



Sección **Diálogos**

**De la Teoría a
la Tecnología:
*Computational Antitrust***

**Concepto, orígenes y estrategias
para su implementación**

Eugenio Ruiz-Tagle W.



Eugenio Ruiz-Tagle W.

Abogado, Pontificia Universidad Católica de Chile. Master of Laws (University College London) y Master of Science in Computer Science (Birkbeck College, University of London). El autor se desempeñó como Sub Jefe de la División Anti-Carteles de la Fiscalía Nacional Económica entre 2017 y 2022. Actualmente es colaborador del proyecto Computational Antitrust del centro Codex de la Universidad de Stanford.

De la Teoría a la Tecnología: *Computational Antitrust*

Concepto, orígenes y estrategias para su implementación

Abstract: Siguiendo la caracterización de Antitrust Político y Económico como ‘olas’ del Derecho Antitrust, el presente trabajo expone la hipótesis, originalmente concebida por el Dr. Thibault Schrepel, que hemos traspasado los umbrales del denominado “Antitrust Computacional” o “Antitrust 3.0”. El aumento exponencial en las capacidades de procesamiento, la expansión de la infraestructura de redes y la digitalización masiva de prácticamente todos los aspectos de la vida económica han dado lugar a la denominada “Competencia Algorítmica”, fenómeno que ha llamado la atención de organismos internacionales y agencias de competencia. No sólo se plantean serios desafíos a la institucionalidad encargada de su defensa, sino que podrían estar entredicho paradigmas establecidos sobre el funcionamiento del proceso competitivo.

En este contexto, las autoridades en esta materia se enfrentan a la tarea de elaborar y poner en marcha una estrategia orientada a integrar herramientas analíticas y métodos computacionales a su quehacer. Por lo anterior, se subraya la necesidad de invertir en equipamiento y capital humano que permita la integración de científicos de datos y expertos en ciencias computacionales al trabajo hasta ahora principalmente encomendado a economistas y abogados. Asimismo, se examina el Proyecto ‘Computational Antitrust’ de la Universidad de Stanford, destacando sus contribuciones en la formación de redes de investigación interdisciplinaria entre expertos, académicos y agencias de competencia alrededor del mundo.

A continuación, se presenta una hoja de ruta especialmente concebida para jurisdicciones en vías de desarrollo, que contempla tres hitos fundamentales: la optimización y organización de recursos internos o ‘base de experiencia’ de las agencias de competencia siguiendo métodos empleados para la gestión de Big Data, la creación de Unidades de Datos siguiendo las mejores experiencias internacionales, y el uso de herramientas predictivas avanzadas al servicio de la función jurisdiccional y el desarrollo jurisprudencial. Concluyo con algunas reflexiones finales sobre la ruta propuesta y desafíos futuros.

ÍNDICE

Introducción.....	5
I. Los Precursores: Antitrust Político y Económico.....	5
II. La transformación tecnológica.....	6
II.(a) Poder de procesamiento.....	6
II.(b) Masificación de redes y ‘datificación’.....	9
III. Competencia Algorítmica.....	10
IV. Antitrust Computacional: Orígenes y objetivos.....	15
V. El Proyecto Computational Antitrust de la Universidad de Stanford.....	16
VI. La puesta en marcha: una propuesta.....	17
VI.(a) Organización, sistematización y explotación de datos propios.....	17
VI.(b) Creación de Unidades de Datos.....	19
VI.(c) Contribución a la adjudicación y al desarrollo jurisprudencial.....	20
VII. Consideraciones finales.....	23
Bibliografía	25

INTRODUCCIÓN

El presente trabajo se inspira en el paper "[Computational Antitrust: An Introduction and research agenda](#)" del Dr. Thibault Schrepe1, quien introdujo el concepto de *Computational Antitrust* o *Antitrust 3.0*, y que posteriormente dio origen al *Proyecto Computational Antitrust* del centro Codex de la Universidad de Stanford.

El mencionado autor identifica dos etapas del derecho de la competencia que conceptualmente denomina *Antitrust Político* y *Antitrust Económico*. Argumenta que, a partir de la última década, estamos en presencia de una nueva era de complejidad y dinamismo en los mercados. *Antitrust 3.0* emerge como un fenómeno global, basado en el reconocimiento de que, para cumplir su trascendental función, el sistema de defensa de la libre competencia precisa poner en marcha un plan ambicioso, orientado a hacerse de capacidades informacionales, analíticas y predictivas, y de personal experto en ciencias de datos y otras áreas afines.

En los párrafos que siguen, explicaré con algún detalle, aunque de forma necesariamente incompleta e imperfecta, cómo el aumento del poder de procesamiento, la masificación de las redes y la "datificación" han transformado la dinámica de los mercados en el sentido antes referido por Schrepe1, dotando de un nuevo sentido al paradigma de la *adaptación inteligente a las condiciones de mercado*.

Pese a que *Antitrust Computacional* ha dado lugar a abundante investigación académica y a diversas iniciativas de colaboración internacional, me centraré en los que considero los aspectos más importantes del programa para su desarrollo e institucionalización por parte de agencias y autoridades de competencia, independiente de su estado de avance en la materia.

I. LOS PRECURSORES: ANTITRUST POLÍTICO Y ECONÓMICO

En su primera encarnación, el Derecho Antitrust sienta sus bases en una teoría económica que identifica claramente los males del monopolio y en un momento político en que se reconoce como necesaria la intervención de agencias del estado para impulsar la libertad individual y el emprendimiento², combatir la concentración excesiva de poder en manos de privados, y en general, reducir el ámbito en el que el bienestar general puede ser supeditado a la discreción de una minoría³. Y aunque el contexto histórico de su introducción varía notablemente entre regiones del mundo⁴, en todos los casos supone la consagración legislativa de un programa político que persigue democratizar la economía de mercado, a la que se aplica una interpretación principalmente *textual*⁵.

Con el avance y ulterior predominio de escuelas pro-mercado o *laissez faire*, el Derecho de la Competencia progresivamente enfoca su atención en el impacto de las conductas en el bienestar general en términos de precios y unidades producidas, llegando algunos autores a cuestionar la utilidad, y aún la legitimidad, de la intervención con cualquiera otros objetivos⁶. Aun cuando algunas de sus posturas más extremas están

1 Thibault Schrepe1, *Computational Antitrust. An Introduction and Research Agenda*. Stanford Computational Antitrust, Vol I (2021).

2 David K. Millon, *The Sherman Act and the Balance of Power*, 61 S. Cal. L. Rev. 1219 (1988).

3 Robert Pitofsky, *The Political Content of Antitrust*, University of Pennsylvania Law Review (1979).

4 En EEUU, su introducción se asocia a la Sherman Act (1890), en Europa, al Tratado de Roma (1957).

5 Schrepe1, *Computational Antitrust*, p.2.

6 Famosamente, Robert Bork y los precursores de la denominada 'Escuela de Chicago'.

virtualmente superadas, su legado ha llevado a que tribunales y agencias de competencia reconozcan el enfriamiento asociado a los falsos positivos, apelando de manera sistemática a conceptos y métodos analíticos de las ciencias económicas, orientados a evaluar y medir impactos en la eficiencia en los mercados de las conductas sujetas a escrutinio⁷.

El denominado 'Antitrust 2.0.' alcanza su madurez con la institucionalización de las ciencias económicas en el derecho de la competencia. Esta etapa está caracterizada por (i) razonamientos judiciales fundados de manera sustancial y explícita en teoría económica, y (ii) la presencia de economistas y expertos en ciencias económicas integrando agencias de competencia y tribunales especializados⁸⁻⁹.

II. LA TRANSFORMACIÓN TECNOLÓGICA

A diferencia de sus antecesoras, Antitrust 3.0 no es heredera de un movimiento ideológico o una revolución política, ni se debe al predominio de una escuela de pensamiento sobre otras. En vez, su advenimiento y desarrollo, en curso pero todavía incompleto, obedece a una serie de fenómenos interrelacionados que derivan del cambio tecnológico exponencial en diversas áreas clave que han tenido lugar, aproximadamente, a partir del año 2010.

Es posible que algunos de los conceptos y eventos que trataremos no sean una novedad, que el lector los conozca o intuya con más o menos familiaridad. Sin embargo, antes de describir esta nueva era del Antitrust, es necesario intentar justificar la existencia del *cambio tecnológico* antes mencionado, y aventurar algunos de los desafíos que puede ofrecer a nuestra disciplina.

II. (a). Poder de procesamiento

"We have computer power coming out of our ears" - Carver Mead

En teoría de la información, la unidad de medida más pequeña es un dígito binario o *bit*. Un *bit* representa la mínima expresión de incertidumbre ante dos alternativas igualmente probables, como tirar una moneda al aire¹⁰. De acuerdo a este principio, un pequeño circuito eléctrico o interruptor que llamamos *transistor* cuenta con dos posibles estados: o se enciende o se apaga; y según el caso, permite o bloquea el flujo de corriente. En *código binario* representamos estos dos estados con ceros (0) y unos (1).

7 En este sentido, Schmalensee aduce que aun cuando algunas posturas de la escuela de Chicago no lograron consenso en el ámbito académico, han ejercido un efecto positivo sobre la política antimonopolio al forzar a los defensores de políticas más intervencionistas a considerar las justificaciones económicas, desplazando el centro de gravedad del debate hacia un análisis basado en efectos. Richard Schmalensee, "Thoughts on the Chicago Legacy on US Antitrust" en Pitrofsky, E. (ed) "How the Chicago School Overshot the Mark" (2008), p.25.

8 William Kovacic y Carl Shapiro, *Antitrust Policy: A Century of Economic and Legal Thinking*. Journal of Economic Perspectives, 14 (1): 43-60. (2000), p. 19.

9 Por ejemplo, en Chile el establecimiento del 'Antitrust Económico' cuenta como hitos relevantes la administración del Fiscal Pedro Mattar que buscó un equilibrio entre la participación de abogados y economistas, abandonando la percepción de la FNE como un 'estudio de abogados' y las ciencias económicas como un 'insumo' a su servicio. Patricio Bernedo, *Historia*, p. 168. La integración permanente de dos Ministros Integrantes del Tribunal de Defensa de la Libre Competencia por expertos en ciencias económicas a partir de la entrada en vigencia de la Ley 19.911, podría entenderse como el momento crucial de este proceso de institucionalización.

10 James Gleick, *The Information: A History, A Theory, A Flood*. Pantheon/Random House (2011).

De la Teoría a la Tecnología: *Computational Antitrust*

Agrupadas en secuencias de a ocho posiciones, cada una con dos alternativas posibles (0 o 1), un *byte* puede representar 256 combinaciones distintas y únicas, sin ninguna redundancia¹¹. Por ejemplo, un *byte* es suficiente para representar el conjunto básico de caracteres del código de texto ASCII¹², o registrar la intensidad de los colores primarios de un *picture element* o *pixel*, la transistor piedra angular de imágenes y videos digitales en el modelo RGB¹³. En un computador, los componentes del hardware, incluidos los *transistores* integrados en los circuitos de la Unidad de Procesamiento Central, ejecutan operaciones lógicas y aritméticas de *procesamiento de datos*, previamente codificadas en este lenguaje binario¹⁴.

A mediados de los 60's, el Director de Investigación y desarrollo de Intel, Gordon Moore, observó que el número de transistores al interior de los circuitos integrados doblaba su densidad cada dos años, al mismo costo, y predijo que esta tendencia continuaría. Pero no fue él, sino su colega y amigo Carver Mead quien acuñó el término "**Ley de Moore**". Mead fue uno de los primeros académicos en comprender que la ingeniería de los microelectrónicos se transformaría en un catalizador para que un día haya "*un pequeño computador dentro de nuestro teléfono, del auto o de la máquina de escribir*". Con millones de estas microscópicas planchitas de silicona, el poder para transmitir, almacenar o procesar datos "*nos saldrá por las orejas*"¹⁵. Corría 1972.

Carver Mead junto a alumnos de su clase de microelectronics



Fuente: Archivo Caltech Library¹⁶

11 En relación, por ejemplo, al lenguaje natural que suele ser ineficiente. El fundador de Teoría de la Información, Claude Shannon, estimó que el inglés tiene una redundancia del 50%, esto es que típicamente los mensajes pueden reducirse por la mitad y ser comprensible, aunque por otro lado, la redundancia sirve de 'antídoto' a la confusión por errores tipográficos y ruido en los mensajes. J. Gleick, *The Information*, p.216.

12 ASCII cuenta con suficientes letras, números y caracteres de puntuación para el procesamiento de texto en inglés. Ha sido hace algunos años superado por UNICODE, que es el estándar hoy.

13 Cada uno de los colores, rojo (R), verde (G) y azul (B) tiene una intensidad posible entre 0 y 255. De esta manera, un solo *pixel* puede reflejar 16.777.216 colores diferentes.

14 El *ensamblador* es un programa que traduce el código binario a 'lenguaje de máquina' para la ejecución de instrucciones en el CPU.


15 Chris Miller, *Chip Wars*, Scribner (2022), p. 71.

16 <https://calteches.library.caltech.edu/303/1/mead.pdf>.

Certera por decenas de años, la ‘Ley de Moore’ es considerada una metáfora del vértigo del cambio tecnológico y la formulación más famosa del tránsito hacia la era digital¹⁷. Si la velocidad de un computador es en gran medida proporcional al número de transistores que conforman su unidad de procesamiento, el aumento del número de transistores, a costos sostenidamente decrecientes, permite la generación de microprocesadores o *chips* capaces de ejecutar más operaciones, con más funcionalidades y mejor rendimiento¹⁸.

Ahora bien, si sabemos que hay una transformación digital en curso desde hace décadas, ¿por qué decimos que el Antitrust Computacional es un fenómeno cuyo origen puede más o menos ubicarse en los 2010s? ¿Qué tan arbitrario es este punto de referencia?

Figura 1: Número de transistores por microprocesador.



Fuente: Our World in Data¹⁹

Exponencial es la calidad de aquello que se multiplica a una proporción constante, un fenómeno caracterizado por su sutileza inicial y posterior explosividad²⁰. En escala de miles de millones (*billions* en la Figura 1, por su nomenclatura en inglés), el número de transistores por microprocesador experimenta un incremento observable a partir de 2009, empujándose agresivamente a mediados de la década siguiente. Sumado a mejoras en la arquitectura de otros componentes, el aumento cuantitativo en el número de transistores equivale a un salto cualitativo del procesamiento secuencial y paralelo, haciendo realidad avances que

17 Robert R. Schaller, *Moore's Law, past, present and future*, *IEEE Spectrum* 34(6):52 - 59.

18 Azeem Azhar, *The Exponential Age*, Diversion Books (2021), p.8.


19 <https://ourworldindata.org/grapher/transistors-per-microprocessor?yScale=linear>

20 Observación presente en el fascinante 'problema del trigo y el tablero de ajedrez'. https://en.wikipedia.org/wiki/Wheat_and_chessboard_problem.

antes sólo eran concebidos teóricamente. Por ejemplo, desde hace años se especula que capas de redes neuronales artificiales podrían impulsar los análisis predictivos que subyacen la nueva era de la inteligencia artificial (IA). Sin embargo, el auge del *deep learning* sólo fue posible con extraordinarias cantidades de *compute power*, que solo recientemente están disponibles²¹.

II. (b). Masificación de redes y 'datificación'

De la mano del poder de procesamiento, este primer cuarto de siglo ha visto un rápido desarrollo de los sistemas interconectados de fibra óptica e inalámbrica, y de la infraestructura de servidores habilitados para la transmisión de datos, a velocidades cada vez más altas y con menor latencia.



Fuente: Elaboración propia en base a información de Statista²² y World Bank²³

En 2010, el 28% de la población mundial estaba conectada a internet, mientras que el 2022 esa proporción alcanzó los dos tercios (Figura 2). Dado que el aumento demográfico representa apenas un 14% en este período, podemos concluir que más del 90% de los 3.300 millones de nuevos usuarios están conectados en buena parte gracias a la penetración de la infraestructura que hace posible el acceso a internet²⁴. El

21 Azeem Azhar, *The Exponential Age*, p.20.

22 <https://www.statista.com/statistics/273018/number-of-internet-users-worldwide/>.

23 Disponible en datacatalog.worldbank.org.

24 De los 3.3 miles de millones de nuevos usuarios, solo unos 280 millones pueden atribuirse al crecimiento de la población.

despliegue de servidores centralizados o distribuidos en distintas zonas geográficas, el *cloud computing* y el *software como servicio* han abierto incontables posibilidades en línea para este nuevo torrente de usuarios, particularmente en lo relativo al comercio electrónico²⁵.

La llamada “digitalización de prácticamente todo”, esto es, la transformación de documentos, fotos, videos, mapas, música, etc., en corrientes de *bits* registrables y reproducibles, es uno de los hitos más notables de nuestra época²⁶. Este poder transformador incluye conspicuamente al producto de los denominados *sensores*: los teléfonos y automóviles que imaginaba Carver Mead, y múltiples dispositivos que usamos diariamente, automáticamente detectan, captan o miden señales o eventos del mundo exterior y los transforman en datos, que luego son retransmitidos vía módulos Wi-Fi convenientemente integrados²⁷.

Así, el volumen de *bits* generados al año se ha multiplicado por 35 desde el año 2010²⁸. No es sorpresa entonces que muchos emprendimientos sean, o se hayan transformado, en negocios de datos²⁹, y que los centros de datos a hiperescala sean considerados la columna vertebral de las plataformas tecnológicas más importantes del mundo³⁰. Y si en grandes volúmenes y a altas velocidades de transmisión se dice que los datos son el nuevo petróleo, valiosos pero inútiles sin refinar³¹, hay entonces bastante por refinar. Y hoy tenemos el poder de procesamiento y la velocidad de transmisión para hacer precisamente eso.

En suma, el surgimiento de una nueva capacidad de procesar, transmitir y almacenar grandes volúmenes de datos, el desarrollo de industrias digitales y servicios en la nube, ha impulsado de manera sutil, pero a la postre explosiva, dando lugar a una era de creciente dinamismo y complejidad en los mercados³².

III. COMPETENCIA ALGORÍTMICA

Un consabido paradigma de la política de competencia supone que, como contrapartida a la prohibición de concertarse entre sí o sustituir competencia por coordinación, los agentes económicos pueden, legítimamente, adaptarse de forma inteligente a la conducta existente o anticipada de sus competidores³³.

Desde hace décadas, el significado práctico de esta *adaptación inteligente* conduce principalmente al denominado *business analytics*, esto es, observación y análisis del mercado usando métodos cuantitativos sobre datos estructurados³⁴. Para gran parte del sector privado, esta situación ha evolucionado, y enfrentar

25 Jaeger, P. T., Lin, J., & Grimes, J. M. (2008). *Cloud Computing and Information Policy: Computing in a Policy Cloud?* Journal of Information Technology & Politics, 5(3), 269–283. <https://doi.org/10.1080/19331680802425479>

26 Eric Brynjolfson y Andrew McAfee, *The Second Machine Age*, Norton (2016), p.66.

27 La proliferación de los denominados *sensores* es fuente de una serie de problemas morales y sociales. Véase M. Andrejevic y M. Burdon, *Defining the Sensor Society*, University of Queensland TC Beirne School of Law Research Paper No. 14-21 (2015).

28 El volumen de datos generados globalmente aumentó de 4 zettabytes (ZB) en 2010 a 145 ZB en 2024. En un zettabyte (ZB) hay 1×10^{21} bytes (un 1 seguido de veintiún ceros). Shirvani Moghaddam, S. *The Past, Present, and Future of the Internet: A Statistical, Technical, and Functional Comparison of Wired/Wireless Fixed/Mobile Internet*. Electronics (2024), 13, 1986.

29 Por ejemplo, el hecho que la información geológica pueda registrarse en grandes lagunas de datos ha derivado en que la minería sea hoy, un negocio de ciencias de datos. Véase <https://brimm.ubc.ca/mining-is-now-a-data-science-business/>.

30 <https://blog.enconnex.com/data-center-history-and-evolution>.

31 Características propias de lo que conocemos como ‘Big Data’. Stucke et al, *Big Data and Competition Policy*, OUP (2016), cap.2. La frase *data is the new oil* es atribuida al matemático Clive Humby.

32 Schrepeel, *Computational Antitrust*, p.4.

33 CJEU Case 8/08, *T-Mobile* [2009] ECR I- 4529, § 33.

34 Referido a variables numéricas (precios de mercado, ventas, costos, etc.), métricas, resultados financieros, usualmente almacenados en bases de datos relacionales como SQL. Como contrapartida, los datos no estructurados o *unstructured data* corresponden a unidades de

las presiones del proceso competitivo ha empujado el desarrollo de business intelligence, un conjunto de técnicas analíticas sobre grandes bases de datos estructuradas y no estructuradas, vía procesos computacionales orientados a identificar, evaluar, y recomendar cursos de acción³⁵.

De acuerdo a las distintas tecnologías que operan tras bastidores, en sus versiones más sofisticadas, el *business intelligence* involucra un conjunto de instrucciones o *algoritmos que aprenden*³⁶ mediante un ejercicio iterativo de constante calibración, orientado a identificar patrones y formular predicciones: Estamos hablando de *Machine Learning* ("ML") y el ancho espectro de técnicas relacionadas³⁷. Pese a que existe vasta literatura y recursos disponibles en línea sobre este tema, vale la pena ofrecer dos muestras de la contribución de las principales variantes de estos modelos ML a la conformación de la *Competencia Algorítmica*³⁸.

ML con aprendizaje supervisado: Un programa computacional de ML que "aprende" con datos previamente etiquetados o marcados como correctos, y que, por medio de un proceso de ajuste repetido o iterativo, intenta producir predicciones útiles sobre datos nuevos o desconocidos.

Tomemos por ejemplo un modelo de *precios dinámicos*, cuya función es sugerir precios óptimos en tiempo real con la función de maximizar utilidades por unidad vendida³⁹. El agente económico carga datos conocidos preprocesados o marcados con 'etiquetas' (*labelled data*) por ejemplo, precios históricos, cantidades vendidas por SKU o categoría de productos, niveles de stock, precios de la competencia, u otros⁴⁰. A continuación, según algunas técnicas populares, el programa genera sucesivos *árboles de decisión* que refinan su poder predictivo por la vía de ser repetidamente modificados en función de los datos y de sus etiquetas.

Consideremos un caso simplificado a modo de ilustración⁴¹. Supongamos que en una primera ronda, el programa considera únicamente el precio promedio de todos los SKU para estimar el precio óptimo para cada producto. Una predicción así construida es sumamente débil, y claramente no muy útil. Pero en una segunda iteración, el modelo intenta pronosticar el precio óptimo echando mano a otra *etiqueta*, como por ejemplo, si el producto pertenece o no a una determinada categoría (eg., productos electrónicos). Dependiendo de la respuesta, ajustará el precio al alza o a la baja para cada producto o SKU, según su pertenencia o no a esta categoría (generando *ramas* del árbol en un segundo nivel). El proceso continúa componiendo la predicción con otras variables como la frecuencia o estacionalidad de las ventas, el diferencial de precios con distintos

datos con formato no almacenable en columnas y filas, desde videos, emails, páginas web, etc. Véase Steven Williams, *Business Intelligence Strategy and Big Data Analytics*, Elsevier(2016), p.44.

35 S. Williams, *Business Intelligence Strategy*, p. 30. El autor equipara data no estructurada, esto es, contenido digital que no suele ser moldeable para categorización en bases de datos tradicionales, con Big Data, con la excepción de que ciertos metadatos incluidos en Big Data como aquella proporcionada por sensores, ubicación, etc si pueden ser estructurados.

36 Una buena simplificación de *algoritmo que aprende*: Aquel que usa la Experiencia (E) para mejorar su rendimiento o Performance (P) en una Tarea (T) específica. Si el algoritmo tiene que aprender a reconocer la presencia de gatos en una foto, la T sería identificar correctamente a los gatos en la imagen, P sería la precisión, y E serían el número de imágenes analizadas. Cuanta más E tiene el algoritmo, mejor se vuelve su P en la T asignada. Mitchel (1997), citado en *Deep Learning*, cap 5, p.97. Estos algoritmos no operan con reglas lógicas, sino probabilísticas, que maximizan la posibilidad de predecir o generalizar en base a patrones o características comunes - que las hagan flexibles frente al *ruido* de la data desconocida con la que pueden encontrarse en el futuro.

37 Cabe añadir en este punto que 'adaptación inteligente' significa también distintas formas ML en sus versiones avanzadas con redes neuronales artificiales o IA. Un 72% de los participantes de la "Encuesta Global en IA" de la consultora McKinsey reportaron usar IA para al menos una función de su negocio, la mitad de ellos en dos o más funciones - un incremento significativo en comparación a los resultados de la misma encuesta el 2023. Véase la encuesta <https://www.mckinsey.com/capabilities/quantumblack/our-insights/the-state-of-ai>.

38 Los conceptos de ML de esta sección fueron obtenidos de I. Goodfellow, Y. Bengio, y A. Courville, *Deep Learning*, MIT Press (2016), específicamente el capítulo 5. El libro está disponible en línea en: <https://www.deeplearningbook.org/>.

39 Mecanismo de pricing flexible, ajustado en tiempo real en base a distintos factores concurrentes.

40 Esta información, conocida de antemano como válida, se denomina *labels* o *etiquetas*.

41 El algoritmo que genera árboles por rondas o iteraciones que estamos describiendo es el Gradient Boosting Machines (GBM) q efectivo para precios dinámicos de acuerdo al estudio Raouya El Youbi et al *Machine Learning-driven Dynamic Pricing Strategies in E-Commerce*, (2023).

competidores al momento de la venta, el volumen demandado esa semana o ese mes, etc.

Como es de esperar, existen múltiples incógnitas a resolver de forma constante, intrínsecas al modelo que involucran sofisticados esfuerzos ingenieriles, estadísticos y pruebas de ensayo y error⁴². Por ejemplo, ¿en qué proporción ajustar al alza o a la baja la predicción de precios por cada capa o nivel del árbol (*tasa de aprendizaje*)? ¿Qué tan profundos deben ser los árboles, o dicho de otra manera, cuántas capas o niveles incluir en la predicción?⁴³. Respecto a esto último, supongamos que la relación entre capacidad de inventario y las condiciones meteorológicas al momento de la venta es poco incidente para estimar el precio óptimo de un producto determinado. En este caso, para prevenir *sobreajuste* o *ruido* que impacte negativamente en el modelo predictivo, podría ser conveniente rediseñar partes del modelo, eliminar variables irrelevantes o realizar una *poda* de ciertos factores⁴⁴.

ML con aprendizaje no-supervisado: El programa recibe como *inputs* datos sin etiquetar (*non-labelled data*) con la instrucción de identificar patrones al servicio de una aplicación concreta. Ilustramos a continuación una técnica específica para ejemplificar el funcionamiento de este tipo de algoritmos⁴⁵:

Un sitio de *ecommerce* desea mejorar su estrategia de precios y marketing segmentando a sus clientes en tres grupos según sus hábitos de consumo (“Grupos”).

Paso 1: El algoritmo elige aleatoriamente a 3 clientes de la base de datos de ventas, y los designa como *centros* de los Grupos 1, 2 y 3 respectivamente.

Paso 2: El programa categoriza e incluye al resto de los clientes dentro de algunos de estos tres grupos. Para decidir a qué grupo corresponde cada uno, se consideran ciertos *atributos* asociados a cada cliente. Supongamos que en este caso, dichos atributos son un valor determinado por la frecuencia y el precio total de cada una de sus compras⁴⁶. Usando una fórmula matemática, se mide la *distancia* entre los atributos de cada cliente y los atributos del cliente designado como *centro* de cada Grupo⁴⁷, asignando cada cliente a alguno de estos tres grupos según su cercanía con el *centro* (es decir, se incluye a los clientes en el Grupo o categoría 1, 2 o 3, dependiendo del centro del que estén más cerca).

Paso 3: Se recalculan los *centros* para cada Grupo. Desde este punto en adelante y para todas las iteraciones sucesivas, los centros corresponderán al *promedio de los atributos* de

42 Este es un ejemplo de otra técnica de machine learning denominada *reinforcement learning*. Este tipo de algoritmos ML básicamente establece funciones de descuentos y recompensas vía ensayo y error, y requiere del ajuste de otras variables, como por ejemplo, la tasa de exploración de acciones recompensadas versus la exploración de nuevas acciones, de resultado desconocido o incierto.

43 Factores como la *tasa de aprendizaje* o la *profundidad del árbol* se denominan ‘hiperparámetros’.

44 Una variante de los precios dinámicos son los precios dinámicos personalizados, que consideran distintas variables asociadas a un identificador (usuario) y considera por ejemplo los hábitos de consumo, monto del ticket promedio y hábitos de navegación en línea. Sin embargo, la predominante aversión de los consumidores a este tipo de discriminación ha prevenido la masificación de esta práctica. Véase Hufnagel, G. et al, *Seeking the perfect price: Consumer responses to personalized price discrimination in e-commerce*. Journal of Business Research, Volume 143, (2022), p. 346-365.

45 El ejemplo expuesto en esta sección corresponde al trabajo de Boyu Shen *E-commerce Customer Segmentation via Unsupervised Machine Learning* (2021).

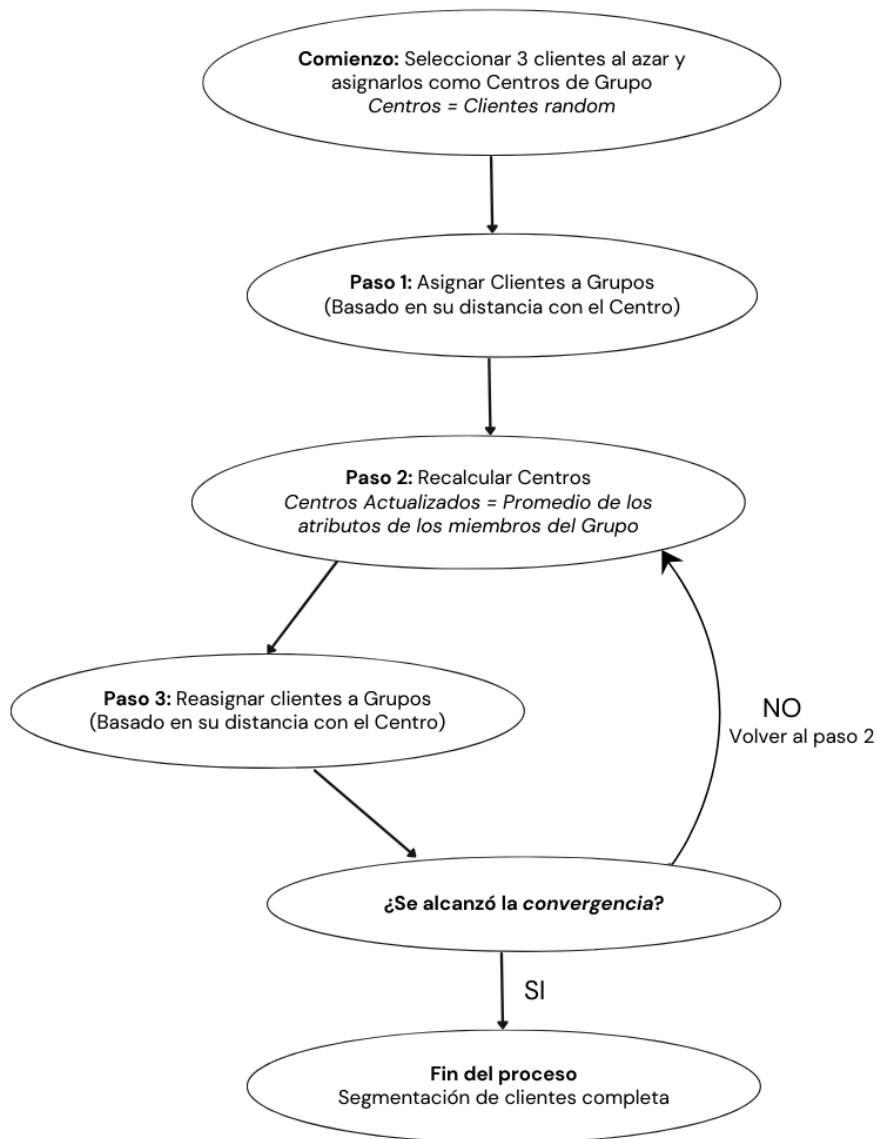
46 Proceso llamado *feature engineering*, consistente en seleccionar qué características (*features*) del mundo real se quieren incorporar al modelo y transformarlos en datos que puedan ser computados por el algoritmo.

47 Se utiliza la fórmula matemática de distancia euclidiana entre los dos puntos, usando como factores (en este caso) la frecuencia y valor de la compra.

sus integrantes.

Fin del proceso: Hasta no alcanzar la *convergencia*, se repiten los pasos 2 y 3 distribuyendo a los clientes en los tres grupos, usando la misma fórmula para medir su distancia con el *centro*. Cuando tras cada nueva repetición ningún cliente cambia de Grupo, se ha alcanzado la *convergencia*, y la segmentación de clientes ha finalizado.

Figura 3: Algoritmo ML de aprendizaje no supervisado basado en atributos para segmentación de clientes en 3 grupos



Fuente: Elaboración propia

Si usando técnicas similares o complementarias se asocia cada uno de estos tres segmentos de clientes a las categorías de productos vendidos según su precio y descripción, el *ecommerce* está en condiciones de hacer predicciones sobre hábitos de consumo que le permitirán elaborar promociones especialmente dirigidas a cada segmento, o predecir qué productos suelen comprarse juntos y ofrecer paquetes así diseñados.

En definitiva, a partir de estos modelos de aprendizaje iterativo, parte importante del trabajo de vanguardia de las ciencias de datos consiste en posicionar estas corrientes de *bits* al servicio de la *predicción*. Predicimos cada vez mejor, y sobre todo, a menor costo. Desafíos que no eran entendidos como problemas de predicción, como por ejemplo, traducir texto a otro idioma, se transformaron en tareas de predicción⁴⁸. Bases de datos masivas, estructuradas y no estructuradas, actualizadas permanentemente y combinadas con algoritmos que aprenden, provee a los operadores de posibilidades antes impensadas, como anticipar fluctuaciones, predecir preferencias, proyectar necesidades futuras y adoptar procesos automatizados de decisión, entre otras⁴⁹⁻⁵⁰.

El efecto neto en términos de oportunidades y riesgos que la creciente prevalencia del uso de estos algoritmos supone para la eficiencia en los mercados, es objeto de amplio debate académico⁵¹. Como destaca la OCDE (2023), los impactos son ambiguos⁵². Otros autores advierten que técnicas como la fijación de precios dinámicos basados en algoritmos podría provocar una masiva redistribución de rentas hacia los vendedores, en perjuicio de los consumidores⁵³. En consecuencia, y no sin razón, el tema ha sido objeto de estudio por agencias de competencia en distintas jurisdicciones, y en la comunidad internacional “[E]stá empezando a ser generalmente aceptada la necesidad examinar directamente estos algoritmos para entender cómo funcionan”⁵⁴.

Ahora bien, de qué manera llevar adelante esta auditoría genera menos consenso, y más desconcierto. Dependiendo si se dispone o no de acceso al algoritmo y a la data subyacente, se han sugerido mecanismos de indagación bastante heterogéneos, desde encuestas a usuarios hasta *reverse engineering*. Entre los problemas que reporta la OCDE para la auditoría de algoritmos, podemos contar: (i) que aun asumiendo que existe personal disponible y con conocimientos específicos, la revisión de miles de líneas de código, a veces producidas por equipos internacionales de programadores, potencialmente desarrollados en varios lenguajes de programación basados en distintos paradigmas, y con dependencias a otros programas o servicios de la empresa, puede significar tiempo y costos exuberantes; (ii) la utilización de múltiples algoritmos para una misma tarea, de manera secuencial o coetánea, algunos de los cuales pueden ser desarrollados o gestionados por terceros ubicados en una jurisdicción distinta; y, (iii) participación humana, sea de los programadores o de los consumidores en los

48 Ajay Agrawal et.al, *Prediction Machines. Expanded Edition*, HBR (2022), p.119.

49 H. Hoffman, H. y I. Lorenzoni, *Future Challenges for Automation in Competition Law Enforcement* Stanford Computational Antitrust (2023), p.37 y ss.

50 ICN CWG SG2 *Project on Big data and Cartels - The impact of digitalization in cartel enforcement* (2020).

51 Una revisión comprensiva de este tema; C. Coglianese y A. Lai, *Antitrust by Algorithm*, Stanford Computational Antitrust Vol II (2022).

52 OECD, *Algorithmic Competition*. Background Note - by the Secretariat, DAF/COMP/2023(3), 14 June 2023, p.35. Véase también: OECD, *AI, Data and Competition*, OECD Artificial Intelligence Papers, 18 (2024), p.51.

53 “We identify a more fundamental challenge posed by algorithmic pricing: in many markets it will raise prices for consumers even in the absence of collusion. The result could be a massive redistribution of wealth from buyers to sellers” A. McKay, y S. Weinstein, *Dynamic Pricing Algorithms, Consumer Harm, and Regulatory Response*, Harvard Business School Working Paper 22-050 (2022), p.55.

54 OECD (2023), p.6. En la misma línea, el Sub-Jefe de la División de Competencia de la OECD Antonio Capobianco (2023) ha insistido en la necesidad de seguir invirtiendo en conocimientos específicos en vez de tratar estos algoritmos como “cajas negras”. Publicado en Promarket (2023), disponible en: https://www.promarket.org/2023/05/23/the-impact-of-algorithms-on-competition-and-competition-law/?mc_cid=d6a91bb9ea.

procesos adheridos a ciertos sistemas de algoritmos, lo cual complejiza su comprensión.

Consideremos otras cuestiones tampoco resueltas. Por ejemplo, si una agencia genera una réplica de un algoritmo según su funcionamiento observable, y lo testea utilizando datos sintéticos pero similares a los del mundo real, ¿bajo qué elementos de juicio puede este ejercicio considerarse adecuado para acreditar la existencia de una infracción? Y si en cambio el auditor pretende contar con acceso directo al programa y a los datos con que opera el algoritmo en tiempo real, cabe preguntarse si un *requerimiento de información* (“RFI”) o incluso una *medida intrusiva* son herramientas idóneas o practicables para una intervención de esta naturaleza, que puede requerir el acceso directo a servidores o aplicaciones internas por varias semanas o meses⁵⁵⁻⁵⁶.

Un RFI constituye, en esencia, una solicitud de documentos internos o registros que el investigado debe proporcionar a la autoridad, sea de manera voluntaria u obligatoria. De este modo es posible acceder a antecedentes como los protocolos y medidas de supervisión humana que hayan sido implementados (*auditoría de gobernanza*). Pero sin acceso directo al sistema —específicamente a sus *inputs* y *outputs*, código fuente, su arquitectura, entre otras— no es posible realizar *auditorías empíricas* o *auditorías técnicas*, que requieren un análisis pormenorizado y pruebas prácticas destinadas a evaluar su funcionamiento interno⁵⁷.

Asimismo, una inspección o allanamiento tampoco parece ser la vía adecuada para una auditoría empírica o técnica. Incluso en aquellas jurisdicciones en que se permite que la agencia realice análisis *in situ* por largos períodos de tiempo, es discutible que esta sea la manera apropiada para efectuar este tipo de pericias. En efecto, las auditorías de algoritmos (sea técnica o empírica) exceden la recolección de evidencia digital, e implican la realización de pruebas al funcionamiento de un sistema interconectado potencialmente en operación. Además, un *dawn raid* tampoco es una oportunidad adecuada que los funcionarios de la autoridad interactúen de forma fluida con desarrolladores u operadores expertos en el funcionamiento de los sistemas en examen, cuestión sumamente relevante. Por último, estas son medidas investigativas son excepcionales, altamente intrusivas a la privacidad e intimidad de las personas. Por ello, no parece razonable ni proporcionado que se desarrollen inspecciones forzosas y no anunciadas en inmuebles de particulares para conducir auditorías que eventualmente pudieran realizarse de forma total o parcialmente remota, o por otras vías menos invasivas.

En definitiva, los órganos regulatorios competentes deberán dilucidar si deben procurarse cambios regulatorios que faciliten el acceso a las agencias al funcionamiento de estos algoritmos, si su uso debe estar sujeto a ciertos requisitos de trazabilidad y explicabilidad, o si estas aplicaciones deben evaluarse por sus resultados, o bien de según sus procesos⁵⁸.

IV. ANTITRUST COMPUTACIONAL: ORÍGENES Y OBJETIVOS

Los organismos de defensa de la competencia, como todas las entidades o instituciones que gobiernan o moldean la sociedad, requieren cierta estabilidad para funcionar. Su capacidad de ajustarse a nuevas

55 C. Coglianese y A. Lai proponen que las compañías tengan acceso al funcionamiento de los algoritmos en tiempo real como parte de acuerdos de composición o settlements, y que muchas empresas pueden tener incentivos para entregar voluntariamente esta información. C. Coglianese y A. Lai, *Antitrust by Algorithm*, p.15.

56 Sin contar otros problemas legales complejos, como acreditar el daño atribuible al funcionamiento del algoritmo, la definición de criterios para determinar la responsabilidad del agente económico o de imputación a personas naturales, que supervisen o intervengan de forma parcial en su diseño o puesta en marcha.

57 La *auditoría empírica* implica el acceso al flujo de información de entrada y salida, sin acceso al funcionamiento interno del algoritmo, mientras que las *auditorías técnicas* busca evaluar el funcionamiento o ejecución del algoritmo *bajo el capó*, identificar riesgos, sesgos, criterios de optimización, etc. Véase Digital Regulation Cooperation Forum, Auditing algorithms: the existing landscape, role of regulators and future outlook, Discussion Paper, 2023.

58 Susan Atey, *The Impact of Machine Learning on Economics*, en *The Economics of Artificial Intelligence: An Agenda* Eds. Ajay Agrawal, Joshua Gans, and Avi Goldfarb (2019), pp.542.

condiciones suele describirse como *lineal*, ya que su estructura, tradiciones, recursos, y el contexto histórico en el que se insertan, las constriñe a evolucionar a un ritmo relativamente constante, y que salvo eventos excepcionales, no son susceptibles a variaciones significativas entre un año y el siguiente. Esta disonancia frente a la revolución tecnológica en las proporciones antes descritas genera un cisma, una brecha que ha sido bautizada como el *gap exponencial*. Un fenómeno que puede ser socialmente disruptivo - mientras que para algunos, fuente de ganancias oportunistas⁵⁹.

En este escenario, el llamado Antitrust Computacional surge como una especificación de la *informática legal*⁶⁰, esto es, una rama de las ciencias informáticas que estudia cómo las herramientas y técnicas computacionales pueden servir de objeto al análisis jurídico⁶¹. Así concebido, este neologismo puede concebirse como un esfuerzo científico multidisciplinario que apunta a estrechar el *gap exponencial* en materia de aplicación de las normas de libre competencia en los mercados⁶². Si bien esta tarea concierne primeramente a autoridades de competencia y organismos reguladores, todos los operadores del sistema, consultores, asesores externos, oficiales de cumplimiento, y en general, actores del sector privado y organizaciones de consumidores, están llamados a reaccionar.

Como las eras que le anteceden, Antitrust 3.0 irrumpe en forma progresiva y escalonada. Su incursión en los órganos antimonopolio es observable en el equipamiento gradual de herramientas técnicas, desarrollo de funciones automatizadas, captación y procesamiento de datos y elaboración de modelos predictivos para diversos propósitos propios de su quehacer. No obstante, es crítico entender que ante todo estamos frente a un proceso *humano* cuyo éxito está supeditado en gran parte a la capacidad de generar las condiciones materiales y laborales para que programadores, científicos y analistas de datos, y otros especialistas en materias afines, sean capaces de colaborar en forma efectiva con economistas, abogados y expertos en política de competencia⁶³.

La Competencia Algorítmica y la transformación tecnológica, algunos de cuyos rasgos se han expuesto en los capítulos que anteceden, han permeado el funcionamiento de los mercados. Las instituciones de defensa de la competencia que ignoren o pospongan indefinidamente la necesidad de planificar su propia transformación digital y hacerse de capacidades a la altura de estos desafíos, lo hacen a su propio riesgo. En palabras de Bill Kovacic citando una línea de la película *The Big Short*, prescindir de dichas capacidades “es como intentar ganar las 500 millas de Indianápolis (carrera automovilística) arriba de un avestruz”⁶⁴.

V. EL PROYECTO COMPUTACIONAL ANTITRUST DE LA UNIVERSIDAD DE STANFORD

Lanzado en enero de 2021, el Centro Codex de la Universidad de Stanford dio acogida al Proyecto Computacional Antitrust (“PCA”). Esta iniciativa, que no recibe financiamiento externo a la Universidad, reúne

59 Azeem Azhar, *The Exponential Age*, pp. 59 y ss. El autor explica que esta disonancia se debe, principalmente a (i) la subestimación de la velocidad del cambio exponencial, (ii) la sobreestimación de nuestra capacidad futura de adaptarnos a cambios exponenciales, y (iii) las consecuencias inesperadas derivadas del cambio exponencial, que escapan nuestras mejores predicciones.

60 No confundir con *derecho informático*, rama de las ciencias jurídicas que suele englobar una serie de materias relacionadas a la regulación aplicable a los sistemas de tratamiento de información en distintos ámbitos (civil, comercial, penal, propiedad intelectual, entre otros).

61 Schrepel, *Computational Antitrust*, p.2.

62 “[T]here is a significant informational gap between the structure of antitrust agencies and the fast moving business world, especially in the use of information and communication technology. This gap has kept antitrust agencies from understanding and using the technology and business frontiers, undermining the agencies’ relevance and effectiveness”. Jin, Zokol & Wagman, *Towards A Technological Overhaul of American Antitrust*, Antitrust, ABA, Vol. 37, No. 1, (2022).

63 Schrepel, *Computational Antitrust*, p.14.

64 Podcast del Proyecto Computacional Antitrust (“Stanford Computational Antitrust”), Episodio 22, enero de 2024, minuto 13.11 y ss.

a una comunidad de académicos de distintas disciplinas con el fin de observar, difundir y proponer el uso de nuevas herramientas tecnológicas en el derecho de la competencia⁶⁵. Entre otras actividades, el PCA publica investigaciones académicas, organiza sesiones de trabajo, produce un podcast de amplia difusión⁶⁶, y colabora activamente con 67 agencias de competencia a nivel global⁶⁷. Anualmente, publica un reporte en el que distintas jurisdicciones comparten las áreas de innovación implementadas para distintas funciones analíticas o prácticas, identificando las tendencias más relevantes⁶⁸.

En su trabajo fundacional, el creador del PCA y su actual Director Dr. Thibault Schrepel (2020) identifica al menos tres áreas en que el progreso de esta integración multidisciplinaria denominada *Antitrust Computacional* significa para la el derecho de la competencia: (1) detección activa de conductas anticompetitivas y herramientas forenses para analizar evidencia y la creación de plataformas para facilitar el acceso a datos de los investigados, (2) en el marco de control de operaciones de concentración, la capacidad de analizar sets de datos y crear simulaciones que contribuyan a evaluar alegaciones de eficiencia, sustituibilidad o contestabilidad de los mercados, y (3) evaluar retrospectivamente intervenciones de la autoridad, decisiones de política de competencia o políticas públicas con un enfoque en la predicción⁶⁹.

En el transcurso de estos últimos años, el trabajo del PCA ha dado luz a tres reportes anuales, y a una serie de proyectos resultantes de sus investigaciones que abren espacio a la contribución de académicos de distintas formaciones. Estas propuestas, documentadas por país en los reportes anuales respectivos⁷⁰, constituyen un material invaluable para promover acciones concretas y abrir nuevos espacios de cooperación internacional.

En los párrafos que siguen, basándonos en algunas de las iniciativas del PCA y otra literatura relevante, ofrecemos lo que consideramos son tres pilares fundamentales en el progreso hacia el Antitrust Computacional.

VI. LA PUESTA EN MARCHA: UNA PROPUESTA

VI. (a). Organización, sistematización y explotación de datos propios

“The agencies collect and store large amounts of data as a result of complaints, merger filings, and investigations. There are opportunities to both utilize emerging technologies in the analysis of data, as well as to generate new datasets that are relevant to antitrust research” - Jin, Sokol y Wagman.

Para replicar sus éxitos y reflexionar sobre sus fracasos, uno de los primeros esfuerzos que es posible sugerir a las autoridades de competencia en su ruta al *Antitrust 3.0* consiste en un ejercicio de introspección sistemática

65 Véase descripción del proyecto acá: <https://law.stanford.edu/codex-the-stanford-center-for-legal-informatics/computational-antitrust-project/>.

66 *Stanford Computational Antitrust podcast*. Disponible en Spotify y otras plataformas: <https://open.spotify.com/show/62DTsUktaAaNoqxR76zlmr?si=eac25c323748488e>.

67 Listado de agencias disponible en: <https://law.stanford.edu/codex-the-stanford-center-for-legal-informatics/computational-antitrust-agencies/>.

68 El tercer reporte anual fue publicado el 11 de junio de 2024, y está disponible aquí: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=4861858. Publicación de CeCo: <https://centrocompetencia.com/computational-antitrust-stanford-un-ano-de-progreso-y-desafios/>.

69 Schrepel, *Computational Antitrust*, p.5 y siguientes.

70 T. Schrepel y T. Groza, *The Adoption of Computational Antitrust by Agencies: 2021 Report*, 2 Stanford Computational Antitrust, 78 (2022); T. Schrepel y T. Groza, *The Adoption of Computational Antitrust by Agencies: 2nd Annual Report*, 3 Stanford Computational Antitrust 55 (2023) y T. Schrepel y T. Groza, *Computational Antitrust Within Agencies: 3rd Annual Report* 4 Stanford Computational Antitrust, 53 (2024).

a su 'base de experiencia'. En otras palabras, asumir como proyecto prioritario la unificación y optimización del flujo de aquellos datos cuya fuente está a su disposición, pero que puede estar desagregada o dispersa, dadas las distintas 'unidades de negocio' que pueden desarrollar sus funciones con relativa autonomía.

Como es evidente, la forma práctica de llevar a cabo este proyecto depende de muchísimas variables propias del tamaño, recursos y objetivos de cada institución. Por tanto, usando una metodología propuesta para la gestión de *Big Data*⁷¹, a continuación esbozamos los tres principales desafíos que pueden servir de punto de partida para pensar en esta tarea.

i) Desafíos de datos: Los datos que dispondrá la organización provienen de distintas fuentes, y se presentan en múltiples formatos, estructurados y no estructurados. Por ejemplo, planillas con datos de industrias o grupos empresariales, presentaciones de las partes y sus metadatos (autor, fecha, hora, caso asociado, petición, etc.), registros de diligencias en formato multimedia, entre muchos otros que pueden pertenecer a su flujo de información actual o de su archivo. El primer desafío consiste en planificar qué datos se recopilarán, por qué medios, computar su volumen aproximado, qué servicios se contratarán para su almacenamiento, y qué plataformas de visualización se implementarán o desarrollarán para los distintos tipos de usuarios que tendrán acceso a los mismos.

ii) Desafíos de procesos: Esto incluye la recolección de los datos, su minería y limpieza para eliminar errores o duplicados, su transformación para garantizar compatibilidad y coherencia entre formatos, y su *indexación* para optimizar recursos de almacenamiento y reducir tiempos de acceso. Esta etapa puede involucrar el uso de aplicaciones para la "Extracción, Transformación y Carga"⁷² de manera de integrar la información en un repositorio central o *data warehouse*, de manera de prepararlo para su almacenamiento y el desarrollo de otras funciones analíticas o automatización de procesos⁷³.

iii) Desafíos de gestión: Por último, será necesario resolver asuntos de suma relevancia, como protocolos de seguridad, privacidad y gobernanza de los datos, gestión de acceso para distintos tipos de usuarios, y optimizar donde sea posible los costos operativos.

La centralización de la base de conocimiento reduce el impacto que puede provocar el cambio en los liderazgos de la agencia, o la salida de funcionarios clave. Puede contribuir a la consistencia u objetividad de sus decisiones y a evaluarlas retrospectivamente. Para sus operadores, puede ahorrar tiempos de búsqueda, mejorar la transparencia de los procesos de la institución, analizar la conveniencia de replicar o sustituir metodologías cuantitativas o econométricas utilizadas en casos pasados, y por último, perfeccionar métricas que ayuden a cuantificar el éxito de los proyectos o a distribuir cargas de trabajo.

En complemento a todo lo anterior, este parece ser el primer paso lógico en cualquier renovación tecnológica, un hito a partir del cual la organización, una vez dominado el flujo de su propio pool de datos mediante estructuras de trabajo y protocolos firmemente establecidos, pueda preparar estos datos para ejercicios analíticos o predictivos más avanzados, o combinarlos con datos externos, sean de libre acceso o de otras entidades públicas o privadas, para distintos fines.

71 U. Sivarajah et al, *Critical analysis of Big Data challenges and analytical methods*, Journal of Business Research (2016).

72 https://en.wikipedia.org/wiki/Extract,_transform,_load.

73 Por ejemplo, este es uno de los servicios que presta desde la nube Amazon Web Services a múltiples agencias en EEUU. Véase: <https://aws.amazon.com/what-is/etl/#:~:text=Extract%2C%20transform%2C%20and%20load%20>

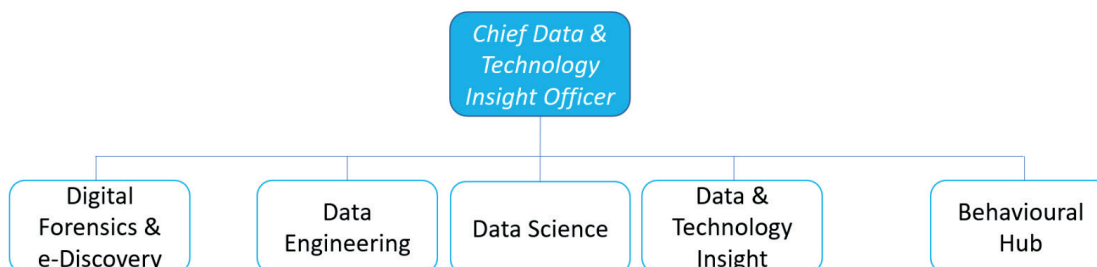
VI. (b). Creación de Unidades de Datos

"In the face of such change, agencies must bring their skills up to date" - Stefan Hunt⁷⁴

Antitrust 1.0 y 2.0 tienen su cuna, indiscutiblemente, en Norteamérica. Pero si medimos *Antitrust 3.0* en términos de su puesta en práctica, es justo afirmar que su versión más ambiciosa y sagaz surge al otro lado del Atlántico. En 2022, el *Director de Insights de Datos y Tecnología* ("DaTa") de la Competition and Markets Authority del Reino Unido y doctor en economía de la Universidad de Harvard, Stefan Hunt, presentó a distintos líderes, oficiales y especialistas del área los esfuerzos de la autoridad del Reino Unido por expandir sus capacidades en lo que llamó *la transformación tecnológica de las agencias de competencia*. Naturalmente, el frenesí de investigaciones en los llamados "mercados digitales" subyace al impulso tras este proyecto. Pero la creación de la llamada unidad DaTa se inspira con igual ahínco en *mejorar radicalmente el rendimiento operativo* de la agencia y optimizar sus recursos, particularmente en el manejo de sus propios datos⁷⁵.

En vez de adoptar un enfoque funcional para la contratación de personal, DaTa - que está hoy está integrada por más de 50 profesionales de distintos perfiles - optó por estructurar la Unidad en base a *conocimientos específicos* y conformar equipos multidisciplinarios diseñados para diferentes proyectos o requerimientos. Hacia 2022, este era el aspecto de DaTa:

Cuadro 1: Estructura del DaTa Unit de la CMA⁷⁶



Los **Ingenieros de Datos** (*Data Engineering*) gestionan la organización e integración de flujos de información interna y externa, combinando desarrollo de software y gestión de la infraestructura tecnológica. Los **Cientistas de Datos** (*Data Science*) programan y diseñan modelos de extracción de datos en base a ML, mientras que el equipo de **Inteligencia de Datos y Tecnología** (*Data & Technology Insight*) opera como una suerte de *liaison* (nexo) entre los equipos investigadores y el resto de la Unidad DaTa, colaborando activamente en los casos que presentan desafíos técnicos de su especialidad. El equipo **Forense Digital y e-Discovery** (*Digital Forensics & e-Discovery*) se especializa en operar las plataformas de revisión documental y de evidencia, y por último, el **Centro de Ciencias del Comportamiento** (*Behavioural Hub*) interviene en el creciente número de casos en el que existe una arista asociada a la economía del comportamiento, asesorando a los equipos en, por ejemplo, decidir qué información

74 Stefan Hunt, *The technology-led transformation of competition and consumer agencies. The Competition and Market's Authority's experience*, Discussion paper (2022), p.4.

75 Stefan Hunt, *The technology-led transformation*.

76 Stefan Hunt, *The technology-led transformation*, p. 36.

solicitar a los investigados para entender la arquitectura o funcionamiento de una plataforma, o evaluar una operación de concentración en términos de cómo puede condicionar o inhibir la elección de los consumidores y proponer posibles remedios adecuados a estos problemas⁷⁷.

Dentro de las lecciones que ofrece el trabajo de la CMA para otras Unidades de Datos, tales como priorización de roles, reclutamiento, y balance entre objetivos de corto plazo e innovación de largo aliento, destacamos dos que me parecen especialmente relevantes:

El primero, es que emulando la metodología del sector *tech* para el desarrollo de software⁷⁸, cada proyecto se estructura en torno a un encargado o *Project Manager*, enfocando el trabajo en entregables de corto plazo o *sprints* de dos a cuatro semanas, luego de las cuales se realizan sesiones grupales colaborativas de evaluación, retroalimentación y planificación. El objetivo es que a medida que el proyecto progresa, se involucre a otras unidades de la agencia como verdaderos “clientes”, procurando integrarlos en el desarrollo de los productos y en pruebas incrementales de versiones preliminares o incompletas, que orienten y perfilen el producto final hacia las necesidades del “cliente” o los objetivos de un caso⁷⁹.

El segundo aspecto, crucial pero fácil de ignorar, es generar consensos previos destinados a delimitar el ámbito de actuación de la Unidad de Datos, esto es, definir con claridad cuales no son sus funciones. Por diseño institucional, la Unidad de Datos no debiese preocuparse por las soluciones o servicios generales IT, ni fijar protocolos de uso de datos o seguridad de la información, ni está a cargo de investigar posibles infracciones en los llamados “mercados digitales”⁸⁰. No le empece pronunciarse sobre aspectos sustantivos de política de competencia, más allá de ofrecer insumos que pueden ser sumamente valiosos desde una perspectiva técnica, y que contribuyan perfeccionar el proceso de toma de estas decisiones.

Además de DaTa, múltiples agencias de competencia y protección al consumidor cuentan con incipientes grupos de trabajo similares. Hasta que logren su consolidación, probablemente deberán evaluar periódicamente su estructura, funcionamiento y metas, al tiempo que, ahí donde sea posible, abogar por mayor financiamiento para la contratación de talento humano con capacidades especializadas. Cabe notar que, considerando exclusivamente aquellos países en que hay unidades de datos en operación, la proporción de funcionarios calificados en ciencias de datos y afines, en relación al resto del personal no-administrativo, es relativamente baja, normalmente igual o inferior al 6%⁸¹⁻⁸².

VI. (c). Contribución a la adjudicación y al desarrollo jurisprudencial

“[B]y using data more effectively, judiciaries around the world, and particularly those in developing countries, will be able to improve their performance, address deficits in the quality and accessibility of justice, and contribute to prosperity” – Ramos-Makeda & Chen⁸³

77 Stefan Hunt, *The technology-led transformation*, p.33.

78 Siguiendo los principios del Manifiesto Ágil para el desarrollo de software. Disponible en <https://agilemanifesto.org/iso/es/principles.html>.

79 Stefan Hunt, *The technology-led transformation*, p. 40.

80 Esto lo tiene a su cargo la Unidad de Mercados Digitales. <https://www.gov.uk/government/collections/digital-markets-unit>.

81 Con excepción de Polonia. Véase OCDE(2023), p.31.

82 En Latinoamérica, Chile cuenta con una unidad especializada (‘Unidad de Inteligencia’), dependiente de la División a cargo de investigar carteles, con algunas atribuciones asimilables a una Unidad de Datos. Otras agencias como CADE (Brasil), CNDC (Argentina), SIC (Colombia) han desarrollado diversos proyectos de aplicación de técnicas computacionales, pero no contarían con un equipo o sección interna con vocación de permanencia para abarcar estos desafíos, en los términos descritos en este acápite. T. Schrepel y T. Groza (eds) *The Adoption of Computational Antitrust by Agencies*, 2021 Report (2022), 2nd Annual Report, (2023) y 3rd Annual Report (2024).

83 Manuel Ramos-Makeda and Daniel Chen, *The data revolution in justice*, World Development, Volumen 186, upcoming (Febrero 2025).

Como se expuso *supra*, la progresiva intervención de expertos en ciencias económicas en el proceso de elaboración jurisprudencial de políticas de competencia puede considerarse un punto de inflexión para la consolidación del denominado *Antitrust Económico o Antitrust 2.0*. Del mismo modo, la institucionalización de las ciencias computacionales y de datos en este ámbito es imprescindible para la culminación del desarrollo *del Antitrust Computacional*.

El incremento de asuntos contenciosos y no contenciosos impulsados por iniciativa de particulares, y la proliferación de demandas por indemnización de perjuicios derivadas de conflictos de competencia, ha impactado en el número de ingresos que deben ser conocidos y procesados por la judicatura⁸⁴. Y si bien tribunales especializados han puesto en marcha programas para sistematizar sus datos e incrementar su capacidad analítica⁸⁵, existen diversos ámbitos en que los organismos jurisdiccionales requerirán, tanto como las agencias y otros litigantes, empezar a considerar su propia transformación digital. A continuación se plantean, sin pretensión de exhaustividad, algunos campos de posible exploración.

i). Procesamiento de lenguaje natural

El procesamiento de lenguaje natural⁸⁶, o la creación de agentes conversacionales usando métodos computacionales ha sido perseguido por científicos de la computación hace décadas⁸⁷. En un comienzo el éxito fue moderado; considérese por un momento el universo de complicaciones asociadas a la densidad, redundancia y complejidad semántica del lenguaje si se la intenta reducir a un conjunto de reglas⁸⁸. El enfoque en métodos estadísticos, la experimentación con distintas arquitecturas de múltiples capas, y finalmente, el entrenamiento masivo de palabras sin etiquetar procesadas en paralelo⁸⁹, han resultado en metodologías sumamente versátiles para el desarrollo de aplicaciones para generar contenido, responder preguntas, clasificar texto, entre otras⁹⁰⁻⁹¹.

El *análisis de temas y análisis de sentimientos*, una forma de clasificación de texto que puede ser abordada a través de múltiples aproximaciones científicas, cuenta con mucho potencial para la investigación y decisión de asuntos contenciosos⁹². Estos métodos pueden utilizarse, por ejemplo, sobre comunicaciones o mensajería

84 Véase por ejemplo anuario 2024 del Tribunal de Defensa de la Libre competencia de Chile, disponible en <https://www.tdlc.cl/anuarios-tdlc/#anuario-2024/1/>.

85 Mencionado como uno de los objetivos para el trienio 2023-2025. Véase Cuenta Pública 2024 del TDLC: <https://www.tdlc.cl/wp-content/uploads/2024/05/Cuenta-Publica-2024.pdf>, pág. 8.

86 Denominamos 'lenguaje natural' cualquier forma de comunicación diaria entre humanos, en contraposición a lenguajes de programación o notaciones matemáticas. Véase *The Natural Language Toolkit* disponible en <http://nltk.org/>.

87 D. Numa y M. Engler, *Introduction to Generative AI*, Manning (2024), p.5.

88 Ruido inexistente en el procesamiento de números o código binario. Piénsese en el problema de intentar programar outputs en el flujo de conversación que sea capaz de procesar palabras homónimas o polisémicas correctamente, por dar algunos ejemplos. K. Gugler et al, *Using Natural Language Processing to Delineate Digital Markets*, Stanford Computational Antitrust (2024), p.5.

89 Los *transformers* o modelos de atención fueron el hito que impulsó la nueva era de LLMs, que básicamente generan nueva versiones de la secuencia y 'premiar' con mayor valor predictivo aquellas palabras clave presentes en una secuencia según su posición específica, considerando todo el contexto en ambas direcciones (de adelante para atrás y al revés). D. Numa y M. Engler, *Introduction to Generative AI*, Manning (2024), p.19.

90 Como se mencionó previamente, los LLMs utilizan una combinación de ML de refuerzo con recompensas y castigos de acuerdo a los resultados esperados en términos de *predicción*.

91 Esta tarea por cierto requiere un intenso trabajo de preprocesamiento, incluyendo la transformación en tokens o fragmentos de palabras o texto para ser representados numéricamente por la matriz, la eliminación o limpieza de preposiciones o palabras con poco valor semántico o predictivo (*stop words*), entre otras. Gugler, *Using Natural Language*, p.38 y ss.

92 Devika M D et al, *Sentiment Analysis: A Comparative Study On Different Approaches*, Elsevier (2016).

entre las partes acusadas de un ilícito anticompetitivo, u orientarse a identificar patrones que pongan de relieve la importancia relativa de ciertos temas, o evaluar actitudes o cargas emocionales frente a diferentes palabras de interés. Estos hallazgos pueden servir para identificar matices y eventualmente contribuir a fortalecer la tesis de la parte persecutora, o las interpretaciones alternativas de las defensas⁹³.

Por otra parte, utilizando LLMs y otras técnicas de *deep learning* sobre textos, escritos, resoluciones y bases de datos de casos anteriores, se ha sugerido que los tribunales podrían eventualmente identificar patrones de comportamiento y refinar su propio proceso de elaboración jurisprudencial. Ello puede, por ejemplo, contribuir a establecer u homogeneizar interpretaciones *quick look o per se*, contribuyendo al establecimiento de reglas de comportamiento administrables basadas en evidencia⁹⁴.

En este punto, es pertinente preguntarse si es deseable que el ejercicio de la función jurisdiccional se apoye en este tipo de aplicaciones para la dictación de resoluciones o sentencias⁹⁵. Sin duda hay riesgos que considerar, desde sesgos inherentes a los datos usados para el entrenamiento de los modelos, hasta la generación de respuestas plausibles pero incorrectas (*alucinaciones*). Por otra parte, la proliferación de servicios basados en IA generativa para abogados⁹⁶⁻⁹⁷ pone presión a la razonabilidad de excluir a la judicatura de las ventajas asociadas al buen uso de esta tecnología, la cual, además, parece inevitable.

En cualquier caso, es preferible que los tribunales optimicen modelos de IA generativa disponibles mediante ajustes específicos (fine-tuning) y entrenamiento con datos propios, adaptándolos según sus necesidades. Un ecosistema privativo a su uso interno, dedicado a hacer más eficiente y completa la articulación de sus decisiones, cuya sustancia en definitiva continuará sujeta a deliberación humana, individual o colegiada. Estas herramientas, cuyos comandos e instrucciones deberán ser diseñados e implementados iterativamente por expertos⁹⁸, deben ser instrumentales a la creación de precedentes más consistentes, que contribuyan a identificar o distinguir presupuestos fácticos para aplicar, interpretar o crear reglas de derecho⁹⁹.

ii). Modelos ML como evidencia en juicio

Aunque ML se orienta a la predicción en vez de causalidad y equilibrios, existe consenso de que los modelos ML pueden contribuir al planteamiento de problemas económicos¹⁰⁰. Por ejemplo, su naturaleza *prospectiva* la hace especialmente adecuada para evaluar escenarios contrafactuales en el ámbito de operaciones de concentración, particularmente dada la posibilidad de los métodos ML en captar otras dimensiones no basadas en precio que pueden enriquecer el análisis de competencia¹⁰¹.

93 Devika M D et al, *Sentiment Analysis*.

94 Daryl Lim, *Can Computational Antitrust Succeed?* Stanford Computational Antitrust (2021), p.42.

95 Sobre las implicaciones del uso de IA y las preguntas alrededor de sistemas de toma de decisiones híbridos entre humanos y máquinas: Tim Wu, *Will AI Eat the Law. The rise of hybrid social-ordering systems*, Columbia Law Review Vol. 119:2001, (2019).

96 Como Cocounsel <https://casetext.com/> o Harvey <https://www.harvey.ai/>.

97 Otra posibilidad, especialmente valiosa en materia de libre competencia, es aprovechar las capacidades de los LLMs para identificar y clasificar ciertos patrones de texto estructurados con el fin de censurar información comercial sensible o preparar versiones públicas. Esto evitaría la censura manual, que suele ser extremadamente costo-intensiva.

98 Denominados 'prompt engineering'. D. Numa y M. Engler, *Introduction to Generative AI*, p.245.

99 Una alternativa razonable es que se construyan estos modelos utilizando la interfaz de programación de aplicaciones ('API') de empresas de inteligencia artificial existentes.

100 Para un análisis de la literatura en esta materia, véase Isaiah Hull, *Machine Learning for Economics and Finance in TensorFlow 2 -Deep Learning Models for Research and Industry*, Apress (2021), cap.2.

101 Daryl Lim, *Can Computational Antitrust Succeed?*, p.44.

De manera similar a los ejercicios econométricos, en los cuales se requiere evaluar, por ejemplo, el modelo teórico empleado y las relaciones que se asumen, la presentación de informes basados en modelos ML sitúan al órgano adjudicador en la necesidad de entender otros aspectos técnicos y metodológicos¹⁰². Este desafío implica el desarrollo progresivo de reglas para apreciar la evidencia basada en ML, replicar o proponer modelos alternativos introduciendo variaciones metodológicas o incluyendo etiquetas que pudieran haber sido soslayadas por los litigantes.¹⁰³

iii). Tratamiento de evidencia digital

La evidencia digital es preponderante en el análisis de conductas anticompetitivas, especialmente carteles¹⁰⁴, y es de suponer que su importancia aumentará en los años por venir. Las agencias de competencia suelen estar franqueadas con distintas prerrogativas legales para hacerse de este tipo de evidencia, y a tal efecto suelen disponer de protocolos internos para su obtención, extracción, análisis, preservación y custodia. El uso de técnicas destinadas a este fin es denominado con el término paraguas de Informática Forense (*Computer Forensics*)¹⁰⁵.

En un litigio, las partes pueden objetar o poner en entredicho distintos aspectos de la evidencia digital, tales como (i) **integridad** o ausencia de alteraciones, (ii) **proveniencia** o el registro de su obtención y modificaciones, (iii) cuestiones asociadas a su **autenticidad y verificabilidad**¹⁰⁶. Más aún, los desafíos vinculados a la generación de contenido audiovisual inauténtico mediante técnicas de IA son inminentes, y conciernen a un conjunto de problemas de derecho procesal que no son privativos del derecho de la libre competencia¹⁰⁷.

Los tribunales deberán enfrentarse a informes periciales contradictorios y testigos expertos en diversos aspectos técnicos de la evidencia digital. Es razonable esperar que puedan asesorarse con especialistas capaces de evaluar metodologías de extracción de datos y criterios técnicos para trazar su proveniencia, entre otros. La importancia de estas reglas de admisibilidad o valoración son sumamente importantes, tanto para orientar a las partes a ponderar criterios de autenticidad e integridad que sean útiles para preparar y presentar su prueba, como en términos de incentivos, para disuadir estrategias meramente dilatorias u objeciones carentes de base.

VII. CONSIDERACIONES FINALES

La transformación digital del derecho de la competencia será materia de múltiples esfuerzos de investigación

¹⁰² La elección del modelo que fue utilizado y cómo fue ajustado, comprobar los resultados de la validación cruzada, como fue regularizado, etc.

¹⁰³ Sobre la necesidad que las autoridades de competencia generen guías para la presentación de evidencia basada en programas ML, ver Phillip Hanspach, *Economics in the Era of Machine Learning*, Stanford Computational Antitrust (2024), p.187,

¹⁰⁴ Véase documento preparado por la International Competition Network, Manual de Enforcement, cap. 3. "Management of Electronically Stored Information (ESI) in searches, raids and inspections" (actualizado 2021), disponible en: https://internationalcompetitionnetwork.org/wp-content/uploads/2022/01/CWG_ACEM_Digital_Evidence_CH3-2021.pdf

¹⁰⁵ De acuerdo al Manual de Enforcement de ICN, Informática Forense corresponde al "uso de técnicas especializadas para la preservación, identificación, extracción, autenticación, examen, análisis, interpretación y documentación de información digital. [Informática Forense] entra en juego cuando un caso involucra cuestiones relacionadas con la reconstrucción del uso de un sistema informático, el examen de datos residuales, la autenticación de datos mediante análisis técnico o la explicación de características técnicas de datos o del uso de equipos computacionales. Requiere una experiencia especializada que generalmente va más allá de las técnicas normales de recolección y preservación de datos disponibles para los usuarios finales o el personal de soporte de sistemas de tecnología de la información (TI)".

¹⁰⁶ Kumar Rana, S. et al.(Eds) *Blockchain-Based model to preserve authenticity of judicial evidence* en Fusion of Artificial Intelligence and Machine Learning for Advanced Image Processing, Data Analysis and Cyber Security, Ch.8, Francis Taylor, 2025 (upcoming).

¹⁰⁷ Existe amplia preocupación de que el fenómeno de los *deepfakes* hará necesario nuevos estándares que elevarán los costos de litigación para prevenir la admisibilidad de evidencia potencialmente falsificada. Véase Daniel J. Capra, *Deepfakes Reach the Advisory Committee on Evidence Rules*, Fordham Law Review, Volume 92 Issue 6 Article 7(2024).

por venir. Que las autoridades de competencia puedan cumplir razonablemente las expectativas sociales cifradas en su éxito, dependerá, a mediano plazo, de su capacidad de articular su propia transformación digital, y de poner sobre relieve la necesidad de una completa reconsideración de su presupuesto en función de este objetivo. Por otra parte, Iniciativas como el PCA de Stanford, y foros como la OCDE y la ICN han demostrado preocupación por estos temas resaltando la importancia de la cooperación internacional en esta materia.

La vasta gama de posibles infracciones o restricciones a la competencia asociadas al uso de herramientas algorítmicas o programas de *business intelligence* basados en IA constituyen en sí mismo un desafío significativo. Al mismo tiempo, los problemas legales y prácticos asociados a la detección e investigación de estas conductas, sumado a la oferta de servicios de innovación pagados y *open source*, ya sea para hacer cumplir o para evadir las leyes de competencia, genera un panorama sumamente complejo y en cierta medida, inmovilizante. En efecto, uno de los puntos centrales del debate actual radica en determinar si en definitiva las autoridades de competencia serán o no capaces de responder a los desafíos de la competencia algorítmica¹⁰⁸.

Se propone a las agencias de competencia, particularmente a aquellas en fase de consolidación institucional, un programa de transformación gradual o escalonado: crear, especializar o fortalecer las Unidades de Inteligencia y Datos en base a las mejores experiencias extranjeras. Comenzar por la recolección, integración y sistematización de datos propios que pueden estar atomizados, utilizando metodologías de trabajo colaborativas similares a la industria de servicios tecnológicos, y equipar a tribunales y jueces con capacidades y acceso a especialistas que les permitan responder adecuadamente a su carga de trabajo y prepararse para los desafíos venideros.

El enfoque incremental aquí propuesto reconoce la realidad de Latinoamérica y otras regiones en vías de desarrollo, donde las agencias de competencia pueden enfrentar limitaciones de recursos, personal e infraestructura para abordar los desafíos de la economía digital. Sin embargo, precisamente por esta razón, con un plan de acción adecuado, optimización de recursos existentes y el fomento de capacidades técnicas locales, estos actores pueden aspirar a un mayor impacto relativo en su productividad que sus pares en países desarrollados.

Más aún, muchas veces tribunales y agencias de competencia participan o influyen en procesos legislativos o regulatorios. Sólo podrán ser persuasivos en la necesidad de introducir aquellos cambios normativos que consideren indispensables una vez que hayan tenido la oportunidad de desenvolverse en sus competencias operando a plena capacidad bajo el marco regulatorio actual. Recordando nuevamente la referencia cinematográfica de Bill Kovacic, montados en un auto de carrera, y no sobre un avestruz.

Finalmente, es necesario advertir que la adopción de nuevas tecnologías en beneficio del *enforcement* no implica necesariamente más intervención, y definitivamente no equivale a la persecución de conductas en ausencia de daño competitivo. Tampoco debe la autoridad, en este afán, convertirse en generadora de 'cajas negras'. En este sentido, hago propias las observaciones de Matiuzzo y Machado en cuanto a que las herramientas empleadas por las autoridades antimonopolio deben estar sujetas a gobernanza, auditabilidad, y transparencia, teniendo en cuenta principios constitucionales y de debido proceso, para lo cual la adopción de buenas prácticas para el desarrollo de software en término de registro y testeado de nuevas herramientas es un buen punto de partida¹⁰⁹.

108 OCDE (2023), p.37.

109 Matiuzzo, M. y Machado, H. "Algorithmic Governance in Computational Antitrust—a Brief Outline of Alternatives for Policymakers", Stanford Computational Antitrust, vol II.

BIBLIOGRAFÍA

- Agrawal, Ajay, Joshua Gans, y Avi Goldfarb, eds. *The Economics of Artificial Intelligence: An Agenda*. The University of Chicago Press, 2019.
- Azeem Ahar. *The Exponential Age*. New York: Diversion Books, 2021.
- Andrejevic, M., y M. Burdon. *Defining the Sensor Society*. University of Queensland TC Beirne School of Law Research Paper No. 14-21 (2015).
- Bermedo, Patricio. *Historia de la Libre Competencia en Chile*, Fiscalía Nacional Económica, 2013.
- Brynjolfsson, Eric, y Andrew McAfee. *The Second Machine Age: Work, Progress, and Prosperity in a Time of Brilliant Technologies*. New York, Norton, 2016.
- Capra, Daniel J. *Deepfakes Reach the Advisory Committee on Evidence Rules*. Fordham Law Review 92, no. 6 (2024).
- Coglianesi, Cary, y Aida Lai. *Antitrust by Algorithm*. *Stanford Computational Antitrust*, vol. II (2022).
- Digital Regulation Cooperation Forum. *Auditing algorithms: the existing landscape, role of regulators and future outlook*. Discussion Paper, 2023.
- Gleick, James. *"The Information: A History, a Theory, a Flood"*. New York: Pantheon Books, 2011.
- Goodfellow, Ian, Yoshua Bengio, and Aaron Courville. *Deep Learning*. Cambridge: MIT Press, 2016.
- Hanspach, Phillip. *Economics in the era of Machine Learning*. *Stanford Computational Antitrust* (2024).
- Hoffman, Harald, y Ilaria Lorenzoni. *Future Challenges for Automation in Competition Law Enforcement*. *Stanford Computational Antitrust* (2023).
- Hull, Isaiah. *Machine Learning for Economics and Finance in TensorFlow 2: Deep Learning Models for Research and Industry*. Apress, 2021.
- Hunt, Stefan. *The Technology-Led Transformation of Competition and Consumer Agencies*. Discussion Paper, The Competition and Markets Authority (2022).
- International Competition Network (ICN). *Manual de Enforcement: Management of Electronically Stored Information (ESI) in Searches, Raids, and Inspections*, updated 2021.
- Jaeger, Paul T., Jin Lin, y James M. Grimes. *Cloud Computing and Information Policy: Computing in a Policy Cloud?* *Journal of Information Technology & Politics* 5, no. 3 (2008): 269–283.
- Kovacic, William E., y Carl Shapiro. "Antitrust Policy: A Century of Economic and Legal Thinking." *Journal of Economic Perspectives* 14, no. 1 (2000): 43–60.
- Lim, Daryl. *Can Computational Antitrust Succeed?* *Stanford Computational Antitrust*, vol. I (2021).
- Matiuzzo, M., y H. Machado. *Algorithmic Governance in Computational Antitrust—a Brief Outline of Alternatives for Policymakers*. *Stanford Computational Antitrust*, vol. II (2022).

- McKay, A., y S. Weinstein. *Dynamic Pricing Algorithms, Consumer Harm, and Regulatory Response*. Harvard Business School Working Paper 22-050 (2022).
- Millon, David K. *The Sherman Act and the Balance of Power*. *Southern California Law Review* 61 (1988): 1219.
- OECD. *AI, Data and Competition*. OECD Artificial Intelligence Papers, 18 (2024).
- OECD. *Algorithmic Competition: Background Note by the Secretariat*. DAF/COMP/2023(3), (2023).
- Pitofsky, Robert. *The Political Content of Antitrust*. *University of Pennsylvania Law Review* 127, no. 4 (1979): 1051–1075.
- Posner, Richard A. "Antitrust Law" The University of Chicago Press, 2nd ed., 2001.
- Ramos-Makeda, Manuel y Daniel Chen. "The Data Revolution in Justice." *World Development*, vol. 186, upcoming (Febrero 2025).
- Schaller, Robert R. Moore's Law: Past, Present, and Future. *IEEE Spectrum* 34, no. 6 (1997): 52–59.
- Schmalensee, Richard. *Thoughts on the Chicago Legacy on US Antitrust*. In *How the Chicago School Overshot the Mark*, edited by R. Pitofsky. New York: Oxford University Press, 2008.
- Schrepel, Thibault. *Computational Antitrust: An Introduction and Research Agenda*. Stanford University Press, 2021.
- Schrepel, Thibault, y Groza, Teodora (editores). *The Adoption of Computational Antitrust by Agencies: 2021 Report*. Stanford Computational Antitrust, (2022).
- Schrepel, Thibault, y Groza, Teodora (editores). *The Adoption of Computational Antitrust by Agencies: 2nd Annual Report*. Stanford Computational Antitrust, (2023).
- Schrepel, Thibault, y Groza, Teodora (editores). *The Adoption of Computational Antitrust by Agencies: 3rd Annual Report*. Stanford Computational Antitrust, (2024).
- Shannon, Claude. *A Mathematical Theory of Communication*. *Bell System Technical Journal* 27 (1948): 379–423.
- Shen, Boyu. *E-commerce Customer Segmentation via Unsupervised Machine Learning*. PhD diss., 2021.
- Uthayasankar Sivarajah et al, *Critical analysis of Big Data challenges and analytical methods*, *Journal of Business Research*, 2016.
- Stucke, Maurice E., y Allen P. Grunes. *Big Data and Competition Policy*. Oxford University Press, 2016.
- Wu, Tim. *Will AI Eat the Law? The Rise of Hybrid Social-Ordering Systems*. *Columbia Law Review* 119 (2019): 2001.



Este documento se encuentra sujeto a los términos y condiciones de uso disponibles en nuestro sitio web:
<http://www.centrocompetencia.com/terminos-y-condiciones/>

Cómo citar este artículo:

Eugenio Ruiz-Tagle Wiegand w., "De la Teoría a la Tecnología: *Computational Antitrust*", [Diálogos CeCo](#)
(marzo, 2025),

<http://www.centrocompetencia.com/category/dialogos>

Envíanos tus comentarios y sugerencias a info@centrocompetencia.com
CentroCompetencia UAI – Av. Presidente Errázuriz 3485, Las Condes, Santiago de Chile

