnicas econométricas para el diseño de índices (ICC y SIPO respectivamente) a partir de los cuales se definan umbrales de elegibilidad. Su consideración y estudio desde una perspectiva comparada, como se ha planteado en el presente trabajo, ha intentado dar cuenta de una matriz común

en el diseño de los PTC que, como fue detallado, encuentra múltiples puntos en común, así como también halla coincidencias en la elección de los mecanismos utilizados para focalizar su población objetivo. No obstante, el dimensionamiento de los errores de focalización, subcobertura y filtración, cuando se contrasta la captación y cobertura efectiva con la población objetivo en las Encuestas Continuas respectivas (ECH y Enaho), arroja diferencias significativas. Según los autores referidos en el estudio, mientras que en el caso de AFAM-PE se registran niveles comparativamente bajos de filtración (10 %) y más elevados de subcobertura (39 %), tomando como referencia la población objetivo, los errores que indican las estimaciones en el caso de Avancemos ascienden a 58,9 % de inclusión y 56,3 % de exclusión con relación a la línea de pobreza. Al analizar las posibles causas, como se desprende de la sistematización realizada acerca de los procesos de implementación de las prestaciones, en ambos casos existen problemas de desactualización de los criterios de elegibilidad y de la fijación de umbrales, lo cual se suma a la dificultad de contar con información al día de los hogares beneficiarios o pasibles de serlo. Así también, en el caso del programa Avancemos de Costa Rica existen criterios de priorización que consideran umbrales diferenciales según subgrupos, así como decisiones de implementación puntuales que han repercutido en los problemas de focalización observados. Esta constatación se encuentra en línea con el planteo de Coady et al. (2004) al respecto, quienes asociaban los buenos desempeños de los mecanismos de focalización principalmente a la *eficacia de la implementación* y gestiones administrativas y, en un plano secundario, a los métodos y modelos utilizados.

Por su parte, otro enfoque a explorar tendiente a reducir los problemas de focalización hallados, el cual constituye el eje central del trabajo, se ha vinculado a la exploración y aplicación de modelos con base en AE. De este modo, con base en los antecedentes al respecto, se ha trabajado sobre la hipótesis de que los diseños de los algoritmos de aprendizaje estadístico logran captar relaciones y patrones complejos y no lineales, lo cual resulta en mejores desempeños y

capacidad predictiva. Para ello, se han tomado como referencia ensayos realizados para el caso del programa Avancemos en Costa Rica y, desde una perspectiva comparada, se realizan pruebas para el caso de AFAM-PE de Uruguay. Tal como fue presentado, estas resultan concluyentes en las ventajas en términos de acierto y exactitud con respecto a los métodos utilizados en la actualidad por parte del Mides para la construcción del ICC, siendo el Random Forest el modelo que mejores resultados presenta.

Tal como fue trabajado, la aplicación de este tipo de modelos con base en AE e IA, abre un actual e importante debate sobre la ética de su implementación y uso en la toma de decisiones en el ámbito público. Las condiciones necesarias para su utilización implican, en primer término, el trabajo sobre la explicabilidad de los modelos, tanto en lo que refiere a la comprensión del diseño y arquitectura de los algoritmos que subyacen, así como a la exploración de la relevancia de las dimensiones y variables que los integran. Al respecto de este segundo elemento, el análisis de los estadísticos de importancia de las variables predictoras realizado y presentado en el trabajo busca aportar en este sentido, bajo el entendido de que debe necesariamente complementarse, tal como fue concebido al momento de diseñar el ICC, con conocimiento teórico y experto que sustente dichas elecciones. De este modo, las ventajas en el manejo de datos de alta dimensión y mejoras en las predicciones que han demostrado los modelos con base en AE con respecto a los tradicionales, permiten una mayor flexibilidad en el diseño y elección de variables a incluir en los métodos e índices que intenten dar cuenta de una dimensión más amplia como es el caso de la vulnerabilidad y el ICC.

Al respecto de los resultados hallados vinculados a los rendimientos de los modelos con base en AE en las métricas fuera de la muestra y ganancias en términos de cobertura al lograr un método de focalización más preciso, en la línea de lo que sostienen trabajos que plantean ensayos similares, existe un aporte en términos de equidad y eficiencia en la asignación de recursos aún considerando los mismos costos administrativos con relación al relevamiento de información

y tiempo de cómputo de los modelos sobre los datos existentes. Así también, cabe aclarar que las decisiones tomadas en el estudio realizado acerca de las calibraciones de parámetros en los modelos a partir de la aplicación de validación cruzada, y evaluación posterior de rendimientos, puede ser trabajado utilizando combinatorias más complejas, encontrando un balance entre rendimiento y tiempos computacionales óptimos.

Como desafíos pendientes, y posibles ensayos futuros, se encuentra la posibilidad de centrar el análisis en las diferencias en los errores de exclusión e inclusión en subgrupos poblacionales. Más allá de que el trabajo en el caso de Uruguay se segmenta entre dos grandes regiones del país, Montevideo e interior, podría resultar interesante, tal como lo realiza Noriega-Campero et al. (2020) para los casos de Colombia y Costa Rica, analizar las diferencias considerando otras dimensiones de interés como el tamaño del hogar, género del jefe/a o pertenencia a zona urbana/rural. Los resultados de estos análisis podrían dar cuenta de la necesidad, o no, de considerar de forma diferencial a dichas poblaciones, por ejemplo en lo que respecta a los umbrales de elegibilidad o la priorización en términos de cupos en el diseño de los PTC.

Otra de las exploraciones posibles, tomando como referencia lo realizado en el presente trabajo, se asocia con la replicación de los procesamientos para un rango temporal mayor, considerando varios años de referencia, con el objetivo de analizar la estabilidad de las predicciones, incluso en momentos con diferencias significativas en los indicadores socioeconómicos más importantes. Esto aportará en términos de solidez de los modelos elegidos.

Por último, a modo de reflexión final, cabe mencionar que el trabajo tuvo la intención de aportar evidencia acerca de la ventaja comparativa de la aplicación de modelos de aprendizaje estadístico como mecanismo de focalización en los PTC a partir del estado de situación y diseño actual de estos. No obstante, las discusiones de implementación que se desprenden deben ser analizadas detalladamente a la luz de las discusiones conceptuales sobre los fenómenos de pobreza, así como

involucrando las dimensiones éticas que garanticen la transparencia en los procesos que buscan impactar sobre poblaciones con altos niveles de vulnerabilidad.

6. Bibliografía

- Abramovich, V(2006). Una aproximación al enfoque de derechos en las estrategias y políticas de desarrollo, Revista de la Cepal, N° 88 (LC/G.2289-P), Santiago, Comisión Económica para América Latina y el Caribe (Cepal), abril de 2006, pág. 36.
- Alfonso Costa (2019). Análisis de los emprendimientos de IA en Latinoamérica. En: <https://pochocosta.com/podcast/analisis-de-los-emprendimientos-de-ia-en-latinoamerica/>
- Amat Rodrigo, J. (2002). Gradient Boosting con Python. En: https://www.cienciadedatos.net/documentos/py09_gradient_boosting_python.html
- Atuesta, B. y Cecchini, S. (2017). Programas de transferencias condicionadas en América Latina y el Caribe. Tendencias de cobertura e inversión. CEPAL - Serie Políticas Sociales N° 224.
- Benavides, B., Solano, J, y Soto, P. (2012). Ficha de Información Social (FIS) Manual de Aplicación. Sistemas de Información e Investigación Social, Subgerencia de Desarrollo Social, Instituto Mixto de Ayuda Social.
- Breiman, L. (2001b). Statistical modeling: The two cultures (with comments and a rejoinder by the author). *Statistical Science*, 16(3), 199-231.
- Brady, D. y Bostic, A. (2015). Paradoxes of Social Policy: Welfare Transfers, Relative Poverty, and Redistribution Preferences. *EconStor Open Access Articles and Book Chapters*, ZBW - Leibniz Information Centre for Economics, pages 268-298.
- Cabrol, M., González, N., Pombo, C., y Sánchez, R. (2020). Adopción y ética y responsable de la inteligencia artificial en América Latina y el Caribe. Nota Técnica del BID.

- Casal, R., Bouzas, J., y Ovideo, M. Aprendizaje Estadístico. En: https://rubenfcasal.github.io/aprendizaje_estadistico/
- Cecchini, S., y Villatoro, P. (2018). ¿Cuál es el alcance de las transferencias no contributivas en América Latina? Discrepancias entre encuestas y registros. CEPAL - Serie Estudios Estadísticos Nro 96.
- Cecchini, S., Filgueira, F., y Robles, C. (2014). Sistemas de protección social en América Latina y el Caribe. Una perspectiva comparada, serie Políticas Sociales, N° 202 (LC/L.3856), Santiago, Comisión Económica para América Latina y el Caribe (Cepal).
- Cecchini, S., y Madariaga, A. (2011). Programas de transferencias condicionadas. Balance de la experiencia reciente en América Latina y el Caribe, Cuadernos de la CEPAL, N°. 95 (LC/G.2497-P), Santiago de Chile, Comisión Económica para América Latina y el Caribe (Cepal).
- Cecchini, S., y Martínez, R. (2011). Protección social inclusiva en América Latina: una mirada integral, un enfoque de derechos, Libros de la CEPAL, N° 111 (LC/G.2488-P), Santiago, Comisión Económica para América Latina y el Caribe (Cepal).
- Contraloría General de la República (2008). Informe sobre el Diseño y Ejecución del programa de transferencia monetaria condicionada denominado Avancemos. San José, Costa Rica: Contraloría General de la República (2008). División de Fiscalización Operativa y Evaluativa, Área de Servicios Sociales. Informe No. DFOE-SOC-17-2008.
- Colafranceschi, M., y Vigorito, A. (2013). Uruguay: evaluación de las políticas de transferencias. La estrategia de inclusión y sus desafíos, Hacia un Uruguay más equitativo: Los desafíos del sistema de protección social, R. Rofman (ed.), Montevideo, Banco Mundial.

- Coady, D., Grosh, M., y Hoddinott, J. (2004). La focalización de las transferencias en los países en desarrollo: Revisión de lecciones y experiencias. Banco Mundial.
- Cookson, T. (2018). *Unjust Conditions Women's Work and the Hidden Cost of Cash Transfer Programs*. University of California Press.
- Delgado Jiménez, F. (2017). Efectividad en la selección de beneficiarios de los programas avancemos y bienestar familiar. *Economía y Sociedad*, Vol. 22, Nro 52 Julio-diciembre 2017, pp. 1-25
- Doshi-Velez, F., y Kim, B. (2017). Towards a rigorous science of interpretable machine learning. no. MI: 1–13. <http://arxiv.org/abs/1702.08608>.
- García Valverde, F. (2017) Responsabilidad y legitimidad en las transferencias monetarias condicionadas. *Diánoia* [online]. 2017, vol.62, n.79, pp.193-216. ISSN 0185-2450.
- Failache, E., Giacobasso, M., y Ramírez, L. (2016). Transferencias de ingresos y mercado de trabajo: El impacto de Asignaciones Familiares Plan de Equidad sobre la informalidad laboral. Serie Documentos de investigación estudiantil, DIE 01/2016. Instituto de Economía, Facultad de Ciencias Económicas y Administración, Universidad de la República, Uruguay.
- Giletta, M., Giordano, A., Mercaú, N., Orden, P., & Villarreal, V. (2020). Inteligencia Artificial: definiciones en disputa. *Sociales Investiga*, (9), 20–33.
- Gujarati, D., y Porter, D. (2010). *Econometría*. México: Mc Graw Hill
- Gómez Mont, C., Del Pozo, C., Martínez Pinto, C., y Martín del Campo, A. (2020). La inteligencia artificial al servicio del bien social en América Latina y el Caribe: Panorámica regional e instantáneas de doce países.

- Hastie, T., Friedman, J., y Tibshirani, R. (2001). *The Elements of Statistical Learning*. Nueva York, Estados Unidos: Springer New York. DOI: 10.1007/978-0-387-21606-5
- Hanlon, J., Barrientos, A., y Hulme, D. (2010). *Just Give Money to the Poor: The Development Revolution from the Global South*. Sterling, VA, USA: Kumarian.
- Hernández Romero, K. (2016). *¿Cómo funciona Avancemos? Mejores prácticas en la implementación de programas de transferencias monetarias condicionadas en América Latina y el Caribe*. Interamerican Development Bank.
- Ibarrarán, P., Medellín, N., Regalia, F., y Stampini, M. (2017). *Así funcionan las transferencias condicionadas. Buenas prácticas a 20 años de implementación*. Banco Interamericano de Desarrollo.
- Instituto Nacional de Estadística (2018). *Ficha Técnica Encuesta Continua de Hogares 2018*. Montevideo, Uruguay
- Jacques, O., y Noël, A. (2018) *The Case for Welfare State Universalism, or the Lasting Relevance of the Paradox of Redistribution*, *Journal of European Social Policy* 28(1): 70–85.
- Korpi, W., y Palme, J. (1998). *The Paradox of Redistribution and Strategies of Equality: Welfare State Institutions, Inequality, and Poverty in the Western Countries*. Vol. 63, No. 5, pp. 661-687. *American Sociological Association*.
- Mides (2019). *Captación de Asignaciones Familiares del Plan de Equidad (AFAM-PE) en las Encuestas Continuas de Hogares*. Documento de trabajo. Daes-Dinem-Mides

- Mides (2018). ICC y pobreza monetaria. En serie de documentos *Aportes a la conceptualización de la pobreza y la focalización de las políticas sociales en Uruguay*. Daes-Desytc-Dinem-Mides.
- Mides (2017-2018). Informe Mides 2017-2018. Seguimiento y evaluación de actividades y Programas. Dinem-Mides.
- Mides (2014). ¿Qué es el Índice de Carencias Críticas? En serie de documentos *Aportes a la conceptualización de la pobreza y la focalización de las políticas sociales en Uruguay*. Daes-Desytc-Dinem-Mides.
- Minujín, A., Davidziuk, A., y Delamónica, E. (2007). El boom de las transferencias de dinero sujetas a condiciones. ¿De qué manera estos programas sociales benefician a los niños y niñas latinoamericanos? *Salud Colectiva*, vol. 3, no. 2, mayo-agosto, pp. 121-131. Universidad Nacional de Lanús. Buenos Aires, Argentina.
- Molyneux, M. (2009). Conditional Cash Transfers. A Pathway to women's empowerment. Pathway Working Paper 5. Institute of Development Studies, Brighton.
- Mordecki, G., García, S., Leiva, A., Miranda R., y Rodríguez, S. (2015). Crisis, recuperación y auge: 15 Años de política económica en Uruguay (2000-2014). Instituto de Economía, FCEA (Udelar)
- Noriega-Campero, A., Bernardo Garcia-Bulle, L. F., Cantu, M., Bakker, L., Tejerina, A., Pentland, (2020). Algorithmic Targeting of Social Policies: Fairness, Accuracy, and Distributed Governance. FAT* '20: Conference on Fairness, Accountability, and Transparency
- Layton, M. (2020). Welfare Stereotypes and Conditional Cash Transfer Programmes: Evidence from Brazil's Bolsa Família. *Journal of Politics in Latin America* 12(1):53-76

- Lavalleja, M., y Tenenbaum, V. (2020). Mecanismos de focalización de los programas de transferencias monetarias en América Latina: el caso del Uruguay, serie Estudios y Perspectivas-Oficina de la CEPAL en Montevideo, Nro 43 (LC/TS.2020/9-LC/MVD/TS.2019/6), Santiago, Comisión Económica para América Latina y el Caribe (CEPAL).
- Lavalleja, M., Mathieu, G., Messina, P. (2012). Evaluación de mecanismos de selección de los beneficiarios de las asignaciones familiares- Plan de equidad. Monografía de grado, Universidad de la República (Uruguay). Facultad de Ciencias Económicas y de Administración.
- R Core Team (2020). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL: <https://www.R-project.org/>.
- Ramírez, F., Villegas, G., y Pacheco, C. (2006). Informe: Actualización y desarrollo del Modelo Estadístico para el cálculo del Puntaje: Construcción del Modelo SIPO-2005. San José, Costa Rica: Eje Sistemas de Información para la Acción Social, Subgerencia de Desarrollo Social, Instituto Mixto de Ayuda Social (IMAS). Consultora: Comercio y Desarrollo SA Mimeografiado.
- Reisman, D., Schultz, J., Crawford, K., y Whittaker, M. (2018). Algorithmic impact assessments: a practical framework for public agency accountability. AI NOW.
- Román Vega, I. (2012). Sistemas de Protección Social en América Latina y el Caribe: Costa Rica. Colección Documentos de Proyecto, LC/W. 509, Cepal, Santiago de Chile.
- Ridgeway, G. (2020). Generalized Boosted Models: A guide to the gbm package. En: <https://cran.r-project.org/web/packages/gbm/vignettes/gbm.pdf>

- Trejos, J., y Sáenz, M. (2007). La selección de los beneficiarios para los programas contra la pobreza: la experiencia del IMAS. En: Economía y Sociedad. Nro. 31 y 32, pp. 79-100.
- Víquez, R. (2005). Sistema de Identificación de la Población Objetivo: SIPO en Costa Rica (Serie de Documentos de Discusión sobre la Protección Social No. 530).
- Wickham, H. (2016). ggplot2: Elegant Graphics for Data Analysis. Springer-Verlag New York. ISBN 978-3-319-24277-4, <https://ggplot2.tidyverse.org>.
- Wright, M. N. y Ziegler, A. (2017). ranger: A fast implementation of random forests for high dimensional data in C++ and R. J Stat Softw 77:1-17. <https://doi.org/10.18637/jss.v077.i01>.

7. Apéndice

a. Probit

Cuadro 7.1: Estimaciones del modelo Probit - Montevideo e Interior

	Montevideo		Interior	
	Estimate	Std. Error	Estimate	Std. Error
(Intercept)	1.395	0.034	0.760	0.023
Clima educativo medio del hogar	-0.120	0.002	-0.093	0.001
Hacinamiento	0.094	0.013	0.166	0.009
Arrendatario	0.334	0.012	0.331	0.009
Ocupante	0.146	0.012	0.113	0.008
Servicio sanitario sin baño o cisterna	0.264	0.041	0.144	0.020
Servicio sanitario entubado u otro	-0.240	0.047	-0.248	0.049
Índice compuesto de acceso a bienes durables y servicios	-0.482	0.006	-0.434	0.004
Tamaño del hogar	0.540	0.017	0.639	0.012
Techo planchada de hormigón sin protección	0.079	0.017	0.135	0.011
Techo liviano con cielorraso	0.210	0.013	0.227	0.008
Techo liviano sin cielorraso o quinchas o materiales de desecho	0.236	0.021	0.322	0.015
Piso de alisado de hormigón o solo contrapiso sin piso	0.071	0.026	0.200	0.012
Tierra sin piso ni contrapiso	0.135	0.022	0.119	0.015
Tasa de dependencia demográfica	0.479	0.010	0.510	0.007

Fuente: Elaboración propia con base en ECH 2018 (INE)

Confusion Matrix and Statistics			Confusion Matrix and Statistics		
Prediction	Reference		Prediction	Reference	
	No	Si		No	Si
No	8755	4110	No	13041	6443
Si	4297	15429	Si	10273	39321
Accuracy : 0.742 95% CI : (0.7373, 0.7468) No Information Rate : 0.5995 P-Value [Acc > NIR] : <2e-16			Accuracy : 0.758 95% CI : (0.7548, 0.7612) No Information Rate : 0.6625 P-Value [Acc > NIR] : < 2.2e-16		
Kappa : 0.4615			Kappa : 0.4362		
Mcnemar's Test P-Value : 0.0425			Mcnemar's Test P-Value : < 2.2e-16		
Sensitivity : 0.6708 Specificity : 0.7897 Pos Pred Value : 0.6805 Neg Pred Value : 0.7822 Prevalence : 0.4005 Detection Rate : 0.2686 Detection Prevalence : 0.3947 Balanced Accuracy : 0.7302			Sensitivity : 0.5594 Specificity : 0.8592 Pos Pred Value : 0.6693 Neg Pred Value : 0.7929 Prevalence : 0.3375 Detection Rate : 0.1888 Detection Prevalence : 0.2821 Balanced Accuracy : 0.7093		
'Positive' Class : No			'Positive' Class : No		

Figura 7.1: Matriz de confusión y métricas de modelo GBM fuera de la muestra - Montevideo e interior

b. Random Forest

Cuadro 7.2: Resultados calibración modelo RF - Montevideo

mtry	splitrule	min.node.size	Accuracy	Kappa	AccuracySD	KappaSD
2	gini	5	0.8296889	0.6436123	0.0042405	0.0092551
2	gini	10	0.8290957	0.6416686	0.0043049	0.0088315
2	gini	20	0.8291775	0.6420972	0.0026057	0.0056256
4	gini	5	0.9532698	0.9036995	0.0016097	0.0033053
4	gini	10	0.9535562	0.9042801	0.0019994	0.0041078
4	gini	20	0.9535357	0.9042083	0.0020759	0.0043117
8	gini	5	0.9696136	0.9369420	0.0003640	0.0007121
8	gini	10	0.9695420	0.9368048	0.0004926	0.0009936
8	gini	20	0.9696443	0.9370218	0.0003871	0.0007722

Cuadro 7.3: Resultados calibración modelo RF - Interior

mtry	splitrule	min.node.size	Accuracy	Kappa	AccuracySD	KappaSD
2	gini	5	0.8127054	0.5581146	0.0026890	0.0074298
2	gini	10	0.8131059	0.5598971	0.0031361	0.0085061
2	gini	20	0.8119237	0.5559029	0.0020876	0.0070649
4	gini	5	0.9418872	0.8703506	0.0021847	0.0047187
4	gini	10	0.9411393	0.8686694	0.0022887	0.0049660
4	gini	20	0.9409511	0.8682136	0.0022006	0.0048111
8	gini	5	0.9615220	0.9141779	0.0010242	0.0021808
8	gini	10	0.9614447	0.9140224	0.0010557	0.0022611
8	gini	20	0.9615027	0.9141402	0.0010127	0.0021847

Confusion Matrix and Statistics			Confusion Matrix and Statistics		
Prediction	Reference		Prediction	Reference	
	No	Si		No	Si
No	12678	641	No	22011	1491
Si	374	18898	Si	1303	44273
Accuracy : 0.9689			Accuracy : 0.9596		
95% CI : (0.9669, 0.9707)			95% CI : (0.9581, 0.961)		
No Information Rate : 0.5995			No Information Rate : 0.6625		
P-Value [Acc > NIR] : < 2.2e-16			P-Value [Acc > NIR] : < 2.2e-16		
Kappa : 0.9354			Kappa : 0.9097		
McNemar's Test P-Value : < 2.2e-16			McNemar's Test P-Value : 0.0004035		
Sensitivity : 0.9713			Sensitivity : 0.9441		
Specificity : 0.9672			Specificity : 0.9674		
Pos Pred Value : 0.9519			Pos Pred Value : 0.9366		
Neg Pred Value : 0.9806			Neg Pred Value : 0.9714		
Prevalence : 0.4005			Prevalence : 0.3375		
Detection Rate : 0.3890			Detection Rate : 0.3186		
Detection Prevalence : 0.4087			Detection Prevalence : 0.3402		
Balanced Accuracy : 0.9693			Balanced Accuracy : 0.9558		
'Positive' Class : No			'Positive' Class : No		

Figura 7.2: Matriz de confusión y métricas de modelo RF fuera de la muestra - Montevideo e interior

c. Stochastic Gradient Boosting

Cuadro 7.4: Resultados calibración modelo GBM - Montevideo

	shrinkage	interaction.depth	n.minobsinnode	n.trees	Accuracy	Kappa	AccuracySD	KappaSD
1	0.1	1	20	200	0.7459958	0.4672648	0.0023319	0.0053062
6	0.1	5	20	200	0.7880009	0.5563241	0.0017708	0.0041087
11	0.1	9	20	200	0.8222943	0.6283333	0.0022434	0.0042467
2	0.1	1	20	400	0.7468447	0.4699218	0.0017709	0.0040748
7	0.1	5	20	400	0.8202180	0.6234274	0.0041692	0.0095060
12	0.1	9	20	400	0.8720007	0.7329642	0.0034822	0.0074255
3	0.1	1	20	600	0.7482255	0.4730667	0.0021485	0.0048006
8	0.1	5	20	600	0.8407142	0.6668729	0.0040774	0.0089288
13	0.1	9	20	600	0.8997893	0.7914477	0.0032822	0.0067739
4	0.1	1	20	800	0.7487778	0.4744683	0.0018453	0.0043212
9	0.1	5	20	800	0.8592468	0.7059730	0.0020401	0.0044053
14	0.1	9	20	800	0.9207765	0.8352510	0.0016871	0.0036507
5	0.1	1	20	1000	0.7491971	0.4752923	0.0022764	0.0053433
10	0.1	5	20	1000	0.8724201	0.7338719	0.0035719	0.0073998
15	0.1	9	20	1000	0.9333258	0.8615283	0.0015131	0.0030448

Cuadro 7.5: Resultados calibración modelo GBM - interior

	shrinkage	interaction.depth	n.minobsinnode	n.trees	Accuracy	Kappa	AccuracySD	KappaSD
1	0.1	1	20	200	0.7579125	0.4317896	0.0021356	0.0050625
6	0.1	5	20	200	0.7817357	0.4942165	0.0032265	0.0082964
11	0.1	9	20	200	0.7991893	0.5368019	0.0029091	0.0074106
2	0.1	1	20	400	0.7602046	0.4396859	0.0021318	0.0052811
7	0.1	5	20	400	0.7980553	0.5328474	0.0039285	0.0097612
12	0.1	9	20	400	0.8252322	0.5974450	0.0033288	0.0078634
3	0.1	1	20	600	0.7607692	0.4416345	0.0022157	0.0053032
8	0.1	5	20	600	0.8091828	0.5585141	0.0037561	0.0096618
13	0.1	9	20	600	0.8444471	0.6423877	0.0039937	0.0093450
4	0.1	1	20	800	0.7621203	0.4447472	0.0020646	0.0049434
9	0.1	5	20	800	0.8205949	0.5860177	0.0032225	0.0079813
14	0.1	9	20	800	0.8592178	0.6773881	0.0035098	0.0082086
5	0.1	1	20	1000	0.7622506	0.4452612	0.0018622	0.0049199
10	0.1	5	20	1000	0.8291118	0.6063557	0.0030307	0.0072904
15	0.1	9	20	1000	0.8722706	0.7082798	0.0032460	0.0074418

Confusion Matrix and Statistics			Confusion Matrix and Statistics		
Reference			Reference		
Prediction	No	Si	Prediction	No	Si
No	12125	1202	No	18039	3374
Si	927	18337	Si	5275	42390
Accuracy : 0.9347			Accuracy : 0.8748		
95% CI : (0.9319, 0.9373)			95% CI : (0.8723, 0.8773)		
No Information Rate : 0.5995			No Information Rate : 0.6625		
P-Value [Acc > NIR] : < 2.2e-16			P-Value [Acc > NIR] : < 2.2e-16		
Kappa : 0.8644			Kappa : 0.7143		
McNemar's Test P-Value : 2.88e-09			McNemar's Test P-Value : < 2.2e-16		
Sensitivity : 0.9290			Sensitivity : 0.7737		
Specificity : 0.9385			Specificity : 0.9263		
Pos Pred Value : 0.9098			Pos Pred Value : 0.8424		
Neg Pred Value : 0.9519			Neg Pred Value : 0.8893		
Prevalence : 0.4005			Prevalence : 0.3375		
Detection Rate : 0.3720			Detection Rate : 0.2611		
Detection Prevalence : 0.4089			Detection Prevalence : 0.3100		
Balanced Accuracy : 0.9337			Balanced Accuracy : 0.8500		
'Positive' Class : No			'Positive' Class : No		

Figura 7.3: Matriz de confusión y métricas de modelo GBM fuera de la muestra

- Montevideo e interior

d. Random Forest (análisis exploratorio)

Confusion Matrix and Statistics			Confusion Matrix and Statistics		
Reference			Reference		
Prediction	No	Si	Prediction	No	Si
No	13052	9	No	23290	22
Si	0	19530	Si	24	45742
Accuracy : 0.9997			Accuracy : 0.9993		
95% CI : (0.9995, 0.9999)			95% CI : (0.9991, 0.9995)		
No Information Rate : 0.5995			No Information Rate : 0.6625		
P-Value [Acc > NIR] : < 2.2e-16			P-Value [Acc > NIR] : < 2e-16		
Kappa : 0.9994			Kappa : 0.9985		
McNemar's Test P-Value : 0.007661			McNemar's Test P-Value : 0.8828		
Sensitivity : 1.0000			Sensitivity : 0.9990		
Specificity : 0.9995			Specificity : 0.9995		
Pos Pred Value : 0.9993			Pos Pred Value : 0.9991		
Neg Pred Value : 1.0000			Neg Pred Value : 0.9995		
Prevalence : 0.4005			Prevalence : 0.3375		
Detection Rate : 0.4005			Detection Rate : 0.3372		
Detection Prevalence : 0.4008			Detection Prevalence : 0.3375		
Balanced Accuracy : 0.9998			Balanced Accuracy : 0.9992		
'Positive' Class : No			'Positive' Class : No		

Figura 7.4: Matriz de confusión y métricas de modelo RF (análisis exploratorio)

fuera de la muestra - Montevideo e interior

<u>Confusion Matrix and Statistics</u>			<u>Confusion Matrix and Statistics</u>		
<u>Reference</u>			<u>Reference</u>		
<u>Prediction</u>	No	Si	<u>Prediction</u>	No	Si
No	12717	334	No	22064	746
Si	335	19205	Si	1250	45018
<u>Accuracy</u> : 0.9795			<u>Accuracy</u> : 0.9711		
<u>95% CI</u> : (0.9779, 0.981)			<u>95% CI</u> : (0.9698, 0.9723)		
<u>No Information Rate</u> : 0.5995			<u>No Information Rate</u> : 0.6625		
<u>P-Value [Acc > NIR]</u> : <2e-16			<u>P-Value [Acc > NIR]</u> : < 2.2e-16		
<u>Kappa</u> : 0.9573			<u>Kappa</u> : 0.935		
<u>Mcnemar's Test P-Value</u> : 1			<u>Mcnemar's Test P-Value</u> : < 2.2e-16		
<u>Sensitivity</u>	: 0.9743		<u>Sensitivity</u>	: 0.9464	
<u>Specificity</u>	: 0.9829		<u>Specificity</u>	: 0.9837	
<u>Pos Pred Value</u>	: 0.9744		<u>Pos Pred Value</u>	: 0.9673	
<u>Neg Pred Value</u>	: 0.9829		<u>Neg Pred Value</u>	: 0.9730	
<u>Prevalence</u>	: 0.4005		<u>Prevalence</u>	: 0.3375	
<u>Detection Rate</u>	: 0.3902		<u>Detection Rate</u>	: 0.3194	
<u>Detection Prevalence</u>	: 0.4004		<u>Detection Prevalence</u>	: 0.3302	
<u>Balanced Accuracy</u>	: 0.9786		<u>Balanced Accuracy</u>	: 0.9650	
<u>'Positive' Class</u> : No			<u>'Positive' Class</u> : No		

Figura 7.5: Matriz de confusión y métricas de modelo RF en modelo reducido (análisis exploratorio) fuera de la muestra - Montevideo e interior