

CONSUMO EN LOS HOGARES MEXICANOS DE OTT Y STAR: UN ANÁLISIS DE REDES NEURONALES

AUTORIDAD INVESTIGADORA
DIRECCIÓN GENERAL DE ANÁLISIS ECONÓMICO

INSTITUTO FEDERAL DE TELECOMUNICACIONES

DICIEMBRE, 2023

DERECHOS RESERVADOS

Derechos reservados © Instituto Federal de Telecomunicaciones, 2023.

Insurgentes Sur 1143, colonia Nochebuena, alcaldía Benito Juárez, C.P. 03720, Ciudad de México.

Queda prohibida la reproducción parcial o total, publicación, edición o fijación material de la presente obra, efectuada por cualquier medio, incluidos los electrónicos, así como la exhibición, distribución o cualquier modificación sin la autorización previa y por escrito del Instituto Federal de Telecomunicaciones, en términos de lo previsto por la Ley Federal del Derecho de Autor y, en su caso, por los tratados internacionales aplicables.

El contenido del presente estudio no debe entenderse como una interpretación del Instituto Federal de Telecomunicaciones (IFT) respecto de la Ley Federal de Competencia Económica, ni podrá utilizarse para vincular la actuación del IFT o a alguna de sus unidades administrativas. El IFT invoca sus facultades para aplicar las disposiciones constitucionales, legales y normativas en materia de competencia económica, caso por caso.

Contenido

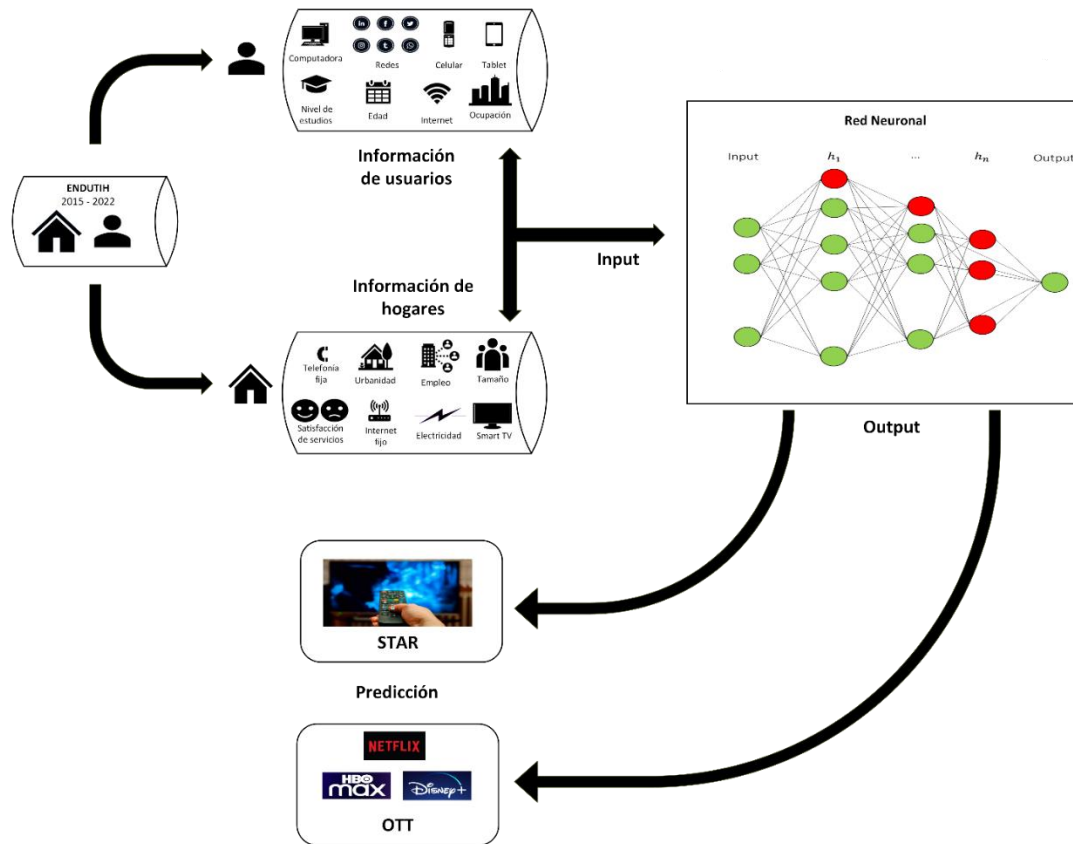
1. Revisión de literatura	6
2. Datos	10
2.1 Censo 2020	10
2.2 ENDUTIH	14
<i>Variables Relevantes</i>	14
<i>Estadística Descriptiva</i>	14
3. Metodología	21
3.1 Aprendizaje Supervisado y Clasificación	21
3.2 Red neuronal profunda	21
3.3 Matriz de confusión y métricas de evaluación	24
3.4 Entrenamiento	26
<i>Arquitectura y Entrenamiento del Modelo CENSO</i>	26
<i>Arquitectura y Entrenamiento del Modelo ENDUTIH</i>	28
4. Resultados	31
4.1 Resultados CENSO	31
4.2 Resultados ENDUTIH	32
4.2.1 Resultados OTT	32
4.2.2 Resultados STAR	34
5. Inferencia y Efectos Marginales	37
5.1 Perfiles de Hogares	37
5.2 Efectos Marginales	40
Conclusiones	50
Bibliografía	51
ANEXO TÉCNICO	53
ANEXO 1. Revisión de literatura	53
ANEXO 2. Datos de las ENDUTIH	54
ANEXO 3. Características socioeconómicas de los usuarios de STAR y OTT	59
ANEXO 4. Clústeres de Hogares – STAR	63
ANEXO 5. Red Neuronal	64
ANEXO 6. Rendiciones 3D de las Distribuciones de Probabilidad	67
ANEXO 7. Accuracy Según Probabilidad STAR-OTT	68

Introducción

- (1) En los últimos años, el consumo de contenidos audiovisuales se ha incrementado a nivel global. La expansión del Internet y la innovación tecnológica ha dado lugar a una nueva generación de plataformas de contenidos audiovisuales que ha cambiado las preferencias de los consumidores y sus decisiones de consumo de contenido de entretenimiento.
- (2) De acuerdo con los datos y previsiones de OMDIA, en el 2023, el número de suscripciones a televisión y vídeos en línea a nivel global presentó un incremento de 2,649 millones con respecto al número de suscripciones registrado en el 2016 (1,302 millones) y se espera que incremente un 20.7% (549 millones) para el 2028. En México, este número de suscripciones incrementó de 25.2 a 53.3 millones del 2016 al 2023, y se espera que incremente en 35.9% (19 millones) para el 2028.¹
- (3) Con la introducción de nuevas plataformas, los hábitos de visualización de contenido de los consumidores se han modificado y su estudio puede ser analizado sobre la base de factores económicos y sociales de los usuarios. Por tanto, los cambios en el consumo de servicios audiovisuales no solo dependen de la disponibilidad de plataformas a las que tienen acceso, sino también del estatus socioeconómico y la composición sociodemográfica del hogar.
- (4) El presente estudio tiene como objetivo analizar las preferencias de los usuarios en el consumo de contenidos audiovisuales de paga que se proveen a través de Internet u *over-the-top* (OTT, por sus siglas en inglés) y de televisión de acceso restringido (STAR) con base en las características socioeconómicas (como ingreso, educación, composición familiar, etc.) y de infraestructura (como el acceso a internet, electricidad, dispositivos, etc.) de los hogares en México, para identificar los factores y las características relevantes que influyen en el consumo de los servicios STAR-OTT de los hogares y usuarios, así como explorar la relación que los consumos de estos servicios tienen entre sí.
- (5) Este estudio propone el uso de redes neuronales, el cual es un método que permite clasificar a los usuarios y hogares como consumidores (o no consumidores) de los servicios STAR-OTT. La relevancia de emplear redes neuronales reside en su capacidad para procesar grandes cantidades de información para aprender, estimar y aproximarse a la relación estadística observada que existe entre las características de los usuarios/hogares y del consumo de contenidos audiovisuales. Para ello, se utilizan datos del Censo de Población y Vivienda 2020 (CENSO 2020) y de la Encuesta Nacional sobre Disponibilidad y Uso de Tecnologías de la Información en los Hogares 2015-2022 (ENDUTIH). La FIGURA 1 proporciona un esquema general del empleo de redes neuronales, alimentadas de datos sobre los usuarios y los hogares, para generar predicciones sobre las probabilidades de contratación de STAR y consumo de OTT audiovisual de los hogares mexicanos.

¹ OMDIA (November 2023). TV & Online Video Intelligence Database.

FIGURA 1. ESQUEMA DE FLUJO DE DATOS A LA RED NEURONAL A PREDICCIONES



Fuente: Elaboración propia.

- (6) El estudio se divide en seis secciones. La primera sección revisa diferentes artículos que analizan el consumo de los servicios de TV de paga y OTT de los usuarios, con la finalidad de identificar tanto las variables que influyen en sus decisiones de consumo como las metodologías de análisis empleadas. La segunda sección describe las dos fuentes de información utilizadas para entrenar a los modelos estadísticos, el Censo 2020 y la ENDUTIH, y da un conjunto de estadísticas descriptivas de las variables más influyentes sobre el consumo de los servicios STAR y OTT de usuarios y hogares en México.
- (7) La tercera sección aborda la metodología cuantitativa de aprendizaje de máquina empleada; a saber, redes neuronales profundas. Los resultados de los modelos estadísticos se interpretan en la cuarta sección. La quinta sección muestra los perfiles de hogares representativos de acuerdo con su información de composición familiar y dotaciones tecnológicas, así como los efectos marginales de cambios en las características de los hogares y de sus integrantes sobre la probabilidad de consumo de STAR-OTT. Finalmente, la sexta sección presenta las conclusiones de la investigación.

1. Revisión de literatura

- (8) La introducción de los servicios de video over-the-top (OTT), a través de proveedores nacionales e internacionales, ha cambiado los hábitos de consumo de contenido audiovisual. Asimismo, en la medida que la penetración de banda ancha, la velocidad de conexión, los dispositivos y la oferta de contenidos aumenta, los servicios OTT han crecido en número y en usuarios. Así, los usuarios pueden acceder a una oferta de contenido personalizada o a la carta, a través de dispositivos móviles o fijos y con independencia de un horario establecido.
- (9) Diversos autores han analizado los factores que afectan las decisiones de suscripción de contenido de los consumidores y, derivado de ello, la probabilidad de que sean contratados los servicios; además, han investigado el fenómeno de corte de cordón o *cord-cutting*, el cual es el proceso de cambiar de una suscripción tradicional de televisión de paga a un servicio de video OTT. También, han abordado algunas implicaciones de las decisiones de los consumidores en los proveedores de contenido.
- (10) Por ejemplo, Banerjee et al. (2014) identificaron tres posibles categorías de consumo de contenido, a saber: i) consumo simultáneo de TV de paga y OTT, ii) consumo de TV de paga sustituido por OTT y, iii) consumo por primera vez de OTT sin probar nunca TV de paga. En su análisis, evaluaron las características geo-demográficas del hogar (género, tamaño y situación del hogar, situación laboral, ingresos del hogar y grupo étnico), el tipo de dispositivo y el historial de suscripción de los consumidores. Con base en un modelo de regresión logit ordenado, encontraron que personas jóvenes usuarias intensivas de internet y con ingresos bajos tienen mayor probabilidad de consumir contenido OTT. Por otro lado, también descubrieron que consumidores entre 45 y 64 años complementan su servicio de TV de paga con el servicio OTT, y los hogares con personas de 65 y más edad, tienen mayor probabilidad de no suscribirse a un servicio OTT como Netflix.
- (11) De igual manera, Nagaraj et al. (2021) identificaron los factores que afectan las decisiones de suscripción OTT de los consumidores, a partir de emplear la misma clasificación de Banerjee et al. (2014). Encontraron que las decisiones de consumo están motivadas por cinco factores, a saber, contenido, conveniencia, características, precio y calidad, junto con variables demográficas (edad, educación y ocupación). Los autores adoptaron un modelo descriptivo de corte transversal y concluyeron que los cinco factores afectaron inversamente las decisiones de los consumidores junto con el precio. Asimismo, la estructura del hogar fue el principal factor de influencia junto con la edad, la ocupación y la educación.
- (12) Por su parte, Malone et al. (2021) identificaron importantes variables predictoras relacionadas con características demográficas, tipos de suscripción/planes y uso de internet en la probabilidad de usar un servicio OTT comparado con el servicio TV de paga. A partir de emplear un modelo probit, afirmaron que las variables relacionadas con el uso de internet

tienen un mayor poder predictivo, es decir, a mayor uso de internet mayor es la probabilidad de usar algún servicio OTT.

- (13) Con respecto a los tipos de suscripción/planes a la televisión, los autores encontraron que entre menos accesible sea un contenido de TV de paga para ser transmitido en un OTT (como contenido de deportes), menor es la probabilidad de usar OTT. Asimismo, señalaron que, empleando datos a nivel hogar con alto nivel de granularidad, los servicios de televisión de paga y OTT son sustitutos. Finalmente, de la misma manera que Banerjee et al. (2014), los hogares pequeños, con jóvenes y de escasos recursos tienen más probabilidad de usar servicios OTT (o hacer cord-cutting). Afirmaron que los adultos mayores ven mucha más televisión tradicional que los más jóvenes. Asimismo, encontraron que entre más grande sea el hogar, mayor es la preferencia de usar TV de paga o ambos servicios.
- (14) Jung y Melguizo (2022) analizaron las decisiones de consumo de los usuarios de servicios audiovisuales a través del tiempo a partir de analizar la relación que existe entre los servicios TV de paga y los servicios OTT. Como variables de control analizaron precios, ingreso per cápita, escolaridad, grupos de población, tecnología/infraestructura (banda ancha, dispositivos y TV) y método de pago. Los autores construyeron un modelo teórico basado en una función de utilidad *constant elasticity of substitution* (CES), la cual estimaron a partir de un modelo de mínimos cuadrados no lineales.
- (15) De acuerdo con sus resultados, los autores mostraron, en primer lugar, que existe una mayor demanda de los servicios OTT a medida que pasa el tiempo, debido en parte por la rápida expansión de Internet, a sus mejores ofertas y precios relativamente más bajos. Incluso afirmaron que los servicios TV de paga-OTT fueron sustitutos en los últimos años de su análisis. En segundo lugar, con respecto a las variables socioeconómicas, observaron que los grupos de mayor edad (mayor de 40 años) muestran una preferencia por ambos servicios audiovisuales, mientras que los grupos de menor edad (menos a 40 años) prefieren más los servicios OTT.
- (16) Los autores encuentran que los años de escolaridad del hogar y, por tanto, de ingreso, el uso de tabletas y tarjetas de débito tuvieron un efecto positivo y significativo en el uso de OTT, pero no en la demanda de TV de paga. Finalmente, al analizar en su conjunto todas las variables significativas, solo las cohortes poblacionales y la escolaridad fueron relevantes en las preferencias de OTT.
- (17) Prince y Greenstein (2017) analizaron las preferencias de los consumidores de contenido de video sobre la base de elegir entre servicios de televisión de paga (cable o satélite), televisión por aire (OTA), transmisión en línea (OTT) o ningún servicio. Los autores emplearon información de los hogares sobre compras de contenido, preferencias tecnológicas, información demográfica (área de mercado, educación, ingresos, tamaño del hogar y edad) y ubicación geográfica de los hogares; y estimaron un modelo econométrico

tipo pseudo-panel de probabilidad lineal dinámico para su análisis. De la misma manera, Malone et al. (2021) y Banerjee et al. (2014) concluyeron que los hogares con personas jóvenes y de bajos ingresos tienen mayor probabilidad de elegir servicios de transmisión en línea, OTT (o hacer cord-cutting). Afirman que las preferencias por OTT pueden reforzarse por las ofertas de contenido original y promociones de sus proveedores.

- (18) Por mencionar otros aspectos particulares, Malone et. al. (2021) indicaron que el cord-cutting tiene implicaciones para los ingresos de los operadores de servicios múltiples (MSO)² y por lo tanto también para sus incentivos. Su estudio reveló que los ingresos mensuales promedio para el MSO disminuyó en un 50%. Esto representa una pérdida significativa para los MSO, además de que también enfrentó los costos de mejorar su red para considerar el aumento en el uso de internet. Los autores identificaron que 2,710 hogares hicieron cord-cutting en el periodo analizado (poco menos del 10% de la muestra) lo cual corresponde a una tasa de corte de televisión por cable de aproximadamente 2.4% hogares anualmente. Esta tasa reduce los ingresos del operador a una tasa que supera el 1% por año. Al mismo tiempo, los operadores de video OTT aumentaron sus ingresos en \$4.11 por hogar-mes, lo que representó solo el 6% de los ingresos perdidos por el MSO.
- (19) En suma, si bien las investigaciones revisadas difieren en los objetivos y modelos, ya sean teóricos o empíricos, los autores identificaron las características, incentivos y hábitos de consumo de los usuarios que influyeron en la probabilidad de contratar los servicios de suscripción audiovisuales, así como la posibilidad que pueda darse el cord-cutting, el cual dependerá de la disponibilidad de la información, su tratamiento y del método empleado para su análisis (véase Anexo 1). La TABLA 1 resume las metodologías y variables relevantes empleadas de la literatura revisada.

² Los operadores de sistemas múltiples (MSO) son proveedores de servicios de telecomunicaciones que incluyen los servicios de internet y servicios de televisión por cable.

TABLA 1. COMPARACIÓN ENTRE METODOLOGÍAS EMPLEADAS PARA EL ESTUDIO DEL CONSUMO DE OTT Y TV DE PAGA

Estudios						
	Banerjee et al (2014)	Prince y Greenstein (2017)	Arnold et al. (2018)	Malone et al. (2021)	Jung y Melguizo (2022)	PAT 2023
Modelo Estadístico	Regresión logit ordenada	Elección discreta con utilidad aleatoria	Regresión de mínimos cuadrados	Probit	CES con mínimos cuadrados no-lineales	Redes Neuronales
Periodo Observado	2010	2007-2009	2015	2012-2016	2011-2020	2015-2022
Periodicidad	1 corte	Anual	1 corte	mensual	anual	Anual
Tamaño de Muestra	~5k	~60k	200k	~300k	170	~600k
Variables Relevantes	Edad, género, ingreso, dispositivos TIC	Edad, ingreso, educación, tamaño del hogar contenido audiovisual OTT	Edad, sexo, ingreso, dispositivos TIC	Tamaño del hogar, edad, ingreso, intensidad de uso de internet	Penetración y precios de OTT y TV de paga, generación, educación, ingreso	Edad, dispositivos TIC, composición familiar
Hallazgos Principales	+ sustitución OTT con: -edad +ingreso +hombre	+ <i>cord-cutting</i> con: -edad -ingreso	+OTT con: -edad +ingreso +dispositivos	+ <i>cord-cutting</i> con: -tamaño de hogar -edad -ingreso +uso de internet	OTT y TV de paga sustitutos entre 2015-2020	+ OTT con: -edad +escolaridad +uso de servicios y dispositivos TIC

Fuente: Elaboración propia con datos de los estudios.

Nota: Tecnologías de la información y comunicación (TIC).

- (20) La TABLA 1 muestra que el consumo de OTT y de televisión de paga se ha estudiado con una gran variedad de modelos estadísticos a niveles de granularidad de información muy distintos. Las ventajas del presente estudio sobre la literatura revisada se pueden resumir en los siguientes puntos: primero, un tamaño de muestra superior; segundo, datos más recientes; tercero, variables e información muy ad hoc a la pregunta de investigación; y cuarto, un modelo estadístico de mayor flexibilidad.
- (21) Este estudio emplea redes neuronales profundas para la estimación de las probabilidades de contratación y consumo de los servicios de televisión de paga y de OTT audiovisual. Una de las razones principales para la elección de esta metodología es la capacidad que tiene una red neuronal para aprender, estimar y aproximarse a la relación estadística que existe entre la variable dependiente y las variables explicativas.
- (22) Las redes neuronales son un subconjunto de modelos estadísticos que buscan entender la relación causal entre variables dependientes (en este caso, la adopción y uso de STAR-OTT) de un conjunto de variables explicativas (por ejemplo, algunas variables sociodemográficas). El Anexo 1 muestra una tabla comparativa de algunas metodologías usadas para la estimación de modelos explicativos y predictivos con variables dependientes, tanto dicotómicas como continuas, con el fin de ubicar a las redes neuronales dentro un subconjunto de los modelos estadísticos. Cada modelo tiene ventajas y desventajas derivadas de sus supuestos, forma funcional, interpretabilidad, y datos, donde la diferencia fundamental entre todas las metodologías cuantitativas para la estimación de modelos estadísticos radica en cómo se define y cómo se estima la función que relaciona las variables dependientes con las variables explicativas.

2. Datos

- (23) Los datos utilizados en este estudio se obtuvieron de dos fuentes de información públicas del INEGI: el Censo de Población y Vivienda 2020³ (Censo 2020 o CENSO), y la Encuesta Nacional sobre Disponibilidad y Uso de Tecnologías de la Información en los Hogares⁴ (ENDUTIH) correspondientes al periodo 2015-2022. Estos conjuntos de datos ofrecen una visión integral de la situación sociodemográfica y de infraestructura de los hogares mexicanos a nivel nacional.

2.1 Censo 2020

- (24) El Censo 2020, realizado del 2 al 27 de marzo de 2020, incluye dos tipos de cuestionarios: el básico con 38 preguntas y el ampliado con 104. El cuestionario ampliado, el cual es una extensión detallada del básico, permite profundizar en las características de las viviendas y de los datos sociodemográficos de sus habitantes. Este censo, que se realiza cada 10 años,

³ INEGI CENSO 2020: <https://www.inegi.org.mx/programas/ccpv/2020/#documentacion>

⁴ ENDUTIH: <https://www.inegi.org.mx/programas/dutih/2022/>

se aplicó a nivel nacional, resultando en una base de datos tipo sección cruzada para el año 2020. Cada observación en esta base representa la información de una vivienda específica mexicana.

- (25) Para este estudio se utilizan los datos obtenidos a partir del cuestionario ampliado con aproximadamente 4 millones de viviendas en todo el país. A partir de estos datos se entrena un modelo de redes neuronales para predecir si la vivienda dispone de los servicios STAR u OTT, ambos o ninguno.
- (26) Para clasificar las viviendas como consumidor STAR u OTT, se consideran 34 variables explicativas que se agrupan en cinco categorías:
- i. **Dispositivos de tecnología de la información y comunicación (TIC) en la vivienda.** Estas variables constituyen los puntos de acceso para el uso de los servicios de entretenimiento audiovisual como televisor, computadora, celular o consola de videojuegos.
 - ii. **Infraestructura de la vivienda.** Disponibilidad de servicios como telefonía fija (STF), banda ancha fija (SBAF) y electricidad en la vivienda.
 - iii. **Otras dotaciones.** Disponibilidad de electrodomésticos como refrigerador, lavadora, horno y motocicleta, así como automóvil propio.
 - iv. **Tiempo libre de la vivienda.** Horas totales de traslado (escuela, trabajo), horas totales de trabajo a la semana en la vivienda.
 - v. **Socioeconómicas y sociodemográficas.** Estas características incluyen ingreso de la vivienda, ocupación de los residentes, mujeres y hombres mayores de 18 años, personas con alguna discapacidad auditiva, escolaridad promedio de los integrantes de la vivienda, entre otros.
- (27) La TABLA 2 muestra el promedio de las características de la vivienda dependiendo del servicio de entretenimiento audiovisual del que dispone.

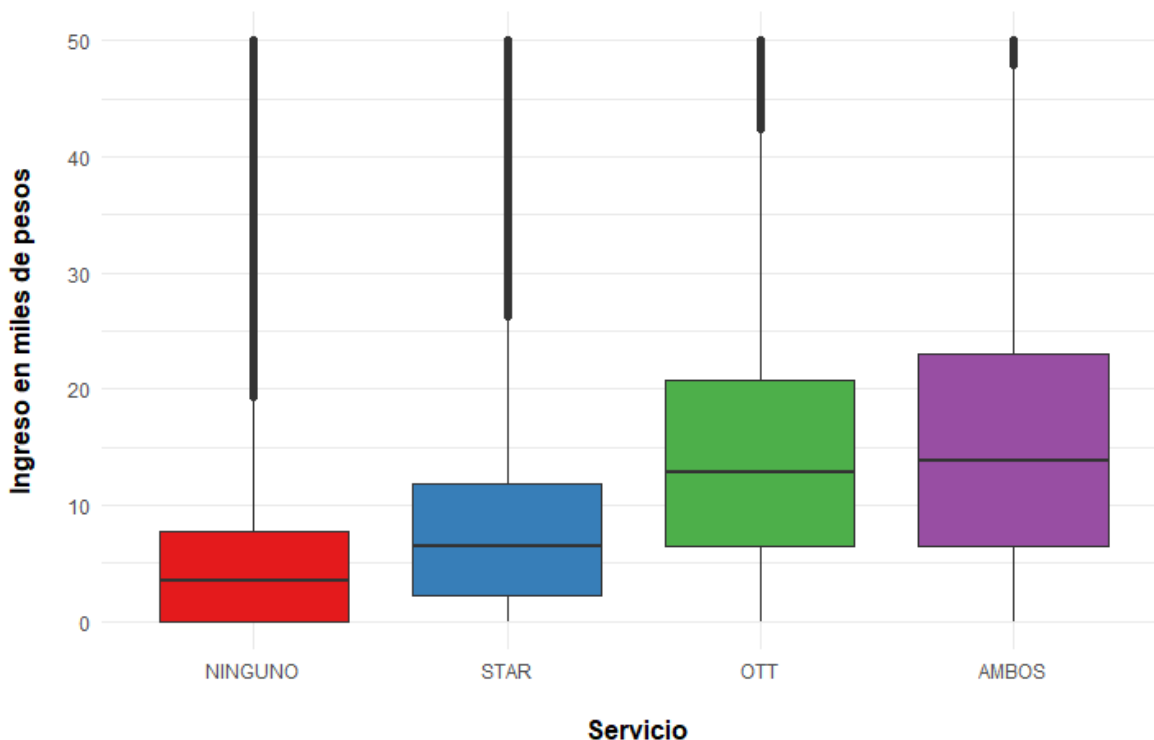
TABLA 2. VALORES MEDIOS DE ALGUNAS VARIABLES EMPLEADAS SEGMENTADAS POR SERVICIO

Variable	Ninguno	STAR	OTT	Ambos
Televisor	0.76	1.0	0.94	1.0
Computadora	0.12	0.28	0.78	0.83
Celular	0.69	0.89	0.99	0.99
Internet	0.20	0.43	1.0	1.0
Número Trabajadores	1.29	1.48	1.69	1.39
Hrs. Trabajadas	53.5	63.1	72.0	72.2
Hrs. Traslado al Trabajo	2.28	2.38	2.93	2.86
Ingreso Mensual	5,545	8,907	18,222	21,578
Número Estudiantes	0.37	0.42	0.50	0.51
Hrs. Traslado Escuela	1.45	1.47	1.76	1.70
Escolaridad	2.6	3.39	5.96	5.96
Automóvil	0.24	0.49	0.70	0.80

Fuente: Elaboración propia con base en los datos del Censo 2020.

- (28) La variable computadora en la vivienda indica si hay disponibilidad de computadora, laptop o tableta. Es posible observar una clara tendencia ascendente en la posesión de estos dispositivos a medida que las viviendas contratan más servicios, pues mientras que el 12% de las viviendas sin servicios de entretenimiento audiovisual contaban con alguno de estos dispositivos, este porcentaje aumenta a un 83% cuando en las viviendas con ambos servicios. Esto es un indicio del vínculo que las tecnologías como computadoras, laptops o tabletas tienen la suscripción a servicios de entretenimiento audiovisual. Es notable cómo las viviendas con disposición de OTT tienen una alta prevalencia en la disposición de computadora laptop o tableta (78%) lo que puede indicar una correlación entre el uso de plataformas digitales y la disposición de computadora, laptop o tableta.
- (29) En el caso del ingreso de la vivienda se aprecia un patrón similar a la computadora. Los hogares sin ningún servicio tienen un ingreso mensual promedio significativamente menor (\$5,545) comparado con aquellos que disponen de OTT (\$18,222). Esta diferencia es aún más evidente al observar que las viviendas con ambos servicios tienen un ingreso promedio de \$21,578, lo que indica que el acceso a servicios de entretenimiento audiovisual es influenciado por la capacidad económica de la vivienda.

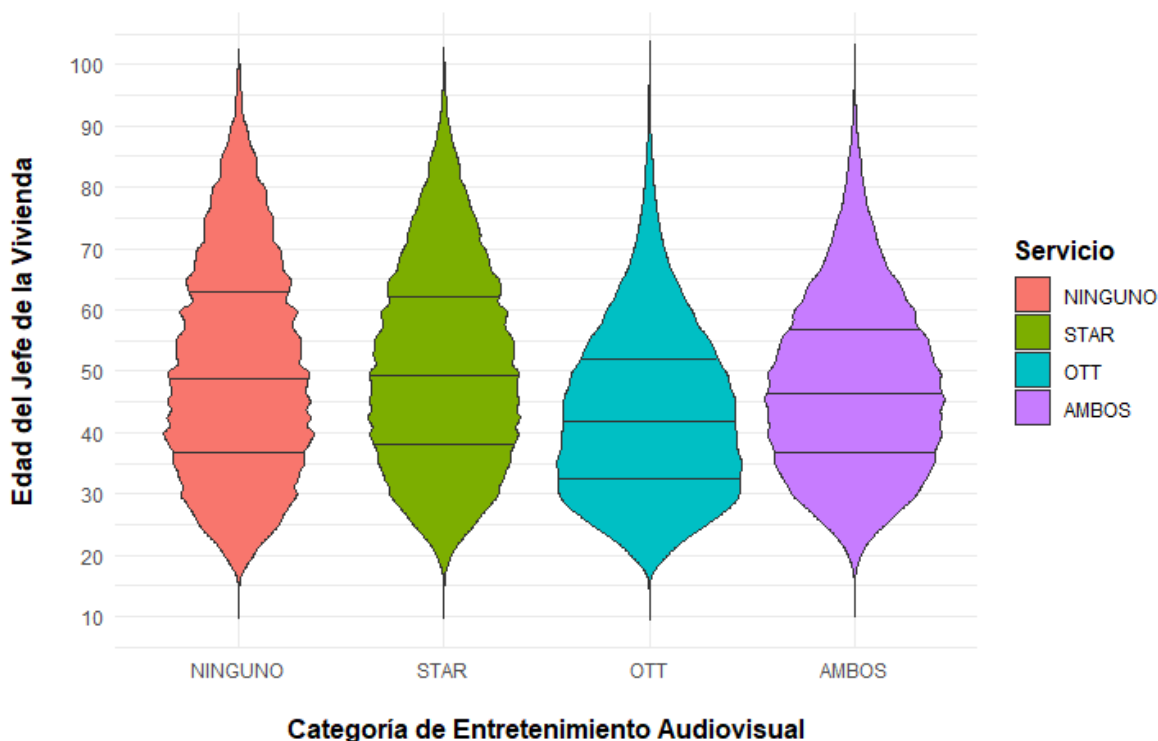
FIGURA 2. DISTRIBUCIÓN DE INGRESOS POR DISPOSICIÓN DE SERVICIOS STAR-OTT EN LA VIVIENDA



Fuente: Elaboración propia con base en los datos del Censo 2020.

(30) Los diagramas de caja en la FIGURA 2 muestran que las viviendas que tienen OTT, con o sin STAR, tienen mayor ingreso medio y mayor variabilidad en su nivel económico. Las viviendas que solo tienen STAR o ningún servicio presentan los ingresos promedio más bajos, así como una menor dispersión respecto a la mediana. Estos resultados refuerzan la noción de que la situación económica de la vivienda es un factor importante en la adopción de estos servicios.

FIGURA 3. DISTRIBUCIÓN DE LA EDAD DEL JEFE DE LA VIVIENDA POR SERVICIO⁵



Fuente: Elaboración propia con base en los datos del Censo 2020.

(31) Respecto a la edad del jefe de familia, la FIGURA 3 muestra que las medianas de edad en las viviendas que no disponen de servicios audiovisuales (49) o solo tienen STAR (50) están por arriba de las medianas de edad de las viviendas que tienen OTT (42) o ambos servicios (46 años). Dicho de otro modo, los jefes del hogar tienden a ser más jóvenes en las viviendas que hacen uso de los servicios de OTT (con o sin STAR) a comparación de aquellas en las que solo hacen uso del STAR o de ninguno de estos servicios audiovisuales.

⁵ Las líneas horizontales en la gráfica de violín, de abajo hacia arriba, representan el primer, segundo (mediana) y tercer cuartil.

2.2 ENDUTIH

- (32) La ENDUTIH, realizada anualmente en el periodo 2015 a 2022 a nivel nacional, recopila información relativa a la disponibilidad de tecnologías de la información y comunicación en los hogares⁶. Con estas ocho olas de la encuesta se conformó una base datos de tipo sección cruzada repetida⁷.

Variables Relevantes

- (33) En el caso de la ENDUTIH el análisis se aborda desarrollando dos modelos distintos para tratar de clasificar, por un lado, a los hogares que disponen STAR y, por otro lado, a los hogares donde el residente encuestado reporta hacer uso de servicios OTT audiovisuales de paga.
- (34) Para el modelo de STAR principalmente se emplean variables explicativas relacionadas con el hogar como: la disposición de los servicios y dispositivos de tecnologías de la información y comunicación (TIC) en el hogar, como STF, SBAF, televisor, computadora, laptop, tableta, celular, etc.; la estructura del hogar (el número de residentes en el hogar por: generación, nivel de estudios, uso de dispositivos TIC, etc.); y las características del jefe del hogar (edad, nivel de estudios, situación laboral, etc.).
- (35) En el modelo de OTT se emplean las variables explicativas del modelo STAR y adicionalmente variables sobre el residente que contesta el apartado de “usuarios” del cuestionario. Entre esta información se encuentran variables sociodemográficas (edad, ocupación, nivel de estudios, etc.) y variables de uso de servicios y dispositivos TIC (equipo de conexión a internet, frecuencia de uso de computadora e internet, redes sociales, entre otras) de este individuo. Para más detalle del tipo de variables utilizadas en los modelos ver Anexo 2.

Estadística Descriptiva

- (36) La TABLA 3 recopila las variables de las olas 2015-2022 de la ENDUTIH utilizadas en los modelos estadísticos. Su tipo y rango de valores se encuentran en la segunda columna. Las últimas dos columnas indican cuáles variables fueron utilizadas en las redes neuronales para el STAR y para el OTT.

⁶ Los periodos en los que ha sido realizada la encuesta varían entre años: Segundo trimestre: 2015, 2016,

⁷ La sección cruzada repetida es un conjunto de datos que tiene información periódica de distintas viviendas. Los datos son representativos a nivel nacional.

TABLA 3. VARIABLES UTILIZADAS EN LOS MODELOS STAR Y OTT

Variable	Tipo y rango de valores que puede tomar	Modelo STAR	Modelo OTT
Año	Numérica entero, rango: 2015-2017	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>
Tipo de televisor	Variables dicotómicas (0,1) del tipo de televisor en el hogar: <ul style="list-style-type: none"> • Analógico • Analógico con decodificado para recibir señal digital • Pantalla plana (televisor digita, LCD o LED) 	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>
Rural/Urbano	Dicotómica (0,1)	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>
Número de viviendas en el hogar	Categorica numérica	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>
Servicio de banda ancha fija (SBAF)	Dicotómica (0,1)	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>
Tipo de conexión de SBAF	Variables dicotómicas (0,1) del tipo de tecnología de SBAF en el hogar: IPC, LTD, WIFI, Satelital o DIALUP	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>
Internet móvil	Dicotómica (0,1), de internet móvil en el hogar	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>
Satisfacción con el servicio SBAF	Dicotómicas (0,1), de satisfacción o insatisfacción con el servicio de SBAF	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>
Satisfacción con el servicio STF	Dicotómicas (0,1), de satisfacción o insatisfacción con el servicio de STF	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>
Disposición de dispositivos TIC en el hogar	Dicotómicas (0,1), disposición de computadora de escritorio, laptop, tableta, celular	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>
Aparatos electrónicos	Dicotómicas (0,1): refrigerador y lavadora	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>
Características de los residentes del hogar	Grupos de variables categóricas numéricas que cuentan cuantos residentes del hogar hay por: <ul style="list-style-type: none"> • Ventana de edad de 5 años • Generación • Uso de dispositivos TIC • Nivel educativo • Con trabajo 	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>
Características del jefe del hogar	Grupos de variables dicotómicas (0,1) que indican si el jefe del hogar tiene alguna de las siguientes características: <ul style="list-style-type: none"> • Edad • Sexo • Nivel educativo • Trabajo • Uso de dispositivos TIC o internet • Estudiante Grupo de variables categóricas numéricas: <ul style="list-style-type: none"> • Número de hijos • Numero de nietos 	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>
Características del residente que contesta la parte de usuarios	Grupo de variables dicotómicas (0,1) que indican si el usuario en el hogar tiene alguna de las siguientes características:		<input checked="" type="checkbox"/>

	<ul style="list-style-type: none"> • Edad • Sexo • Nivel educativo • Trabajo • Uso de dispositivos TIC o internet • Estudiante • Lugar de uso de internet • Equipo de conexión a internet • Antigüedad del uso de internet • Problemas de navegación en internet • Uso de redes sociales • Acceso a OTT gratuito como YouTube <p>Grupo de variables categóricas numéricas:</p> <ul style="list-style-type: none"> • Frecuencia en horas de uso de computadora • Frecuencia en horas de uso de internet • Número de pagos en internet 		
Uso de OTT⁸	Dicotómica (0,1)		<input checked="" type="checkbox"/>
Disponibilidad de STAR⁹	Dicotómica (0,1)	<input checked="" type="checkbox"/>	
Factor de hogar¹⁰	Numérica 0 – 26624	<input checked="" type="checkbox"/>	
Factor de persona¹¹	Numérica 0 – 212995		<input checked="" type="checkbox"/>

Fuente: Elaboración propia.

(37) La tabla anterior identifica las variables que comparten ambos modelos. Existen diferencias importantes en estas variables entre aquellos hogares que disponen de STAR respecto de aquellos en donde se consumen OTT. El Anexo 2 permite observar a mayor detalle el contraste entre los valores que toman estas variables para los hogares que disponen de STAR, para aquellos donde se usa el OTT y para los que no tienen ningún servicio.


⁸ La variable de OTT viene de la sección del cuestionario donde se pregunta sobre el *uso* de OTT audiovisual a un residente del hogar seleccionado de manera aleatoria.

⁹ La variable de STAR viene de la sección del cuestionario donde se pregunta sobre la *disponibilidad* del STAR en el hogar.

¹⁰ El factor de hogar es un factor de expansión que pondera la representatividad del hogar encuestado y permite calcular estadísticas de hogares a nivel nacional.

¹¹ El factor de persona es un factor de expansión que pondera la representatividad de la persona encuestada y permite calcular estadísticas de los usuarios mayores a seis años a nivel nacional.

FIGURA 4. DISPONIBILIDAD DE STAR Y USO DE OTT EN LOS HOGARES



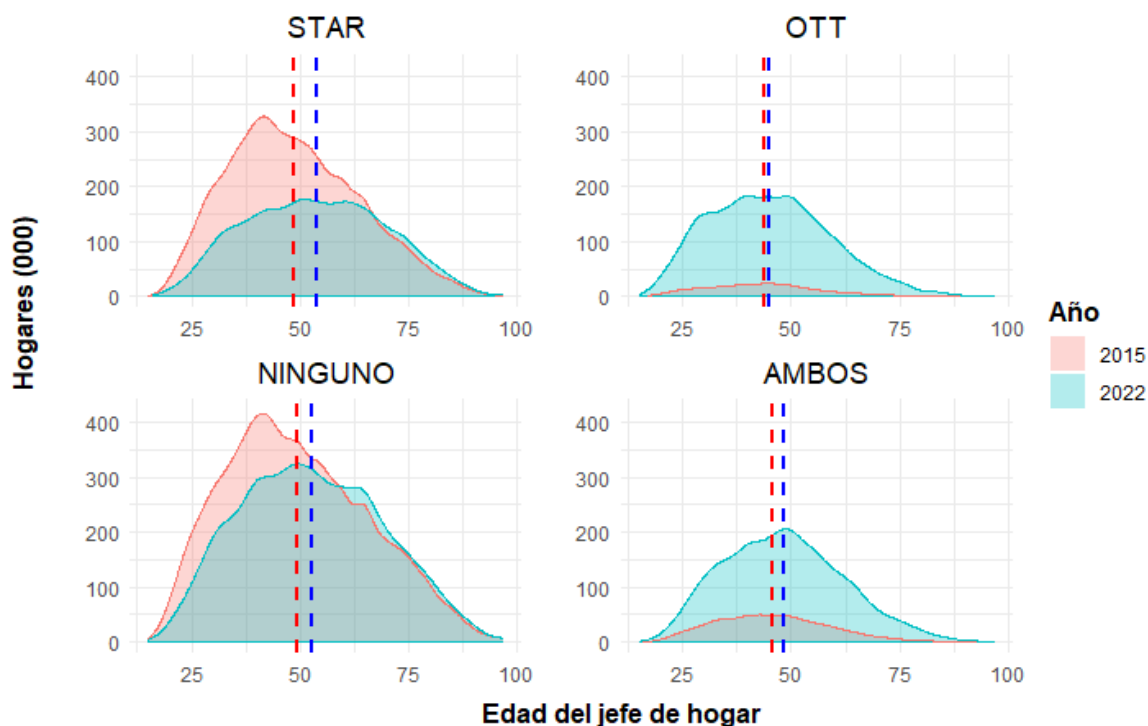
Fuente: Elaboración propia con base en los datos de las ENDUTIH 2015-2022.

Nota: Las barras representan el cambio porcentual en hogares (eje izquierdo) y las líneas azul y rojo representan el número de hogares (eje derecho)

- (38) La FIGURA 4, lado izquierdo STAR, muestra que el mayor cambio porcentual en la disposición del servicio respecto al año anterior se registró en el 2016. Con respecto al servicio OTT, el mayor crecimiento de estos servicios ocurrió durante 2016 y 2017, con un incremento de 60% y 70%, respectivamente, para después reducirse y estabilizarse alrededor del 10% en los últimos tres años investigados. Estos datos son un reflejo del estado de mayor madurez del mercado STAR con respecto al mercado OTT; mientras que el STAR ha llegado a una penetración que oscila entre 62% y 72% en los últimos 5 años¹², el OTT es un mercado en auge evidenciado por su incremento de 2.5 millones de hogares en el 2015 a 15 millones en el 2022.
- (39) Una de las variables empleadas para explicar la disposición del STAR y uso del OTT en los hogares fue la edad del jefe de familia. Su distribución, distinguiendo entre servicios, se muestra en la FIGURA 5.

¹² Medida como el número de accesos por cada 100 hogares según el Banco de Información de Telecomunicaciones (BIT).

FIGURA 5. DENSIDAD DE LA EDAD DEL JEFE PARA LOS HOGARES QUE DISPONEN DE STAR O HACEN USO DE UN OTT¹³



Fuente: Elaboración propia con base en los datos de las ENDUTIH 2015 y 2022.

(40) La FIGURA 5 muestra que los jefes de familia son más jóvenes en los hogares donde se usa el OTT y no se dispone del STAR que aquellos hogares en donde disponen de STAR y no usan OTT. Esta diferencia fue de 3.5 años en el 2015 y se amplió a 5 años para 2022¹⁴. Analizando como la forma de las distribuciones del 2015 (en rosa) cambian para el 2022 para las cuatro categorías de hogares, se puede observar lo siguiente:

- Disminuye el número de hogares con sólo STAR y con jefes de hogar con menos de 60 años.
- Disminuye el número de hogares sin ningún servicio y con jefes de hogar con menos de 50 años.
- Las dos disminuciones anteriores se ven reflejadas como incrementos en la cantidad de hogares con OTT (ya sea con o sin STAR).

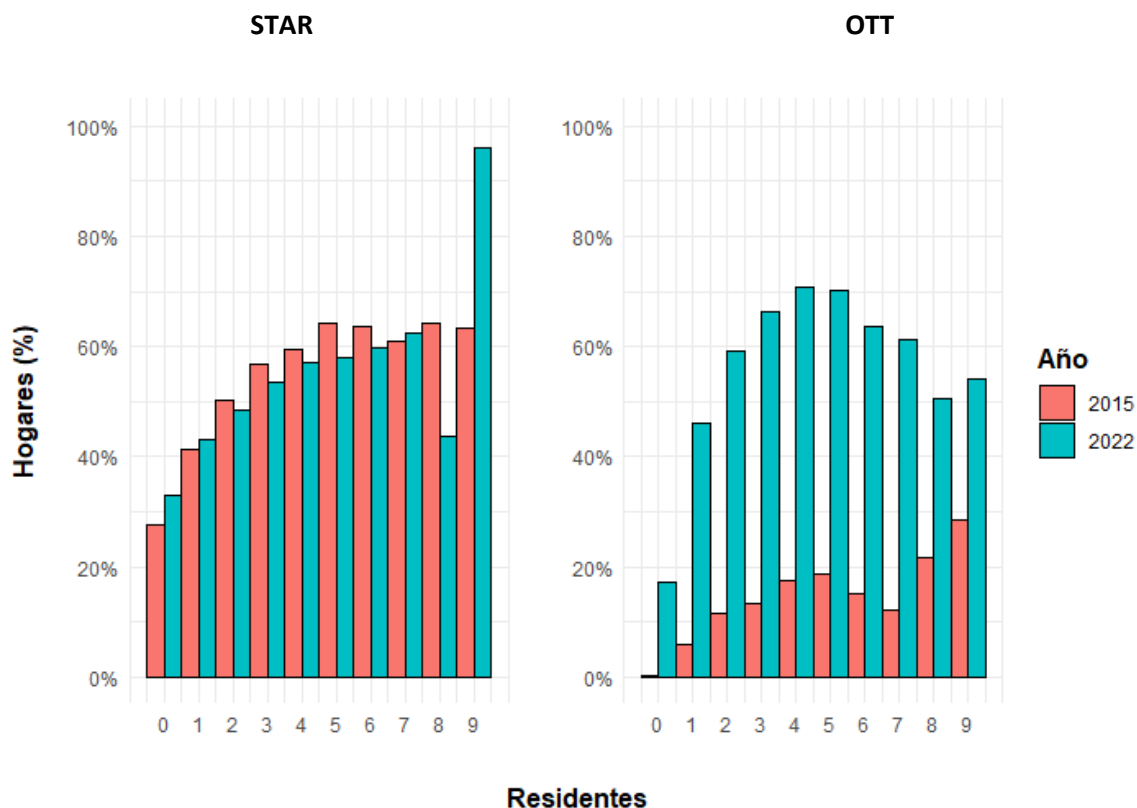
(41) Lo anterior es evidencia fuerte de que la adopción de OTT se está llevando a cabo principalmente en los hogares con jefes “jóvenes”.

¹³ Las líneas punteadas de la figura muestran los promedios de la edad del jefe de hogar. La línea roja indica la edad promedio para 2015, mientras que la azul representa el 2022.

¹⁴ Para más información de estas diferencias, véase las tablas A2.2 Estadística descriptiva de algunas variables usadas para el modelo STAR (ENDUTIH) y A2.3 Estadística descriptiva de algunas variables usadas para el modelo OTT (ENDUTIH) del Anexo 2.

(42) Las ENDUITH también proporcionan información acerca del uso de otras tecnologías relacionadas con la utilización de STAR y OTT en los hogares, por ejemplo, las computadoras y el internet. La FIGURA 6 muestra el porcentaje de hogares que disponen de STAR y utilizan OTT según el número de integrantes del hogar que utilizan una computadora (de escritorio, laptop o tablet) para los años 2015 y 2022.

FIGURA 6. PREVALENCIA DE LA DISPONIBILIDAD DE STAR Y USO DE OTT SEGÚN EL NÚMERO DE RESIDENTES USUARIOS DE COMPUTADORA




Fuente: Elaboración propia con base en los datos de las ENDUTIH 2015 y 2022.

(43) Como se puede observar en la figura de arriba, a mayor número de residentes usuarios de computadora, mayor es el porcentaje de hogares con STAR y OTT. Por ejemplo, de los hogares donde 4 residentes utilizan una computadora 70% utilizan OTT. También se aprecia que la relación estrecha entre uso de computadora y OTT se refuerza significativamente del 2015 al 2022. Los promedios de estas distribuciones y de otras variables relevantes pueden consultarse en las TABLAS A2.2 y A2.3 del Anexo 2.

(44) Además de las computadoras, el Internet es otra de las tecnologías estrechamente vinculadas con el consumo de contenidos por medio de OTT. La FIGURA 7 muestra el porcentaje de hogares que utilizan OTT según el número de horas al día que sus residentes utilizan una computadora e internet.

FIGURA 7. USO DE OTT SEGÚN EL NÚMERO DE HORAS EN COMPUTADORA O INTERNET



Fuente: Elaboración propia con base en los datos de las ENDUTIH 2015 y 2022.

(45) Si bien la TABLA A2.3 del Anexo 2 muestra que el número promedio de las horas al día que pasa el usuario de OTT en la computadora disminuyó de 3.6 a 2.7, el número promedio de horas al día que estos usuarios pasan en internet aumentó de 5.3 a 5.7 entre el 2015 y 2022. Adicionalmente, en la FIGURA 7 se observa que, a más horas de uso de computadora e internet, mayor es el porcentaje de horas que usan OTT. Esta relación se agudiza del 2015 al 2022.

(46) Finalmente, las gráficas del Anexo 3 permiten inferir lo siguiente:

- El uso de OTT ha ido aumentando constantemente para todos los niveles de escolaridad. Sin embargo, la adopción de este servicio es mucho más pronunciado para aquellos con nivel superior y es prácticamente inexistente para aquellos con ningún nivel de escolaridad completado (FIGURA A3.4).
- Entre más tipos de pagos se realicen por internet, más probable es el usuario de utilizar OTT (FIGURA A3.5)
- Las redes sociales están asociadas con el uso de OTT. Aquellos usuarios que usan LinkedIn son más propensos a utilizar OTT, más que los usuarios de Instagram, Twitter y Facebook (FIGURA A3.6).

3. Metodología

3.1 Aprendizaje Supervisado y Clasificación

- (47) En el campo de la inteligencia artificial, los modelos de aprendizaje de máquina se usan principalmente para tareas de clasificación y de regresión. Un proceso de clasificación implica designar a una observación como parte de un grupo u otro, es decir, una categorización. Por otro lado, una tarea de regresión implica calcular un valor continuo a partir de un conjunto de datos dado. Por ejemplo, categorizar a una muestra de agua como potable o no potable es una tarea de clasificación mientras que estimar el precio de un producto en función de sus características es una tarea de regresión. En este estudio se emplean técnicas de clasificación para categorizar a los hogares y usuarios como consumidores o no de los servicios de OTT y de STAR considerando sus características sociodemográficas y de uso y disposición de dispositivos TIC.
- (48) Aunado a la diferencia entre las tareas de clasificación y regresión, también existe una distinción entre el aprendizaje supervisado y no-supervisado. Para explicar esta diferencia, considere el siguiente ejemplo. Existe una base de datos de 10,000 animales de diferentes especies, la cual incluye información biométrica acerca de peso, estatura, color y otras características físicas (como el número de patas, dedos o longitud de la cola) sobre la cual se podría implementar un modelo de clasificación. Esta base de datos hipotética podría o no venir etiquetada con el nombre de la especie de cada observación. Si el nombre de la especie no estuviera en la base de datos, entonces un algoritmo de aprendizaje no supervisado sería empleado, como el análisis de clúster, para agrupar a las observaciones basándose en sus características. Se esperaría que el algoritmo de aprendizaje no supervisado clasificara, por ejemplo, a todas las observaciones de perros dentro del mismo grupo o clúster y a las aves en otro.
- (49) Ahora bien, si las observaciones de esta base de datos sí estuvieran etiquetadas por especie, entonces se utilizaría un algoritmo de aprendizaje supervisado para monitorear que las predicciones hechas sobre la especie de cada observación coincidan con las que efectivamente la base tiene registradas. Los modelos de redes neuronales de este estudio son un caso de aprendizaje supervisado. Partiendo de las características de los hogares y sus residentes, así como el dato ya existente sobre el consumo o no de los servicios de OTT y de STAR dentro de estos hogares, se entrenaron modelos que predecir el consumo de estos servicios dentro de los hogares.

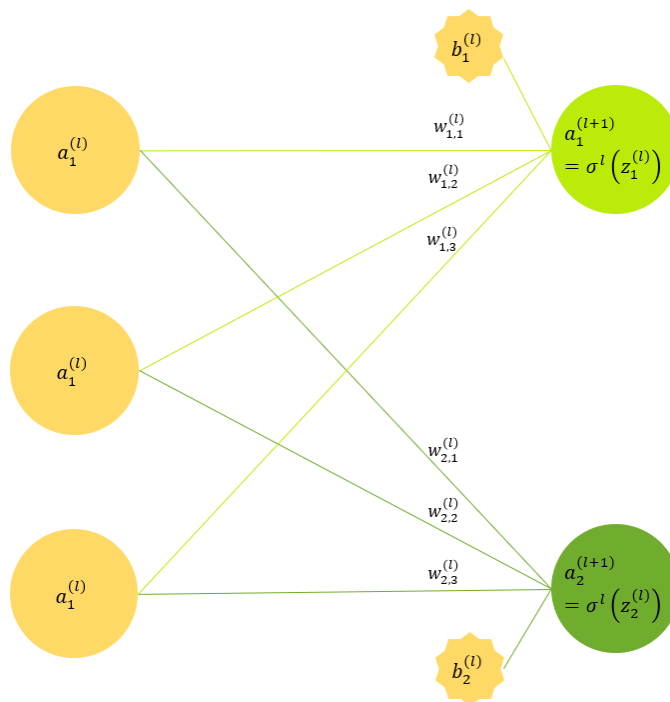
3.2 Red neuronal profunda

- (50) Una red neuronal profunda es un modelo estadístico inspirado en el funcionamiento y estructura de las neuronas de un cerebro. Estos modelos están compuestos de unidades básicas denominadas *neuronas*, las cuales se organizan en capas de entrada, capas ocultas y capas de salida. La *profundidad* de la red, es decir, la presencia de numerosas

capas ocultas es lo que permite que la red aprenda representaciones de y patrones en los datos progresivamente más complejas y abstractas.

- (51) La propagación de información a través de una red neuronal funciona de la siguiente manera. Cada neurona recibe una o más entradas (inputs) que son procesadas mediante una suma ponderada y, posteriormente, pasan por una función de activación que genera una salida (output). Todas las conexiones entre neuronas tienen un parámetro asociado, conocido como peso, que se ajusta durante el proceso de entrenamiento para minimizar el error, medido como la diferencia entre las predicciones del modelo y los datos observados. Mediante este mecanismo, las redes neuronales “aprenden” los patrones subyacentes en los datos para realizar tareas de clasificación y regresión.
- (52) La FIGURA 8 representa cómo se propaga la información entre la capa l y $l + 1$ de una red neuronal, donde la capa l tiene 3 neuronas $a_1^{(l)}$, $a_2^{(l)}$ y $a_3^{(l)}$.

FIGURA 8. PROPAGACIÓN DE LA INFORMACIÓN ENTRE DOS CAPAS CONTIGUAS



Fuente: Elaboración propia.

(53) La capa $l + 1$ tiene 2 neuronas $a_1^{(l+1)}$ y $a_2^{(l+1)}$. Para definir el valor de la primera neurona de la capa $l + 1$, primero se calcula la suma de los valores de las neuronas de la capa l ponderada por los pesos $w_{1,1}^{(l)}$, $w_{1,2}^{(l)}$ y $w_{1,3}^{(l)}$ que relacionan a la capa l con la neurona $a_1^{(l+1)}$, adicionando un valor de sesgo $b_1^{(l)}$ ¹⁵. Después, este valor pasa por la función de activación σ^l para obtener el valor de la neurona $a_1^{(l+1)}$. Análogamente se hace el cálculo de la neurona $a_2^{(l+1)}$, ponderando la suma de las neuronas con los pesos $w_{2,1}^{(l)}$, $w_{2,2}^{(l)}$ y $w_{2,3}^{(l)}$; donde, $z_k^{(l)} = a_1^{(l)}w_{k,1}^{(l)} + a_2^{(l)}w_{k,2}^{(l)} + a_3^{(l)}w_{k,3}^{(l)} + b_k^{(l)}$ con $k \in \{1, 2\}$.

(54) Existen otros elementos en la red neuronal que permiten adaptarla a problemas específicos. La *arquitectura* de una red neuronal alude a la organización y configuración estructural de sus componentes, tales como las capas de neuronas, el número de neuronas en cada capa y las conexiones entre ellas. Por otro lado, los hiperparámetros del modelo, definen la manera en cómo la red irá explorando el espacio de soluciones a su objetivo de minimización de error. La siguiente lista describe los principales hiperparámetros de una red neuronal:

- El **número de capas** en la red neuronal. Entre más capas, más “profunda” se considera la red.
- El **número de neuronas por capa**.
- El **optimizador**, es el algoritmo utilizado para actualizar los pesos de la red durante su entrenamiento. Algunos ejemplos de optimizadores comunes incluyen el Descenso del Gradiente Estocástico (SGD, por sus siglas en inglés), *Root Mean Square Propagation* (RMSprop) y *Adaptive Moment Estimation* (Adam), entre otros.
- La **función de activación**, como su nombre lo indica, es una función matemática que determina el valor de las neuronas en capas posteriores usando la información de salida de neuronas en capas anteriores. Al introducir no linealidades en la red, le permite a ésta aprender patrones complejos y descubrir asociaciones no lineales entre los *inputs* y los *outputs* de la red neuronal. Algunos ejemplos de funciones de activación incluyen la Unidad Rectificada Lineal (ReLU), sigmoide y función exponencial normalizada (Softmax).
- El tamaño de lote, o **batch size**, hace referencia al número de ejemplos de entrenamiento utilizados en cada iteración durante el proceso de entrenamiento. Este parámetro influye tanto a la capacidad de la red neuronal para generalizar a datos fuera de la muestra (Keskar 2016) como a la eficiencia computacional del proceso.
- La **tasa de aprendizaje**, o *learning rate*, es otro hiperparámetro importante que determina la magnitud de las actualizaciones de los pesos proporcional a la magnitud del gradiente. Tanto un *learning rate* alto como uno bajo tienen ventajas y desventajas:

¹⁵ El sesgo es un parámetro adicional que influye en el nivel de activación de la neurona en cuestión.

con un *learning rate* alto el algoritmo de optimización avanza con brincos más grandes y por lo tanto más rápidamente, pero estos mismos brincos en general no son óptimos para alcanzar el punto más bajo de mínimos locales; con un *learning rate* bajo el algoritmo avanza más lentamente y con brincos más pequeños, lo que le permite en general alcanzar puntos más bajos dentro de un mínimo local deseado. Sin embargo, los brincos pequeños pueden causar que el algoritmo se quede atorado en un mínimo local no deseado.

- Las **épocas**, representan el número de veces que el algoritmo de aprendizaje recorre todo el conjunto de datos, siendo un factor que determina cuanto tiempo y recursos se permitirá que la red utilice para aprender los patrones en los datos. Cada época es una combinación de una fase de *forward pass*, donde se hacen predicciones y se calcula la pérdida del modelo, y una fase de *backward pass*, donde se actualizan los pesos.

- (55) Cada uno de estos hiperparámetros debe seleccionarse y ajustarse cuidadosamente, ya que ejercen un impacto en la habilidad de la red neuronal para aprender efectivamente a partir de los datos y para generalizar a datos no vistos previamente por el modelo.
- (56) Las redes neuronales no son más que funciones matemáticas complejas y versátiles, lo que les permite mapear variables de entrada (datos) a variables de salida (predicciones y/o clasificaciones) de manera acertada. Dicha característica es esencial en la capacidad de la red neuronal para aprender y adaptarse a una amplia variedad de patrones y complejidades en los datos. Una red neuronal es un algoritmo aproximador de funciones. Para más detalle sobre esto se refiere al lector a Hornik et al. (1989), Yang et al. (2013), Goodfellow et al. (2016) y al Anexo 5.

3.3 Matriz de confusión y métricas de evaluación

- (57) Tras explorar la arquitectura de las redes neuronales, resulta esencial dirigir la atención hacia la evaluación del poder predictivo de estos modelos. En el aprendizaje automático supervisado, las métricas de evaluación son herramientas que permiten cuantificar el desempeño de los modelos de manera objetiva y comparativa. Una de estas métricas es el *accuracy*, la cual indica el porcentaje de predicciones acertadas por el modelo; sin embargo, esta métrica por sí sola es incapaz de brindar una imagen completa del rendimiento de la red neuronal. Por tal motivo, se utilizan otras métricas como la precisión, el *recall* y el estadístico F1 ya que proporcionan una visión más amplia del poder predictivo del modelo, resaltando áreas específicas de fortaleza y debilidad. El cálculo e interpretación de estas métricas se llevan a cabo comúnmente mediante una *matriz de confusión*.
- (58) Imaginemos que tenemos un modelo de red neuronal que ha sido entrenado para clasificar en dos categorías. Por ejemplo, clasificar si un usuario está suscrito al STAR o no. Una vez que el modelo ha hecho sus predicciones, éstas se contrastan con lo observado. La matriz de confusión es una tabla en el cual:

- Las etiquetas de las filas representan las categorías observadas.
- Las etiquetas de las columnas representan las categorías predichas por el modelo.

(59) La TABLA 4 presenta un ejemplo de matriz de confusión sobre la clasificación de usuarios según su suscripción. Cada celda de la tabla contrasta y cuantifica lo observado con lo predicho por el modelo. Por ejemplo, la celda superior izquierda de la tabla muestra el número de usuarios suscritos al STAR que correctamente fueron clasificados como suscriptores del STAR.

Tabla 4. Ejemplo de Matriz de Confusión

		Predicho	
		STAR	No STAR
Observado	STAR	10 (verdadero positivo, TP)	5 (falso negativo, FN)
	No STAR	10 (falso positivo, FP)	75 (verdadero negativo, TN)

Fuente: Elaboración propia.

(60) En la nomenclatura de matrices de confusión, un resultado positivo se refiere a observaciones predichas como STAR, negativo a observaciones predichas como No STAR, verdadero se refiere a observaciones clasificadas de manera correcta (lo predicho coincide con lo observado) y falso a observaciones clasificadas incorrectamente. Se observa que el modelo asociado a esta matriz clasificó a 10 de los usuarios de STAR como STAR (verdadero positivo, TP) y clasificó incorrectamente a 5 usuarios de este servicio como No STAR (falso negativo, FN). A su vez clasificó a 75 usuarios que no tenían acceso a este servicio como No STAR (verdadero negativo, TN), mientras que 10 usuarios que tampoco estaban suscritos fueron asignados a la categoría STAR (falso positivo, FP).

(61) A continuación, se presentan algunas de las métricas más comúnmente utilizadas para evaluar el desempeño del modelo al clasificar los datos. Para cada una de éstas, los valores cercanos a 1 indican un buen rendimiento y los valores cercanos a 0 indican un mal rendimiento.

- *Accuracy*: mide cuantas observaciones del total fueron clasificadas de manera correcta. En el ejemplo, el *accuracy* es de 85%, es decir, el 85% de los usuarios fueron clasificados en la categoría que pertenecen. La fórmula de cálculo es $accuracy = \frac{TP+TN}{TP+FP+TN+FN}$.
- Sensibilidad (*sensitivity, recall*): mide que tan bien se clasifican los usuarios que realmente eran suscriptores de STAR. La sensibilidad en este caso es 66.6%, es decir, dos de cada tres usuarios de STAR son clasificados correctamente. La fórmula de cálculo es $sensitivity = \frac{TP}{TP+FN}$.

- Especificidad (*specificity*): mide que tan bien se clasifican los usuarios que no tienen STAR. En el ejemplo, la especificidad es de 93.75%, es decir, 93.75% de los usuarios sin este servicio se clasificaron correctamente como No STAR. La fórmula de cálculo es $specificity = \frac{TN}{TN+FP}$.
- Precisión (*precision, positive predicted value*): mide que tan bien se clasifican los usuarios predichos como STAR. En el ejemplo, la precisión es de 50%, es decir, 50% de los usuarios que fueron predichos como suscriptores de STAR realmente lo eran. La fórmula de cálculo es $precision = \frac{TP}{TP+FP}$.
- F1 score: es la media armónica entre el *precision* y el *recall*.¹⁶ Esta métrica pondera tanto la capacidad de predecir correctamente dentro de los usuarios que están suscritos a STAR y dentro de aquellos usuarios que son predichos como suscriptores a STAR. La F1 también se puede interpretar como una ponderación entre el error tipo I y el error tipo II.¹⁷

3.4 Entrenamiento

- (62) Para el desarrollo y entrenamiento de los modelos, se emplearon software de código abierto, específicamente Keras y TensorFlow, librerías de aprendizaje profundo que fueron diseñadas para la construcción de redes neuronales. En términos de hardware, se utilizaron cuatro equipos de cómputo idénticos, cada uno equipado con un procesador Intel Xeon W-10885M de 2.4 GHz, que consta de 8 núcleos físicos y 16 subprocesos¹⁸, además de 32 GB de RAM. A continuación, se detallan los hiperparámetros y arquitecturas de las redes neuronales empleadas en este estudio.

Arquitectura y Entrenamiento del Modelo CENSO

- (63) Como se mencionó en la sección de Datos, el modelo utilizó 34 variables explicativas relacionadas con la composición familiar, la infraestructura, dispositivos y servicios TIC disponibles en la vivienda. El objetivo del modelo fue minimizar el error del modelo para clasificar a las viviendas que contratan los servicios STAR-OTT de manera acertada.
- (64) La TABLA 5 resume los principales hiperparámetros del modelo que presentó el mejor rendimiento para los datos del CENSO.

¹⁶ Existen varios tipos de medias, entre ellos: la armónica, la geométrica y la aritmética. Cada una tiene sus pros y contras. La media armónica se utiliza para promediar proporciones. Adicionalmente, la media armónica "castiga" a las proporciones muy cercanas al cero.

¹⁷ El error tipo I ocurre cuando se clasifican como STAR a aquellos usuarios que no están suscritos a este servicio y el error tipo II ocurre cuando no se clasifican como STAR a aquellos usuarios que sí lo utilizan.

¹⁸ Las librerías de TensorFlow y Keras están diseñadas para el cómputo en paralelo. Es decir, hacen uso de todos los *threads* (subprocesos) para llevar a cabo las multiplicaciones matriciales.

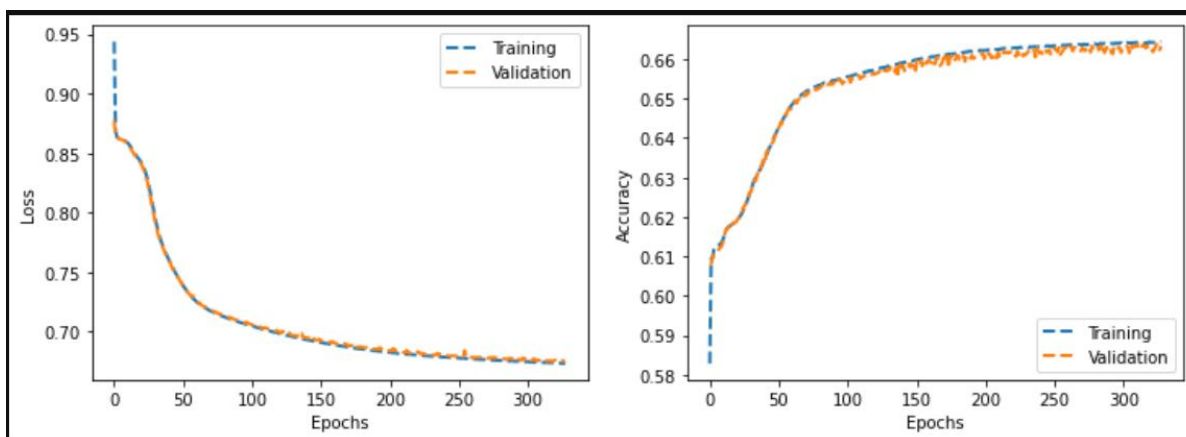
TABLA 5. ARQUITECTURA E HIPERPARÁMETROS DEL MODELO CENSO

Arquitectura del mejor modelo
<ul style="list-style-type: none">• <i>Optimizador</i>: Adam• <i>Función de activación</i>: Sigmoid• <i>Batch size</i>: 10,000• <i>Learning rate</i>: 0.001• <i>Nodos en la primera capa</i>: 34• <i>Capas ocultas</i>: 2• <i>Nodos en las capas ocultas</i>: (12,4)• <i>Función de pérdida</i>: categorical crossentropy• <i>Épocas</i>: ~350• <i>Tiempo</i>: ~12 minutos

Fuente: Elaboración propia.

- (65) La arquitectura final del modelo se definió después de la exploración metódica de diversas configuraciones de redes neuronales, con el objetivo de identificar la que ofreciera el mejor rendimiento en términos de poder predictivo. Se probaron más de 2,300 combinaciones distintas de arquitectura e hiperparámetros. Para esto, se variaron los optimizadores, funciones de activación, *batch size*, *learning rates*, número de capas y número de neuronas por capa.
- (66) Se experimentó con los optimizadores SGD, RMSprop y Adam. Asimismo, se exploraron dos funciones de activación: la sigmoide y la tangente hiperbólica (tanh), con el objetivo de investigar su impacto en la capacidad de la red para aprender y generalizar patrones en los datos.
- (67) El *batch size* y *learning rate* fueron ajustados con el objetivo de equilibrar la eficiencia computacional y la convergencia del modelo durante el entrenamiento. Se exploraron distintos tamaños de batch size: 10,000, 50,000 y 100,000, así como *learning rates*: 0.05, 0.01, 0.005, 0.001.
- (68) El modelo final fue seleccionado basándonos en el *accuracy* tanto de entrenamiento como de validación. La FIGURA 9 muestra el comportamiento de la función de pérdida y *accuracy* del modelo final del CENSO a lo largo de sus épocas de entrenamiento.

FIGURA 9. FUNCIÓN DE PÉRDIDA Y ACCURACY DEL MODELO CENSO



Fuente: Elaboración propia con base en los resultados del entrenamiento.

- (69) La gráfica de la función de pérdida (*loss*) en la parte izquierda de la FIGURA 9 muestra que el error del conjunto de entrenamiento (*training*) y el conjunto validación va disminuyendo durante el entrenamiento de la red neuronal. Ambas curvas siguen la misma tendencia, lo que indica que los patrones aprendidos por la red neuronal de los datos de entrenamiento permiten generalizar su poder predictivo a los datos sobre los cuales no se entrenó (conjunto de validación). La gráfica del nivel de *accuracy* revela que el modelo llega a tener un poder predictivo por arriba del 66%. Como referencia, un modelo que aleatoriamente clasifica a observaciones en cuatro categorías tendría un *accuracy* de 25% en promedio. En este sentido, la red neuronal entrenada para el CENSO es significativamente superior al *benchmark* de comparación.

Arquitectura y Entrenamiento del Modelo ENDUTIH

- (70) Para los datos de las ENDUTIH, se entrenaron dos redes neuronales de clasificación dicotómica: una para clasificar a los hogares como detentores del STAR y otro para clasificarlos como usuarios de OTT¹⁹. En el modelo STAR se utilizaron 76 variables explicativas que capturan diferentes características del hogar, como número de residentes, características sociodemográficas de los integrantes, información sobre el jefe del hogar y disponibilidad de servicios y dispositivos TIC. Para el modelo OTT, se utilizaron las 76 variables explicativas del modelo STAR más 47 variables adicionales sobre hábitos del residente de hogar que contestó el apartado “Usuario” de la ENDUTIH. Estas últimas variables miden el lugar e intensidad de uso de los servicios y dispositivos TIC.

¹⁹ La variable STAR mide disponibilidad en el hogar y la variable OTT mide uso por un residente del hogar, como se explica en la sección de Datos. Esta distinción debe tomarse en cuenta al interpretar los resultados de los modelos.

(71) La TABLA 6 ilustra la arquitectura e hiperparámetros finales utilizados para entrenar las redes neuronales para el OTT y para el STAR.

TABLA 6. ARQUITECTURA E HIPERPARÁMETROS DEL MODELO ENDUTIH

Arquitectura para Modelo OTT	Arquitectura para Modelo STAR
<ul style="list-style-type: none"> • Optimizador: <i>Adam</i> • Función de activación: <i>Leaky ReLU</i> • Batch size: 32 • Learning rate (LR): 0.002 • LR exponential decay: 0.95 • Nodos en la primera capa: 123 • Capas ocultas: 5 • Nodos en las capas ocultas: (128, 256, 128, 64, 32) • Parámetros: 92,194 • Función de pérdida: <i>categorical crossentropy</i> • Épocas: 40 • Tiempo: ~150 minutos 	<ul style="list-style-type: none"> • Optimizador: <i>Adam</i> • Función de activación: <i>Leaky ReLU</i> • Batch size: 32 • Learning rate (LR): 0.002 • LR exponential decay: 0.95 • Nodos en la primera capa: 76 • Capas ocultas: 5 • Nodos en las capas ocultas: (128, 256, 128, 64, 32) • Parámetros: 86,178 • Función de pérdida: <i>categorical crossentropy</i> • Épocas: 60 • Tiempo: ~90 minutos

Fuente: Elaboración propia.

(72) Si bien para llegar a la configuración final del modelo CENSO se experimentó con miles de combinaciones de arquitecturas e hiperparámetros, este proceso no fue necesario para los modelos STAR y OTT de la ENDUTIH²⁰.

(73) El lector perspicaz notará que las gráficas de función de pérdida y *accuracy* para las redes neuronales ENDUTIH son cualitativamente distintas a aquella de la red neuronal del CENSO. Mientras que en la FIGURA 9 las curvas de entrenamiento y validación siguen casi exactamente la misma tendencia, en las FIGURAS 10 Y 11 las dos curvas inician pegadas antes de la época 50 y posteriormente divergen. Esto se debe a dos razones:


- i. En la literatura de estadística existe el concepto de *bias-variance tradeoff*. entre más complejo sea el modelo, menor es el sesgo y mayor es la varianza de sus predicciones y viceversa. Para la ENDUTIH se construyen intencionalmente modelos “complejos” en el sentido de tener numerosos parámetros: 92,194 para OTT y 86,178 para STAR. El riesgo de construir redes tan grandes es que tienden a sobreajustarse a los datos si se entrenan por muchas épocas. El sobreajuste es

²⁰ De acuerdo con la experiencia del equipo de trabajo que desarrolló el modelo CENSO, la variabilidad en el poder predictivo de los más de 2,300 redes neuronales fue muy baja. Es decir, aunque técnicamente algunas arquitecturas resultan en mejoras cuantitativas en el poder predictivo, éstas no son lo suficientemente altas como para justificar los costos en los que se incurren al probar miles de arquitecturas para llegar a la arquitectura “óptima”.

visualmente observable en las FIGURAS 10 Y 11 como la divergencia entre las curvas a partir de las épocas 60 y 40 para STAR y OTT, respectivamente.

- ii. El entrenamiento de las redes neuronales se dejó corriendo hasta la época 10,000 (no mostrado en las gráficas) para intentar (sin éxito) alcanzar a la zona de *deep double descent*²¹.

FIGURA 10. FUNCIÓN DE PÉRDIDA Y ACCURACY DEL MODELO STAR




Fuente: Elaboración propia con base en los resultados del entrenamiento.

- (74) La FIGURA 10 muestra que mientras la pérdida de entrenamiento baja constantemente y el *accuracy* de entrenamiento sube constantemente, esto no sucede con su contraparte de validación. Es decir, posteriormente a la época 60 las curvas divergen y el modelo se sobreajusta a los datos. En la FIGURA 11, esto sucede aproximadamente a partir de la época 40. Como se detalla en la TABLA 6, para los modelos OTT y STAR, se utilizaron los valores de los parámetros de las redes neuronales en las épocas 40 y 60, respectivamente, antes de las zonas de sobreajuste.

²¹ En la teoría clásica estadística, modelos grandes entrenados por mucho tiempo llevan a sobreajuste. Esto daña la capacidad para generalizar de los modelos. Sin embargo, el fenómeno de *deep double descent* muestra que, bajo ciertas condiciones, aumentar la cantidad de datos, el tamaño del modelo y el tiempo de entrenamiento lleva a una mejora inesperada en la pérdida del conjunto de validación. Para más detalles sobre este fenómeno ver Nakkiran (2019) y Lafon et al. (2022).

FIGURA 11. FUNCIÓN DE PÉRDIDA Y ACCURACY DEL MODELO OTT



Fuente: Elaboración propia con base en los resultados del entrenamiento.

4. Resultados

4.1 Resultados CENSO

(75) Como principal resultado, el modelo con datos del CENSO 2020 no es lo suficientemente preciso para distinguir satisfactoriamente entre las diferentes categorías, aun cuando se haya utilizado la red neuronal con el mejor rendimiento. La FIGURA 12 muestra la matriz de confusión del modelo del CENSO 2020 que fue utilizado para clasificar a los hogares en cuatro categorías:

- NINGUNO: El hogar no tiene ni STAR ni OTT.
- TV de Paga: El hogar tiene TV de paga, pero no OTT.
- OTT: El hogar tiene OTT, pero no TV de Paga.
- AMBOS: El hogar tienen tanto TV de Paga como OTT.

(76) Se observa que el 83.57% de las observaciones sin uso de STAR ni OTT (renglón “ninguno”) fueron correctamente clasificadas (columna “ninguno”). No obstante, el modelo tuvo problemas al discernir entre otras categorías, llegando incluso a clasificar adecuadamente sólo al 0.10% de las observaciones de hogares que consumían OTT. El modelo clasifica a los hogares con sólo OTT en TV de paga o “ambos”. Es por esto por lo que el modelo tiene un *accuracy* de sólo 0.66.

TABLA 7. MATRIZ DE CONFUSIÓN DEL MEJOR MODELO OTT-STAR (CENSO 2020)

		PREDICHO			
		Ninguno	TV de Paga	OTT	Ambos
OBSERVADO	Ninguno	83.57% (1,759,475)	14.98% (315,546)	0.00% (91)	1.4% (30,061)
	TV de Paga	52.35% (576,968)	42.16% (464,677)	0.00% (71)	5.46% (60,232)
	OTT	16.10% (13,559)	44.70% (37,633)	0.10% (143)	39.01% (32,847)
	Ambos	5.8% (12,151)	45.70% (95,389)	0.00% (113)	48.41% (101,044)

Fuente: Elaboración propia. Los porcentajes mostrados suman cien por fila.

(77) Adicionalmente, el modelo tiene bajo poder predictivo para los hogares que tienen contratado STAR y OTT, pues el 45.70% de los hogares fueron erróneamente clasificados dentro de la categoría “TV de paga” como se aprecia en la matriz de confusión. Las limitaciones principales del modelo son las siguientes:

- Al 52.35% de hogares con sólo TV de paga los clasifica como “ninguno”. Para mejorar el poder predictivo para este servicio se necesitarían variables que distingan a los hogares con TV de paga de aquellos sin el servicio.
- Al 99.9% de los hogares con OTT son erróneamente clasificados en las categorías de hogares *sin* OTT. Esto es un indicio claro de la falta de información relevante para la buena predicción del consumo de contenido audiovisual por internet.
- Más del 50% de los hogares con “ambos” son mal clasificados como hogares *sin* OTT. Esto también apunta a la carencia de datos correlacionadas, positiva o negativamente, con el consumo de OTT.

4.2 Resultados ENDUTIH

(78) Para los datos de las ENDUTIH 2015-2022 se elaboraron dos modelos: uno predice la probabilidad de que un usuario en el hogar consuma OTT audiovisual; el otro predice la probabilidad de que se tenga contratado STAR en el hogar. Estos modelos superaron por mucho en poder predictivo al modelo con datos del CENSO a pesar de que este último empleó 4 millones de datos mientras que las redes neuronales de ENDUTIH emplearon aproximadamente 650,000 datos.

4.2.1 Resultados OTT

(79) La FIGURA 12 muestra la matriz de confusión del modelo OTT. Esta tabla de tres por tres se interpreta de la siguiente manera:

- 1 significa que el usuario del hogar consume OTT y 0 que no.
- Los títulos de columna se refieren a lo observado sobre los hogares encuestados.
- Los títulos de fila se refieren a lo predicho por el modelo.

- La fila y la columna con Σ (sigma) representan las sumas por columna y por fila, respectivamente.
- Los números en el centro de cada celda representan los porcentajes y conteos respecto al total de observaciones.
- Los porcentajes en la parte inferior de cada celda representan el porcentaje respecto a la columna en cuestión.
- Los porcentajes en la parte derecha de cada celda representan el porcentaje respecto a la fila en cuestión.

FIGURA 12. MATRIZ DE CONFUSIÓN - OTT

		OBSERVADO		
		1	0	Σ
PREDICHO	1	16.6% 108661 68.9%	6.4% 41578 8.4%	23% 150239
	0	7.5% 49130 31.7%	69.5% 454125 91.6%	77% 503255
	Σ	24.1% 157791	75.9% 495703	653494

Fuente: Elaboración propia.

(80) De la tabla se puede deducir que de los 653,494 hogares encuestados, 24.1% tienen por lo menos a un integrante que consume OTT mientras que el modelo predijo que 23% de los hogares consumen OTT. De los 157,951 hogares que consumen OTT, 68.9% fueron correctamente clasificados como consumidores de OTT y de los 495,703 hogares que no consumen OTT, 91.6% fueron correctamente clasificados como *no consumidores* de OTT. La TABLA 8 resume algunas estadísticas del poder predictivo de la red neuronal.

TABLA 8. MÉTRICAS DE EVALUACIÓN - OTT

Métrica	Valor
Accuracy	86.1%
Precision (Positive Predictive Value)	72.3%
Sensitivity/Recall (True Positive Rate)	68.9%
F1	70.6%
Specificity (True Negative Rate)	91.6%
Error Tipo I	8.4%
Error Tipo II	31.1%

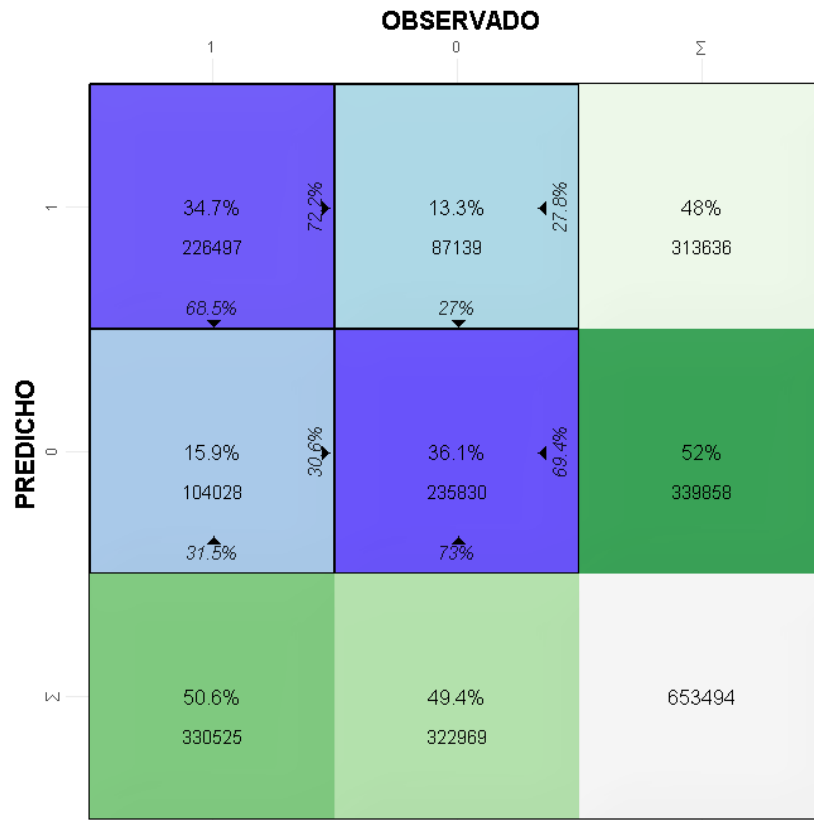
Fuente: Elaboración propia.

- (81) Primero, se vuelven a visitar las definiciones las métricas de la TABLA 7 y posteriormente las interpretamos. *Accuracy* es el porcentaje del total que se clasificó correctamente. *Precision* es el porcentaje de los predichos como consumidores de OTT que se clasificó correctamente. *Sensitivity* es el porcentaje de hogares consumidores de OTT que se clasificó correctamente. F1 es una ponderación entre *precision* y *sensitivity*. *Specificity* es el porcentaje de hogares no consumidores de OTT que se clasificó correctamente. Finalmente, el error tipo I es el porcentaje de hogares no consumidores de OTT que se clasificó erróneamente como consumidores de OTT y el error tipo II es el porcentaje de hogares consumidores de OTT que se clasificaron erróneamente como *no consumidores* de OTT.
- (82) Partiendo de lo anterior se puede decir que la red neural para OTT tiene un poder predictivo general (*accuracy*) elevado de 86.1%. Si bien en tareas como el reconocimiento de imágenes el *accuracy* de los modelos de aprendizaje de máquina puede llegar a ser 95-98%, en el dominio de las ciencias sociales el *accuracy* no suele ser tan alto. El modelo es bueno para predecir cuándo un hogar no consume OTT (*specificity*=91.6% y error tipo I = 8.4%). Sin embargo, la tasa de error tipo II elevada indica que el modelo falla con una tasa de 31.1% al clasificar a los hogares consumidores de OTT como hogares *no consumidores* de OTT.

4.2.2 Resultados STAR

- (83) De acuerdo con la FIGURA 13, de los 653,494 hogares encuestados, el 50.6% tiene contratado el STAR mientras que el modelo predice que 48% de los hogares tienen STAR. Este modelo tiene un *accuracy* de 70.8%, inferior al *accuracy* del modelo OTT.

FIGURA 13. MATRIZ DE CONFUSIÓN – STAR



Fuente: Elaboración propia.

(84) Cuando un hogar no tiene contratado el STAR, esta red neuronal lo predice correctamente con una tasa de 73% y cuando sí tiene contratado el STAR lo predice correctamente con una tasa de 68.5%. Sin embargo, el error tipo I y el error tipo II son 27% y 31.5%, respectivamente. Una posible explicación del poder predictivo no tan elevado de esta red neuronal es la falta de información sobre preferencias de contenido audiovisual. Por ejemplo, aumentaría la capacidad de la red para predecir STAR si se contara con información sobre los gustos de los integrantes del hogar (telenovelas, series, películas, noticias, etc.).

TABLA 9. MÉTRICAS DE EVALUACIÓN – STAR

Métrica	Valor
Accuracy	70.8%
Precision (Positive Predictive Value)	72.2%
Sensitivity/Recall (True Positive Rate)	68.5%
F1	70.3%
Specificity (True Negative Rate)	73.0%
Error Tipo I	27.0%
Error Tipo II	31.5%

Fuente: Elaboración propia.

- (85) La TABLA 9 muestra que el modelo clasifica mejor a los hogares que no cuentan con STAR (*specificity* = 73%) que a los hogares que sí (*sensitivity* = 68.5%). Este resultado es similar a la red neuronal entrenada con datos del Censo 2020 en el sentido de que ambos modelos clasifican mejor a los hogares que no cuentan con servicios e indica que los datos contenidos tanto en la ENDUTIH como el CENSO tienen información sobre características del hogar *necesarias* para el uso de STAR-OTT pero no *suficientes* para el uso de STAR-OTT. Por ejemplo, las variables de dispositivos TIC (laptop, TV digital, celular) en el hogar se pueden considerar variables *necesarias* pero no *suficientes* para el OTT: si el hogar no cuenta con esos dispositivos no puede consumir OTT (el dispositivo es *necesario*) pero aun cuando el hogar cuente con esos dispositivos, sus integrantes pueden decidir no consumir OTT (los dispositivos no son *suficientes* para predecir el consumo de OTT). Por estas razones, se considera que las bases de datos utilizadas carecen de información relevante sobre las preferencias y hábitos de los integrantes de los hogares *suficientes* para predecir el consumo de OTT.
- (86) Por último, en la FIGURA A7.1 del Anexo 7 se puede observar cómo el poder predictivo, medido por el *accuracy*, es mayor cuando el modelo tiene alta certidumbre sobre la clase a predecir. Es decir, cuando el modelo arroja probabilidades cercanas a 0 o a 1 (baja incertidumbre) el *accuracy* está por arriba de 0.9 y cuando el modelo arroja probabilidades entre 0.4-0.6 (alta incertidumbre) su *accuracy* está cerca del 0.5 (un volado).

5. Inferencia y Efectos Marginales

(87) Una red neuronal entrenada se puede emplear para obtener las probabilidades de uso de OTT y de la contratación de STAR para todas las observaciones de la encuesta y también para hogares hipotéticos fuera de la muestra²². Por ejemplo, la red neuronal de OTT nos indica qué tan probable es que un hogar hipotético compuesto por 5 integrantes, 2 adultos y 3 menores de edad, con laptop, internet y TV digital utilice algún servicio audiovisual OTT. Lo útil del modelo estadístico es que este hogar puede ser o no observado en la ENDUTIH. Posteriormente, se puede hacer inferencia sobre qué sucedería con la probabilidad del uso de OTT si, por ejemplo, el hogar no contara con internet o tuviera más integrantes adolescentes. En las siguientes secciones se exponen los resultados de la aplicación de las técnicas de componentes principales y de análisis de clúster para encontrar perfiles de hogares. Adicionalmente, se muestran los efectos marginales de algunas variables importantes sobre las probabilidades de contratación de STAR y uso de OTT.

5.1 Perfiles de Hogares

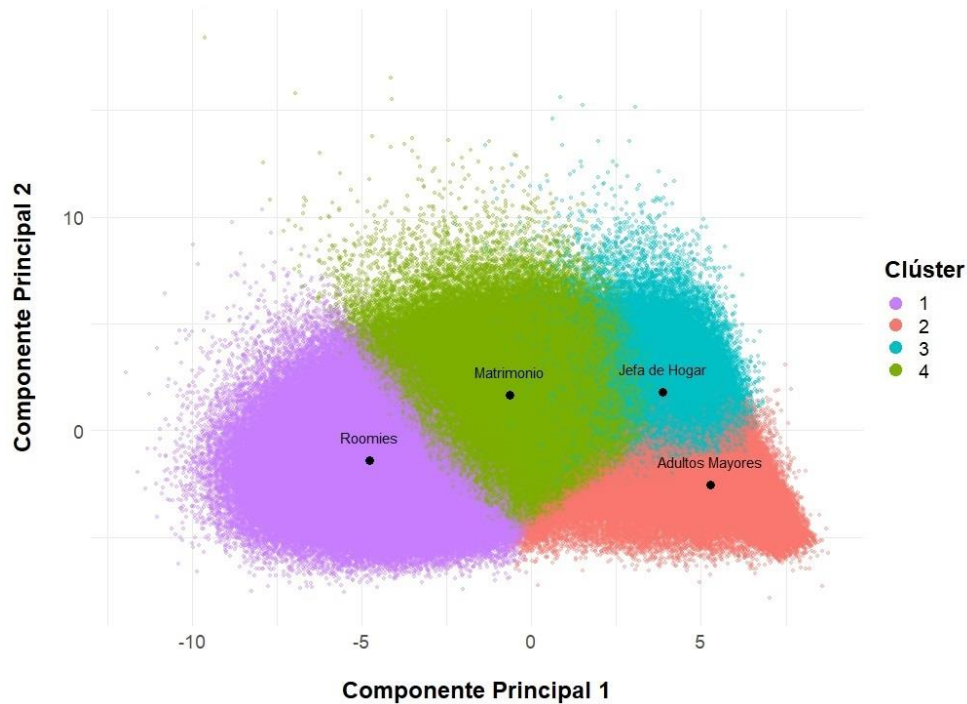
- (88) La obtención de perfiles de hogares se llevó a cabo en dos etapas. El primer paso fue reducir la dimensionalidad de la información de los hogares y usuarios mediante un análisis de componentes principales (PCA). En la base de datos utilizada para la predicción del uso de OTT se cuenta con 122 características y éstas fueron reducidas a 73 componentes (transformación de las características). En la base de datos utilizada para la predicción del uso de STAR se cuenta con 76 características y éstas fueron reducidas a 46 componentes.
- (89) Posteriormente se realizó un análisis de clúster de *k-means*²³ sobre estos componentes (que en esencia representan las características de los hogares en México) con el cual se identificaron cuatro clústeres. Cada uno de estos clústeres tiene un centro, o punto representativo²⁴, que se puede interpretar como un perfil de hogar una vez que las coordenadas de estos puntos se traducen del espacio de componentes principales al espacio original de características de hogar. Los clústeres que se identificaron son los siguientes:
- i. Hogar de pareja con hijos menores (“Matrimonio”)
 - ii. Jefa de hogar con hijos y sin pareja (“Jefa de Hogar”)
 - iii. Hogar de personas jóvenes (“Roomies”)
 - iv. Pareja de adultos mayores (“Adultos Mayores”).

²² Claro que esto depende la capacidad del modelo para generalizar y extrapolar. De acuerdo con la sección de resultados, el poder predictivo dentro de la muestra (datos de entrenamiento) de las redes neuronales entrenadas está al mismo nivel que su poder predictivo fuera de la muestra.

²³ *K-means* es un algoritmo de aprendizaje no supervisado que minimiza la varianza de distancias entre cada clúster y los miembros de ese clúster. En términos simples, encuentra agrupaciones de datos donde los miembros de cada grupo sean similares entre sí.

²⁴ Técnicamente “centroide” definido como el punto cuyas coordenadas son el promedio de cada una de las dimensiones o componentes principales de todos los puntos que pertenecen al clúster.

FIGURA 14. CLÚSTERES Y PERFILES DE HOGAR PARA OTT



Fuente: Elaboración propia con base en los resultados del PCA.

Nota: Los componentes principales 1 y 2 son los dos con mayor varianza.

- (90) Una representación visual del PCA con los datos utilizados para el modelo OTT se muestra en la FIGURA 14²⁵. Cada punto representa un hogar de la ENDUTIH. Como se puede observar, la separación no es muy nítida ya que los clústeres están traslapados en sus fronteras. A pesar de que en estas dos dimensiones la separabilidad no sea tan clara, todos estos puntos residen en un espacio de 123 dimensiones (variables, características) donde sí tienen una separación más marcada. Es decir, a pesar de que los componentes principales carezcan (en este caso) de interpretabilidad,²⁶ si se pudieran graficar todos los hogares bajo todos los componentes principales, se observarían más ejes de diferenciación entre clústeres y perfiles de hogar.
- (91) El análisis de clúster se implementó con los datos de la red neuronal para STAR y con los datos de la red neuronal para OTT. En ambos casos se llegó al mismo número de clústeres y con características muy similares. Sin embargo, la distribución de hogares de la encuesta que cae dentro de estos clústeres difiere ligeramente. La TABLA 10 muestra que para STAR,

²⁵ Ver Anexo 4 para la gráfica análoga con los datos de STAR.

²⁶ En otras aplicaciones, las variables pueden tener *loadings* cargadas hacia ciertos componentes principales. Esto le otorga un significado a cada componente. Por ejemplo, aunque no sea el caso en este estudio, podría ser que el componente principal 1 esté asociado a las variables de composición familiar y el componente principal 2 a las variables de nivel socioeconómico.

el matrimonio con hijos menores constituye un 32% de los hogares, ejemplificando la estructura nuclear tradicional y una adaptación significativa a la tecnología. Las Jefas de Hogar, con su dinámica familiar extendida y monoparental, representan el 21%. Los *Roomies*, jóvenes adultos que comparten vivienda, conforman el 25% de la muestra, destacándose por su alta integración tecnológica y diversidad educativa. Finalmente, la pareja de Adultos Mayores abarca un 22%, reflejando la etapa de vida post-laboral con un uso limitado de tecnología.

- (92) En contraste, en el contexto OTT, los porcentajes varían de la siguiente manera: Matrimonio 34%, Jefa de Hogar 18%, *Roomies* 30%, y Adultos Mayores 18%. Esta distribución resalta las diferencias y similitudes en las composiciones familiares y su adopción tecnológica entre los dos contextos, ofreciendo una visión amplia de la estructura de hogares en México. Estos datos son fundamentales para comprender la diversidad y las tendencias predominantes en los hogares mexicanos.

TABLA 10. DISTRIBUCIÓN PORCENTUAL DE LOS PERFILES DEL HOGAR

Distribución de los Hogares para STAR (%)			
Matrimonio	Jefa de Hogar	<i>Roomies</i>	Adultos Mayores
32%	21%	25%	22%
Distribución de los Hogares para OTT (%)			
Matrimonio	Jefa de Hogar	<i>Roomies</i>	Adultos Mayores
34%	18%	30%	18%

Fuente: Elaboración propia con base en los resultados del modelo STAR-OTT (ENUDITH)

- (93) El primer hogar, presente en ambos contextos, consiste en un matrimonio entre una pareja de 36 a 40 años con dos hijos menores de 0 a 5 años. Este núcleo familiar ejemplifica la estructura familiar tradicional en un entorno urbano. Respecto a la educación, se observa que uno de los padres ha completado la educación básica y el otro la media superior, mientras que los niños aún no han iniciado su formación académica.
- (94) En el ámbito tecnológico, hay diferencias significativas entre los hogares STAR y OTT. Bajo STAR, el hogar está equipado con una computadora de escritorio y tiene acceso a internet fijo. En contraste, el hogar OTT carece de estos recursos. Sin embargo, en ambos casos, tres miembros de la familia utilizan activamente internet y celulares, y disponen de televisión tanto analógica como digital, lo que indica una inclinación hacia la conectividad inalámbrica y móvil.
- (95) El segundo hogar, igualmente representativo en ambos contextos STAR y OTT, es liderado por una madre soltera de 41 a 45 años, con tres hijos. Este hogar resalta por su estructura familiar extendida y monoparental. En educación, tres miembros han alcanzado la educación básica y dos la media superior. Tecnológicamente, el hogar STAR incluye

computadora e internet fijo, a diferencia del hogar OTT. No obstante, en ambos, dos integrantes hacen uso regular de internet.

- (96) En ambos hogares, los padres están empleados, con la madre como jefa de hogar, lo que subraya su importancia en la gestión doméstica y la aportación económica. Además, ambos cuentan con electrodomésticos esenciales como refrigerador y lavadora, evidenciando un nivel de comodidad y funcionalidad doméstica.
- (97) Otro de estos hogares en ambos contextos se compone de dos varones de edades comprendidas entre los 16 y 20 años y de 21 a 25 años, junto con una mujer en el rango de 21 a 25 años. Este perfil refleja la dinámica de los *Roomies*, jóvenes adultos que compaginan sus estudios con el trabajo, viviendo juntos en un departamento. Este grupo se caracteriza por la posesión de dispositivos móviles, computadoras y tabletas, reflejando un nivel de educación que varía desde el bachillerato hasta estudios universitarios, acorde a sus edades. En cuanto a la conectividad, todos son usuarios activos de internet.
- (98) El último hogar, representativo en ambos contextos STAR y OTT, está formado por dos adultos mayores, una mujer y un hombre, ambos superando los 61 años. La educación promedio en este núcleo es diversa: uno cuenta con educación básica y el otro no posee estudios formales. Uno de ellos se mantiene activo en la fuerza laboral. A pesar de las diferencias generacionales, ambos utilizan teléfonos móviles y al menos uno se beneficia del acceso a internet. La edad promedio del jefe de familia en este grupo es de 68 años.
- (99) En todos los grupos de hogares, a pesar de las diferencias en composición y tecnología, se destaca la presencia de teléfonos móviles y de electrodomésticos básicos como el refrigerador y la lavadora, lo cual demuestra que ciertas comodidades son comunes en la mayoría de los hogares analizados.

5.2 Efectos Marginales

- (100) A partir de tomar a un perfil de hogar como punto de partida, se calcula su probabilidad de uso de OTT o de contratación de STAR. El siguiente paso consiste en variar una característica del hogar de interés, manteniendo el resto de las características constantes. De esta manera, se puede obtener el cambio en la probabilidad de uso de algún servicio por parte del hogar derivado del aumento o disminución en el valor de una de sus características. Hay tres variantes de este cálculo de acuerdo con Wooldridge (2010) y Greene (2012):
 - i. **Efecto marginal promedio**²⁷. Para cada hogar de la encuesta se calcula el efecto marginal sobre la probabilidad de uso de algún servicio derivado de la variación del

²⁷ Este cálculo es computacionalmente costoso, en particular cuando se cuenta con un gran número de variables y de observaciones.

valor de una de sus características. Posteriormente se promedian todos estos efectos marginales.

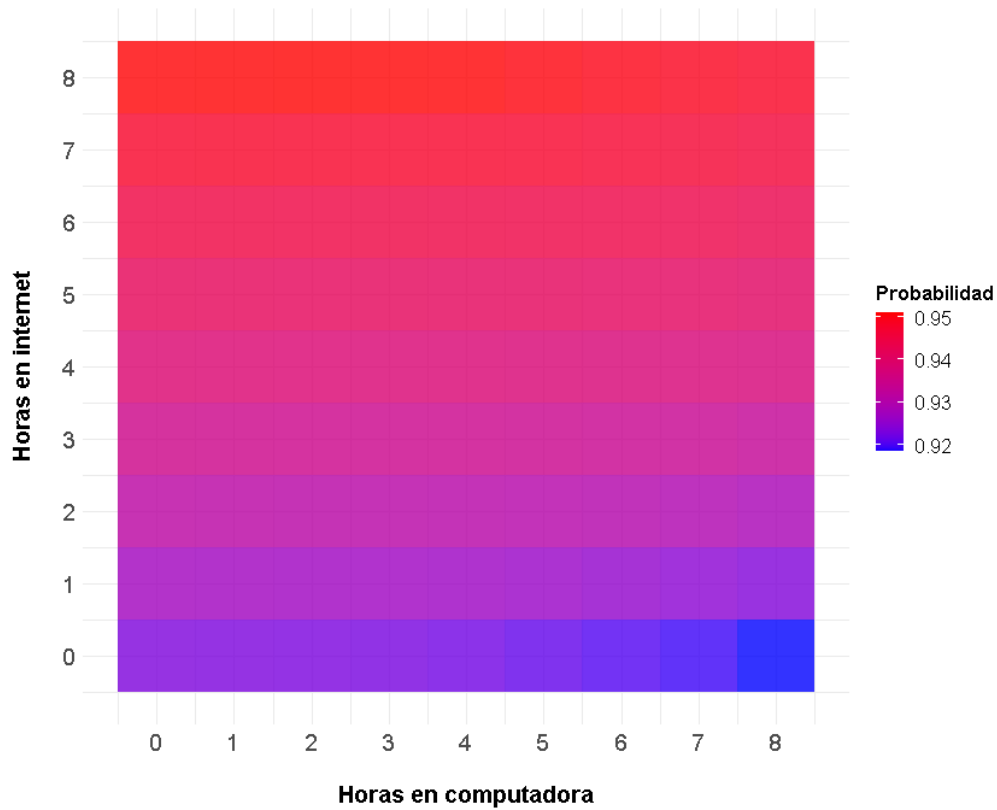
- ii. **Efecto marginal en el promedio**²⁸. Para un hogar con características promedio se calcula el efecto marginal sobre la probabilidad de uso de algún servicio derivado de la variación del valor de una de sus características.
- iii. **Efecto marginal en los valores representativos**. Para algún hogar típico o característico, se calcula el efecto marginal sobre la probabilidad de uso de algún servicio derivado de la variación del valor de una de sus características.

(101) Dados los costos computacionales del efecto marginal promedio (debido a que la red neuronal tiene decenas de miles de parámetros) y dado que los datos utilizados contienen muchas variables dicotómicas, en este estudio se eligió calcular efectos marginales en los valores representativos. Estos valores representativos son justamente los perfiles de hogar que se encontraron en la sección anterior.

(102) Para el hogar representativo *Roomies*, el tiempo promedio de uso de internet y computadora son 6 y 4 horas respectivamente. La FIGURA 15 muestra una gráfica de calor de las probabilidades de utilizar OTT para este perfil de hogar dependiendo las horas en computadora y en internet de sus integrantes, donde los colores más cercanos al rojo indican una probabilidad mayor de usar OTT.

²⁸ El promedio de una característica no es adecuado cuando se tienen variables dicotómicas en el modelo.

FIGURA 15. PROBABILIDAD DE USO DE OTT PARA EL PERFIL ROOMIES




Fuente: Elaboración propia con base en los resultados del modelo OTT (ENUDITH).

(103) En la figura anterior es posible observar dos fenómenos; por un lado, cambios en el número de horas de internet afectan más la probabilidad de utilizar OTT que cambios en el número de horas de computadora (el cambio de color es más notorio verticalmente que horizontalmente). A pesar de lo anterior, las probabilidades en el espacio de la gráfica de calor se mantienen entre 92% y 95%. Esto quiere decir que las horas de uso de internet y computadora no son un factor tan importante en el uso o no de OTT para el perfil de hogar *Roomies*.

(104) La FIGURA 16 muestra la probabilidad de que el perfil de hogar Matrimonio tenga contratado el STAR en función del número de hijos e hijas que tienen. Se puede observar que la probabilidad más baja (aproximadamente 70%) corresponde al hogar con sólo una hija y la probabilidad más alta (aproximadamente 77% y marcado en un cuadro con bordes amarillos) corresponde a los matrimonios con 3 hijas y 3 hijos. Estos resultados aportan evidencia de que la cantidad de hijos es un factor relevante en la decisión del hogar sobre la contratación de STAR.


FIGURA 16. PROBABILIDAD DE USO DE STAR PARA EL PERFIL MATRIMONIO



Fuente: Elaboración propia con base en los resultados del modelo STAR (ENUDITH).

(105) Por otra parte, también se analiza la probabilidad de adopción de los servicios STAR y OTT en los cuatro perfiles de hogar a lo largo del tiempo. Las probabilidades estimadas para los periodos 2012-2014 y 2023-2025 son extrapolaciones fuera de la muestra dado que las redes neuronales sólo se entrenaron con datos de 2015-2022.


FIGURA 17. PROBABILIDAD DE CONTRATO DE STAR POR PERFIL (PERIODO 2012-2025)



Fuente: Elaboración propia con base en los resultados del modelo STAR (ENUDITH).

- (106) Resaltan dos aspectos principales de la FIGURA 17. Primero, si bien la probabilidad para el perfil de hogar Adultos Mayores disminuye del 2018 al 2020, ésta se mantiene constante posteriormente. Segundo, para el resto de los perfiles de hogar (*Roomies*, Matrimonio y Jefa de Hogar), la probabilidad de contratación de STAR disminuye de manera constante durante todo el periodo analizado. Esto último resultado alude a que los hogares del tipo Adultos Mayores conservan en cierta medida la contratación de este servicio y su preferencia por el mismo, mientras que el resto de los hogares están “cortando el cable”.
- (107) La probabilidad de uso de OTT para los cuatro perfiles durante el mismo periodo se muestra en la FIGURA 18. Esta figura muestra que, para los perfiles Jefa de Hogar y Adultos Mayores, el uso de OTT no ha sido y no será prevalente (al menos en el periodo analizado). Para el perfil *Roomies* la probabilidad de uso de OTT aumenta drásticamente del 2012 al 2016 para después estabilizarse alrededor del 95%. Por otro lado, las probabilidades para el perfil Matrimonio muestran un incremento paulatino. Esto sugiere que los hogares con perfil de *Roomies* tuvieron una rápida adopción del servicio y han llegado a un punto de saturación, mientras que los hogares con perfil Matrimonio están en proceso de adopción.

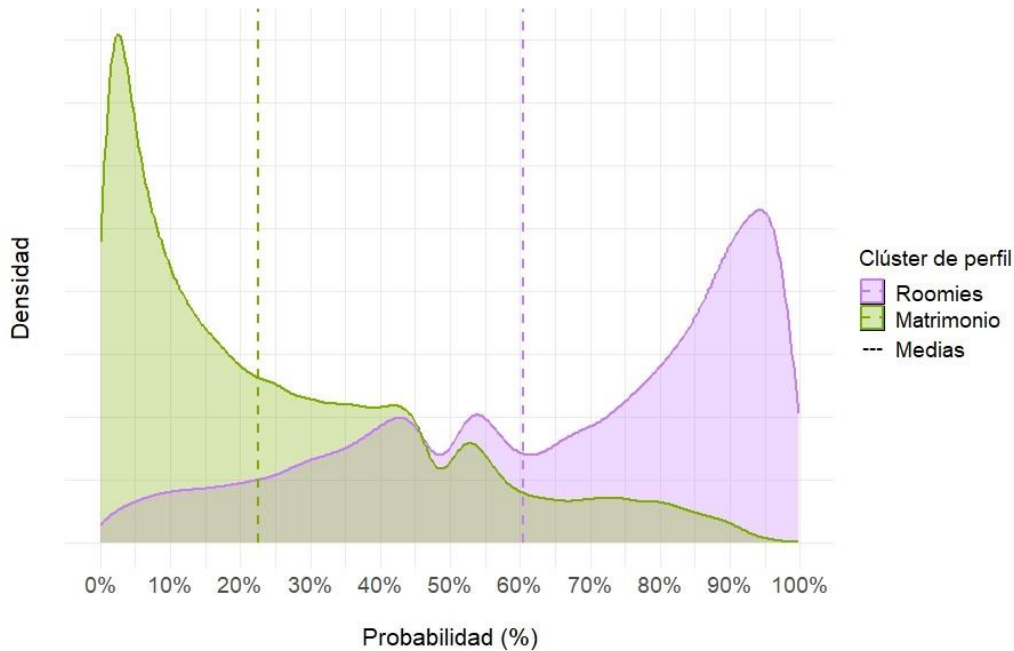
FIGURA 18. PROBABILIDAD DE USO DE OTT POR PERFIL (PERIODO 2012-2025)



Fuente: Elaboración propia con base en los resultados del modelo OTT (ENUDITH).

(108) Para profundizar un poco más sobre este último resultado, la FIGURA 19 muestra la distribución de probabilidades de uso de un OTT en los perfiles de hogares *Roomies* y *Matrimonio* para todos los hogares observados en la ENDUTIH 2015-2022. Se omiten de esta gráfica los perfiles de *Jefa de Hogar* y *Adultos Mayores* debido a que más del 95% de estos hogares tienen probabilidad de uso de OTT inferior al 5%.

FIGURA 19. PROBABILIDADES DE USO OTT EN EL HOGAR – ENDUTIH 2015-2022



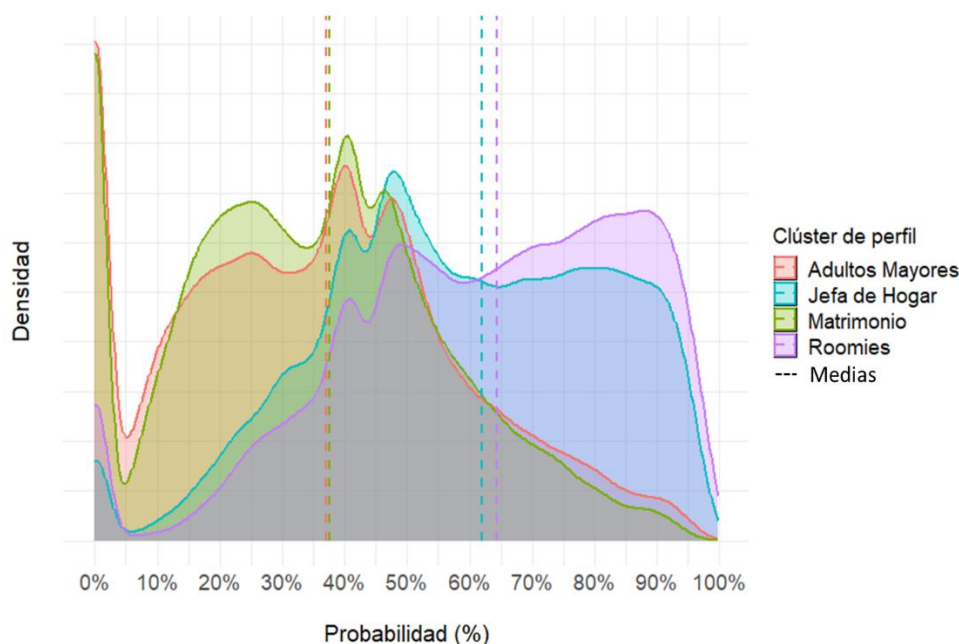
Fuente: Elaboración propia con base en los resultados del modelo OTT.

Nota: Las frecuencias utilizadas para generar estas distribuciones están ponderadas por los factores de usuario de la ENDUTIH.

- (109) En la imagen anterior destaca la gran diferencia entre las probabilidades de uso de OTT de los hogares de la encuesta que pertenecen al perfil *Roomies* de aquellas en el clúster Matrimonio. La probabilidad media de uso de OTT del perfil *Roomies* es 60% mientras que para el perfil Matrimonio es poco arriba del 20%. Es posible inferir que, aunque existen hogares de perfil *Roomies* y Matrimonio con baja y alta probabilidad de uso de OTT, respectivamente, si se seleccionara un hogar de perfil *Roomies* aleatoriamente, lo más probable sería que uno de sus residentes utilice OTT; caso contrario al perfil Matrimonio, pues de una selección aleatoria de un hogar con este perfil, lo más probable sería que ninguno de sus residentes utilice OTT.
- (110) Es importante recordar que los cuatro perfiles de hogar utilizados en esta sección surgieron de un análisis de clúster, el cual arrojó que los hogares de la ENDUTIH podrían agruparse en cuatro tipos de hogares. Estos perfiles se pueden interpretar como el hogar representativo, hasta cierto grado, de cada clúster²⁹.

²⁹ Para los clústeres representados por una nube de puntos en el espacio, el centroide del clúster puede fungir como punto representativo del conjunto. Sin embargo, el centroide del clúster no tiene sentido lógico en este estudio ya que la gran mayoría de las variables utilizadas en el análisis de clúster son dicotómicas o categóricas.

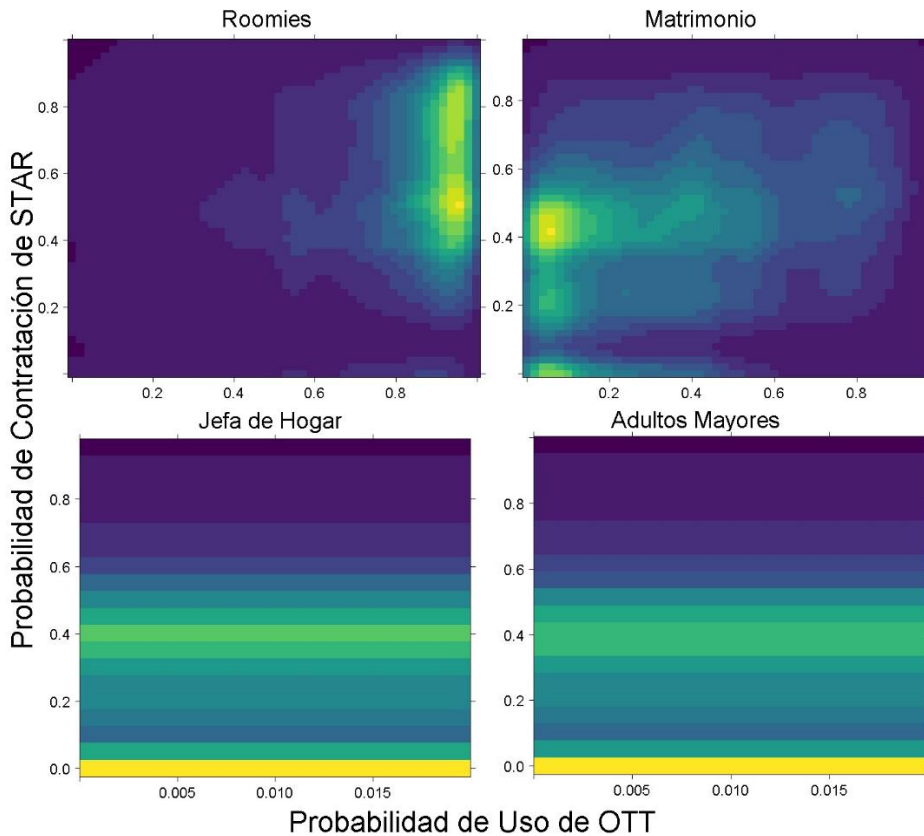
FIGURA 20. DISTRIBUCIÓN DE LAS PROBABILIDADES DE CONTRATACIÓN DE STAR POR PERFIL



Fuente: Elaboración propia con base en los resultados del modelo OTT. Las frecuencias utilizadas para generar estas distribuciones están ponderadas por los factores de hogar de la ENDUTIH.

- (111) La distribución de las probabilidades de contratación de STAR en el hogar no muestran diferencias tan drásticas como el caso OTT. Como se observa en la FIGURA 20, las probabilidades de STAR están traslapadas en gran parte por el rango de 40-60%. Sin embargo, los perfiles *Roomies* y *Jefa de Hogar* tienen las probabilidades medias más altas arriba del 60% y los perfiles *Matrimonio* y *Adultos Mayores* tienen las probabilidades medias por debajo del 40%.
- (112) Si bien estas distribuciones muestran que existen hogares de cualquier perfil con probabilidades muy altas o bajas, debe destacar la masa de hogares que residen en cada percentil de probabilidad. Por ejemplo, entre las probabilidades 0-10%, la gran mayoría de hogares pertenecen a los perfiles *Adultos Mayores* y *Matrimonio* mientras que entre las probabilidades 90-100% predominan los hogares *Roomies* y *Jefa de Hogar*.
- (113) La FIGURA 21 combina las perspectivas de las FIGURAS 19 y 20 para dar una visión amplia de la relación STAR-OTT de acuerdo con los perfiles. Estos mapas de calor permiten ubicar a los perfiles en el espacio de probabilidades de contratación y uso de los servicios STAR-OTT. El eje horizontal representa la probabilidad de utilizar OTT y el eje vertical representa la probabilidad de contratar STAR. Se muestran 4 mapas de calor, uno para cada perfil de hogar, donde el color amarillo significa que los hogares de la encuesta se aglomeran en esa región mientras que el color azul oscuro significa que hay pocos hogares en esa región.

FIGURA 21. PROBABILIDAD DE CONTRATACIÓN DE STAR Y USO DE OTT PARA LOS CUATRO PERFILES



Fuente: Elaboración propia con base en las predicciones de los modelos.

Nota: El rango del eje horizontal para los perfiles Jefa de Hogar y Adultos Mayores está acotado al (0, 0.2) debido a que estos perfiles tienen bajas probabilidades de uso de OTT.

- (114) Los hogares del perfil *Roomies* se concentran en la parte superior derecha mientras los hogares del perfil *Matrimonio* se ubican en la parte inferior izquierda. Esto quiere decir que los hogares con perfil *Roomies* son altamente propensos a utilizar OTT y medianamente propensos a contratar el servicio STAR; mientras que los hogares con perfil *Matrimonio* son poco propensos a usar OTT, pero medianamente propensos a contratar el STAR. Rendiciones 3D de la distribución de probabilidades para los cuatro perfiles se pueden consultar en el Anexo 6.
- (115) En resumen, a partir de la red neuronal entrenada se pueden inferir las probabilidades de consumo de STAR-OTT para cualquier hogar (observado o hipotético). Fijando las características del hogar y haciendo variar alguna de interés se pueden obtener sus efectos marginales. Se observa que el perfil *Roomies* es mucho más propenso a utilizar el OTT que

los demás. Esto se debe, en parte, a su dotación de servicios y dispositivos TIC y a la juventud de sus integrantes.

- (116) Asimismo, los resultados del modelo sugieren que los perfiles Matrimonio, Jefa de Hogar y Adultos Mayores prefieren el STAR sobre el OTT. La propensión al uso de OTT ha aumentado con el tiempo; mientras que la del STAR ha disminuido para los cuatro perfiles de hogar seleccionados. Además, existen varias características que influyen sobre el uso de OTT y la contratación del STAR, como el número de hijos e hijas y el uso de la computadora y el internet.
- (117) Los efectos marginales son estimables para cualquier otra variable empleada en la estimación del modelo estadístico. Sin embargo, cualquier inferencia derivada de las redes neuronales sólo es tan confiable como la certidumbre que se le atribuye a estos modelos estadísticos, cuantificada por (y proporcional a) su poder predictivo.

Conclusiones

- (118) El objetivo de este estudio fue analizar las preferencias de los usuarios en el consumo de contenidos que se proveen a través de los servicios OTT y de STAR con base en los datos del CENSO y de las ENDUTIH sobre características socioeconómicas y de infraestructura de los hogares en México, a partir de un modelo de redes neuronales para calcular sus probabilidades de consumo. En ese sentido, se destaca la funcionalidad de la técnica con la información mencionada, los resultados obtenidos nos ayudan a explicar el consumo de OTT y STAR en función de las características de los hogares mexicanos.
- (119) Los modelos de redes neuronales profundas desarrollados tuvieron distintos niveles de poder predictivo entre servicios y entre fuente de datos. Mientras que los modelos de OTT y STAR que utilizaron datos de la ENDUTIH tuvieron un *accuracy* por encima de 0.8, este estadístico se redujo hasta 0.66 para el caso del modelo usando información del CENSO.
- (120) El CENSO contiene información de composición familiar y socioeconómica de cuatro millones de hogares. Si bien el modelo elaborado con estos datos tuvo un alto poder predictivo arriba del 83% para los hogares que no cuentan con servicios, su precisión para aquellos hogares con OTT fue prácticamente nula.
- (121) Por otro lado, las ENDUTIH utilizadas contienen información no sólo de la composición familiar y socioeconómico de aproximadamente 650 mil hogares sino también de los hábitos de consumo de servicios de sus integrantes y de sus dotaciones de dispositivos TIC. Estos modelos lograron un poder predictivo superior al del CENSO con menos observaciones pero mayor periodicidad y con datos más relevantes a la pregunta de investigación.
- (122) El contraste en desempeño de estos modelos es una indicación clara de la importancia de la naturaleza de los datos aún con modelos predictivos de vanguardia. El uso exitoso de *big data* implica, más allá de una gran cantidad de datos y de técnicas cuantitativas modernas, una frecuencia de observación alta, relevancia y calidad de la información.
- (123) Se considera que la información de la ENDUTIH es superior que aquella del CENSO para los objetivos de este estudio. Sin embargo, a pesar de las cualidades de la información utilizada, se podría mejorar el poder predictivo para STAR y OTT empleando información derivada de preguntas de encuesta más ad hoc a los temas de preferencias y hábitos de consumo de estos servicios.
- (124) Se resalta la importancia de la exploración de técnicas cuantitativas adicionales con el fin valorar la utilidad y alcance de la metodología de redes neuronales. Esta herramienta estadística, aunque útil para el descubrimiento de la relación entre el consumo de STAR-OTT y las características de los hogares, sigue siendo una caja negra cuyos miles de parámetros carecen de la interpretabilidad que caracteriza a los modelos econométricos y estructurales más clásicos.

Bibliografía

- Arnold, R., Schneider, A., & Hildebrandt, C.; (2018) *All communication services are not created equal – Substitution of OTT Communications Services for ECS from a Consumer Perspective*. ResearchGate. Disponible en: <https://www.researchgate.net/publication/328419334> [Arnold et. al. (2018)]
- Banerjee, A., Rappoport, P., & Alleman, J., (2014) *Forecasting Video Cord-Cutting: The Bypass of Traditional Pay Television*. ResearchGate. Disponible en: <https://www.researchgate.net/publication/259642776>. [Banerjee, et al. (2014)]
- Greene, W. H., (2012) *Econometric Analysis 7th Edition* [Greene (2012)]
- Goodfellow, I. J., Bengio, Y. & Courville, A. (2016), *Deep Learning*, MIT Press [Goodfellow et al. (2016)]
- Hornik, K., Stinchcombe, M. B., & White, H. (1989). *Multilayer feedforward networks are universal approximators*. *Neural Networks*, 2(5), 359–366. [https://doi.org/10.1016/0893-6080\(89\)90020-8](https://doi.org/10.1016/0893-6080(89)90020-8), [Hornik et al. (1989)]
- Jung, J., & Melguizo, Á. (2022). *Is your Netflix a substitute for your telefonos? Evidence on the dynamics of traditional pay TV and OTT in Latin America*. Universidad Pontificia Comillas. ICADE, [Jung & Melguizo (2022)]
- Keskar, N. S. (2016). *On Large-Batch training for deep learning: generalization gap and sharp minima*. arXiv.org. <https://arxiv.org/abs/1609.04836> [Keskar (2016)]
- Lafon, M., Thomas, A. (2022) *Understanding the double descent phenomenon*. <https://alxthm.com/assets/pdf/double-descent.pdf> [Lafon et al. (2022)]
- Malone, J., Nevo, A., Nolan, Z., & Williams, J. (2021), *Is OTT Video a Substitute for TV? Policy Insights from Cord-Cutting*, The University of North Carolina at Chapel Hill. Disponible en: https://jonwms.web.unc.edu/wp-content/uploads/sites/10989/2021/06/CordCutting_WP-2021.pdf [Malone, et. al. (2021)]
- Nagaraj, S., Singh, S., & Yasa, V. R. (2021) *Factors affecting consumers' willingness to subscribe to over-the-top (OTT) video streaming services in India*, Elsevier, vol. 65. [Nagaraj et al. (2021)]
- Nakkiran, P. (2019). *Deep double descent: where bigger models and more data hurt*. arXiv.org. <https://arxiv.org/abs/1912.02292> [Nakkiran (2019)]
- Prince, J., & Greenstein, S. (2017). *Measuring consumer preferences for video content provision via cord-cutting behavior*. *Journal of Economics & Management Strategy*, 26(2), 293-317 [Prince & Greenstein (2017)]

Wooldridge, J. M., (2010) *Econometric Analysis of Cross Section and Panel Data 2nd Edition*.
[Wooldridge (2010)]

Yang, S., Ting, T. O., Man, K. L., & Guan, S. (2013). *Investigation of neural networks for function approximation*. *Procedia Computer Science*, 17, 586–594.
<https://doi.org/10.1016/j.procs.2013.05.076>, [Yang et al. (2013)]

ANEXO TÉCNICO

ANEXO 1. Revisión de literatura

TABLA A1.1 COMPARACIÓN DE METODOLOGÍAS USADAS EN LOS MODELOS ESTADÍSTICOS PARA SERVICIOS OTT Y TV DE PAGA

Modelo Estadístico	Forma Funcional	Descripción de la Función	Estimación Numérica	Ventajas	Desventajas
Mínimos cuadrados ordinarios	$y = X\beta + \epsilon$	Lineal en los parámetros	Solución analítica $\beta = (X^T X)^{-1} X^T y$	Fácil de estimar. Simple de interpretar. Flexible dentro de su restricción de linealidad.	Supuestos sobre la distribución de los errores. No admite no-linealidades en los parámetros.
Logit	$Prob(y = 1) = \frac{e^{X\beta}}{1 + e^{X\beta}}$	Logística y lineal en los parámetros	Solución numérica: Máxima verosimilitud	Restringe la predicción al intervalo (0,1). Fácil de estimar.	Más complicada la interpretación. Imposible de estimar en presencia de separación perfecta.
Mínimos cuadrados no-lineales con ecuaciones simultáneas	$\log(y_1) = f_1(X, y_2) + \epsilon_1$ $\log(y_2) = f_2(X, y_1) + \epsilon_2$	No-lineal en los parámetros	Solución numérica: Algoritmo Gauss-Newton	Admite no-linealidades en los parámetros.	Fuertes supuestos sobre la forma funcional de la relación entre las variables.
Red Neuronal	$Prob(y = 1) = f_k(f_{k-1}(\dots f_1(X) \dots))$	Anidaciones de funciones sigmoideas	Solución numérica: Descenso de gradiente estocástico	Puede aproximar casi cualquier forma funcional.	Estimación computacionalmente costosa. Requiere cantidad sustancial de datos.

Fuente: Elaboración propia.

ANEXO 2. Datos de las ENDUTIH

La siguiente tabla muestra el número de observaciones por año, totales y después de la limpieza durante el periodo 2015-2022.

TABLA A2.1 NÚMERO DE OBSERVACIONES EN ENDUTIH, PREVIO Y POST LIMPIEZA

Observaciones	2015	2016	2017	2018	2019	2020	2021	2022
ENDUTIH	80125	118957	135341	133745	21620	58154	59285	58540
ENDUTIH (filtrada)	79008	116213	131781	133338	21553	57947	59088	58360

Fuente: Elaboración propia con base en los datos ENDUTIH 2015 – 2022.

El proceso de limpieza de los datos implicó eliminar observaciones de hogares sin electricidad y de hogares con información faltante en alguna de las 123 variables explicativas.

En las siguientes tablas se muestran los promedios de algunas variables utilizadas en los modelos STAR y OTT, contrastando únicamente entre los años 2015 y 2022.

TABLA A2.2 ESTADÍSTICA DESCRIPTIVA DE ALGUNAS VARIABLES USADAS PARA EL MODELO STAR

Variables	2015		2022	
	NO STAR	STAR	NO STAR	STAR
Edad del jefe del hogar	49.30	48.39	50.38	51.28
Número de integrantes del hogar que utilizan internet.	1.44	2.25	2.12	2.67
Número de integrantes del hogar que utilizan computadora, laptop o tablet.	1.31	2.05	0.97	1.47
Número de integrantes del hogar que utilizan celular.	2.09	2.75	2.42	2.87
Tipo de conexión fija: Internet por cable.	0.02	0.18	0.21	0.51
Número de integrantes del hogar con educación superior.	0.28	0.69	0.43	0.70
SBAF.	0.21	0.53	0.54	0.79
STF.	0.29	0.51	0.30	0.50
Satisfacción con el servicio: SBAF.	0.17	0.42	0.42	0.61
Satisfacción con el servicio: STF.	0.24	0.43	0.26	0.44
Lavadora.	0.60	0.84	0.69	0.86
Número de integrantes del hogar con trabajo.	1.44	1.65	1.47	1.64
Laptop.	0.18	0.42	0.27	0.43

Fuente: Elaboración propia con base en los datos ENDUTIH 2015-2022.

TABLA A2.3 ESTADÍSTICA DESCRIPTIVA DE ALGUNAS VARIABLES USADAS PARA EL MODELO OTT

Variables	2015		2022	
	NO OTT	OTT	NO OTT	OTT
Televisor digital.	0.34	0.63	0.73	0.89
Uso OTT.	0.04	0.12	0.32	0.47
Número de integrantes del hogar con educación media superior.	0.52	0.75	0.63	0.77
Nivel de estudios del jefe del hogar.	0.66	0.50	0.58	0.48
RURAL.	0.26	0.16	0.25	0.19
Uso computadora por el jefe del hogar.	0.26	0.48	0.24	0.36
Edad del jefe del hogar.	48.9	44.9	53.3	46.2
Edad de usuario	38.1	29.8	44.4	32.2
Rural	0.2	0.0	0.3	0.1
Intensidad de uso de internet por el usuario	1.4	5.3	1.8	5.7
Intensidad de uso de computadora por el usuario	0.9	3.6	0.6	2.7
Número de integrantes del hogar que utilizan computadora, laptop o Tablet.	1.6	2.8	0.7	1.9
Número de integrantes del hogar que utilizan internet	1.8	2.9	1.9	3.0
Uso de computadora por el jefe del hogar	0.4	0.8	0.1	0.5
Uso de internet por el jefe del hogar	0.4	0.9	0.5	0.9
Satisfacción del servicio: SBAF	0.3	0.6	0.4	0.7
Número de integrantes del hogar con trabajo	1.5	1.8	1.4	1.7
Número de integrantes con educación media superior.	0.6	0.8	0.5	0.9
Nivel de estudios del usuario: educación superior.	0.2	0.5	0.1	0.3
STF	0.4	0.7	0.3	0.5
Uso de celular por parte del jefe del hogar.	0.8	0.9	0.8	0.9
Televisor digital	0.5	0.8	0.7	0.9
Usuario en generación Z	0.2	0.2	0.2	0.4
Usuario en generación <i>baby boomers</i>	0.2	0.1	0.2	0.1
Usuario en generación <i>millennial</i> .	0.3	0.5	0.2	0.3
Nivel de estudios del usuario: educación media superior	0.2	0.3	0.2	0.3
Nivel de estudios del jefe del hogar: educación básica.	0.6	0.2	0.7	0.4
Razón de no uso de computadora por el usuario: No sabe utilizarla.	0.3	0.0	0.4	0.1
Nivel de estudios del usuario: educación básica.	0.6	0.2	0.7	0.3
Número de integrantes en el hogar con educación básica	2.1	1.2	2.0	1.4
Edad del jefe del hogar	48.9	44.9	53.3	46.2
Edad del usuario.	38.1	29.8	44.4	32.2

Fuente: Elaboración propia con base en los datos de ENDUTIH.

TABLA A2.4 COMPARACIÓN ESTADÍSTICA DE ALGUNAS VARIABLES USADAS EN LOS MODELOS STAR Y OTT CON LA ENDUTIH

Variable	Descripción (cómo se obtuvo la variable)	Principales cambios en el periodo 2015-2022	
		STAR	OTT
Edad del jefe del hogar	Esta variable se obtuvo al preguntar la edad del jefe del hogar. De la ENDUTIH se filtraron los resultados de acuerdo con la disponibilidad o uso del servicio (STAR y OTT).	<ul style="list-style-type: none"> En 2015 la edad promedio de estas personas era 49.3 años si su hogar no contaba con STAR, siendo ligeramente mayor que aquellas viviendas que tenían este servicio (48.39 años). Para 2022 la edad promedio del jefe del hogar de aquellas casas con STAR fue de 51.28 años, mayor que los 50.38 años de los jefes de hogar sin este servicio. 	<ul style="list-style-type: none"> En 2015 la edad promedio en hogares con OTT era de 44.9 años, cuatro años menos que la edad promedio en aquellos hogares sin OTT con 48.9 años. En 2022 esta diferencia de edad se volvió siete años mayor que en 2015, pues la edad del jefe del hogar con OTT fue de 46.2 años, mientras que fue de 53.3 años en hogares sin OTT.
STF	Para construir esta variable solamente se consideró a aquellas personas que afirmaron tener una línea de telefonía fija. Los resultados se filtraron dependiendo si los hogares tenían o usaban el servicio (STAR y OTT).	<ul style="list-style-type: none"> La adopción de los servicios de telefonía fija se ha mantenido relativamente constante, con mayor penetración en aquellas viviendas con TV de paga que sin éstas. En aquellos hogares con STAR, la adopción de STF descendió solamente un punto porcentual, al pasar de 51% en 2015 a 50% en 2022. En el caso de los hogares sin STAR, el porcentaje de STF incrementó un punto porcentual al pasar de 29% en 2015 a 30% en 2022. 	<ul style="list-style-type: none"> Los servicios STF han visto un notable decremento en su adopción en los hogares con OTT. Para aquellos hogares que no contaban con OTT, el porcentaje de hogares con STF decayó diez puntos porcentuales al pasar del 40% en 2015 a 30% en 2022. Para el caso de los hogares con OTT, la caída en la penetración de STF fue del doble, ya que pasó de estar presente en el 70% de estas viviendas en 2015 a 50% durante 2022.
Intensidad de uso de internet por el usuario.	La intensidad está medida en horas al día	<ul style="list-style-type: none"> No aplica 	<ul style="list-style-type: none"> Existe una clara diferencia en la intensidad de uso del internet en los hogares con OTT con aquellos que no lo hacen. En hogares que usaban OTT aumentó el uso de internet en aproximadamente media hora, al pasar de 5.3 horas promedio al día en 2015 a 5.7 horas promedio en 2022 (en general pasan poco más de una cuarta parte del día).

Fuente: Elaboración propia con base en resultados de las ENDUTIH 2015 y 2022.

TABLA A2.4 COMPARACIÓN ESTADÍSTICA DE ALGUNAS VARIABLES USADAS EN LOS MODELOS STAR Y OTT CON LA ENDUTIH (CONTINUACIÓN)

Variable	Descripción (cómo se obtuvo la variable)	Principales cambios en el periodo 2015-2022	
		STAR	OTT
Niveles de satisfacción SBAF	Esta variable determina qué tan satisfechos están los hogares con su servicio de SBAF, filtrándose si las viviendas también tienen contratados o han usado los servicios STAR y OTT respectivamente.	<ul style="list-style-type: none"> • Porcentaje de hogares satisfechos con su servicio SBAF mayor en aquellos hogares con STAR respecto a las que no lo tenían. • Mayor crecimiento en el porcentaje de viviendas satisfechas que no contaban con STAR en comparación de aquellas que si lo tenían. • En 2015, el porcentaje de hogares satisfechos con SBAF y que no contaban con STAR era del 17%, incrementando 25 puntos porcentuales hasta llegar a ser del 42% en 2022. • Para aquellos hogares con STAR y satisfechos del SBAF, sólo incrementó de 42% en 2015 a 61% en 2022. 	<ul style="list-style-type: none"> • En aquellos hogares con OTT también resultaron ser aquellos con mayores niveles de satisfacción respecto de aquellos donde no se consumían contenidos de esta forma. • El incremento en el porcentaje de satisfacción del SBAF fue el mismo sin importar si los hogares consumían o no un OTT. • En 2015, el 30% de los hogares sin OTT estaban satisfechos con su servicio SBAF, subiendo hasta un 40% en 2022. • Por su parte, el 60% hogares que consumían OTT también estaban satisfechos del SBAF, aumentando a 70% para 2022.
Número de integrantes del hogar que hacen uso de computadora.	Esta variable brinda información sobre el número integrantes que usan computadora según el residente que da la información del hogar, filtrando por los hogares que disponen o usan el servicio (STAR, OTT)	<ul style="list-style-type: none"> • Mayor uso de computadoras en los hogares con servicio de STAR respecto a aquellos sin éste. • El número promedio de residentes que usaron computadora en los hogares con STAR se redujo de 2.05 en 2015 a 1.47 en 2022. En los hogares que no contaban con el servicio paso de 1.31 a 0.97 residentes en promedio. 	<ul style="list-style-type: none"> • El número promedio de personas que utilizan computadora es mayor si en el hogar hay OTT, aunque disminuyó en 2022 sin importar su uso o no en el hogar. • En los hogares con OTT, el número de integrantes promedio usaron una computadora pasó de 3.6 a 2.7 personas; mientras bajó de 0.9 a 0.6 personas en aquellas viviendas sin OTT.
Intensidad de uso de computadora por el usuario	La intensidad está medida en horas al día	<ul style="list-style-type: none"> • No aplica 	<ul style="list-style-type: none"> • La intensidad de uso de la computadora es mayor en los hogares con OTT que sin este servicio. • En el caso de las horas promedio del uso de computadora, disminuyó de 3.6 a 2.7 horas en hogares con OTT. Si los usuarios no lo utilizaban, la intensidad de uso bajó de 0.9 a 0.6 horas al día.

Fuente: Elaboración propia con base en resultados de las ENDUTIH 2015 y 2022.


TABLA A2.5 GENERACIONES POR INTERVALOS DE EDAD

Generación	Año de nacimiento
Generación silenciosa o anterior	Antes de enero de 1946.
Baby boomers	Entre 1946 y 1963.
Generación X	Entre 1964 y 1979
Generación Y (millennials)	Entre 1980 y 1996
Generación Z	Entre 1997 y 2012.
Generación Alfa	De 2013 y 2022.

Fuente: Elaboración propia con base en resultados de las ENDUTIH 2015 y 2022.

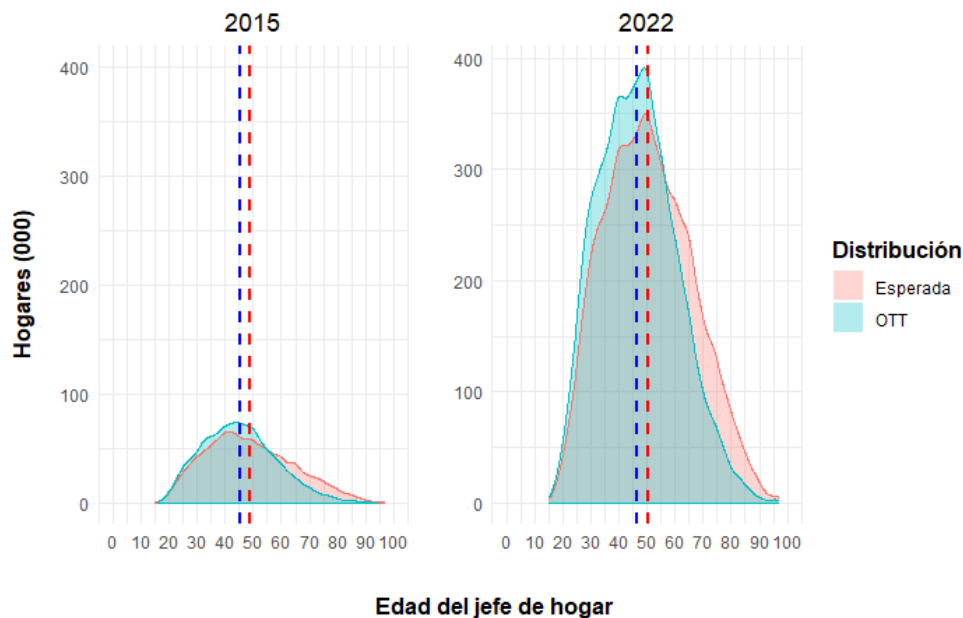
ANEXO 3. Características socioeconómicas de los usuarios de STAR y OTT

FIGURA A3.1 CRECIMIENTO DEL STF Y SBAF PARA HOGARES CON STAR U OTT



Fuente: Elaboración propia con datos de las ENDUTIH 2015-2022.

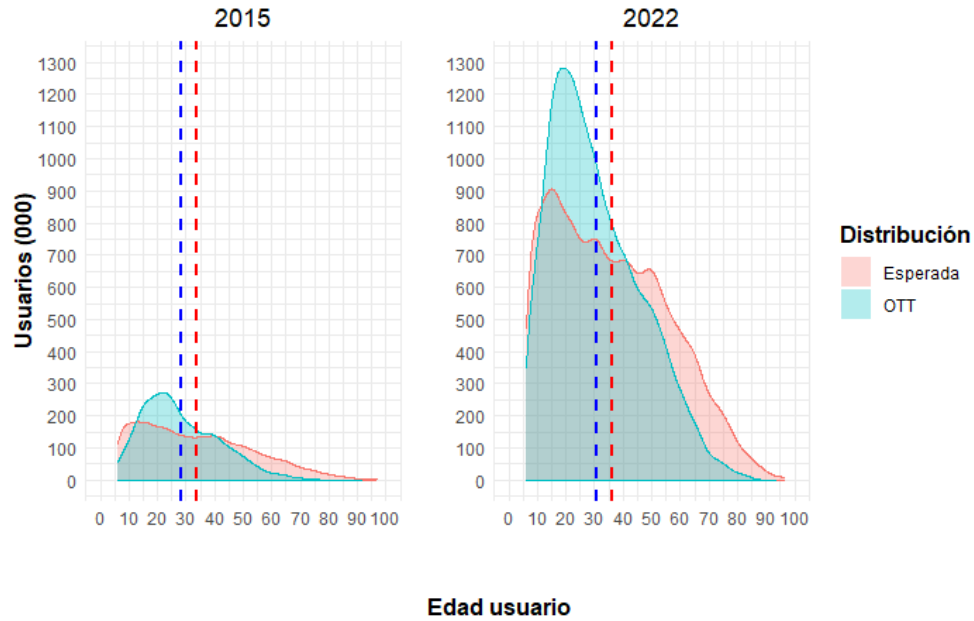
FIGURA A3.2 EDAD DEL JEFE EN HOGARES CON USO DE OTT³⁰



³⁰ Se comparan las edades de los jefes en los hogares con uso de OTT respecto a la distribución de las edades del jefe en los hogares totales ponderada por el promedio de hogares que dijo hacer uso de OTT, 8% y 39% para 2015 y 2022 respectivamente.

Fuente: Elaboración propia con datos de las ENDUTIH 2015 y 2022.
Nota: La distribución “esperada” es la distribución de la población total multiplicada por la proporción de la población total que utiliza OTT.


FIGURA A3.3 EDADES DE USUARIOS DE OTT³¹



Fuente: Elaboración propia con datos de las ENDUTIH 2015 y 2022.
Nota: La distribución “esperada” es la distribución de la población total multiplicada por la proporción de la población total que utiliza OTT.

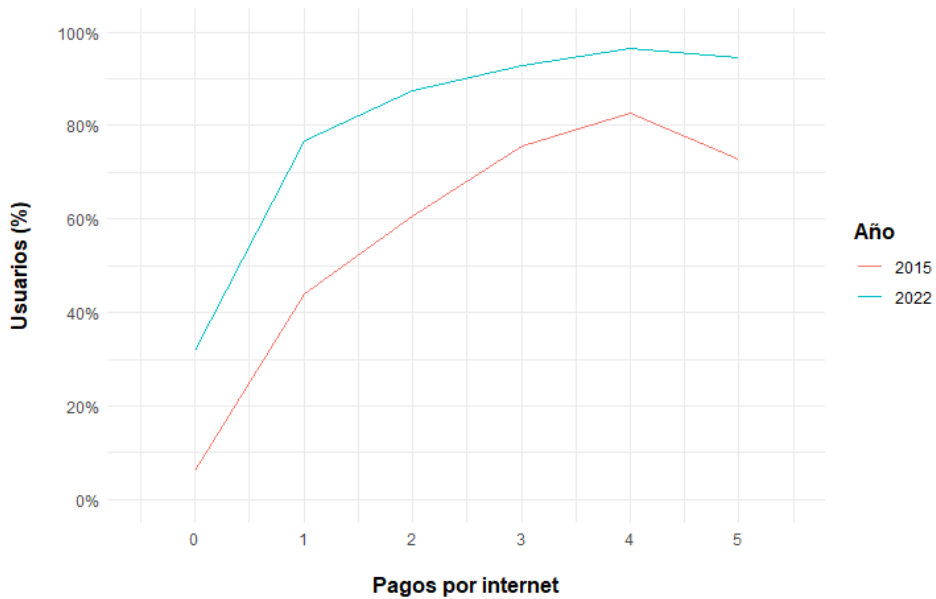
³¹ Edades de usuarios de OTT respecto a la edad de las personas de 6 años o más ponderada por el promedio de usuarios que dijo hacer uso de OTT, 8% y 39% para 2015 y 2022 respectivamente.

FIGURA A3.4 DISPOSICIÓN DE STAR POR NIVEL DE ESTUDIOS DEL JEFE Y CONSUMO DE OTT POR NIVEL DE ESTUDIOS DEL USUARIO



Fuente: Elaboración propia con datos de las ENDUTIH 2015-2022.

FIGURA A3.5 USO DE OTT SEGÚN EL NÚMERO DE PAGOS POR INTERNET³².



Fuente: Elaboración propia con datos de las ENDUTIH 2015 y 2022.

³² El tipo de pagos por internet que se toman en cuenta para esta variable son: libros, computadoras, alimentos y bebidas, reservación de boletos y aparatos electrónicos.

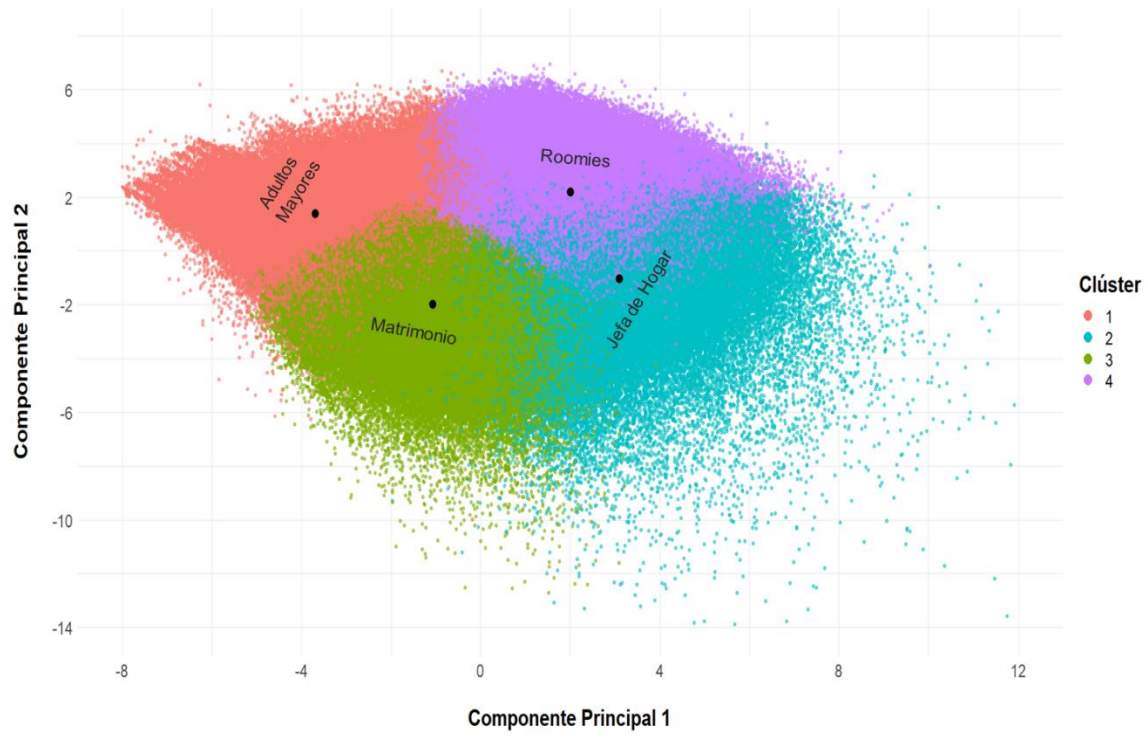
FIGURA A3.6 USO DE OTT SEGÚN EL USO DE REDES SOCIALES



Fuente: Elaboración propia con datos de las ENDUTIH 2015-2022.

ANEXO 4. Clústeres de Hogares – STAR

GRÁFICA A4.1 AGRUPACIÓN DE HOGARES POR PERFIL



Fuente: Elaboración propia con los resultados del PCA para datos del modelo STAR.

ANEXO 5. Red Neuronal

Dada la arquitectura e hiperparámetros, es posible determinar cuáles serán los valores de las neuronas en capas posteriores en función de aquellas neuronas ubicadas en capas precedentes. Para profundizar en este aspecto, consideremos una red neuronal con L capas, donde N_l denota el número de neuronas en la capa $l \in \{1, \dots, L\}$ y $\mathbf{a}_n^{(l)}$ representa la n -ésima neurona de la capa l , con $n \in \{1, \dots, N_l\}$. Así, la capa l se denotará como el vector $\mathbf{a}^{(l)}$ cuyas entradas están conformadas por las neuronas $\mathbf{a}_1^{(l)}, \mathbf{a}_2^{(l)}, \dots, \mathbf{a}_{N_l}^{(l)}$. Definamos $\mathbf{W}^{(l)}$ como la matriz de pesos de dimensiones $N_{l+1} \times N_l$ que conectan las neuronas de $\mathbf{a}^{(l)}$ con las neuronas de $\mathbf{a}^{(l+1)}$, y $\mathbf{b}^{(l)}$ como el vector de sesgos que se añade en cada combinación lineal de neuronas y pesos desde la capa l a la capa $l + 1$. Sea $\sigma^{(l)}: \mathbb{R} \rightarrow (0,1)$ la función de activación³³ de la capa l . Definamos a $\mathbf{z}^{(l)} = \mathbf{W}^{(l)}\mathbf{a}^{(l)} + \mathbf{b}^{(l)}$. Todas las capas y neuronas, excepto la primera capa (capa de entrada), pueden ser representadas de la siguiente manera.

$$\begin{aligned} \begin{bmatrix} \mathbf{a}_1^{(l+1)} \\ \mathbf{a}_2^{(l+1)} \\ \vdots \\ \mathbf{a}_{N_{l+1}}^{(l+1)} \end{bmatrix} &= \mathbf{a}^{(l+1)} = \sigma^{(l)}(\mathbf{z}^{(l)}) = \sigma^{(l)}(\mathbf{W}^{(l)}\mathbf{a}^{(l)} + \mathbf{b}^{(l)}) \\ &= \sigma^{(l)}\left(\left(\begin{bmatrix} w_{1,1}^{(l)} & w_{1,2}^{(l)} & \dots & w_{1,N_l}^{(l)} \\ w_{2,1}^{(l)} & w_{2,2}^{(l)} & \dots & w_{2,N_l}^{(l)} \\ \vdots & \vdots & \ddots & \vdots \\ w_{N_{l+1},1}^{(l)} & w_{N_{l+1},2}^{(l)} & \dots & w_{N_{l+1},N_l}^{(l)} \end{bmatrix} \begin{bmatrix} \mathbf{a}_1^{(l)} \\ \mathbf{a}_2^{(l)} \\ \vdots \\ \mathbf{a}_{N_l}^{(l)} \end{bmatrix} + \begin{bmatrix} \mathbf{b}_1^{(l)} \\ \mathbf{b}_2^{(l)} \\ \vdots \\ \mathbf{b}_{N_{l+1}}^{(l)} \end{bmatrix}\right) \end{aligned} \quad (1)$$

Vemos que la capa $\mathbf{a}^{(l+1)}$ queda en función de la capa $\mathbf{a}^{(l)}$, la matriz $\mathbf{W}^{(l)}$ y el vector de sesgos $\mathbf{b}^{(l)}$. Ahora, planteemos como se vería la capa $\mathbf{a}^{(l+2)}$:

$$\begin{aligned} \mathbf{a}^{(l+2)} &= \sigma^{(l+1)}(\mathbf{z}^{(l+1)}) = \sigma^{(l+1)}(\mathbf{W}^{(l+1)}\mathbf{a}^{(l+1)} + \mathbf{b}^{(l+1)}) \\ &= \sigma^{(l+1)}\left(\mathbf{W}^{(l+1)}\left(\sigma^{(l)}(\mathbf{W}^{(l)}\mathbf{a}^{(l)} + \mathbf{b}^{(l)})\right) + \mathbf{b}^{(l+1)}\right) \end{aligned}$$

Por construcción, se sigue que la capa $l + r$ quedaría expresada de la siguiente forma:

$$\mathbf{a}^{(l+r)} = \sigma^{(l+(r-1))}\left(\mathbf{W}^{(l+(r-1))} \dots \left(\sigma^{(l)}(\mathbf{W}^{(l)}\mathbf{a}^{(l)} + \mathbf{b}^{(l)})\right) \dots + \mathbf{b}^{(l+(r-1))}\right)$$

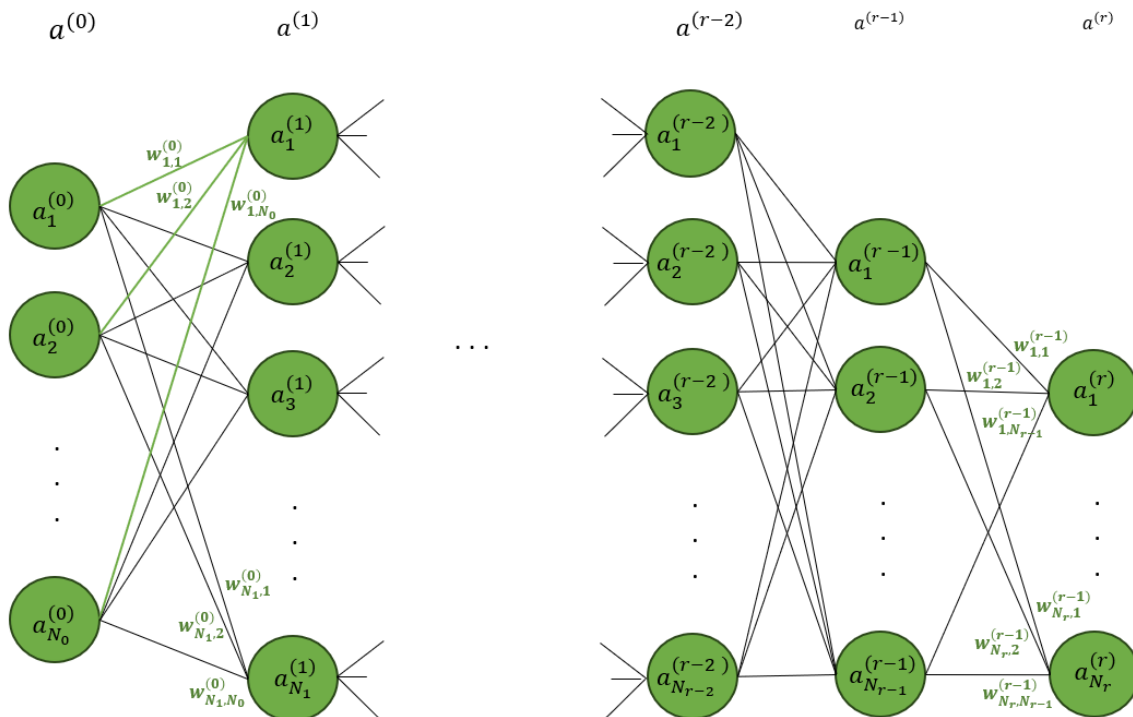
La última ecuación ilustra cómo cualquier capa es función de las neuronas, pesos y sesgos de las capas que la preceden. Como nota, los valores de las neuronas de la capa

³³ En el caso de este análisis el espacio imagen de las funciones de activación (sigmoid, softmax) son el intervalo $(0,1)$, pero existen funciones que tienen otros intervalos como espacio imagen.

de entrada no son calculados, sino que están dados por los datos que se le provee a la red para el entrenamiento.

Supongamos ahora que nuestra red neuronal tiene r capas, sin contar la de entrada, Sea $l = 0$, entonces la capa $\mathbf{a}^{(l)} = \mathbf{a}^{(0)}$ representa el conjunto de neuronas de input, y $\mathbf{a}^{(0+r)}$ representa la capa de salida. En este contexto, los resultados en la capa de salida pueden interpretarse como los resultados de una función anidada que depende de todos los pesos, sesgos, funciones de activación y las variables de entrada (neuronas en la capa de entrada). En este sentido, las redes neuronales actúan como aproximadoras de funciones: los pesos y sesgos se ajustan con el objetivo de aproximar la relación funcional entre las variables de entrada y la variable a predecir (por ejemplo, una variable dicotómica como el utilizar o no OTT). Sin embargo, esta aproximación de la función es consecuencia del problema de optimización que busca minimizar la función de pérdida o costo de la red neuronal (por ejemplo, entropía cruzada categórica). Para ejemplificar, examinemos las siguientes figuras: en la primera se muestra la estructura general de la red, mientras que en la segunda se ilustra cómo algunos componentes llegan a cada neurona desde la capa anterior, como se acaba de describir.

FIGURA A5.1 RED NEURONAL




Fuente: Elaboración propia.

La FIGURA A5.1 representa gráficamente la arquitectura de la red neuronal empleada para abordar el problema de clasificación. La imagen ilustra una serie de capas $a^{(l)}$ interconectadas, cada una con un conjunto de neuronas etiquetadas como $a_n^{(l)}$ con $l \in$

$\{0, \dots, r\}$ y $n \in \{1, \dots, N_l\}$ que funcionan como variables portadoras de información. En la capa de entrada a_0 (primera capa de la red) las neuronas son las variables que tenemos del conjunto de información con el cual se entrena el modelo. Las líneas que conectan a dos capas contiguas representan los pesos, los cuales son ajustados durante todo el proceso de entrenamiento. Estos pesos son esenciales para determinar la influencia de cada variable sobre el output de la red y, en última instancia, para alcanzar una precisión óptima en la clasificación de los datos. En las capas ocultas o de salida la neurona $a_n^{(l)}$ se calcula como una suma ponderada de los pesos entre la neurona $a_n^{(l)}$ y la capa $l - 1$ como se muestra en la FIGURA A5.2, donde también es posible apreciar que se incluye un término de sesgo $b^{(l)}$.

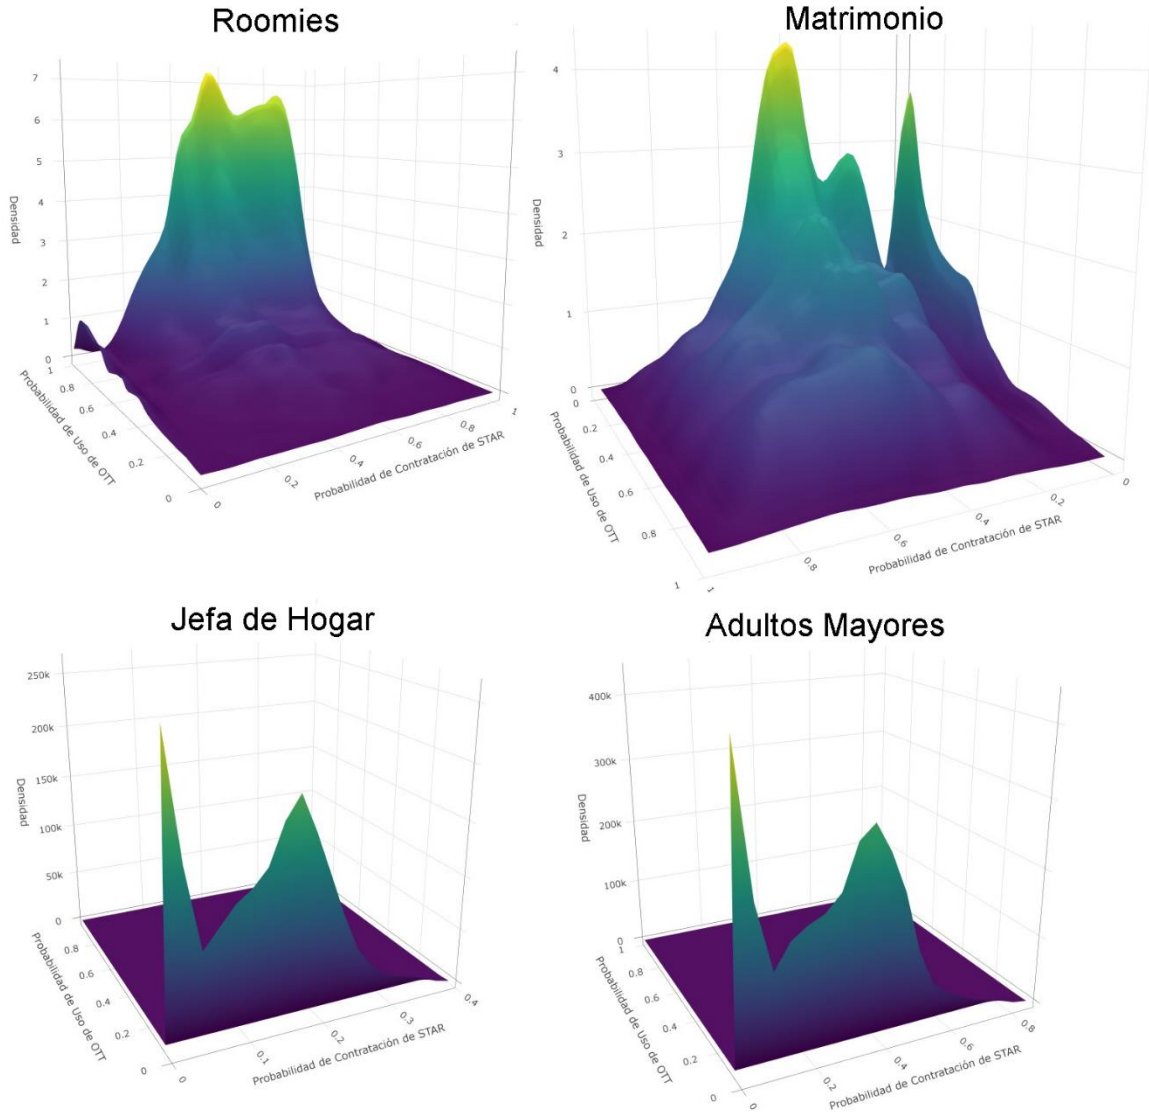
FIGURA A5.2 NEURONA EN RED NEURONAL



Fuente: Elaboración propia.

ANEXO 6. Rendiciones 3D de las Distribuciones de Probabilidad

Figura A6.1 Distribución de las Probabilidades de Contratación de STAR y de Uso de OTT por Perfil de Hogar




Fuente: Elaboración propia con base en las predicciones de los modelos STAR-OTT.

Nota: La gráfica del perfil Matrimonio se visualiza desde otra perspectiva para poder apreciar mejor la forma de la masa de densidad.

ANEXO 7. Accuracy Según Probabilidad STAR-OTT

FIGURA A7.1 ACCURACY DE LOS MODELOS STAR-OTT SEGÚN DECILES DE PROBABILIDADES PREDICHAS



Fuente: Elaboración propia con base en las predicciones de los modelos STAR-OTT para ENDUTIH.

Nota: El *accuracy* está calculado como la media armónica entre el *accuracy* del modelo OTT y el *accuracy* del modelo STAR para cada percentil de probabilidad $\{(0.0,0.1),(0.1,0.2)\dots(0.9,1.0)\}$.