

GRADO: Economía.

Curso 2022/2023

TÍTULO:

EFFECTOS SOBRE LA COMPETENCIA DE LOS ALGORITMOS DE FIJACIÓN DE PRECIOS.

Autor/a: Xabier Arrate Vicente

Director/a: Aitor Ciarreta Antuñano.

Bilbao, a 15 de febrero de 2023.



Estructura:

0. Resumen.....	3
1. Abreviaturas.....	4
2. Tablas y Figuras.....	4
3. Introducción.....	5
4. Algoritmos. Machine Learning. Tipos y Aplicaciones al negocio.....	6
5. Literatura publicada.....	10
6. Problemas y ventajas para la competencia.....	16
7. Simulación numérica con PSO.....	21
8. Conclusiones.....	25
9. Bibliografía.....	27
10. Anexos.....	29

0. Resumen:

La tecnología se desarrolla sin freno y está transformando los negocios. La Inteligencia Artificial realiza cada vez más tareas empresariales antes únicamente ejecutables por personas. Entre otras, la fijación autónoma de precios con algoritmos guiados por IA es cada vez más frecuente, usada con el objetivo de maximizar el beneficio empresarial. A pesar de la novedad de la cuestión, la capacidad transformativa de esta tecnología ha provocado que economistas y autoridades de la competencia investiguen el impacto que esta supone sobre la competencia de mercado. Sin embargo, no se alcanza un consenso debido a la divergencia de los experimentos realizados, con diferentes algoritmos actuando en estructuras de mercado diversas. Este TFG trata de unificar las distintas líneas de investigación con el fin de lanzar un diagnóstico general de las consecuencias que podría acarrear la implementación de estos algoritmos. Para ello se analiza la más relevante literatura publicada sobre el tema y se analizan las ventajas y desventajas de su aplicación, además de realizar una simulación numérica con el fin de explicar el algoritmo Particle Optimization Swarm (PSO). Como conclusión principal se niega el carácter bueno, malo o neutral de la tecnología, dependiendo este de las características del mercado y de los incentivos empresariales. Dejando en manos de los investigadores y autoridades responsables la tarea de analizar cada mercado con el fin de potenciar los aspectos positivos y penalizar los negativos de la implementación de algoritmos guiados por IA en la fijación de precios.

1. Abreviaturas:

- IA: Inteligencia Artificial.
- ML: Machine Learning.
- RL: Reinforcement Learning.
- QL: Q-Learning.
- PSO: Particle Swarm Optimization.
- RAE: Real Academia Española.

2. Tablas y figuras:

- **Tabla 1.** *Literatura publicada: Tabla Resumen: (Elaboración propia a partir de (Ezrachi, 2016), (Calvano et al., 2018a), (Rab, 2020), (Harrington Jr., 2021), (Sánchez-Cartas & Katsamakas, 2022))..... 15*
- **Tabla 2.** *Efectos sobre la competencia: Tabla Resumen (Elaboración propia a partir de (OCDE, 2017), (Harrington Jr., 2021), (Sánchez-Cartas & Katsamakas, 2022))..... 20*
- **Tabla 3.** *Resultados PSO: $l_1 = 0.1$, $\epsilon = 10^{-8}$. (Elaboración propia) 22*
- **Tabla 4.** *Resultados PSO: $l_1 = 0.5$, $\epsilon = 10^{-8}$. (Elaboración propia) 23*
- **Figura 1.** *Evolución algoritmo: Beneficios (Elaboración propia) 24*

3. Introducción:

El vertiginoso desarrollo de las tecnologías está transformando nuestras vidas y, como no podía ser de otra manera, los negocios también. Las organizaciones y sectores económicos están en continua evolución y cada empresa u organización pública deberá procurar mantenerse en la vanguardia tecnológica para seguir obteniendo buenos resultados y no estancarse en el pasado.

Dentro del mencionado desarrollo tecnológico hay un ámbito que resulta especialmente asombroso, el de la inteligencia artificial. La RAE define la IA de la siguiente manera: “disciplina científica que se ocupa de crear programas informáticos que ejecutan operaciones comparables a las que realiza la mente humana, como el aprendizaje o el razonamiento lógico”. Muchos dejan el sentimiento de asombro de lado y adoptan comportamientos más escépticos o incluso de pavor. Pero la realidad es que las “máquinas” son cada vez más capaces de realizar tareas que antes eran realizadas exclusivamente por humanos.

Entre estas tareas, la que concierne a este TFG, hay una que revoluciona especialmente el mundo de los negocios: la fijación de precios a través de algoritmos guiados por IA. Estos algoritmos están diseñados para fijar los precios que logren el objetivo empresarial de maximización de beneficios. Esta irrupción de la tecnología autónoma en el marco económico y empresarial ha levantado suspicacias en cantidad de autoridades de competencia. Ya que los efectos que la fijación autónoma de precios pueda provocar en la competencia de mercado son, hoy en día, inciertos. Por lo que regular su aplicación podría ser todavía imprudente.

A pesar de la actualidad del tema, ya existen numerosas investigaciones sobre el funcionamiento y las consecuencias de la implementación de algoritmos en la fijación de precios y, generalizando, en los negocios (*algorithmic business*). Sin embargo, los resultados obtenidos son poco claros y a menudo difieren según las características de los experimentos realizados. Por ello es necesario seguir investigando en la materia para tratar de comprender realmente la transformación que los algoritmos suponen en los negocios y para poder diseñar y aplicar las medidas económicas adecuadas, en caso de que fueran necesarias.

Los objetivos del TFG son profundizar en los efectos del “*algorithmic business*” en la competencia de mercado y unificar diferentes líneas de investigación con el fin de obtener un diagnóstico más general. La estructura del trabajo es la que sigue:

El primer punto introduce el tema, los conceptos de necesario conocimiento para comprender el trabajo. Conceptos como algoritmos, Machine Learning y sus diferentes tipos (PSO y Q-Learning) y aplicaciones. Para terminar de enmarcar la investigación, el segundo punto repasa 5 artículos académicos sobre el tema. Por una parte, de manera individualizada y, por otra, en formato tabla resaltando los puntos principales de cada uno. En el tercer punto se analizan las ventajas y desventajas que podrían surgir del “*algorithmic business*”. En el cuarto punto, con el objetivo de comprender mejor el funcionamiento de uno de los algoritmos, PSO, se plantea un problema práctico de maximización de beneficios y, a través de un sencillo programa desarrollado en Python, se trata de alcanzar el precio óptimo, el que maximice los beneficios. Por último, se presentan las principales conclusiones del trabajo.

4. Algoritmos. Machine Learning. Tipos y Aplicaciones al negocio.

Para comprender completamente la investigación que se presenta es imprescindible definir algunos términos que permitan enmarcar el problema. Conceptos como algoritmo, Inteligencia Artificial, Machine Learning... van a aparecer constantemente.

- *Algoritmo*: un algoritmo es una secuencia de operaciones definidas previamente aplicadas de una manera sistemática y mecánica que permite obtener una solución numérica de un problema determinado. El estado descrito inicialmente se denominará input y la solución numérica será el output.

Un algoritmo puede ser escrito de múltiples maneras, desde el lenguaje plano, pasando por diagramas matemáticos, hasta programas interpretables por un ordenador. Con la evolución de la tecnología computacional los algoritmos han desarrollado la capacidad de realizar cálculos complejos e interpretaciones a partir de conjuntos de datos masivos fuera del alcance de los humanos. Lo que a menudo les permite tomar decisiones y aportar medidas más eficientes que una persona. Esto

facilita enormemente la resolución de problemas en cualquier disciplina científica y, en nuestro caso, la maximización de la función de beneficios empresarial mediante el cálculo del precio óptimo (output del problema) (OCDE, 2017).

Los algoritmos fijadores de precio tienen una complejidad superior ya que son algoritmos guiados por IA. La IA permitirá que sean capaces de fijar precios de manera autónoma sin supervisión humana ninguna, gracias al aprendizaje autónomo (Machine Learning).

- *Machine Learning*: subcampo de la IA que mediante algoritmos que aprenden de los datos y la experiencia pasada crea máquinas inteligentes.

A menudo se confunden ML e IA, sin embargo, ML no es más que una rama de la IA. Originalmente se definía IA como cualquier replica de comportamiento humano, replica que se podría conseguir mediante una lista de instrucciones específicas que consiguieran que una máquina pudiera ejecutar una tarea “humana” de manera eficiente. El aprendizaje autónomo va más allá, además de imitar tareas “humanas” permite que las máquinas aprendan, piensen y se desarrollen como un cerebro humano. (OCDE, 2017)

El ML permite que los ordenadores obtengan información valiosa de conjuntos inmensos de datos, de identificar patrones y generar predicciones útiles para la empresa. Predicciones como la demanda futura de mercado, cambios en las preferencias de los clientes, variaciones de precios de las materias primas, estrategias de la competencia... Esto ha supuesto una revolución en el mundo empresarial, ya que permite la automatización de cantidad de procesos y decisiones empresariales, como la fijación autónoma de precios vía algoritmos inteligentes, de una manera más eficiente y rápida que si ejerciera un humano. (OCDE, 2017)

Los algoritmos de fijación de precios tienen como objetivo la maximización de beneficios de la empresa. A través de modelos de predicción deberán de ser capaces de fijar el precio que maximice el beneficio esperado y, además, de evitar que el precio fijado sea desorbitado (en 2011 un algoritmo autónomo de fijación de precios determinó que la maximización de beneficios en la venta de un libro se obtenía con el precio de 24 millones de euros la unidad) (Sánchez-Cartas & Katsamakos, 2022).

Cantidad de algoritmos podrían ejecutar estas dos tareas, algoritmos complejos de diferentes vertientes del ML (Reinforcement Learning, Deep Learning, Q-Learning...). Sin embargo, la opacidad de las empresas que utilizan este tipo de tecnologías nos impide conocer las especificidades de cada uno y, al igual que en la investigación de Sánchez-Cartas & Katsamakos, (2022) este trabajo se centra en dos de los más sencillos, pero útiles y valiosos en sus tareas, algoritmos: Q-Learning y PSO.

- Q-Learning: el algoritmo QL pertenece a la familia del aprendizaje por refuerzo (Reinforcement Learning). Los modelos de RL se caracterizan por un agente, un conjunto de estados y un conjunto de acciones posibles por estado. Al elegir una acción el agente cambiará de estado y tendrá otro conjunto nuevo de acciones posibles. El objetivo del modelo será maximizar la recompensa total que obtendrá el agente, calculada por las esperanzas matemáticas de las recompensas descontadas que obtendrá en los siguientes pasos, empezando desde el actual (Matiisen, 2015). En concreto, Q-Learning estima de manera iterativa una función Q (Q-function), que representa la recompensa total descontada de elegir una acción $a_i \in A$ en el estado $s \in S$.

$$Q_i(s, a_i) = E(s, a_i^t) + \delta E[s^t, a_i^t] \quad (1)$$

(Donde $\rightarrow A$: conjunto de acciones, S : conjunto de estados, δ : factor descuento, i : número individuo, t : número de iteración.)

Suponiendo que A y S son finitos, la función Q se puede describir como una matriz $|A| * |S|$. El algoritmo Q-Learning empieza desde una matriz aleatoria (generalmente llena de ceros) y la actualiza en cada iteración. Cada celda de la matriz será una media ponderada de la recompensa previa obtenida y la recompensa total descontada actual, obtenida de las esperanzas matemáticas de las recompensas futuras. En los primeros periodos t el algoritmo es posible que elija acciones que no sean las óptimas, por lo que habrá un periodo de exploración donde Q-Learning explorará todos los estados y acciones posibles en cada estado mediante un proceso de prueba y error con el objetivo de encontrar

los mejores resultados y poder explotarlos en periodos posteriores. (Sánchez-Cartas & Katsamakos, 2022) (Calvano et al., 2018).

- Particle Swarm Optimization: PSO es englobado por otra de las ramas del Machine Learning, la de los algoritmos evolutivos (Evolutionary Algorithms). El origen de este algoritmo se encuentra en una investigación sobre el comportamiento social de algunos grupos de animales migratorios, (bandadas de pájaros, bancos de peces...), donde se creó un modelo que explicaba como en base a la cooperación y el aprendizaje de los distintos agentes del grupo lograban encontrar el mejor hábitat para vivir (Kennedy & Eberhart, 1995). Más adelante, se descubrió que este mismo modelo servía para realizar optimizaciones en otros campos de la ciencia de manera simple pero efectiva. PSO genera un número finito de puntos en un espacio multidimensional, los cuales obtienen una recompensa o puntuación, depende de lo que se quiera maximizar en el problema. Al igual que en el modelo original cada punto comparte la información del resultado obtenido, tras múltiples iteraciones los puntos se moverán hacia los puntos en los que se obtengan las mayores recompensas y se obtendrá el óptimo global, en base a la cooperación y el aprendizaje del 'enjambre' de puntos. La posición de cada punto (p_i^t) esta influenciada por la posición de los puntos con mejores resultados (velocidad evolutiva, $v_{i,t}$), que determina la posición del punto junto con la mejor posición encontrada por ese punto u óptimo local (p_i^l) y la mejor posición encontrada por cualquier punto del enjambre, óptimo global (p_i^g). Ecuación del modelo:

$$p_i^t = p_i^{t-1} + v_i^{t-1} \quad (2)$$

donde

$$v_i^{t-1} = wv_i^{t-2} + l_1 u_1 (p_i^l - p_i^{t-1}) + l_2 u_2 (p_i^g - p_i^{t-1}) \quad (3)$$

(Y donde w es un factor de inercia que representa cuanto influyen las acciones pasadas en las actuales, l_1 y l_2 son parámetros de aprendizaje del modelo y u_1 y u_2 son los números aleatorios iniciales, distribuidos uniformemente entre 0 y 1.)

Influenciados por cambios del entorno el óptimo global (p_i^g) y el local (p_i^l) podrían variar y, con ellos, todos los demás parámetros de la ecuación. Al igual que en QL habrá un periodo de explotación donde el algoritmo realizará muchas iteraciones conociendo el entorno y reuniendo información sobre qué puntos obtienen los mejores resultados para después poder entrar en un periodo de explotación (Sánchez-Cartas & Katsamakas, 2022).

Ambos algoritmos son relativamente simples, pero son capaces de cumplir sus objetivos en entornos determinados. En el caso del QL podría cumplir con éxito el propósito de fijar el precio que maximice beneficios con una caracterización sencilla del problema. Sin embargo, la caracterización del problema se complicaría sobremanera en casos de empresas con varios productos. Por otra parte, PSO podría obtener buenos resultados tanto con un problema simple como con uno de mayor complejidad, ya que no necesita tener en cuenta la cantidad de estados y de acciones por estado (que aumenta exponencialmente según aumenta la complejidad del problema). A diferencia del algoritmo Q-Learning, PSO no aprende a tomar buenas decisiones, simplemente las selecciona, lo que lo aleja de los modelos económicos tradicionales, más intuitivos y con una estrategia determinada (Sánchez-Cartas & Katsamakas, 2022). En cualquier caso, ambos algoritmos son ampliamente utilizados en el mundo empresarial y nos acercan a averiguar los posibles resultados de la implementación de la IA y el ML en la fijación de precios.

5. Literatura Publicada.

A pesar de que la aplicación de algoritmos fijadores de precio sea un fenómeno novedoso ha llamado mucho la atención tanto a las autoridades de la competencia como a investigadores y economistas, debido a la gran transformación que podría suponer en los mercados. En este punto se trata de poner contexto a la literatura publicada sobre la aplicación de algoritmos autónomos para la fijación de precios, su funcionamiento y su influencia en la competencia de mercado.

En 2016, el jurista experto en ley de competencia Ariel Ezrachi escribía por primera vez sobre la responsabilidad de las autoridades de competencia de mantener bajo control el uso de tecnologías como el Big Data, la IA y los algoritmos en los negocios por los riesgos que estas suponían. En la editorial “Virtual Competition” (Ezrachi, 2016) menciona que la tecnología no es ni buena, ni mala, ni neutral; si no que dependerá del uso que le quieran dar los agentes de mercado y de la estructura competitiva donde se apliquen. Asimismo, menciona aspectos beneficiosos para el consumidor de su aplicación, como la mejora en eficiencia de los mercados y del flujo de información. Sin embargo, se centra en los aspectos lesivos que podrían surgir y en los que se deberían focalizar las autoridades de mercado:

- Colusión tácita: colusión empresarial sin necesidad de acuerdo explícito. Menciona que el diseño maximizador de beneficios de los algoritmos los podría llevar a fijar precios supracompetitivos. Además de que la naturaleza automática de los algoritmos facilita la coordinación de un mayor número de agentes.
- Discriminación conductual: concierne sobre las estrategias de extracción y explotación de datos personales, utilizados por las empresas para impulsar a comprar al consumidor y conociendo con más precisión los precios que cada individuo estaría dispuesto a pagar, apropiándose así del excedente del consumidor.
- ‘Frenemy’: así define la relación de las grandes empresas tecnológicas y aplicaciones web y de móvil. Inicialmente, estas prestan servicios gratuitos, a priori beneficiosos para el consumidor, para recolectar grandes cantidades de datos. Después, competirán para explotar estos datos e intentar extraer el excedente del consumidor.

Estos fenómenos y alguno más se mencionan en los *papers* que analizo a continuación por año de publicación:

En 2018, Calvano et al (2018a) aplicaron el algoritmo Q-Learning en una estructura de mercado de oligopolio. El objetivo era investigar más en profundidad la hipótesis que hacía Ezrachi en 2016 de que los algoritmos podían aprender a coludir.

En la introducción del artículo se menciona la dificultad tanto teórica como práctica de responder a esta cuestión. En el análisis teórico, debido a la habitual simplicidad de los algoritmos con los que se experimenta es difícil llegar a conclusiones realistas, aunque las investigaciones ayuden a aproximarnos a la respuesta. Y en lo que a la práctica respecta, conocer el comportamiento de los algoritmos en los mercados reales es inviable dada la opacidad y el secretismo empresarial en la materia.

Tras tratar de emular un escenario de oligopolio donde todas las empresas fijan los precios a través de un mismo algoritmo Q-Learning, se determinó que en el estado estacionario Q-Learning aprendía a coludir de manera sistemática, a base de prueba y error, sin necesidad de conocimiento previo del entorno y sin comunicarse con los demás algoritmos, lo que resultaba en precios supracompetitivos.

La validez de estos resultados es cuestionada por sus mismos autores, que señalan 3 puntos débiles: un entorno económico poco realista, una velocidad de aprendizaje de los algoritmos superior a la real y poca variedad de algoritmos (todos un Q-Learning igualmente caracterizado).

En 2020 Suzanne Rab publicó una investigación sobre la influencia de la aplicación de algoritmos en los mercados on-line. Al introducir el tema destacaba la falta de consenso entre los economistas sobre la necesidad de endurecer o no las leyes de competencia.

En el desarrollo del artículo se analizan los principales aspectos negativos de la aplicación de algoritmos en los mercados on-line. Inicialmente menciona el aumento de la posibilidad de que se de colusión tácita, a pesar del número de empresas. También se mencionan 3 nuevas formas de conductas anticompetitivas surgidas de la implementación de algoritmos: discriminación de precios, coopectencia ('frenemy') y la extracción y captación de datos personales.

Al igual que en la investigación de Calvano et al (2018a), se advierte de que los resultados de las investigaciones en esta materia son poco ajustados a la realidad debido a la simplificación excesiva del entorno y de los tipos de algoritmos, por lo que concluye

advirtiéndolo de la posible prematuridad de las regulaciones a la competencia algorítmica, porque podrían ser contraproducentes.

En 2021, Harrington Jr. (2021) detectó una tendencia habitual en las empresas de comercios online, estas habitualmente externalizaban la tarea de la fijación de precios a empresas de software ajenas al mercado.

Destaca la diferencia de incentivos cuando el desarrollador es la propia empresa vendedora y cuando se externaliza la tarea a una empresa de software. Por una parte, si fuera la empresa vendedora la desarrolladora del algoritmo, esta buscaría la fijación del precio que consiga vender el máximo de unidades al máximo precio posible, lo que resultaría en precios supracompetitivos. Sin embargo, esto dará ventaja a empresas que no usen el algoritmo, ya que mantendrán precios competitivos y venderán más que la empresa si lo usen. Por lo tanto, la empresa de software tratará de diseñar un algoritmo que fije precios más sensibles a la demanda, esto es, que fijen precios competitivos cuando la demanda es baja y los suban cuando la demanda es alta. De esta forma, todas las empresas del mercado estarán incentivadas a contratar sus servicios.

Como conclusiones de la investigación, Harrington determina que el algoritmo usado no reduce la competencia, sin embargo, vuelve los precios más sensibles a la demanda, lo que traslada excedente del consumidor al productor. También destaca la posibilidad de que muchas empresas del mismo mercado contacten con la misma empresa externa y, usando el mismo algoritmo, lleguen a un escenario de colusión tácita.

Una vez más, el experimento es una simulación orientativa pero alejada de la realidad debido a: información perfecta sobre la demanda y ajuste instantáneo de los precios, capacidad de aprendizaje demasiado rápida y poca variedad de algoritmos.

En 2022 Sánchez-Cartas y Katsamakos (2022) investigaban la influencia en la competencia del uso de dos de los algoritmos más comunes para la fijación de precios, Q-Learning y Particle Swarm Optimization (PSO). Para entender el funcionamiento de los algoritmos crearon 3 entornos de mercado diferentes (funciones de demanda Logit, del mercado de Hotelling y lineal) y los dejaron actuar.

Los experimentos llegaron a la premisa general de que PSO fija precios más competitivos que Q-Learning que, de acuerdo con Calvano et al (2018a), determinaron

que fijaba precios supracompetitivos. Sin embargo, destacan que cambios en los algoritmos y en las estructuras de mercado llevan a resultados totalmente distintos, así lo muestran las simulaciones en 3 estructuras de mercado diferentes. Por lo que destacan la necesidad de ser precavidos con la regulación del uso de algoritmos antes de conocer con más precisión las concreciones de cada mercado.

A modo de resumen, en la tabla 1 esquematizo los 5 artículos en los siguientes puntos: título, autores, resumen, palabras clave y principales conclusiones.

Recopilando y acoplado todos los artículos se pueden trazar unas líneas generales sobre los efectos en la competencia y el bienestar del consumidor del uso de algoritmos autónomos para la fijación de precios. La primera es que la tecnología no es buena, mala o neutral; dependerá de los incentivos de las empresas y de la estructura de mercado que el resultado sea beneficioso o perjudicial para los consumidores. La segunda es que algunos algoritmos, tratando maximizar los beneficios empresariales, podrían llevar a colusión tácita. Además, podrían surgir nuevas conductas anticompetitivas como la discriminación de precios, la cooptencia o el uso de datos personales que permitirían a las empresas apropiarse del excedente del consumidor, reduciendo su bienestar. Por lo tanto, el uso de los algoritmos, más allá de lo transformativo y beneficiosos que pueden ser para la sociedad por sus mejoras de eficiencia, no necesariamente aumentan nuestro bienestar. Para ahondar en el efecto social neto que provocan los algoritmos, en el siguiente punto se analizan las ventajas y desventajas de su aplicación, basándome en la estructura del informe de la OCDE, “algorithms and collusion” (2017).

5.1. Tabla resumen:

Título.	Virtual Competition	AI, Algorithmic pricing and collusion.	AI, Algorithms and antitrust.	The effect of outsourcing pricing on algorithms and market structures.	AI, Algorithmic competition and market structures.
Autores.	-Ariel Ezrachi -Maurice E. Stucke.	-Emilio Calvano. -Giacomo Calzolari. -Vincenzo Denicolo. -Sergio Pastorello.	-Suzanne Rab.	-J.E. Harrington.	-J.M. Sanchez -E. Katsamakas.
Resumen.	Análisis de las implicaciones de aplicar Big Data, AI y Algoritmos a los negocios.	Análisis de la aplicación de algoritmos Q-Learning en una estructura de mercado de oligopolio.	Análisis de los efectos en la competencia y el bienestar social de la aplicación de algoritmos en los mercados online.	Análisis de los efectos en la competencia de delegar la tarea de fijación de precios a una empresa de software externa que diseña algoritmos maximizadores de beneficios.	Análisis de los efectos en la competencia de los algoritmos Q-Learning y PSO en 3 tipos diferentes de mercados.
Palabras clave.	· Colusión. · Discriminación conductual. · Freenemy.	· Q-Learning. · Estrategia colusiva.	· Colusión tácita. · Discriminación de precios. · Co-opetencia. · Extracción de datos.	· Excedente del consumidor. · Colusión. · Discriminación de precios.	· PSO. · Q-Learning. · Estructura de mercado. · Colusión.
Conclusiones	· La tecnología no es buena, ni mala, ni neutral. Depende de las intenciones de su aplicación y del entorno donde se aplique. · Colaboración de grandes empresas para recopilar información, pero competencia a la hora de extraer el excedente del consumidor.	· Q-Learning fija precios supracompetitivos, lo hace aplicando estrategias colusivas clásicas, penalizando a la empresa que se desvíe del equilibrio. · Los algoritmos tienen más facilidad que los humanos para coludir, sobretodo de manera tácita. · Entorno económico poco realista, poca variedad de algoritmos.	· Los algoritmos facilitan la colusión tácita, aumenta la posibilidad de que se dé independientemente del número de empresas. · Experimentación superficial, lejanos a la realidad.	· No se reduce la competencia. · Los precios se vuelven más sensibles a la variación de la demanda, lo que permite al productor apropiarse del excedente del consumidor. · Los algoritmos son diferentes cuando los diseña una empresa externa o la propia productora debido a la diferencia de incentivos. · Entorno económico experimental, poco ajustado a la realidad y algoritmos simples.	· PSO lleva a resultados más competitivos. · Q-Learning fija precios supracompetitivos · Los resultados dependen de los algoritmos, su modelización y de la estructura de mercado donde se apliquen.

Tabla 1. Tabla Resumen: (Elaboración propia a partir de (Ezrachi, 2016), (Calvano et al., 2018a), (Rab, 2020), (Harrington Jr., 2021), (Sánchez-Cartas & Katsamakas, 2022)).

6. Problemas y ventajas para la competencia.

Como se mencionaba en la introducción, los efectos en los mercados provocados por los algoritmos son inciertos, por una parte, por lo novedoso que es el problema y, por otra, por la opacidad empresarial en estos asuntos. Sin embargo, desde la irrupción de esta tecnología en los mercados se conocen varias tendencias en pro y en contra de la competencia, que favorecen o perjudican de manera diferente a consumidores y a empresas. De este modo, tanto las consecuencias positivas como negativas del *“algorithmic business”* se pueden separar en dos grupos según a que agentes del mercado afecten, las que afectan al lado de la demanda y las que lo hacen al de la oferta.

6.1. Efectos pro competitivos del *“algorithmic business”*.

La aplicación de algoritmos en los entornos de mercado genera eficiencias tanto en el lado de la oferta como en el de la demanda. Las eficiencias generadas en el lado de la oferta pueden ser tanto dinámicas como estáticas en función de donde se generen, si nacen de la aplicación de algoritmos dentro de la empresa serán estáticas (proceso productivo, marketing...), por otro lado, si surgen de la actividad del mercado serán eficiencias dinámicas. En cuanto a las eficiencias en el lado de la demanda, aparecen gracias a las nuevas herramientas de búsqueda y procesamiento de información de los individuos, de modo que la racionalidad y la información disponible de los consumidores mejora, pudiendo tomar decisiones más acertadas. (OCDE, 2017)

Las mejoras estáticas surgen del aumento de la eficiencia en los procesos internos de la empresa. El proceso de encontrar patrones en los datos pasados, crear tendencias y generar predicciones futuras que permitan tomar las decisiones óptimas en procesos empresariales supondría una gran inversión de tiempo y de dinero si fueran realizadas por un humano, los algoritmos por un coste cada vez menor lo realizan en segundos. La automatización de la cadena de producción permitirá reducir costes de producción y, en determinadas estructuras de mercado, podría traducirse en precios finales más bajos. Por otra parte, las decisiones comerciales de la empresa serán más eficaces gracias a los algoritmos o motores de búsqueda que permiten a las empresas acercarse de manera más individualizada y eficaz a los potenciales compradores, ahorrando en campañas de marketing mal enfocadas y poco efectivas. El último ejemplo de eficiencia estática, o eficiencia dentro de la empresa, es el que atañe a este TFG, el de los algoritmos fijadores

de precios, que como ya se ha explicado tratan de maximizar los beneficios empresariales fijando el precio que considere óptimo en base a las tendencias del pasado (OCDE, 2017).

Las eficiencias dinámicas, por otro lado, surgen del aumento de la competencia que podría generar el “algorithmic business”. La reducción de los costes de la ciencia computacional y de la aplicación de algoritmos en los negocios ha reducido las barreras de entrada a muchos mercados y ha aumentado la capacidad innovadora de las empresas, lo que provoca que las empresas estén reinventándose constantemente mejorando el producto final que ofrecen (OCDE, 2017).

En lo que al consumidor final respecta, los algoritmos también asisten en la toma de decisiones comerciales individuales. En entornos de mercado guiados por datos los algoritmos pueden diferenciar los bienes y servicios según su precio, calidad o el parámetro que elija el consumidor. La mayor accesibilidad a la tecnología permite al individuo acceder a mayor cantidad de información y de racionalizarla mejor, reduciendo los clásicos problemas de asimetría de información y de racionalidad limitada (OCDE, 2017).

En definitiva, la mayor accesibilidad a información y el fácil procesamiento de esta gracias a los algoritmos genera entornos donde la transparencia empresarial y la confianza cliente-empresa se vuelven esenciales, donde la atención es más individualizada y la innovación constante mejora la calidad del producto, donde la automatización de procesos internos de la empresa disminuye los costes de producción y, ocasionalmente, los precios finales del mercado.

6.2. Efectos anticompetitivos del “algorithmic business”.

A pesar de la capacidad de los algoritmos de extraer valor de la cantidad de datos generada en la economía digital, también existen ciertas preocupaciones al respecto. En ciertos mercados, dominados por un reducido número de agentes, estos podrían aprovechar su establecido poder y utilizar los algoritmos en búsqueda de intereses propios, lejanos a los sociales. Existe la preocupación de que los algoritmos puedan facilitar las prácticas colusivas en mercados propensos a ellas (oligopolios, mercados con grandes costes fijos y barreras de entrada), brindando nuevas herramientas de

coordinación empresarial. A este fenómeno se le denomina colusión algorítmica (OCDE, 2017).

Para comprender mejor el papel que podrían tener los algoritmos en las actividades colusivas es necesario definir algunos conceptos tradicionales de colusión. La colusión es la coordinación de empresas competidoras con el objetivo de obtener beneficios superiores a los que obtendrían en el equilibrio competitivo. La colusión puede ser de dos tipos:

- *Colusión explícita*: colusión tradicional, carteles. Las empresas pactan de manera explícita ya sea vía oral o escrita la estrategia de competencia, los precios a fijar.
- *Colusión tácita*: se da en mercados transparentes de baja competencia, donde las empresas son capaces de mantener la coordinación con la competencia sin necesidad de acuerdos explícitos. La estrategia empresarial de cada empresa es independiente, sin embargo, debido a las condiciones de mercado se ven incentivadas a mantener precios colusivos, ya que en el largo plazo obtendrán mayores beneficios que si compitieran en precios. Un caso típico de colusión tácita es la del liderazgo de precios, cuando la empresa con mayor cuota de mercado modifica los precios y las demás empresas la siguen. (Harrington, 2012)

Las prácticas colusivas se dan en mercados con determinadas condiciones que perjudican la competencia de empresas, incentivadas a elegir precios supracompetitivos, incluso sin necesidad de pactos explícitos. Existe la preocupación de que el uso de algoritmos y el big data modifiquen las estructuras de mercado en detrimento de la competencia, alterando los factores de mercado que facilitan la colusión, sobre todo en mercados on-line. A continuación, explico alguno de estos factores y la potencial influencia del “*algorithmic business*”:

Gran parte de las actividades colusivas nacen a partir de un mercado con una estructura oligopolística, de pocas empresas, baja competencia, altas barreras de entrada al mercado, transparencia empresarial y alta frecuencia de interacción. La parte estructural del mercado es esencial para que las actividades colusivas sean sostenibles en el medio-largo plazo, ya que un mayor número de empresas dificulta la coordinación

y, la ausencia de barreras de entrada junto con la obtención de beneficios extraordinarios provocaría la entrada de nuevas empresas. Los algoritmos, en este aspecto, generan barreras de entrada, por una parte, ya que la empresa establecida en el mercado tiene más datos y algoritmos más desarrollados, además de poder ser automatizados para actuar de manera agresiva ante nuevos competidores y; por otra parte, las reduce aumentando la información disponible de los mercados. Los algoritmos también restan importancia al número de empresas del mercado a la hora de coludir, ya que la automatización de la fijación de precios facilita la coordinación empresarial. Con respecto a la transparencia del mercado y la frecuencia de las interacciones los algoritmos favorecen las actividades colusivas aumentando la información disponible y la frecuencia con la que las empresas cambian los precios (*dynamic pricing*), facilitando detectar desviaciones de los precios colusivos de equilibrio. (OCDE, 2017)

6.3. Efectos sobre la competencia tabla resumen.

A modo de resumen, la aplicación de los algoritmos es un factor disruptivo, que afecta directamente a las 'reglas del juego' de los mercados. La influencia del "*algorithmic business*" no será igual en todos los mercados, dependerá de las características de cada uno, pero en términos generales hay una serie de consecuencias que favorecen a la competencia y otras que la perjudican. Por una parte, la automatización de la fijación de precios facilita la coordinación empresarial tácita, incluso en mercados con muchas empresas donde tradicionalmente la colusión era inviable. Por otra parte, la aplicación algorítmica incentiva la innovación empresarial, concepto que dificulta la colusión. Acerca del número de empresas y las barreras de entrada la influencia neta de los algoritmos es incierta, ya que, a pesar de generar posibles barreras de entrada debido a la ventaja posicional de las empresas más poderosas, la información disponible y la mayor capacidad de procesarla las reducen.

En consecuencia, este nuevo escenario deja un reto a las autoridades de competencia, que deberán de centrarse en potenciar los efectos positivos de los algoritmos a la vez que controlan los aspectos más lesivos de su implementación.

Efectos de los algoritmos sobre la competencia.	Sobre la oferta.	Sobre la demanda.
Positivos	<ul style="list-style-type: none"> - Más transparencia. - Mejora, innovación de productos. - Disminución de las barreras de entrada. - Optimización de recursos, reducción de costes. - Mayor facilidad para encontrar el equilibrio de mercado y maximizar beneficios. 	<ul style="list-style-type: none"> - Mejora en la toma de decisiones. - Aumento de la racionalidad individual. - Oferta de bienes y servicios más ajustada a las preferencias individuales. - En determinadas estructuras de mercado reducciones de precios. - Menor posibilidad de demanda insatisfecha.
Negativos	<ul style="list-style-type: none"> - Favorecen más a las empresas más poderosas, pudiendo afectar a la competencia. - Pueden ser automatizados para actuar de manera agresiva ante la entrada de nuevas empresas. - Aumentan la transparencia de mercado y la frecuencia de interacción, facilitando la colusión tácita. 	<ul style="list-style-type: none"> - En mercados con demanda elástica, reducción de demanda ante precios colusivos.

Tabla 2. Efectos sobre la competencia: Tabla Resumen (Elaboración propia a partir de (OCDE, 2017), (Harrington Jr., 2021), (Sánchez-Cartas & Katsamakos, 2022)).

7. Simulación PSO.

Con el fin de llevar a la práctica el tema analizado, en este punto se realiza una simulación numérica utilizando el algoritmo previamente descrito PSO. Para la mayor simplicidad de la programación, la simulación se ha realizado con el Método Acelerado de PSO. A diferencia del método original, en el cual el movimiento y la posición de cada partícula se veían influenciados por la posición del óptimo local (p_i^l) y del óptimo global (p_i^g) de la iteración t (ecuaciones (2) y (3)), en el método acelerado vienen determinados por la posición del óptimo global y por el azar. El azar aporta diversidad al enjambre, sin el factor aleatorio todas las partículas se moverían hacia el óptimo global de la iteración t sin tener la certeza de que ese sea el óptimo global general del problema.

PSO método acelerado:

$$p_i^t = (1 - l_1)p_i^{t-1} + l_1p_i^g + \alpha (\epsilon - 0.5) \quad (4)$$

(donde l_1 es un parámetro de aprendizaje del modelo, α es un parámetro de aprendizaje acelerado del modelo y ϵ es un vector aleatorio cuyas coordenadas están uniformemente distribuidas entre 0 y 1. Como en la versión anterior t es el periodo o número de la iteración e i es el número de la partícula.)

La programación del método acelerado es razonablemente sencilla. Se ha desarrollado en lenguaje de programación Python y, para la mejor visualización del programa, en el entorno Jupyter Notebook. Lo primero es importar las librerías necesarias: Numpy y Matplotlib. Numpy para crear las matrices y vectores que nos van a ayudar a crear el enjambre de partículas y a describir su movimiento. Y Matplotlib para visualizar gráficamente la evolución del algoritmo. El segundo paso es la descripción de los parámetros del modelo que, como veremos más adelante, son determinantes en su rendimiento. Después, se definen las matrices de la población inicial, de las mejores partículas de cada iteración y de los valores de la función con el valor de la mejor partícula. Para terminar de describir el modelo introducimos la función objetivo que se trata de optimizar. A partir de todo lo anterior, se describe el movimiento de las partículas en cada iteración y se obtienen los mejores resultados y un gráfico con la evolución de los resultados del algoritmo. (Anexo 1)

Para la mejor comprensión del funcionamiento del algoritmo PSO y con el fin de desarrollar un programa relativamente sencillo se ha escogido un escenario de monopolio. La estructura de mercado es la siguiente:

- Función de demanda: $d(x) = 100 - p$
- Coste marginal constante: $C_{mg} = 10$
- Costes fijos nulos: $CF = 0$
- Función de beneficios: $\pi = \text{Ingreso Total} - \text{Coste total} = p * x - 10x$

En este caso nos interesa tener la función de beneficio en función del precio, por lo que la función objetivo introducida al algoritmo es la siguiente:

$$\pi = p(100 - p) - 10(100 - p) = 110p - p^2 - 1000 \quad (5)$$

Como es un monopolio no existe competencia por lo que la empresa tiene completo poder de mercado y podrá fijar el precio que maximice sus beneficios sin preocuparse por el precio que fijará el rival. El precio de máximo beneficio será, por tanto:

$$\frac{\partial \pi}{\partial p} = 110 - 2p = 0 \quad p^* = 55 \text{ y } \pi^* = 2025$$

A continuación, se presenta el comportamiento del algoritmo PSO con diferentes niveles en los parámetros del modelo. Como los resultados del algoritmo dependen en parte de la posición inicial de las partículas, se presentan los resultados en rangos de resultados que puede devolver el algoritmo. Los rangos seguirán una distribución aleatoria y uniforme, al igual que las partículas en el espacio.

$l_1 = 0.1$ $\epsilon = 10^{-8}$	Número de iteraciones			
	p^* y π^*	10	100	1000
Número de partículas	10	{50, 60} y {2000, 2025}	{50, 60} y {2000, 2025}	{51, 59} y {2009, 2025}
	100	{54, 56} y {2024, 2025}	{54.7, 55.3} y {2024.91, 2025}	{54.8, 55.2} y {2024.96, 2025}
	1000	{54.9, 55.1} y {2024.99, 2025}	{54.9, 55.1} y {2024.99, 2025}	{54.9, 55.1} y {2024.99, 2025}

Tabla 3. Resultados PSO: $l_1 = 0.1$, $\epsilon = 10^{-8}$. (Elaboración propia).

$l_1 = 0.5$ $\epsilon = 10^{-8}$	Número de iteraciones			
	p^* y π^*	10	100	1000
Número de partículas	10	{54.8, 55.2} y {2024.96, 2025}	{55} y {2025}	{55} y {2025}
	100	{54.9, 55.1} y {2024.99, 2025}	{55} y {2025}	{55} y {2025}
	1000	{55} y {2025}	{55} y {2025}	{55} y {2025}

Tabla 4. Resultados PSO: $l_1 = 0.5$, $\epsilon = 10^{-8}$. (Elaboración propia).

Como podemos observar, fijar una tasa de aprendizaje superior lleva a mejores resultados. No obstante, esto se debe a la sencillez del problema planteado. En tareas de optimización más complejas una tasa de aprendizaje demasiado elevada podría llevar a resultados menos precisos. Por lo que la mejor solución dependerá de la complejidad del problema y deberá de seguirse un proceso de entrenamiento, validación y test del modelo para comprobar que el modelo funciona y seleccionar los mejores valores para los parámetros.

Lógicamente, el resultado mejora al añadir más partículas y más iteraciones, por que la probabilidad de encontrar el óptimo general global del problema aumenta. De nuevo, el número de partículas y de iteraciones es modesto debida la sencillez del problema. Sin embargo, la mayor complejidad del problema vendrá acompañada de la necesidad aumentar tanto el número de partículas como el de iteraciones, y dependerá de la capacidad computacional de cada empresa el obtener programas más o menos precisos.

El siguiente gráfico muestra la evolución del algoritmo PSO (100 partículas, 100 iteraciones, $l_1 = 0.3$, $\epsilon = 10^{-8}$):

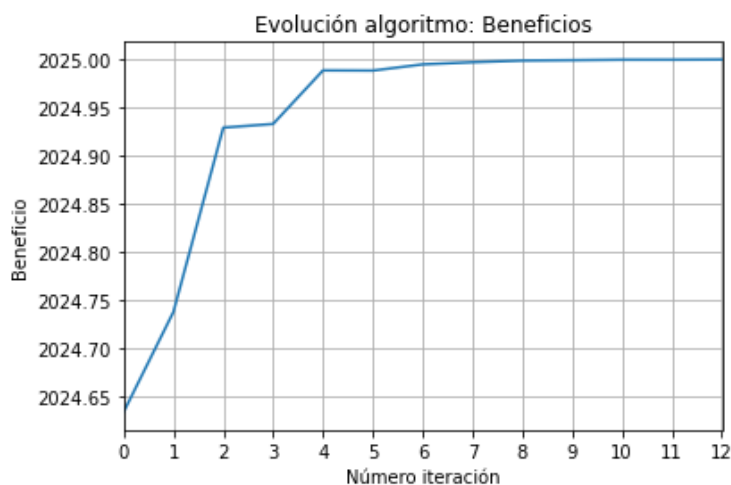


Figura 1. Evolución algoritmo: Beneficios (Elaboración propia).

El algoritmo falla, aunque se queda cerca, al alcanzar el óptimo global general en las primeras iteraciones. A partir de ahí, el movimiento hacia el óptimo global y las desviaciones azarosas de las partículas consiguen que el enjambre encuentre el óptimo global general.

Este resultado casa con la interpretación económica de la actuación de un monopolista. Al fijar el precio, el monopolista no acertará a la primera, tendrá que probar varios precios para estimar una función de demanda y así, poder maximizar los beneficios. Aunque cabe recordar que PSO no aprende a seleccionar los mejores escenarios, simplemente los selecciona, lo que lo aleja de los modelos económicos.

En definitiva, este modelo nos sirve para comprender el funcionamiento del algoritmo. Sin embargo, no nos permite profundizar en la cuestión de la colusión algorítmica. Para ello se deberían de programar múltiples algoritmos PSO y ejecutarlos en una estructura de mercado artificial. De ese modo la función a maximizar de cada empresa estaría condicionada por los precios fijados por las demás empresas. En este caso se necesitarían varias iteraciones para alcanzar el punto de equilibrio y la capacidad computacional necesaria sería superior.

En el anteriormente analizado artículo de Sánchez-Cartas y Katsamakos (2022) se realizaron varias simulaciones utilizando el algoritmo PSO y se concluyó que fijaba

precios cercanos a los competitivos, tanto si competía contra otra firma que utilizaba PSO como si lo hacía contra una empresa que utilizaba una función tradicional de mejor respuesta. Lo que en primera estancia nos permitiría descartar el riesgo de colusión. Sin embargo, compitiendo con otro tipo de algoritmos o contra agentes colusivos, PSO podría aprender a fijar precios supracompetitivos en caso de maximizar así los beneficios empresariales.

Una vez más, las características del mercado son determinantes para el desarrollo de escenarios no competitivos, perjudiciales para el consumidor.

8. Conclusiones.

A modo de cierre, paso a destacar las principales conclusiones del proyecto. Recordando la introducción, se fijaban como objetivos profundizar en los efectos sobre la competencia de mercado de los algoritmos autónomos fijadores de precio y la unificación de líneas de investigación con el objetivo de realizar un diagnóstico general. Si bien es verdad que la simulación numérica no aporta nuevos resultados sobre la posibilidad de que los algoritmos coludan, debida su simplicidad, resulta útil para demostrar dos principales puntos. El primero es la capacidad de los algoritmos analizados de realizar tareas de maximización de manera mecánica y más rápida que un humano, incluso en un escenario tan simple como en el de monopolio. Y el segundo es la accesibilidad a la tecnología necesaria para desarrollar algoritmos guiados por IA y ML, lo que permite pronosticar un uso cada vez más ubicuo y extendido de esta.

En cuanto al segundo objetivo principal, la principal conclusión es que los algoritmos no son buenos, malos o neutrales en si mismos, dependerá de la intención de los agentes de mercado que los utilicen y de las estructuras de mercado donde sean aplicados. Por lo que sería imprudente que las autoridades responsables diseñen regulaciones generales sin conocer la especificidad de cada mercado. Por otra parte, conocer los detalles de cada algoritmo y cada mercado a menudo es inviable, debida la política empresarial de no revelar sus algoritmos y no perder su ventaja competitiva.

Sería interesante una aplicación de los algoritmos a modelos de oligopolio donde la interacción entre efectos positivos y negativos es más evidente e interesante de analizar, pero este análisis quedaba fuera del alcance de mi investigación.

La permanente investigación de los mercados será necesaria para potenciar los aspectos beneficiosos de la tecnología y tratar de frenar los perjudiciales para la competencia y, en definitiva, para el bienestar del individuo.

9. Bibliografía.

- OECD (2017), Algorithms and Collusion: Competition Policy in the Digital Age www.oecd.org/competition/algorithms-collusion-competition-policy-in-the-digital-age.htm

- *Descubre los principales beneficios del Machine Learning*. (s. f.).Iberdrola.
<https://www.iberdrola.com/innovacion/machine-learning-aprendizaje-automatico>

- Ezrachi, A. & Stucke, M. E. (2016). Virtual Competition. *Journal of European Competition Law & Practice*, 7(9), 585-586.
<https://doi.org/10.1093/jeclap/lpw083>

- Kennedy, J. & Eberhart, R. (1995). Particle swarm optimization. *Proceedings of ICNN'95 - International Conference on Neural Networks*.
<https://doi.org/10.1109/icnn.1995.488968>

- Harrington, J. E. (2012). A Theory of Tacit Collusion. *Research Papers in Economics*. <https://www.econstor.eu/bitstream/10419/101362/1/684816040.pdf>

- Harrington Jr, J. E. (2021). The Effect of Outsourcing Pricing Algorithms on Market Competition. *SSRN Electronic Journal*.
<https://doi.org/10.2139/ssrn.3798847>

- Sánchez-Cartas, J. M., & Katsamakos, E. (2022). Artificial Intelligence, Algorithmic Competition and Market Structures. *IEEE Access*, *10*, 10575-10584. <https://doi.org/10.1109/access.2022.3144390>

- Calvano, E., Calzolari, G., Denicolo, V., & Pastorello, S. (2018a). Artificial Intelligence, Algorithmic Pricing and Collusion. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.3304991>

- Rab, S. (2020). Artificial intelligence, algorithms and antitrust. *Competition Law Journal*, *18*(4), 141-150. <https://doi.org/10.4337/clj.2019.04.02>

- Matiisen, T. (2015, 19 diciembre). *Demystifying Deep Reinforcement Learning* | Computational Neuroscience Lab. <https://neuro.cs.ut.ee/demystifying-deep-reinforcement-learning/>

10.Anexos.

Anexo 1. PSO: <https://github.com/xarrvic/PSO/blob/main/PSO%20notebook.ipynb>