



Universidad de Buenos Aires
Facultad de Ciencias Económicas

CEAT



Centro de Estudios en Administración Tributaria

Investigación y capacitación aplicados a los ingresos públicos

MODELOS PREDICTIVOS DE RIESGO FISCAL BASADOS EN INTELIGENCIA ARTIFICIAL

Una propuesta para fortalecer la detección temprana de evasión en la AATT
argentina

Autor: CP María Laura Verrastro

Coordinador: CP/LA/Abog. Pablo L. Emlek

Resumen

La creciente digitalización de la economía y la expansión de los sistemas de información han transformado los procesos de fiscalización de las administraciones tributarias (AATT), planteando nuevos desafíos para la detección temprana de conductas evasivas. En este contexto, la inteligencia artificial y las técnicas de *machine learning* ofrecen herramientas con potencial para fortalecer la gestión del riesgo fiscal y optimizar la asignación de recursos de control.

El presente trabajo propone un modelo conceptual de *scoring* de riesgo fiscal basado en inteligencia artificial, orientado a complementar los mecanismos tradicionales de perfilamiento de contribuyentes en la administración tributaria argentina. A partir de una revisión del marco teórico y del análisis del estado actual de la fiscalización digital, se diseña una arquitectura conceptual del modelo y se ilustra su funcionamiento mediante un ejemplo con datos sintéticos, preservando las restricciones normativas y éticas propias del ámbito tributario.

El estudio pone énfasis en la integración del modelo a los procesos de auditoría electrónica, en el rol del control humano y en la necesidad de un adecuado marco de gobernanza y responsabilidad algorítmica. Como conclusión, se sostiene que la analítica predictiva, utilizada de manera gradual y responsable, puede constituir un instrumento estratégico para mejorar la eficiencia, focalización y carácter preventivo de la fiscalización tributaria.

Índice

I. Introducción	
II. Marco teórico	
a. Digitalización de los procesos tributarios.....	
b. Análisis de datos aplicado a la fiscalidad.	
c. Referencias internacionales.	
III. Panorama de la administración tributaria argentina.....	
a. Estructura institucional y marco operativo actual.....	
b. Herramientas actuales de control y fiscalización digital.	
c. Limitaciones del modelo vigente y desafíos que justifican la adopción de analítica predictiva.	
d. Oportunidades para la modernización basada en la IA	
IV. Propuesta del modelo predictivo de riesgo fiscal.	
a. Objetivo y alcance del modelo predictivo propuesto.....	
b. Fuentes de datos e insumos analíticos.	
c. Variables e indicadores de riesgo fiscal.....	
d. Enfoque metodológico y lógica del modelo de scoring	
e. Integración del modelo en los procesos de fiscalización.	
f. Consideraciones sobre validación, monitoreo y actualización del modelo.....	
V. Ejemplo de aplicación.....	
a. Descripción del modelo simulado con datos sintéticos.....	
b. Arquitectura conceptual del modelo predictivo de riesgo fiscal.....	
c. Análisis de resultados.	
d. Alcances y limitaciones.	
VI. Conclusiones	
VII. Bibliografía	

I. Introducción

La administración tributaria argentina —como el resto de sus pares— enfrenta desde hace décadas el desafío de detectar y prevenir conductas evasivas en un escenario caracterizado por la expansión del comercio digital, la multiplicación de fuentes de información y la creciente complejidad de las transacciones económicas. En este contexto, organismos como la Agencia de Recaudación y Control Aduanero (ARCA) y las agencias tributarias provinciales avanzaron en la incorporación de auditorías electrónicas, regímenes de información y mecanismos de cruce automatizado de datos. Sin embargo, el volumen, la velocidad y la heterogeneidad de los datos disponibles superan las capacidades analíticas tradicionales y limitan la posibilidad de identificar patrones de riesgo de manera oportuna (OCDE, 2017; OCDE, 2019).

La inteligencia artificial (IA), y en particular las técnicas de *machine learning*¹, han emergido en los últimos años como herramientas capaces de procesar grandes cantidades de información y extraer patrones sutiles que suelen pasar inadvertidos para los métodos convencionales. Diversas AATT —entre ellas, HMRC (Reino Unido), ATO (Australia), IRS (Estados Unidos) y la Agencia Tributaria de España— ya utilizan modelos predictivos de riesgo fiscal para priorizar fiscalizaciones, mejorar el perfilamiento de contribuyentes y aumentar la eficiencia en la asignación de recursos (HMRC, 2020; ATO, 2019; IRS, 2018; AEAT, 2021). Estos desarrollos muestran que la IA puede complementar los sistemas de auditoría electrónica, potenciando la detección temprana de inconsistencias, anomalías y probables incumplimientos (OCDE, 2019; OCDE, 2021).

En el caso argentino, resulta relevante destacar que la administración tributaria nacional cuenta desde hace varios años con herramientas orientadas al perfilamiento de contribuyentes, entre las cuales se encuentra el Sistema de Perfil de Riesgo (SIPER), cuya finalidad es categorizar a los contribuyentes y responsables inscriptos en el impuesto al valor agregado en función del grado de cumplimiento de sus deberes fiscales formales y materiales, a partir de la información disponible en las bases de datos del organismo. De acuerdo con los considerandos de la Resolución General AFIP N° 3985/2017, el SIPER constituye un proceso objetivo, permanente y dinámico, orientado a reflejar el comportamiento fiscal del universo de contribuyentes y a permitir la aplicación de procedimientos diferenciales en la administración de los tributos y los recursos de la seguridad social. En este sentido, la propia normativa reconoce la conveniencia de avanzar en etapas de actualización y reestructuración informática y operativa del sistema, con el fin de mejorar la precisión y oportunidad de las categorizaciones asignadas.

¹ Aprendizaje automático. Subcampo de la inteligencia artificial que desarrolla algoritmos capaces de aprender patrones a partir de datos y mejorar su desempeño sin reglas explícitamente programadas.

A partir de estas premisas, el presente proyecto se propone estudiar la viabilidad conceptual de un modelo predictivo de riesgo fiscal aplicable a la realidad argentina, que pueda complementar y potenciar los esquemas de perfilamiento actualmente existentes. El interés central radica en analizar cómo la integración de datos provenientes de regímenes informativos, declaraciones juradas, historial de cumplimiento y cruces de información en general, podría servir como base para un sistema de *scoring*² que permita anticipar comportamientos evasivos. Asimismo, se examinarán los principales enfoques algorítmicos posibles —como árboles de decisión, *random forest*³ y técnicas de aprendizaje supervisado— junto con los flujos de información necesarios para su implementación (OCDE, 2019).

Si bien la potencialidad de estos modelos resulta significativa, su aplicación en materia tributaria exige considerar cuidadosamente aspectos éticos, de gobernanza y transparencia, especialmente en lo referido al uso legítimo de datos fiscales, la reducción de sesgos algorítmicos y la explicación de los resultados obtenidos. En este sentido, la presente investigación buscará no sólo describir las capacidades de la IA para mejorar la detección de evasión, sino también delimitar las condiciones bajo las cuales su implementación puede fortalecer la equidad, la eficiencia y la legitimidad del accionar fiscal (OCDE, 2021; Floridi, 2019).

En síntesis, este proyecto pretende aportar un marco teórico-práctico para comprender cómo la inteligencia artificial puede servir como herramienta estratégica en la gestión del riesgo fiscal⁴ en Argentina, proponiendo un modelo conceptual de *scoring*, identificando sus potenciales aplicaciones en auditorías electrónicas y evaluando las oportunidades y limitaciones asociadas a su uso. Se espera que los resultados contribuyan al debate sobre modernización tributaria y sienten las bases para el desarrollo de soluciones predictivas orientadas a optimizar la selección de casos y mejorar la detección temprana de conductas evasivas.

² Puntaje de riesgo. Resultado de un modelo analítico que asigna a cada sujeto un valor o categoría que representa su nivel relativo de riesgo dentro de un universo comparable.

³ Algoritmo de aprendizaje supervisado que combina múltiples árboles de decisión construidos sobre subconjuntos aleatorios de datos y variables, mejorando la robustez y reduciendo el sobreajuste del modelo.

⁴ Enfoque integral que combina información, analítica y criterios institucionales para anticipar, prevenir y mitigar riesgos de incumplimiento tributario. Incluye la identificación de patrones de riesgo, la segmentación de contribuyentes y la aplicación de estrategias diferenciadas de control y asistencia.

II.Marco teórico

a. Digitalización de los procesos tributarios.

Concepto, funciones y evolución hacia las auditorías electrónicas.

En el contexto de las AATT modernas, la digitalización de procesos y la expansión de los sistemas de información redefinieron la manera en que se gestionan las funciones esenciales de control y verificación. Más que un cambio operativo, este proceso implicó una reconfiguración del ciclo de fiscalización, ahora sustentado en flujos de datos masivos, estructuras digitales de reporte y capacidades analíticas que permiten monitorear el cumplimiento fiscal en tiempo casi real (OCDE, 2021). La AATT no opera ya sobre registros fragmentados o inspecciones puntuales, sino sobre ecosistemas de información integrados que habilitan modelos de detección temprana basados en evidencia y analítica avanzada (FMI, 2021).

Durante las últimas dos décadas, las administraciones del mundo avanzaron de manera sostenida hacia modelos de gestión tecnológicamente intensivos, impulsados por la generalización de los sistemas de facturación electrónica, la expansión de los servicios web para contribuyentes y la automatización progresiva de los mecanismos de verificación. Este proceso, frecuentemente denominado *transformación digital tributaria*⁵, reconfiguró la manera en que los fiscos interactúan con los ciudadanos y los modos en que los primeros obtienen información para evaluar la conducta fiscal (OCDE, 2019). En esta evolución, la captura masiva de datos transaccionales, bancarios, aduaneros y laborales se consolidó como la base sobre la cual se estructuran los nuevos esquemas de control⁶.

La fiscalización tradicional, caracterizada por auditorías presenciales, revisiones documentales y procedimientos extensos, cedió terreno frente a formas más ágiles y escalables de verificación. Estos nuevos enfoques, reunidos bajo el concepto de *auditorías electrónicas*, utilizan algoritmos, cruces automatizados y análisis digital de documentación para detectar inconsistencias en etapas tempranas y focalizar los recursos de inspección (AFIP, 2020). La auditoría electrónica no elimina el componente humano, pero sí redefine su rol: el inspector deja de ser un recolector manual de información para convertirse en un analista de riesgos que interviene sobre casos previamente filtrados mediante herramientas tecnológicas.

⁵ La OCDE define la transformación digital tributaria como la adopción estratégica de tecnologías digitales —incluyendo automatización, análisis de datos y servicios electrónicos— para optimizar procesos internos, mejorar el cumplimiento y fortalecer la relación con los contribuyentes, en línea con estándares internacionales de eficiencia administrativa (OCDE, 2020).

⁶ Sobre la integración creciente de datos heterogéneos para fiscalización, ver ARCA (2022): *Plan de Digitalización y Modernización de Procesos de Fiscalización*; y OCDE (2021): *Tax Administration 2021*.

En este marco, los cruces de datos se transformaron en la piedra angular de la fiscalización moderna. Al integrar fuentes heterogéneas —facturación electrónica, libros IVA digitales, declaraciones juradas, información de terceros, consumos con tarjetas, movimientos aduaneros, registros laborales, e incluso fuentes externas normalizadas— las administraciones pueden reconstruir patrones económicos con mayor fidelidad y detectar brechas entre lo declarado y lo efectivamente realizado. La automatización de estos procesos amplía la capacidad de control y permite aplicar modelos de monitoreo continuo, reduciendo la dependencia de operativos puntuales o verificaciones aisladas (OCDE, 2017; OCDE, 2019).

La digitalización también posibilita el avance hacia esquemas de verificación remota, donde el contribuyente recibe comunicaciones electrónicas basadas en inconsistencias detectadas algorítmicamente y puede responder o subsanar de manera virtual. Esta modalidad, desplegada en distintos países, optimiza tiempos, disminuye costos administrativos, además de facilitar e impulsar el cumplimiento voluntario (OCDE, 2023).

En síntesis, la AATT contemporánea opera sobre un entorno en el que la información y la capacidad de procesarla se vuelven activos estratégicos. La disponibilidad de datos en gran escala, combinada con herramientas de análisis avanzadas, habilita una gestión más inteligente del riesgo fiscal y allana el camino hacia la incorporación de tecnologías emergentes como la analítica predictiva, el *machine learning* y los sistemas automatizados de priorización de casos. Este proceso, que continúa en expansión, redefine el paradigma de fiscalización y sienta las bases para la aplicación de modelos predictivos orientados a anticipar comportamientos de incumplimiento (OCDE, 2023).

b. Análisis de datos aplicado a la fiscalidad.

Modelos predictivos, riesgo fiscal y perfilamiento de los contribuyentes.

El uso de analítica de datos y *machine learning* en las AATT no constituye un desarrollo experimental, sino un componente consolidado dentro de los sistemas modernos de gestión del riesgo fiscal. A diferencia de la digitalización general mencionada en el apartado anterior —centrada en la disponibilidad, calidad e interoperabilidad de la información—, este apartado aborda las herramientas específicas que permiten transformar esos volúmenes de datos en capacidades efectivas para detectar inconsistencias, anticipar comportamientos y priorizar intervenciones. En esta transición, la analítica se convierte en el puente entre la infraestructura de datos y las estrategias de fiscalización avanzadas.

En la literatura especializada existe consenso en que las capacidades analíticas de las AATT se estructuran en torno a tres grandes enfoques⁷: descriptivo, predictivo y prescriptivo.

⁷ OCDE (2022): *Tax Administration 2022: Comparative Information on OECD and other Advanced and Emerging Economies*. OECD Publishing.

- La **analítica descriptiva** se orienta a reconstruir y comprender el comportamiento fiscal histórico mediante indicadores, paneles de control y modelos de segmentación. Permite identificar brechas entre declaraciones, detectar inconsistencias simples, evaluar series temporales de cumplimiento y analizar patrones estructurales por sector, tamaño o localización.
- La **analítica predictiva**, por su parte, incorpora técnicas estadísticas y de *machine learning* para estimar la probabilidad futura de determinados comportamientos —por ejemplo, riesgo de subdeclaración (o *declaraciones en menos*), probabilidad de mora o posibilidad de incumplimiento— sobre la base de variables históricas y comportamientos comparables.
- A su vez, la **analítica prescriptiva** se orienta a optimizar decisiones operativas, como la priorización de auditorías o la asignación de recursos de inspección, a partir de los resultados predictivos.

En paralelo, la evolución del machine learning amplió las posibilidades de estos enfoques analíticos al introducir algoritmos capaces de procesar grandes volúmenes de datos heterogéneos y detectar relaciones complejas que exceden los métodos tradicionales. En el ámbito tributario, los algoritmos supervisados —tales como árboles de decisión, *random forest*, *gradient boosting*⁸ y regresiones regularizadas⁹— son los más utilizados para construir modelos de riesgo fiscal que asignan puntajes o clasificaciones a contribuyentes¹⁰. Estos modelos permiten identificar comportamientos atípicos o no deseados dentro de universos comparables, ponderar múltiples variables de manera conjunta e incorporar relaciones no lineales entre los factores de riesgo, características frecuentes en los patrones de evasión y difícilmente capturables mediante reglas o umbrales fijos.

Los métodos no supervisados también han ganado relevancia en la identificación de grupos de riesgo y patrones de comportamiento que no se encuentran explícitamente etiquetados. Técnicas como *k-means*¹¹, *clustering jerárquico*¹², DBSCAN¹³ y modelos de detección de anomalías basados en

Centro Interamericano de Administraciones Tributarias (CIAT) (2021): *Analítica de datos para administraciones tributarias: conceptos y aplicaciones*. CIAT.

⁸ Técnica de aprendizaje supervisado que construye modelos de manera secuencial, donde cada nuevo modelo corrige los errores del anterior, permitiendo capturar relaciones complejas y mejorar la capacidad predictiva.

⁹ Modelos de regresión que incorporan penalizaciones sobre los coeficientes con el fin de reducir el sobreajuste, mejorar la estabilidad de las estimaciones y manejar conjuntos de variables numerosos o correlacionados.

¹⁰ Alm, J., & McClelland, G. (2022): *Tax Compliance and Data Analytics in Modern Tax Administrations*. Journal of Tax Administration.

¹¹ Algoritmo de *clustering* (agrupamiento) no supervisado que agrupa observaciones en un número predefinido de clusters, minimizando la distancia interna dentro de cada grupo.

¹² Técnica de agrupamiento no supervisado que organiza las observaciones en una estructura jerárquica según su similitud, sin requerir definir previamente el número de grupos.

¹³ Algoritmo de *clustering* no supervisado basado en densidad que identifica grupos de datos concentrados y distingue observaciones atípicas o ruido, sin requerir un número fijo de clusters.

densidad¹⁴ permiten identificar contribuyentes cuyas conductas difieren significativamente de su segmento económico, facilitando la detección de perfiles evasivos emergentes¹⁵. Este enfoque resulta especialmente valioso en contextos donde las etiquetas de incumplimiento son escasas, incompletas o sesgadas, una situación frecuente en administraciones con recursos limitados o con historiales fragmentados de fiscalización.

Otro conjunto de técnicas aplicadas en el ámbito tributario son los modelos de detección de anomalías mediante sistemas híbridos que combinan reglas tradicionales con algoritmos de aprendizaje. Estos sistemas permiten identificar desviaciones sutiles —como variaciones atípicas en la facturación, inconsistencias en los movimientos de comercio exterior o desalineamientos entre consumos bancarios y bases imponibles declaradas— y emitir alertas tempranas. Su uso es común en esquemas de auditorías electrónicas, donde los sistemas generan observaciones automáticas que posteriormente son revisadas y validadas por analistas humanos.

Las experiencias documentadas por la OCDE y el CIAT, muestran que los países que avanzaron en la integración de estas técnicas lograron mejoras significativas en precisión, focalización y eficiencia operativa. En particular, la utilización de modelos predictivos para la selección de casos, ha permitido reducir cargas de fiscalización innecesarias, concentrar esfuerzos en contribuyentes con mayor probabilidad de riesgo y fortalecer las capacidades de respuesta ante esquemas evasivos que se adaptan con rapidez. Esta evidencia empírica demuestra que la incorporación de *machine learning* no reemplaza la función fiscalizadora tradicional, sino que la potencia, orientando mejor los recursos y proporcionando herramientas más robustas para la toma de decisiones estratégicas.

En síntesis, la analítica avanzada y el *machine learning* constituyen hoy pilares metodológicos que habilitan una gestión del riesgo fiscal más precisa, dinámica y proactiva. Su aplicación no se limita a mejorar procesos ya existentes, sino que redefine los cimientos sobre los cuales se construyen los modelos modernos de fiscalización. En este marco, el desarrollo de modelos predictivos de riesgo fiscal —como el que se propone en este trabajo— se inserta en una tendencia global que busca anticipar comportamientos de incumplimiento a partir de evidencia cuantitativa y criterios de priorización sistemáticos.

c. Referencias internacionales.

La adopción de herramientas de analítica avanzada y modelos predictivos en las AATT no es un fenómeno aislado, sino parte de una tendencia global impulsada por organismos internacionales como

¹⁴ Técnicas analíticas que identifican observaciones que se desvían significativamente de patrones habituales en función de la densidad de los datos.

¹⁵ OCDE (2021): *Advanced Analytics for Tax Administration*. OECD Publishing.

la OCDE, el CIAT y el FMI¹⁶. Estas entidades han promovido la modernización de los sistemas de gestión del riesgo fiscal y la transición hacia modelos de fiscalización sustentados en datos, lo que ha derivado en una variedad de experiencias comparadas que sirven de referencia para los países que se encuentran en etapas de evolución o consolidación tecnológica.

En el ámbito de la OCDE, varios países han desarrollado estrategias sistemáticas para incorporar analítica predictiva en la gestión del cumplimiento. Australia y Canadá se destacan por el uso de modelos de *compliance risk management*¹⁷ que clasifican contribuyentes según probabilidad de incumplimiento y magnitud potencial de riesgo, permitiendo orientar auditorías hacia segmentos de mayor impacto¹⁸. En ambos casos, la integración de fuentes de información financieras, laborales y de facturación electrónica, posibilitó la implementación de sistemas automatizados de alerta temprana y la priorización dinámica de casos.

En el Reino Unido, la HMRC opera desde hace más de una década con plataformas de análisis masivo de datos que combinan *machine learning*, detección de anomalías y cruces automatizados¹⁹. Este enfoque ha permitido fortalecer las capacidades de fiscalización digital y reducir la brecha fiscal mediante mecanismos de segmentación avanzada, perfiles de riesgo y modelos de predicción aplicados a sectores específicos, como comercio electrónico, rentas personales y trabajo independiente. La experiencia británica se destaca, además, por la integración de equipos multidisciplinarios de ciencia de datos dentro de la estructura tributaria.

La Unión Europea ofrece un marco cooperativo particularmente relevante. Iniciativas como *EUROFISC*²⁰ y los mecanismos de intercambio de información en tiempo casi real entre AATT han permitido trabajar con modelos predictivos en contextos transfronterizos²¹. Estos instrumentos están orientados principalmente a la detección de fraudes en el IVA, en particular esquemas complejos como

¹⁶ OCDE (2021): *Documentos y lineamientos sobre gestión del riesgo fiscal y digitalización tributaria*. OCDE.

¹⁷ Proceso sistemático de identificar, evaluar y mitigar los riesgos legales, regulatorios y éticos que enfrenta una organización —pública o privada—. Su objetivo es evitar sanciones, multas, litigios y daños reputacionales mediante el cumplimiento de normas externas e internas, protegiendo así la sostenibilidad de la entidad.

¹⁸ OCDE (2019): *Compliance Risk Management: experiencias comparadas*. OCDE.

¹⁹ Her Majesty's Revenue and Customs (2020): *Data and analytics strategy*. HMRC.

²⁰ Red de cooperación administrativa de la Unión Europea orientada a la prevención y detección del fraude en el impuesto al valor agregado (IVA). Facilita el intercambio rápido de información entre Estados miembros y el análisis conjunto de riesgos transfronterizos, constituyendo un ejemplo de fiscalización basada en datos y cooperación internacional.

²¹ European Commission (2021): *EUROFISC annual report*. EU Commission.

el *fraude carrusel*²², mediante análisis de redes comerciales, detección de inconsistencias y monitoreo de operadores sospechosos.

Finalmente, entre los países de América Latina, Brasil constituye uno de los casos de referencia más sólidos. La adopción de la “Nota Fiscal Eletrônica” y la progresiva digitalización de los libros contables, creó un ecosistema de datos único en la región, que habilitó la automatización de controles, el análisis de redes comerciales y el desarrollo de modelos predictivos para detectar omisiones e incongruencias²³. El volumen y granularidad²⁴ de los datos disponibles posicionan a Brasil como uno de los líderes en fiscalización algorítmica.

Chile, por su parte, ha avanzado en el uso de modelos estadísticos y análisis de comportamiento aplicados a micro y pequeñas empresas, especialmente en segmentos donde el riesgo de informalidad es estructural²⁵. La integración entre facturación electrónica, información bancaria y declaraciones juradas permitió fortalecer los sistemas de alertas automáticas y aumentar la cobertura de fiscalización no presencial. El Servicio de Impuestos Internos (SII) también ha desarrollado herramientas de segmentación predictiva que priorizan fiscalizaciones basadas en la trayectoria histórica del contribuyente.

En conjunto, estas experiencias muestran que la analítica avanzada se ha consolidado como un componente central de las estrategias modernas de gestión del riesgo fiscal. Los casos internacionales ilustran que su adopción requiere no sólo infraestructura tecnológica y calidad de datos, sino también capacidades institucionales, gobernanza algorítmica y marcos regulatorios que aseguren transparencia y control. Para las AATT que se encuentran en proceso de modernización, estos antecedentes ofrecen evidencia sobre los beneficios potenciales y los desafíos asociados a la incorporación de modelos predictivos en la fiscalización.

²² También denominado *Missing Trader Intra-Community Fraud* (MTIC), es un esquema de evasión del IVA caracterizado por la intervención de empresas reales y ficticias que simulan operaciones comerciales intracomunitarias para aprovechar la exención en las ventas transfronterizas. European Commission (2018): *EUROFISC: Cooperation in combating VAT fraud*. European Union Publications.

²³ CIAT (2022): *Experiencias de fiscalización electrónica en América Latina*. CIAT.

²⁴ Nivel de detalle con el que se registran y analizan los datos, donde una mayor granularidad implica información más desagregada y potencialmente más útil para la detección de patrones de riesgo.

²⁵ Servicio de Impuestos Internos (2020): *Memoria institucional y reportes de gestión del riesgo tributario*. SII.

III. Panorama de la administración tributaria argentina.

a. Estructura institucional y marco operativo actual.

ARCA constituye actualmente el organismo federal responsable de la administración tributaria, aduanera y de los recursos de la seguridad social. Su diseño institucional responde a un modelo orientado a la integración funcional, la gestión del riesgo fiscal y el uso intensivo de información estructurada y no estructurada, siguiendo los lineamientos promovidos por organismos internacionales para AATT modernas²⁶.

Desde el punto de vista organizacional, ARCA adopta un esquema de tipo matricial que combina áreas sustantivas (fiscalización, recaudación, aduana) con áreas transversales de soporte tecnológico y analítico. Este enfoque apunta a superar el histórico carácter fragmentado de algunas AATT y avanzar hacia una arquitectura interoperable de sistemas, recomendada por la OCDE y el CIAT como condición para la gestión del riesgo basada en datos²⁷.

No obstante, cabe destacar que el grado de consolidación de este modelo presenta diferencias entre funciones y dominios operativos: mientras ciertos procesos tributarios muestran altos niveles de estandarización y digitalización —como la gestión de declaraciones juradas y la facturación electrónica—, otros ámbitos, en particular aquellos que requieren la integración intensiva de múltiples fuentes de información o la coordinación entre áreas tributarias y aduaneras, evidencian mayores desafíos en términos de interoperabilidad y explotación analítica de los datos.

Desde una perspectiva operativa, ARCA articula:

- Procesos de administración y control tributarios y aduaneros centralizados, sostenidos por plataformas digitales que integran declaraciones, pagos, operaciones de comercio exterior y registros financieros.
- Un sistema unificado de gestión del riesgo fiscal, estructurado mediante criterios metodológicos comunes para la clasificación de contribuyentes, la detección temprana de inconsistencias y la priorización de fiscalizaciones.
- Un modelo de gobierno del dato, con estándares de calidad, seguridad y trazabilidad, alineado con buenas prácticas internacionales para el uso posterior de analítica avanzada²⁸.

En síntesis, ARCA opera bajo un enfoque que combina funciones tradicionales de control con una creciente orientación a procesos digitales y decisiones basadas en datos, aunque con niveles de

²⁶ OCDE (2021): *Tax Administration 2021: Comparative Information on OECD and other Advanced and Emerging Economies*.

²⁷ CIAT (2022): *Modelo de gestión del riesgo en las administraciones tributarias*.

²⁸ Banco Mundial (2023): *Data Governance in Tax Administrations: Framework and Implementation Pathways*.

madurez heterogéneos entre áreas y procesos, lo que resulta relevante al momento de evaluar la factibilidad y el alcance de modelos predictivos más sofisticados.

b. Herramientas actuales de control y fiscalización digital.

El ecosistema tecnológico de ARCA reúne un conjunto de herramientas que permiten automatizar procesos, monitorear conductas tributarias y ejecutar fiscalizaciones con mayor alcance y precisión. Este conjunto, constituye la base sobre la cual pueden desarrollarse modelos analíticos más sofisticados, en línea con las tendencias observadas en diferentes administraciones del mundo²⁹.

Entre los principales componentes se destacan:

1) Declaraciones y registros electrónicos consolidados.

Incluyen facturación electrónica, libros IVA y de empleados digitales, registros aduaneros y declaraciones juradas integradas. Estas herramientas se alinean con los estándares de digitalización promovidos por la OCDE, que identifica la consolidación de registros electrónicos como el pilar para la fiscalización basada en datos³⁰.

2) Sistemas de cruces automatizados o semi-automatizados.

Los cruces de información —bancaria, registral, laboral, aduanera y comercial— constituyen una práctica extendida en América Latina. El CIAT destaca que estos mecanismos representan la transición desde la fiscalización reactiva hacia esquemas de verificación preventiva³¹.

3) Perfiles de riesgo y segmentación primaria de contribuyentes.

ARCA utiliza matrices de riesgo sustentadas en reglas, indicadores de capacidad económica y antecedentes. Sin embargo, tal como señala el FMI, las matrices tradicionales basadas en puntuaciones estáticas presentan limitaciones frente a esquemas de riesgo dinámico basados en IA³².

4) Fiscalización remota y procedimientos digitales de control.

Comprenden verificaciones electrónicas, requerimientos automatizados y mecanismos de control no presencial basados en criterios de selectividad. Estas modalidades se han consolidado como una práctica internacional eficiente, especialmente en administraciones con elevado volumen transaccional, al reducir costos operativos y ampliar la cobertura de fiscalización sin incrementar proporcionalmente los recursos humanos³³.

²⁹ OCDE (2023): *Advanced Analytics for Tax Administration*.

³⁰ OCDE (2021): *Tax Administration 2021*.

³¹ CIAT (2021): *Gestión del riesgo y control preventivo en las administraciones tributarias*.

³² Fondo Monetario Internacional (2022): *Digitalization and Risk Management in Tax Administrations*.

³³ OCDE (2020): *Electronic Audit Practices in Tax Administrations*.

5) Sistemas de monitoreo aduanero basados en riesgo.

Estos, integran antecedentes del operador, rutas, valores de referencia y perfiles logísticos. Sin embargo, persiste una brecha respecto de la integración tributario-aduanera, una problemática frecuente en la región, según estudios del Banco Interamericano de Desarrollo³⁴.

c. Limitaciones del modelo vigente y desafíos que justifican la adopción de analítica predictiva.

A partir del análisis de la normativa vigente, la documentación institucional disponible y la literatura especializada, pueden identificarse una serie de limitaciones estructurales que condicionan la capacidad de la administración tributaria argentina para avanzar hacia modelos de gestión del riesgo basados en analítica avanzada e inteligencia artificial.

En primer lugar, persisten brechas de interoperabilidad entre sistemas informáticos derivadas de desarrollos históricos no homogéneos y de la coexistencia de plataformas con distintos niveles de madurez tecnológica³⁵. Esta fragmentación dificulta la integración efectiva de información tributaria, aduanera y de seguridad social en repositorios unificados, lo que limita la explotación analítica de los datos y la posibilidad de construir modelos predictivos consistentes.

En segundo término, se observan restricciones vinculadas a la calidad, consistencia y normalización de los datos disponibles³⁶. La heterogeneidad de formatos, la duplicación de registros, los rezagos temporales y la falta de trazabilidad plena afectan la confiabilidad de los insumos analíticos y aumentan el riesgo de sesgos en los procesos de clasificación y priorización de contribuyentes.

Asimismo, el esquema actual de gestión del riesgo fiscal se apoya mayormente en matrices de riesgo estáticas y reglas determinísticas, entendidas como criterios de decisión predefinidos que asignan alertas o categorías de riesgo en función del cumplimiento de umbrales fijos e indicadores tradicionales, **sin mecanismos de aprendizaje o actualización dinámica**³⁷. Si bien estos instrumentos permiten orientar la fiscalización, presentan limitaciones para captar patrones complejos o emergentes de evasión, particularmente en contextos de alto dinamismo económico y sofisticación de las conductas evasivas.

³⁴ BID (2022): *Customs and Tax Administration Integration Challenges in Latin America*.

³⁵ Organisation for Economic Co-operation and Development (2021): *Tax Administration 2021: Comparative Information on OECD and Other Advanced and Emerging Economies*. OECD Publishing.

³⁶ Centro Interamericano de Administraciones Tributarias (2022): *Gestión del riesgo y analítica avanzada en las administraciones tributarias*. CIAT.

³⁷ International Monetary Fund (2021): *Digitalization and risk management in tax administrations*. IMF Fiscal Affairs Department.

Otra limitación relevante se vincula con las capacidades analíticas y organizacionales del organismo³⁸. La disponibilidad de perfiles especializados en ciencia de datos, estadística aplicada e ingeniería de datos podría resultar todavía insuficiente para sostener, de manera sistemática, el desarrollo, validación y mantenimiento de modelos analíticos avanzados. Esta brecha dificulta la conformación de equipos interdisciplinarios estables y la institucionalización de prácticas de mejora continua basadas en evidencia.

Por otra parte, subsisten condicionantes normativos y de gobernanza del dato que inciden en el alcance de las herramientas analíticas disponibles³⁹. En particular, la ausencia de marcos específicos para la documentación, explicabilidad y auditoría de modelos automatizados, junto con restricciones asociadas al uso y reutilización de información fiscal, plantea desafíos adicionales para la adopción responsable de sistemas basados en inteligencia artificial.

En conjunto, estas limitaciones no constituyen obstáculos insalvables, pero sí delinean un conjunto de aspectos críticos que deben ser abordados para que la incorporación de modelos predictivos en la gestión del riesgo fiscal resulte técnicamente viable, jurídicamente segura y operativamente sostenible.

d. Oportunidades para la modernización basada en la IA

Las limitaciones estructurales del modelo vigente, lejos de constituir un impedimento absoluto, delinean un conjunto de oportunidades concretas para la modernización de la gestión del riesgo fiscal mediante el uso de inteligencia artificial. En particular, la disponibilidad creciente de datos digitales, junto con la experiencia acumulada en auditorías electrónicas y sistemas de perfilamiento, crea un contexto propicio para avanzar hacia enfoques analíticos más sofisticados, de carácter predictivo y adaptativo (OCDE, 2021).

1. **Evolución de los sistemas de perfilamiento existentes.** Una primera oportunidad se vincula con la evolución de los esquemas actuales de segmentación y categorización, como el Sistema de Perfil de Riesgo (SIPER), hacia modelos que incorporen técnicas de *machine learning*. Mientras los sistemas basados en reglas determinísticas permiten ordenar el universo de contribuyentes según criterios explícitos, los modelos predictivos pueden complementar este enfoque estimando probabilidades de incumplimiento a partir de múltiples variables combinadas y actualizadas de manera continua. La literatura especializada señala que este tipo de modelos permite mejorar la precisión del riesgo

³⁸ Banco Mundial (2020): *Tax Administration Diagnostic Assessment Tool (TADAT): Improving tax administration performance*. World Bank Group.

³⁹ OCDE (2022): *OECD Framework for the Governance of Digital Tax Administration*. OECD Publishing.

asignado, sin eliminar la supervisión humana (*human in the loop*)⁴⁰ ni los criterios normativos preexistentes⁴¹.

2. **Optimización de la selección y priorización de casos.** En segundo lugar, la IA ofrece oportunidades relevantes para optimizar la selección y priorización de casos de fiscalización. Mediante modelos de *scoring* de riesgo, es posible focalizar los recursos de control en contribuyentes con mayor probabilidad de incumplimiento y mayor impacto potencial, reduciendo la carga administrativa sobre segmentos de bajo riesgo, o bajo “rendimiento” del control. Este enfoque resulta especialmente valioso en contextos de restricciones presupuestarias y alta dispersión del universo fiscalizable, donde la eficiencia en la asignación de recursos adquiere un rol central (OCDE, 2019).

3. **Integración analítica de fuentes de información heterogéneas.** Otra área de oportunidad reside en la integración analítica de fuentes de información, actualmente sub-explotadas. La combinación sistemática de datos provenientes de regímenes informativos, declaraciones juradas, historial de cumplimiento, operaciones aduaneras y fuentes externas permite construir representaciones más completas del comportamiento fiscal. Las técnicas de IA facilitan el análisis conjunto de estas fuentes heterogéneas, superando las limitaciones de los cruces simples y habilitando la detección de patrones complejos o inconsistencias no evidentes, tal como señalan diversos estudios comparados en AATT avanzadas⁴².

4. **Fortalecimiento de la fiscalización electrónica y el enfoque de “alerta temprana”.** Asimismo, la aplicación de modelos predictivos puede fortalecer los mecanismos de fiscalización electrónica y verificación remota, al generar alertas tempranas basadas en inconsistencias de ciertas variables. Esto abre la posibilidad de transitar desde un esquema predominantemente reactivo, hacia uno más preventivo, orientado a corregir conductas apenas se producen, o cuando comienzan a manifestarse señales que anticipan un eventual incumplimiento, contribuyendo también a mejorar el cumplimiento voluntario⁴³.

5. **Transparencia, gobernanza del dato y explicabilidad algorítmica.** Finalmente, la modernización basada en IA ofrece una oportunidad para institucionalizar prácticas de gestión del riesgo más transparentes y trazables, siempre que se acompañe de adecuados marcos de gobernanza del dato y explicabilidad algorítmica. La documentación de modelos, la validación periódica de resultados y la supervisión humana de las decisiones automatizadas resultan condiciones necesarias

⁴⁰ Principio según el cual los sistemas automatizados operan bajo control y validación humana, especialmente cuando influyen en decisiones con efectos jurídicos o administrativos.

⁴¹ International Monetary Fund (2021): *Digitalization and risk management in tax administrations*. IMF Fiscal Affairs Department.

⁴² Centro Interamericano de Administraciones Tributarias (2022): *Gestión del riesgo y analítica avanzada en las administraciones tributarias*. CIAT.

⁴³ OCDE (2020): *Electronic audit practices in tax administrations*. OECD Publishing.

para compatibilizar el uso de herramientas avanzadas con los principios de legalidad, equidad y seguridad jurídica que rigen la actuación de la administración tributaria⁴⁴.

En conjunto, estas oportunidades muestran que la incorporación de inteligencia artificial en la gestión del riesgo fiscal no constituye un salto disruptivo aislado, sino un proceso evolutivo, apoyado en capacidades ya existentes. En este sentido, el desarrollo de un modelo conceptual de *scoring* predictivo —como el que se propone en este trabajo— se inscribe en una trayectoria plausible de modernización, orientada a fortalecer la detección temprana de evasión y a mejorar la eficiencia del accionar fiscal en la Argentina.

IV. Propuesta del modelo predictivo de riesgo fiscal.

A partir del diagnóstico realizado sobre el estado actual de la administración tributaria argentina y de las oportunidades identificadas para la modernización basada en inteligencia artificial, este capítulo presenta una propuesta conceptual de modelo predictivo de riesgo fiscal orientado a fortalecer la detección temprana de conductas evasivas y optimizar la selección de casos para fiscalización.

La propuesta se concibe como un esquema complementario a los instrumentos actualmente vigentes — en particular, a los sistemas de perfilamiento y segmentación basados en reglas— y no como un reemplazo de los mecanismos existentes. En este sentido, el modelo busca integrar técnicas de machine learning dentro de un marco institucional compatible con los principios de legalidad, transparencia y control humano que rigen la actuación de la administración tributaria.

El énfasis del capítulo no se encuentra en la implementación técnica específica, sino en el diseño lógico y metodológico del modelo, poniendo el foco en sus componentes esenciales, en los tipos de datos que podrían ser utilizados y en la lógica general de construcción de un *scoring* de riesgo fiscal. Este abordaje permite analizar la viabilidad del modelo sin requerir acceso a información protegida por el secreto fiscal ni a sistemas internos del organismo.

Asimismo, la propuesta contempla el uso de datos sintéticos y escenarios simulados con fines ilustrativos, con el objetivo de mostrar el funcionamiento general del modelo, sus posibles resultados y sus limitaciones, sin comprometer información real de los contribuyentes. De este modo, el capítulo busca ofrecer un marco de referencia conceptual que permita comprender cómo un modelo predictivo de riesgo fiscal podría incorporarse progresivamente a los procesos de fiscalización electrónica, aportando mayor eficiencia y capacidad de anticipación al accionar del fisco.

⁴⁴ OCDE (2022): *OECD Framework for the Governance of Digital Tax Administration*. OECD Publishing.

a. Objetivo y alcance del modelo predictivo propuesto.

El objetivo del modelo predictivo de riesgo fiscal propuesto es complementar los mecanismos actuales de gestión del riesgo mediante la incorporación de técnicas de inteligencia artificial orientadas a anticipar comportamientos de incumplimiento y optimizar la selección de casos para la fiscalización electrónica. En este sentido, el modelo se concibe como una herramienta de apoyo a la toma de decisiones, destinada a mejorar la eficiencia del control tributario sin sustituir los procedimientos normativos ni el criterio experto de los agentes fiscales.

El alcance del modelo es conceptual y metodológico. No se propone el desarrollo de un sistema operativo ni su implementación directa en los entornos productivos de la AATT, sino la definición de una arquitectura analítica plausible que permita evaluar su viabilidad técnica, operativa y normativa. Este enfoque resulta consistente con las recomendaciones de organismos internacionales, que sugieren avanzar progresivamente desde modelos piloto y marcos conceptuales hacia soluciones institucionalizadas de analítica avanzada⁴⁵.

Desde una perspectiva funcional, el modelo se orienta a la construcción de un *scoring* de riesgo fiscal, entendido como una medida sintética que estima la probabilidad relativa de incumplimiento de un contribuyente dentro de un universo comparable. Dicho *scoring* no constituye una determinación automática de evasión ni un acto administrativo, sino un insumo para la priorización de acciones de control, compatible con esquemas de fiscalización diferenciada y enfoques basados en riesgo (OCDE, 2019).

En cuanto a su ámbito de aplicación, el modelo se focaliza en contribuyentes con información digital disponible, particularmente aquellos alcanzados por regímenes de facturación electrónica, declaraciones juradas periódicas y sistemas de información de terceros. Esta delimitación responde tanto a criterios de factibilidad analítica como a la necesidad de contar con series históricas consistentes para el entrenamiento y validación de modelos predictivos⁴⁶.

Asimismo, el alcance del modelo se restringe a la detección temprana de señales de riesgo, evitando su utilización como mecanismo exclusivo para la adopción de decisiones con efectos jurídicos directos. En línea con los principios de gobernanza algorítmica, se asume que los resultados del modelo deben ser interpretados, contextualizados y eventualmente contrastados por agentes humanos, garantizando la trazabilidad y explicabilidad de los criterios utilizados.

⁴⁵ OCDE (2021): *Tax Administration 2021: Comparative Information on OECD and Other Advanced and Emerging Economies*. OECD Publishing.

⁴⁶ International Monetary Fund (2021): *Digitalization and risk management in tax administrations*. IMF Fiscal Affairs Department.

En conclusión, el modelo propuesto se diseña bajo el supuesto de uso responsable de los datos fiscales, respetando los principios de legalidad, proporcionalidad y minimización, y contemplando desde su concepción instancias de control, revisión periódica y actualización metodológica. De este modo, el objetivo no es maximizar la detección de incumplimientos a cualquier costo, sino mejorar la calidad del control tributario, fortaleciendo simultáneamente la eficiencia administrativa y la legitimidad del accionar fiscal⁴⁷.

b. Fuentes de datos e insumos analíticos.

El diseño de un modelo predictivo de riesgo fiscal requiere identificar, de manera preliminar, las fuentes de datos potencialmente disponibles y analíticamente relevantes, así como los criterios para su integración y tratamiento. En el contexto de la administración tributaria argentina, la digitalización progresiva de los procesos fiscales ha ampliado de forma significativa el volumen y la diversidad de información susceptible de ser utilizada con fines analíticos, siempre dentro de los límites impuestos por el marco normativo vigente.

Una primera categoría de insumos está constituida por los datos declarativos, principalmente las declaraciones juradas de impuestos nacionales y los registros asociados a regímenes de información periódicos. Estos datos permiten reconstruir el comportamiento fiscal histórico de los contribuyentes, identificar inconsistencias internas y analizar la evolución temporal de variables clave como bases imponibles, saldos a favor, créditos fiscales y niveles de cumplimiento formal.

En segundo lugar, adquieren especial relevancia los datos transaccionales, en particular aquellos derivados de la facturación electrónica y de los libros digitales. Estas fuentes ofrecen un nivel de granularidad superior al de las declaraciones agregadas y permiten analizar patrones de emisión, frecuencia, montos, contrapartes y desvíos respecto de comportamientos sectoriales comparables. La literatura especializada destaca que este tipo de información constituye uno de los pilares para el desarrollo de modelos de riesgo basados en analítica avanzada (OCDE, 2021).

Una tercera fuente relevante corresponde a los datos provenientes de terceros, tales como información bancaria, laboral, aduanera y registral, obtenida a través de regímenes de información y convenios de intercambio interinstitucional. La integración de estas fuentes permite contrastar lo declarado por el contribuyente con información externa, ampliando la capacidad de detección de inconsistencias y reduciendo la dependencia de controles exclusivamente declarativos⁴⁸.

⁴⁷ Floridi, L. (2019): Establishing the rules for building trustworthy AI. *Nature Machine Intelligence*, 1(6), 261–262.

⁴⁸ Centro Interamericano de Administraciones Tributarias (2022): *Gestión del riesgo y analítica avanzada en las administraciones tributarias*. CIAT.

Asimismo, a partir de estas fuentes primarias pueden construirse variables derivadas e indicadores sintéticos, cuya definición y utilización se desarrollan en el apartado siguiente⁴⁹.

Desde una perspectiva metodológica, la utilización de estas fuentes exige atender a criterios de calidad, consistencia y trazabilidad de los datos, así como a la gestión de valores faltantes, errores de carga y sesgos estructurales. Organismos internacionales subrayan que la preparación y gobernanza del dato constituye una etapa crítica del ciclo de vida de los modelos analíticos, con impacto directo sobre la confiabilidad de los resultados obtenidos⁵⁰.

De esta manera, el modelo propuesto asume como principio rector el uso responsable y proporcional de la información fiscal, limitando los insumos analíticos a aquellos estrictamente necesarios para el objetivo perseguido y garantizando que el tratamiento de los datos se encuentre debidamente documentado. Este enfoque resulta coherente con las recomendaciones en materia de gobernanza algorítmica y protección de derechos del contribuyente, especialmente en contextos de aplicación de inteligencia artificial en funciones públicas sensibles⁵¹.

c. Variables e indicadores de riesgo fiscal.

La definición de las variables e indicadores de riesgo constituye un componente central en el diseño del modelo predictivo propuesto, en tanto determina su capacidad para capturar señales relevantes de incumplimiento y discriminar comportamientos fiscales heterogéneos dentro de universos comparables. En esta propuesta, las variables se conciben como insumos analíticos de carácter indirecto, orientados a estimar probabilidades relativas de riesgo y no a determinar de manera automática la existencia de evasión.

Desde una perspectiva conceptual, las variables de riesgo pueden agruparse en categorías funcionales, en base al tipo de información que reflejan y al rol que cumplen dentro del modelo. Esta clasificación facilita tanto la interpretación de los resultados como la gobernanza posterior del sistema.

- Una primera categoría está integrada por **variables de comportamiento declarativo**, vinculadas al cumplimiento formal y material de las obligaciones fiscales. Incluyen indicadores como la presentación en término de declaraciones juradas, la regularidad en los pagos, la recurrencia de rectificativas y la existencia de inconsistencias internas entre distintos tributos o períodos fiscales. Se trata de variables altamente informativas para la detección temprana de riesgos, especialmente cuando se analiza su evolución temporal.

⁴⁹ International Monetary Fund (2021): *Digitalization and risk management in tax administrations*. IMF Fiscal Affairs Department.

⁵⁰ Banco Mundial (2020): *Tax Administration Diagnostic Assessment Tool (TADAT): Improving tax administration performance*. World Bank Group.

⁵¹ OCDE (2022): *OECD Framework for the Governance of Digital Tax Administration*. OECD Publishing.

- En segundo lugar, se identifican **variables económicas y transaccionales**, derivadas del análisis de bases imponibles, volúmenes de facturación, estructura de ingresos y egresos, y patrones de operación observados a través de la facturación electrónica y otros registros digitales. Estas variables permiten evaluar la coherencia económica del contribuyente, detectar desvíos significativos respecto de comportamientos históricos propios o de referencias sectoriales y capturar cambios abruptos que pueden constituir señales de alerta temprana.
- Una tercera categoría corresponde a **variables relacionales**, construidas a partir de la vinculación del contribuyente con terceros, tales como proveedores, clientes u operadores de comercio exterior. Indicadores de concentración de operaciones, recurrencia de contrapartes de riesgo o pertenencia a redes con comportamientos atípicos han sido ampliamente utilizados en modelos de riesgo fiscal en distintas administraciones, dada su capacidad para revelar esquemas complejos de evasión que no resultan evidentes a partir del análisis individual.
- Asimismo, el modelo contempla la incorporación de **variables temporales y dinámicas**, orientadas a capturar tendencias, estacionalidades y rupturas en el comportamiento fiscal. La variación interanual de determinados indicadores, la volatilidad de la facturación o la persistencia de desvíos a lo largo del tiempo permiten enriquecer la capacidad predictiva del modelo y diferenciar situaciones coyunturales de patrones sistemáticos de incumplimiento.
- A su vez, se prevé la utilización de **indicadores sintéticos o compuestos**, contruidos a partir de la combinación ponderada de múltiples variables primarias. Estos indicadores facilitan la traducción de información compleja en señales operativas para los procesos de fiscalización, sin perder de vista la necesidad de trazabilidad y explicabilidad de los criterios utilizados. En este sentido, se asume que la selección y ponderación de variables debe ser objeto de revisión periódica, a fin de mitigar sesgos y adaptar el modelo a cambios en el entorno económico y normativo (OCDE, 2022).

En conjunto, la definición de variables e indicadores propuesta busca equilibrar capacidad predictiva, interpretabilidad y viabilidad institucional, priorizando señales observables y documentables que puedan ser integradas de manera gradual a los esquemas actuales de gestión del riesgo fiscal.

d. Enfoque metodológico y lógica del modelo de *scoring*

El enfoque metodológico del modelo propuesto se basa en la utilización de técnicas de aprendizaje automático supervisado, orientadas a estimar la probabilidad relativa de incumplimiento de los contribuyentes a partir de información histórica disponible. Este tipo de enfoque resulta especialmente adecuado en contextos tributarios donde existen registros previos de fiscalización, ajustes o

inconsistencias detectadas, que pueden ser utilizados como referencia para el entrenamiento de los modelos, aun reconociendo las limitaciones y sesgos inherentes a dichas etiquetas.

Desde el punto de vista conceptual, el modelo se estructura en torno a la construcción de un sistema de *scoring* de riesgo, entendido como una función que asigna a cada contribuyente un puntaje continuo o una categoría ordinal que refleja su nivel relativo de riesgo dentro de un universo comparable. A diferencia de los esquemas basados exclusivamente en reglas determinísticas, este enfoque permite ponderar múltiples variables de manera simultánea, capturar interacciones complejas y actualizar los criterios de riesgo en función de nueva información.

En cuanto a los algoritmos potencialmente aplicables, la literatura especializada señala una preferencia por modelos supervisados interpretables o parcialmente interpretables, tales como árboles de decisión, *random forests*, *gradient boosting* y regresiones regularizadas (OCDE, 2021). Estos algoritmos ofrecen un equilibrio razonable entre capacidad predictiva y explicabilidad, un aspecto central en el ámbito tributario, donde los resultados analíticos deben ser comprensibles y auditables por los equipos técnicos y jurídicos de la administración.

El proceso metodológico del modelo puede describirse, a nivel general, en cuatro etapas⁵²:

1. **Preparación y depuración de los datos**, incluyendo la selección de variables, el tratamiento de valores faltantes y la normalización de escalas;
2. **Entrenamiento del modelo**, utilizando datos históricos y técnicas de validación cruzada para reducir el riesgo de sobreajuste;
3. **Evaluación del desempeño**, mediante métricas apropiadas como precisión, sensibilidad, y medidas de capacidad discriminatoria, que permiten evaluar la aptitud del modelo para ordenar contribuyentes según su nivel relativo de riesgo; y
4. **Generación del *scoring* de riesgo**, que sirve como insumo para la priorización de acciones de control.

Un aspecto central del enfoque propuesto es que el *scoring* obtenido no constituye una decisión automática, sino un elemento de apoyo para los procesos de fiscalización electrónica y selección de casos. En este sentido, se asume la existencia de instancias de revisión humana, tanto en la validación del modelo como en la interpretación de sus resultados, en línea con las recomendaciones sobre supervisión humana de sistemas automatizados en funciones públicas.

Asimismo, el modelo incorpora una lógica de actualización periódica y monitoreo continuo, reconociendo que los patrones de incumplimiento fiscal evolucionan en el tiempo. La recalibración de los modelos, la revisión de las variables utilizadas y el control de posibles sesgos constituyen

⁵² Hastie, T., Tibshirani, R., & Friedman, J. (2017): *The Elements of Statistical Learning* (2nd ed.). Springer.

componentes esenciales para garantizar la estabilidad y equidad del sistema, evitando degradaciones en su desempeño predictivo⁵³.

En conjunto, el enfoque metodológico propuesto combina rigor analítico, prudencia institucional y viabilidad operativa, sentando las bases para un modelo de *scoring* de riesgo fiscal que pueda integrarse progresivamente a los esquemas actuales de gestión del riesgo, sin comprometer los principios de legalidad, transparencia y control humano.

e. Integración del modelo en los procesos de fiscalización.

La utilidad del modelo predictivo de riesgo fiscal propuesto depende, en gran medida, de su adecuada integración en los procesos existentes de fiscalización y control, evitando su concepción como una herramienta aislada o paralela a los esquemas vigentes. En este sentido, el *scoring* de riesgo debe ser entendido como un insumo analítico transversal, destinado a fortalecer los mecanismos de selección y priorización de casos dentro de las auditorías electrónicas y los procedimientos de verificación remota.

Desde una perspectiva operativa, el modelo puede integrarse como una capa analítica complementaria a los sistemas actuales de perfilamiento de contribuyentes, como el SIPER. Mientras estos sistemas clasifican a los contribuyentes en categorías discretas a partir de reglas y criterios predefinidos, el *scoring* predictivo permite introducir una medida continua de riesgo que refine dicha segmentación, facilite comparaciones intra-segmento y mejore la focalización de las acciones de control.

En el marco de las auditorías electrónicas, el modelo puede desempeñar un rol relevante en la selección temprana de casos, priorizando aquellos contribuyentes que combinan una mayor probabilidad estimada de incumplimiento con un impacto fiscal potencial significativo. De este modo, la fiscalización se orienta hacia un enfoque basado en riesgo, reduciendo intervenciones innecesarias sobre contribuyentes de bajo riesgo y optimizando el uso de recursos administrativos, tal como recomiendan los organismos internacionales (OCDE, 2021).

Asimismo, el *scoring* de riesgo puede ser utilizado como insumo para esquemas de verificación remota y acciones preventivas, tales como comunicaciones electrónicas segmentadas, requerimientos automáticos de información o alertas tempranas. Este tipo de integración permite avanzar hacia modelos de cumplimiento cooperativo y control preventivo, en los que la intervención del fisco se produce antes de que el incumplimiento se consolide, contribuyendo a mejorar el cumplimiento voluntario⁵⁴.

⁵³ Ídem Nota 47.

⁵⁴ Centro Interamericano de Administraciones Tributarias (2021): *Control preventivo y cumplimiento cooperativo en las administraciones tributarias*. CIAT.

Un aspecto central de la integración propuesta es la preservación del control humano en la toma de decisiones. El modelo no sustituye el análisis técnico ni la evaluación de los agentes fiscales, sino que proporciona información adicional para orientar su intervención. En particular, se asume que las decisiones con efectos jurídicos directos —como el inicio de una fiscalización formal— deben sustentarse en instancias de revisión humana debidamente documentadas, en línea con los principios de supervisión y *responsabilidad algorítmica*⁵⁵.

Finalmente, la integración del modelo requiere definir procedimientos claros de uso, revisión y actualización, incluyendo la documentación de los criterios analíticos empleados, la capacitación de los equipos técnicos y la articulación entre áreas operativas y analíticas. La experiencia comparada muestra que la adopción exitosa de modelos predictivos en AATT depende tanto de la calidad técnica del modelo como de su adecuada inserción en los flujos de trabajo institucionales⁵⁶.

En conjunto, la integración del modelo predictivo en los procesos de fiscalización permite consolidar un enfoque de gestión del riesgo fiscal más inteligente, focalizado y preventivo, alineado con las capacidades actuales de la administración tributaria argentina y con los principios que rigen su actuación.

f. Consideraciones sobre validación, monitoreo y actualización del modelo.

La implementación de un modelo predictivo de riesgo fiscal exige contemplar, desde su diseño, mecanismos sistemáticos de validación, monitoreo y actualización, con el fin de garantizar la confiabilidad de los resultados, la estabilidad del desempeño y la adecuación del modelo a los cambios en el entorno económico y normativo. La experiencia comparada muestra que la efectividad de los modelos analíticos no depende únicamente de su etapa inicial de desarrollo, sino de su gestión a lo largo del tiempo (OCDE, 2021).

En una primera instancia, la validación del modelo resulta indispensable para evaluar su desempeño predictivo antes de su utilización operativa. Este proceso incluye la comparación entre las predicciones del modelo y resultados históricos observados, la utilización de conjuntos de datos separados para entrenamiento y prueba, y la aplicación de métricas apropiadas —como sensibilidad, precisión y medidas de capacidad discriminadora— acordes a los objetivos de fiscalización. La validación permite

⁵⁵ Entiéndase como la obligación institucional de documentar, auditar y responder por el uso de modelos automatizados en los procesos de fiscalización

⁵⁶ International Monetary Fund (2021): *Digitalization and risk management in tax administrations*. IMF Fiscal Affairs Department.

identificar posibles errores sistemáticos, sobreajustes o sesgos iniciales que podrían afectar la equidad y eficiencia del sistema⁵⁷.

Una vez en funcionamiento, el modelo requiere un monitoreo continuo de su desempeño, orientado a detectar degradaciones en su capacidad predictiva o cambios en la distribución de los datos utilizados. Factores como modificaciones normativas, alteraciones en los patrones de cumplimiento o adaptaciones estratégicas de los contribuyentes pueden reducir la efectividad de los modelos si no se realizan ajustes oportunos. Es por ello que resulta de especial importancia establecer indicadores de alerta temprana que permitan identificar desvíos relevantes en el comportamiento del modelo.

La actualización periódica del mismo constituye otro componente central del ciclo de vida analítico. Esta actualización puede implicar la incorporación de nuevas variables, la recalibración de los parámetros existentes o incluso la revisión del enfoque metodológico utilizado. Lejos de ser un evento excepcional, la actualización debe concebirse como un proceso regular, alineado con la evolución de los riesgos fiscales y con los cambios en las fuentes de información disponibles⁵⁸.

Asimismo, la validación y el monitoreo del modelo deben integrarse en un marco de *gobernanza algorítmica*⁵⁹, que contemple responsabilidades claras, documentación adecuada y procedimientos de auditoría interna. La trazabilidad de las decisiones analíticas, la conservación de versiones del modelo y la posibilidad de explicar los criterios utilizados constituyen elementos esenciales para garantizar la transparencia y la rendición de cuentas, especialmente cuando los resultados del modelo influyen en procesos de fiscalización.

Cabe destacar que la supervisión humana debe estar presente en todas las etapas del ciclo del modelo, desde su validación inicial hasta su actualización periódica. La intervención de equipos técnicos interdisciplinarios permite contextualizar los resultados, evaluar su razonabilidad y asegurar que el uso del modelo se mantenga alineado con los principios de legalidad, proporcionalidad y equidad que rigen la actuación de la administración tributaria. De este modo, la validación y el monitoreo no sólo fortalecen la calidad técnica del modelo, sino también su legitimidad institucional.

⁵⁷ Hastie, T., Tibshirani, R., & Friedman, J. (2017): *The Elements of Statistical Learning* (2nd ed.). Springer.

⁵⁸ Centro Interamericano de Administraciones Tributarias (2022): *Gestión del riesgo y analítica avanzada en las administraciones tributarias*. CIAT.

⁵⁹ Refiere al conjunto de normas, procesos y mecanismos institucionales que regulan el diseño, uso y supervisión de modelos automatizados.

V. Ejemplo de aplicación.

a. Descripción del modelo simulado con datos sintéticos.

Con el fin de ilustrar el funcionamiento del modelo predictivo de riesgo fiscal propuesto, este capítulo desarrolla un ejemplo conceptual basado en datos sintéticos. La utilización de información simulada responde, en primer lugar, a las restricciones normativas propias del ámbito tributario, en particular al secreto fiscal. En este contexto, el uso de datos reales resulta jurídicamente improcedente para fines de investigación académica, mientras que los datos sintéticos constituyen una alternativa metodológicamente válida y ampliamente aceptada para la demostración conceptual de modelos analíticos.

Desde una perspectiva metodológica, los datos sintéticos permiten reproducir estructuras de información y relaciones plausibles entre variables relevantes, sin replicar observaciones reales ni comprometer información sensible. De este modo, es posible mostrar el flujo lógico del modelo, la construcción de variables y la generación de un *scoring* de riesgo, sin pretender validar empíricamente su desempeño ni extrapolar resultados cuantitativos al universo real de contribuyentes. El alcance del ejemplo es, por lo tanto, estrictamente ilustrativo y no evaluativo.


El conjunto simulado de datos representa un universo hipotético y acotado de contribuyentes ficticios, caracterizados a partir de tipologías de variables coherentes con las fuentes de información descriptas en el acápite anterior. Dichas variables se agrupan, a los fines analíticos, en cuatro categorías principales:

- Variables declarativas
- Variables económicas y transaccionales
- Variables relacionales
- Variables temporales y dinámicas

A partir de estas variables primarias se generan indicadores derivados y medidas sintéticas, diseñadas para alimentar el modelo de *scoring* de riesgo. La asignación de valores se realiza de manera controlada, introduciendo perfiles diferenciados de bajo, medio y alto riesgo con el único propósito de mostrar cómo el modelo puede discriminar entre comportamientos heterogéneos dentro de un entorno simulado.

Sobre esta base, el apartado siguiente presenta el flujo lógico del modelo predictivo de riesgo fiscal, detallando las etapas que van desde la integración de los datos hasta la generación del *scoring* y su utilización como insumo para los procesos de fiscalización.

b. Arquitectura conceptual del modelo predictivo de riesgo fiscal.



Fuente: Elaboración propia.

El modelo predictivo de riesgo fiscal propuesto se estructura a partir de un flujo lógico secuencial, que articula la integración de datos, su procesamiento analítico y la generación de un *scoring* de riesgo orientado a apoyar los procesos de fiscalización. Este flujo no representa una arquitectura informática específica, sino una secuencia conceptual de etapas, coherente con las prácticas observadas en AATT que han incorporado analítica avanzada en la gestión del riesgo.

La primera etapa corresponde a la integración de fuentes de datos, que incluye información declarativa y transaccional generada por los propios contribuyentes, regímenes de información de terceros con los que ya cuenta la AATT, así como fuentes externas heterogéneas que no se originan en el sistema tributario propiamente dicho. Estas últimas pueden provenir de ámbitos financieros, comerciales, logísticos o digitales, y presentan distintos niveles de estructura, formato y calidad. En esta instancia, los datos se conciben como insumos heterogéneos que requieren procesos específicos de integración, normalización y transformación para su posterior utilización analítica, sin que ello implique aún una evaluación de riesgo *per se*.

La segunda etapa consiste en el pre-procesamiento de los datos, orientado a garantizar su calidad, consistencia y comparabilidad. Esta fase incluye tareas de limpieza, transformación, normalización y construcción de variables derivadas, necesarias para reducir “ruidos”, corregir inconsistencias y adaptar la información a los requerimientos del modelo predictivo. Esta instancia resulta crítica para el desempeño posterior del modelo, en tanto condiciona la calidad de las inferencias que se obtengan como resultado.

En una tercera etapa se ubica el modelo predictivo de *scoring* de riesgo, basado en algoritmos de *machine learning* supervisado. A partir de las variables construidas, el modelo estima una probabilidad relativa de incumplimiento o asigna un puntaje de riesgo, que permite ordenar a los contribuyentes dentro de un universo comparable. Este *scoring* no constituye una calificación jurídica ni una presunción automática de incumplimiento o evasión, sino una herramienta analítica destinada a apoyar la toma de decisiones.

La cuarta etapa corresponde a la generación e interpretación de los resultados del modelo, expresados en puntajes continuos o categorías de riesgo (bajo, medio, alto). Estos resultados deben ser interpretados en función del contexto económico, sectorial y temporal de cada contribuyente, y pueden complementarse con información adicional disponible en los sistemas de la AATT.

El flujo culmina en la utilización operativa del *scoring* de riesgo como insumo para los procesos de fiscalización. Entre sus posibles aplicaciones, se incluyen la priorización de casos para auditorías electrónicas, la emisión de alertas tempranas y la selección de contribuyentes para verificaciones remotas. En todos los casos, se asume la existencia de instancias de validación y control humano, de modo que el modelo actúe como un sistema de apoyo y no como un mecanismo automático de decisión, retroalimentando y corrigiendo posibles desvíos.

En conjunto, el flujo lógico presentado permite visualizar cómo la analítica predictiva puede integrarse de manera progresiva en los esquemas actuales de gestión del riesgo fiscal, fortaleciendo la capacidad de detección temprana de inconsistencias sin alterar los principios de legalidad, proporcionalidad y control que rigen la actuación de la administración tributaria.

c. Análisis de resultados.

A partir de la aplicación del modelo predictivo sobre el conjunto de datos sintéticos, se obtiene un puntaje de riesgo fiscal (*scoring*) para cada contribuyente, que permite ordenar el universo analizado según su nivel relativo de riesgo. Tal como se ha señalado, estos resultados no representan evaluaciones reales ni determinaciones jurídicas, sino que cumplen una función estrictamente ilustrativa orientada a mostrar el comportamiento general del modelo.

En el escenario simulado, el *scoring* permite diferenciar perfiles de riesgo bajo, medio y alto a partir de la combinación de variables declarativas, económicas, relacionales y temporales. Los contribuyentes ubicados en los niveles de riesgo más elevado presentan, de manera consistente, mayores desvíos respecto de sus patrones históricos, irregularidades recurrentes en el cumplimiento formal o comportamientos atípicos en relación con su grupo de referencia. Por el contrario, los perfiles de bajo riesgo exhiben trayectorias más estables y coherentes con los parámetros simulados de cumplimiento.

Uno de los principales aportes del modelo, aún en este arquetipo simplificado, radica en su capacidad para integrar múltiples señales de riesgo de manera simultánea, superando la lógica de alertas aisladas basadas en reglas determinísticas. El *scoring* resultante no se encuentra dominado por una única variable, sino que refleja el efecto conjunto de distintos indicadores, permitiendo captar situaciones en las que el riesgo emerge de la interacción entre factores y no de un desvío individual fácilmente observable⁶⁰.

Asimismo, el análisis de los resultados muestra que el modelo resulta especialmente útil para ordenar prioridades dentro de universos comparables, incluso cuando las diferencias absolutas entre contribuyentes no son extremas. Esta capacidad de discriminación relativa resulta clave para los esquemas de fiscalización basados en riesgo, donde el objetivo no es identificar con certeza absoluta la evasión, sino optimizar la asignación de recursos de control hacia aquellos casos con mayor probabilidad estimada de incumplimiento y mayor impacto potencial.

Desde una perspectiva operativa, los resultados del *scoring* podrían ser utilizados como insumo para decisiones diferenciadas, tales como la selección de contribuyentes para auditorías electrónicas, la emisión de alertas tempranas o la priorización de verificaciones remotas. El ejemplo refuerza, en este sentido, la idea de que el modelo actúa como un sistema de apoyo a la decisión, cuya interpretación requiere necesariamente del análisis contextual y del control humano por parte de los agentes fiscales.

Finalmente, el ejercicio permite observar que el valor del modelo no reside únicamente en la clasificación final de los contribuyentes, sino también en su capacidad para aportar información estructurada sobre los factores que inciden en el riesgo fiscal. Esta característica resulta particularmente relevante para la gestión tributaria, en tanto facilita la comprensión de los patrones subyacentes y contribuye a una fiscalización más focalizada, eficiente y transparente.

En conjunto, el análisis de los resultados simulados muestra que el modelo predictivo de riesgo fiscal propuesto es conceptualmente consistente y operativamente plausible, y que su principal aporte radica en mejorar la priorización de acciones de control y fortalecer la detección temprana de comportamientos de riesgo dentro de un marco de uso responsable de la inteligencia artificial.

d. Alcances y limitaciones.

El ejemplo desarrollado en este capítulo tiene un alcance estrictamente ilustrativo y conceptual, orientado a mostrar cómo podría funcionar un modelo predictivo de riesgo fiscal, basado en inteligencia artificial dentro de una AATT. En este sentido, su propósito no es validar empíricamente el desempeño

⁶⁰ Hastie, T., Tibshirani, R., & Friedman, J. (2017): *The Elements of Statistical Learning* (2nd ed.). Springer.

del modelo, ni medir su impacto fiscal, sino facilitar la comprensión del enfoque metodológico propuesto y de su posible integración en los procesos de fiscalización.

Una primera limitación relevante del ejercicio, radica en el uso de datos sintéticos, que, si bien permite preservar la confidencialidad y cumplir con las restricciones del secreto fiscal, no reproduce la complejidad, heterogeneidad, ni las distribuciones empíricas observadas en bases de datos reales. En consecuencia, los resultados obtenidos no pueden extrapolarse al comportamiento efectivo de los contribuyentes ni utilizarse como evidencia de eficacia predictiva.

Asimismo, el modelo presentado simplifica las relaciones entre variables, omitiendo factores institucionales, normativos y conductuales que influyen en la dinámica del cumplimiento tributario. En una implementación real, estos elementos deberían ser incorporados progresivamente, junto con procesos de validación técnica más exhaustivos y pruebas en entornos controlados antes de su eventual uso operativo⁶¹.

Otra limitación del ejemplo, se vincula con la ausencia de retroalimentación real entre los resultados del modelo y las acciones de fiscalización. En contextos reales, las decisiones adoptadas por la administración —como auditorías, ajustes o comunicaciones preventivas— generan información adicional que puede ser utilizada para recalibrar los modelos y mejorar su desempeño a lo largo del tiempo. Esta dinámica de aprendizaje continuo no puede ser replicada en un ejercicio simulado.

Por último, y desde una perspectiva institucional, el ejemplo tampoco aborda en profundidad los desafíos organizacionales y operativos asociados a la adopción de modelos predictivos, tales como la capacitación del personal, la coordinación entre áreas técnicas y operativas, o la adecuación de los marcos normativos internos. Estos aspectos resultan centrales para una implementación efectiva, pero exceden el alcance del presente trabajo.

En síntesis, el ejercicio desarrollado permite visualizar de manera concreta la plausibilidad conceptual y operativa del modelo predictivo propuesto, al tiempo que explicita sus principales limitaciones. Estas restricciones refuerzan la necesidad de una adopción gradual, responsable y cuidadosamente gobernada de la inteligencia artificial en el ámbito tributario, alineada con las buenas prácticas internacionales y con las particularidades del contexto argentino.

⁶¹ International Monetary Fund (2021): *Digitalization and risk management in tax administrations*. IMF Fiscal Affairs Department.

VI. Conclusiones

La transformación digital de las AATT ha redefinido de manera sustantiva los procesos de fiscalización y control, desplazando el eje desde esquemas predominantemente reactivos hacia enfoques basados en información, análisis y gestión del riesgo. En este contexto, la inteligencia artificial y, en particular, los modelos predictivos basados en *machine learning*, emergen como herramientas con un potencial significativo para fortalecer la detección temprana de conductas evasivas y optimizar la asignación de los recursos de control.

A lo largo del presente trabajo se analizó el marco conceptual y operativo en el que podría inscribirse un modelo predictivo de riesgo fiscal aplicable a la administración tributaria argentina, atendiendo tanto a las capacidades existentes como a las restricciones institucionales, normativas y éticas propias del ámbito tributario. El análisis del estado actual, muestra que organismos como ARCA cuentan con un grado relevante de digitalización, con sistemas de auditoría electrónica, cruces automatizados de información y esquemas de perfilamiento de contribuyentes que constituyen una base adecuada para la incorporación progresiva de analítica avanzada.

En este sentido, la propuesta desarrollada no plantea una ruptura con los instrumentos vigentes, sino una evolución complementaria. El modelo predictivo de *scoring* de riesgo fiscal se concibe como una capa analítica adicional, capaz de integrar múltiples señales de riesgo de manera simultánea, capturar relaciones complejas entre variables y ordenar contribuyentes según su nivel relativo de riesgo. Este enfoque permite superar algunas de las limitaciones inherentes a las matrices de riesgo estáticas y a las reglas determinísticas, sin renunciar a la trazabilidad, ni a la explicabilidad necesarias en la gestión pública.

El ejemplo ilustrativo con datos sintéticos permitió mostrar, de forma concreta, la plausibilidad conceptual y operativa del modelo propuesto. Aún reconociendo sus limitaciones, el ejercicio evidenció la capacidad del *scoring* para diferenciar perfiles de riesgo, apoyar la priorización de auditorías electrónicas y servir como insumo para acciones preventivas y verificaciones remotas. De este modo, se refuerza la idea de que el principal valor de la analítica predictiva en materia tributaria no reside en la automatización de decisiones, sino en su aporte como herramienta de apoyo al análisis humano.

Un aspecto central del trabajo fue la incorporación de consideraciones relativas a la gobernanza y responsabilidad algorítmica, entendidas como condiciones necesarias para un uso legítimo y sostenible de la inteligencia artificial en la fiscalización tributaria. La necesidad de control humano, transparencia, documentación de los modelos y revisión periódica de su desempeño, se presenta no como una limitación, sino como un requisito indispensable para preservar la equidad, la legalidad y la confianza en el accionar del fisco.

En conjunto, este trabajo busca contribuir al debate sobre la modernización de la administración tributaria argentina desde una perspectiva realista y aplicada, proponiendo un marco conceptual que articula tecnología, gestión del riesgo y principios institucionales. Lejos de ofrecer soluciones cerradas, la investigación sienta las bases para futuras líneas de análisis orientadas a la validación empírica de modelos, el estudio de impactos fiscales concretos y la adaptación de estas herramientas a las particularidades normativas y organizacionales del país.

Finalmente, puede afirmarse que la inteligencia artificial, utilizada de manera responsable y estratégicamente integrada, tiene el potencial de convertirse en un instrumento clave para una fiscalización más inteligente, focalizada, e incluso preventiva, capaz de fortalecer la eficiencia del sistema tributario y de mejorar la relación entre el Estado y los contribuyentes, en un entorno económico cada vez más complejo y digitalizado.

VII. Bibliografía

- Australian Taxation Office. (2021). *Data matching protocols*. Australian Government.
- Ayres, I., & Braithwaite, J. (1992). *Responsive regulation: Transcending the deregulation debate*. Oxford University Press.
- Brynjolfsson, E., & McAfee, A. (2014). *The second machine age: Work, progress, and prosperity in a time of brilliant technologies*. W. W. Norton & Company.
- Davenport, T. H., & Ronanki, R. (2018). Artificial intelligence for the real world. *Harvard Business Review*, 96(1), 108–116.
- European Commission. (2018). *EUROFISC: Cooperation in combating VAT fraud*. Publications Office of the European Union.
- European Commission. (2021). *Ethics guidelines for trustworthy AI*. Publications Office of the European Union.
- Floridi, L., & Cows, J. (2019). A unified framework of five principles for AI in society. *Harvard Data Science Review*, 1(1). <https://doi.org/10.1162/99608f92.8cd550d1>
- Frey, C. B., & Osborne, M. A. (2017). The future of employment: How susceptible are jobs to computerisation? *Technological Forecasting & Social Change*, 114, 254–280.
- Hastie, T., Tibshirani, R., & Friedman, J. (2017). *The elements of statistical learning: Data mining, inference, and prediction* (2nd ed.). Springer.
- HM Revenue & Customs. (2022). *Compliance yield: Methodology and results*. UK Government.
- Janssen, M., van der Voort, H., & Wahyudi, A. (2017). Factors influencing big data decision-making quality. *Journal of Business Research*, 70, 338–345.
- Kreps, D., & Wilson, R. (1982). Reputation and imperfect information. *Journal of Economic Theory*, 27(2), 253–279.
- Luttmer, E. F. P., & Singhal, M. (2014). Tax morale. *Journal of Economic Perspectives*, 28(4), 149–168.
- McKinsey Global Institute. (2022). *Jobs lost, jobs gained: Workforce transitions in a time of automation*. McKinsey & Company.
- OCDE. (2017). *Technology tools to tackle tax evasion and tax fraud*. OECD Publishing.

- OCDE. (2021). *Tax administration 2021: Comparative information on OECD and other advanced and emerging economies*. OECD Publishing.
- OCDE. (2022). *Tax administration 2022: Comparative information on OECD and other advanced and emerging economies*. OECD Publishing.
- OCDE. (2023). *Tax Administration 3.0: Digital transformation of tax administrations*. OECD Publishing.
- Pomeranz, D. (2015). No taxation without information: Deterrence and self-enforcement in the VAT. *American Economic Review*, 105(8), 2539–2569.
- Russell, S., & Norvig, P. (2020). *Artificial intelligence: A modern approach* (4th ed.). Pearson.
- Slemrod, J. (2019). Tax compliance and enforcement. *Journal of Economic Literature*, 57(4), 904–954.
- Slemrod, J., & Weber, C. (2012). Evidence of the invisible: Toward a credibility revolution in the empirical analysis of tax evasion and the informal economy. *International Tax and Public Finance*, 19(1), 25–53.
- Tegmark, M. (2017). *Life 3.0: Being human in the age of artificial intelligence*. Penguin Books.
- Torgler, B. (2007). *Tax compliance and tax morale: A theoretical and empirical analysis*. Edward Elgar Publishing.
- World Economic Forum. (2023). *The future of jobs report 2023*. World Economic Forum.