

Doctorado en Economía UCA

Tesis Doctoral

Aceptación y Rechazo de Recomendaciones Algorítmicas

Doctorando: Sebastián Visotsky

Director de Tesis: Profesor Daniel Aromí

Abstracto

La tecnología está influyendo y modelando la forma en que actuamos en la vida cotidiana. También el proceso de toma de decisiones se modifica con los cambios en los sistemas de información y las nuevas tecnologías.

Nuestro objetivo fue evaluar cómo actúan los agentes decisorios expuestos a algoritmos de recomendación, así como el posible cambio en este patrón en caso de un escenario adverso a lo recomendado por el algoritmo.

Medimos los resultados de la utilización de algoritmos en el plano económico, la tasa de adopción y rechazo de las recomendaciones proporcionadas y el precio que están dispuestos a pagar los agentes. Para ello realizamos tres experimentos a través de los cuales evaluamos la toma de decisiones: el primero en condiciones de certidumbre, el segundo en condiciones de riesgo y el tercero en condiciones de incertidumbre.

Supusimos que la tasa de adopción de las recomendaciones emitidas por los algoritmos sería adoptada en forma creciente con cada iteración. La iteración daría, al participante, la posibilidad de familiarizarse con la herramienta y al constatar los resultados podría apreciar los beneficios de utilizarla. El crecimiento en la adopción y valoración del algoritmo a medida que avanzaban los experimentos se observó en el experimento I, en condiciones de certidumbre. En los experimentos II y III el objetivo era además evaluar si un escenario adverso, luego de adoptar la recomendación, generaba una menor tasa de adopción en las recomendaciones subsiguientes. En condiciones de riesgo o incertidumbre podemos tomar una buena decisión y tener un mal resultado (*good decisions bad outcomes*). En caso de comprobar que un escenario adverso a la recomendación del algoritmo generaba rechazo de las siguientes recomendaciones, podíamos afirmar que esa actitud coincidía con las investigaciones y publicaciones de los últimos años, respecto a la intolerancia de los usuarios a los errores de los algoritmos. Este resultado sería significativo ya que los errores son corregibles mientras que los resultados adversos en decisiones inciertas no los son y suelen ser más frecuentes. Según lo observado en nuestros experimentos, los participantes juzgan los escenarios adversos a la recomendación de manera similar a un error del algoritmo. Creemos que será vital para el éxito de la adopción de algoritmos de recomendación, encontrar las formas de modificar esta percepción de los usuarios.

En los experimentos observamos importantes diferencias de género en la propensión a aceptar las recomendaciones de los algoritmos, en la auto percepción de las capacidades, en la valoración de los algoritmos y su influencia sobre las decisiones.

Los sesgos de *autoservicio* y *outcome* se detectaron en casi todos sus aspectos. Los balances finales de los participantes, que dependían en gran medida del azar, resultaron ser significativos a la hora de autoevaluar las capacidades propias, la de los algoritmos, el nivel de arrepentimiento y la percepción de control sobre los resultados.

Algunos resultados específicos de cada experimento son interesantes de resaltar y merecen mayor investigación. Principalmente el factor que jugó la impaciencia en el experimento III para esperar la recomendación del algoritmo. En el experimento II el momento de la primera pérdida también tuvo influencia en la auto percepción de las capacidades propias, la del algoritmo y la sensación de arrepentimiento.

Índice

I.	Introducción	6
II.	El estado de la cuestión	10
	i. Teoría decisional	14
	ii. Teoría de la racionalidad	20
	iii. Críticas al Homo Economicus	21
III.	El futuro del racionalismo	23
	i. Tecnología y decisiones	24
	ii. Tecnología, información imperfecta y tiempos de procesamiento	24
	iii. Tautología de las preferencias	25
	iv. Tecnología y sesgos cognitivos	26
IV.	¿La tecnología funciona como se esperaba?	29
	i. Nuevos problemas que surgen por el uso de tecnología	32
	ii. Adopción de la tecnología	38
V.	Evidencia experimental	43
	i. Experimento I	44
	a. Introducción	44
	b. Método del experimento	45
	c. Resultados	46
	d. Conclusión	54
	ii. Experimento II	55
	a. Introducción	55
	b. Método del experimento	59
	c. Resultados	63
	d. Análisis de las percepciones	70
	e. Conclusión	79
	iii. Experimento III	81
	a. Introducción	81
	b. Método del experimento	82

	c. Resultados	85
	d. Análisis de las percepciones	92
	e. Conclusión	99
VI.	Conclusiones	100
VII.	Anexo I	103
VIII.	Anexo II	110
IX.	Anexo III	112
X.	Bibliografía	128

I. Introducción

Determinar cómo actuarán los agentes económicos es de suma importancia en la teoría económica que se apoya en el modelo del *Homo Economicus* como base de predicción de los comportamientos. La ciencia económica necesita de un sistema para analizar los procesos económicos. Sin un sistema, no podríamos ni siquiera afirmar conceptos básicos de economía tales como que frente a un aumento en el precio de un producto se retraerá su demanda. Existen causas y consecuencias, procesos y resultados, al igual, o por lo menos parecido, a las ciencias exactas. Podemos predecir el comportamiento de los agentes económicos debido a que estamos sujetos a leyes descifrables. Es decir, si pudiésemos construir un sistema donde incorporar todos los factores o causas y conocer los procesos, podríamos predecir el accionar de los agentes. Si planteamos la dicotomía entre el *azar ignorancia* y *azar absoluto*¹, la ciencia económica busca despejar la ignorancia. A diferencia de las ciencias exactas, la aproximación económica es probabilística, no logramos predecir con exactitud el comportamiento de los agentes. Nuestra imposibilidad de descifrar con precisión se debe a la incapacidad de realizar un cálculo infinito. Sin embargo, las nuevas tecnologías, especialmente las de información, están realizando un intento cada vez mayor por predecir ciertos comportamientos.

Según Yuval Noah Harari², el humanismo se enfrenta a un desafío existencial debido a que tenderemos a basar nuestras decisiones, en algoritmos y sistemas informáticos, cada vez en mayor medida. Parte central de la motivación de esta tesis radica en suponer que el avance tecnológico está cambiando nuestra forma de decidir, cambiando la intuición por los cálculos complejos que exceden nuestras capacidades cognitivas y de las cuales no precisábamos en el pasado. Debemos analizar cómo la accesibilidad a la tecnología moldea nuestras decisiones, qué diferencias impondrá sobre la forma en que los agentes toman decisiones y en las teorías que describen su accionar. Por ejemplo, la teoría de la elección racional, es un paradigma en la economía que sirve como marco de pensamiento para construir modelos formales de comportamiento económico y social como base para la

¹ Landro, A. (2010). Acerca de la Probabilidad: La interpretación del concepto de azar y la definición de probabilidad.

² Homo Deus: Breve historia del mañana, Ed. Debate, 2016, ISBN 978-1945540943

microeconomía, y es fundamental para la teoría de juegos. Existen varios modelos de elección racional, pero todos asumen que los individuos eligen la mejor acción de acuerdo a una función de preferencia estable y dada, y de acuerdo a las restricciones que enfrentan. Los defensores de los modelos de elección racional, no argumentan que los supuestos del modelo sean una descripción completa de la realidad, sino que los buenos modelos pueden ayudar a comprender y proporcionar hipótesis de lo que en realidad ocurre. Quienes se oponen a estos modelos argumentan que tiene fallas, que se basan en suposiciones incorrectas y que, aunque predice mal el comportamiento de las personas, continúan aferrándose a él. Consideramos que la tecnología desafía esta idea de que los supuestos de la teoría son incorrectos. El acceso a la información completa, la capacidad predictiva de las preferencias y la ausencia de sesgos en los algoritmos, podrían ser potenciales ejemplos de cómo la tecnología podría estar cambiando este paradigma.

Para entender cómo las nuevas tecnologías influyen en la forma que tomamos decisiones, primero expondremos el estado de la cuestión en lo que respecta a la tecnología de apoyo en las decisiones. Luego revisaremos la Teoría Decisional, qué herramientas utiliza y cuáles son sus limitaciones. Debemos analizar las etapas del proceso de decisión y diferenciar cada una ellas. Luego revisaremos el modelo que utiliza la economía clásica para pronosticar las decisiones de los agentes, más específicamente, analizaremos su agente decisor, el Homo Economicus. Analizaremos el impacto que pueden tener en la teoría decisional y el Homo Economicus, las nuevas tecnologías. Por último, expondremos los experimentos, sus resultados y conclusiones. En el capítulo II, El Estado de la Cuestión, realizaremos una revisión de las ventajas de la tecnología, pero también de los nuevos problemas que su utilización genera. Específicamente nos concentramos en la no utilización de los algoritmos de recomendación, luego de que el usuario los ve fallar. Este fenómeno se conoce como *aversión algorítmica*. Queremos evaluar esta aversión en escenarios donde pueden darse resultados adversos producto del riesgo o incertidumbre, inherentes a la situación y no por una falla de programación del algoritmo.

Existen varias fuerzas que modelan la utilización de la tecnología y que pretendemos poner a prueba. La adopción y aceptación por parte del usuario de la tecnología y los dispositivos

y servicios móviles se ha estudiado con varios modelos, como el *Modelo de Aceptación de Tecnología (TAM)*, *Teoría Unificada de Aceptación y Uso de Tecnología (UTAUT)* entre otros³. Para Delicia F. A. M. *et al.* (2007), en *TAM* las variables principales son: la utilidad percibida, es decir la creencia de una persona cuando utiliza un sistema en particular de cómo este mejorara su desempeño, y la facilidad de uso percibida, es la creencia de una persona que usar un sistema en particular, sería fácil y sin esfuerzo⁴. Ambas variables impactan en la intención de uso, lo que a su vez impacta en el comportamiento de uso real. El *UTAUT*, según Venkatesh V. y Zhang X. (2010), utiliza cuatro variables: expectativa de rendimiento, influencia social, expectativa de esfuerzo y facilidades, como determinantes directos de la intención de uso. También se identifican cuatro moderadores clave: género, edad, experiencia y voluntariedad de uso⁵.

Como herramienta para el análisis de la hipótesis, pusimos a prueba la toma de decisión con tres experimentos, con el objetivo de medir la influencia de herramientas tecnológicas en la toma de decisión, es decir si la tecnología modifica el resultado y si los individuos tienden a usar y basarse en estas herramientas para tomar decisiones. Queremos evaluar particularmente cómo, un resultado adverso debido a las condiciones de riesgo o incertidumbre, influye en dichos comportamientos.

Según McKnight D. H. *et al.*, la confianza en los *agentes de recomendación (RA)* y por ello la aceptación de sus recomendaciones dependen de tres variables: la competencia, la benevolencia y la integridad.

La competencia se define como la percepción del usuario de que un *RA* cuenta con la capacidad técnica, las habilidades y la experiencia suficiente para desempeñarse con eficacia en el dominio dado. La benevolencia es la percepción del consumidor de que un *RA* no tiene conflicto de interés y se preocupa solo por el interés del usuario y actúa en ese sentido. Por último, la integridad es la percepción de que un *RA* recomienda de forma honesta y según

³ King, W. R., & He, J. (2006). A meta-analysis of the technology acceptance model. *Information & management*, 43(6), 740-755.

⁴ Delicia, F. A. M., FRANCO, M. J. S., VELICIA, F. A. M., & RAMOS, Á. F. V. (2007). El modelo TAM y la enseñanza superior. Una investigación del efecto moderador del sexo. *Revista española de pedagogía*, 459-478.

⁵ Venkatesh, V., & Zhang, X. (2010). Unified theory of acceptance and use of technology: US vs. China. *Journal of global information technology management*, 13(1), 5-27. of recommendation agents. *MIS quarterly*, 941-960.

valores éticos aceptados y cumple con las promesas explícitas o implícitas hechas a los usuarios Wang W. y Benbasat, I. (2007)⁶.

Creemos que un resultado adverso puede derivar en una pérdida de confianza en la competencia, de la misma forma que lo hace un error del *RA*.

⁶ Wang, W., & Benbasat, I. (2007). Recommendation agents for electronic commerce: Effects of explanation facilities on trusting beliefs. *Journal of Management Information Systems*, 23(4), 217-246.

II. El Estado de la Cuestión

Los sistemas computarizados para la toma de decisiones (*Decision Support System -DSS*) son un subgrupo dentro de los sistemas de información (*IT*) que se centra en apoyar y mejorar la toma de decisiones gerenciales.

Diferentes investigadores presentan los *DSS* desde varios puntos de vista e incluyen: algoritmos de clasificación, algoritmos de análisis, algoritmos de *clustering*, *Data Mining*, *Business Intelligence* e *Inteligencia artificial*, entre otros. Sobre esta amplia gama de modelos, los investigadores informan diferentes procesos de lo ocurrido y de cómo se desarrollaron estas tecnologías (Power D. J. 2004)⁷. Se entiende por *DSS*, a los sistemas de información que sirven de soporte en el proceso de toma de decisiones, los cuales involucran la integración de datos y la concepción de esquemas para estandarizar, cotejar y valorar los distintos resultados posibles, ayudando a los decisores a reunir información, generar alternativas y tomar la mejor decisión⁸. Estos sistemas se desarrollan para las particularidades de cada rubro o necesidades de decisión en distintas empresas u organizaciones. De esta manera podemos encontrar *DSS* para decisiones en el sector aeronáutico Sarter N. B. (2001), sector salud Musen, M. A (2014), para negociaciones Arnott D. y Pervan G. (2016), para seguros Massaro A. (2021), etc.

Los *DSS* fueron creados en un principio como herramientas analíticas para dominios de alta complejidad, como por ejemplo el apoyo para decisiones médicas, aeronáuticas o gestión de desastres. Por esta razón, los *DSS* fueron concebidos para ser utilizados solo por los expertos en cada área, exigiendo cierto nivel de destreza y capacidad por parte del usuario. La veloz evolución de los *DSS* los llevó, en un corto plazo, a conformar el *mainstream* del gerenciamiento de la información y la toma de decisiones gerenciales Arnott D. y Pervan G. (2016).

La arquitectura de un *DSS* generalmente cuenta con tres componentes principales: (1) base de información (2) interfaz de usuario y (3) modelo para inferir las decisiones⁹. Dichos

⁷ Power, D. J. (2008). Decision support systems: a historical overview. In Handbook on decision support systems 1 (pp. 121-140). Springer, Berlin, Heidelberg.

⁸ Turban, E., Sharda, R., & Delen, D. (2014). Decision support and business intelligence systems (Vol. 9). Pearson

⁹ García-Díaz, V. (Ed.). (2021). Algorithms in Decision Support Systems. MDPI-Multidisciplinary Digital Publishing Institute.

modelos pueden basarse en múltiples tipos de algoritmos, como redes neuronales, regresión logística, árboles de clasificación, lógica difusa, etc.

Según Peña Marí R. (2021), los algoritmos están entre nosotros desde el inicio de la humanidad. Por ejemplo, el algoritmo de Euclides, el teorema de Pitágoras y mucho más atrás en el tiempo las tablillas de arcilla de los babilonios con cálculos numéricos como la fórmula del interés compuesto. Los algoritmos existen desde antes de que se inventaran aparatos que podían realizar los procedimientos de forma mecánica e independiente. Los hitos de la irrupción algorítmica moderna son demasiados y cualquier lista dejaría afuera algunos muy importantes¹⁰. Podemos comenzar nombrando como el primer hito de la era moderna a la máquina de Alan Turing. Luego, ya en los años 50', IBM desarrolla su primera computadora de escala industrial y comienzan a surgir los lenguajes de programación. Entre los años 50' y 60', Simon H. A. sienta las bases conceptuales de trabajo para la incorporación de los sistemas de apoyo y los algoritmos dentro de las empresas. En los años 60', comienzan los algoritmos de lógica difusa a procesar datos aproximados y son un primer esbozo de lo que años más tarde sería internet. Podemos nombrar como ejemplo de este tipo de desarrollos a DENDRAL, un *DSS* que ayudó a los médicos a diagnosticar enfermedades de la sangre en función de conjuntos de síntomas clínicos. El proyecto dio como resultado el desarrollo del primer sistema experto (Buchanan B. G. y Shortliffe E. H. 1984). En los años 70' comienzan importantes avances en lo que respecta al hardware, como fueron los microprocesadores, disquetes, la portabilidad de las computadoras entre otros y esto permite la creación de algoritmos de iteración repetitiva y la utilización de memoria a gran escala. Ya a partir de los 80' crece la ubicuidad de la computación personal y es el preámbulo para los dispositivos que nos rodean y que harán que miles de algoritmos estén a nuestra disposición. En los 90' irrumpe con mayor fuerza la utilización de la *world-wide web* que comenzará a generar cantidades inmensas de datos estructurados y no estructurados. Esta disponibilidad de datos, permitió avances en áreas críticas, como por ejemplo, la seguridad nacional. Los algoritmos del sistema Carnivore, por ejemplo, permitieron a las agencias gubernamentales de E.E.U.U., realizar búsquedas de palabras

¹⁰ Burstein, F., & Holsapple, C. W. (Eds.). (2008). Handbook on decision support systems 2: variations. Springer Science & Business Media.

clave en correos electrónicos recopilados a través de la cooperación de proveedores de servicios de Internet en el sector privado. El sistema almacena datos estructurados y no estructurados y admite consultas a su base de datos. De esta manera, puede identificar la organización jerárquica de un grupo terrorista, o analiza los cambios en temas clave a lo largo del tiempo para identificar tendencias (Kolda T. 2005). A partir del año 2000, y hasta la actualidad, existe una proliferación de desarrollos que aportan, a veces de manera divergente, y en otras convergentes, a la incorporación de cientos de algoritmos en nuestra vida cotidiana. En la simple lista de música en nuestros celulares podemos encontrar diversos algoritmos, como, por ejemplo, la compresión de señal de audio basadas en la transformación rápida de Fourier, el algoritmo de filtración de frecuencias redundantes de Brandenburg y la compresión de bits de Huffman, por nombrar algunos (Peña Marí R. 2021)

La proliferación del uso de internet, las computadoras y los *Smartphones* han acercado a los usuarios individuales, y no solo a las organizaciones, la posibilidad de utilizar herramientas de este tipo en la vida cotidiana. Este cambio está generando un impacto en la forma en que tomamos decisiones y en cómo se toman decisiones en nuestro entorno. Cuando las personas no están familiarizadas o no son expertos en un dominio específico pueden acudir a estas herramientas de soporte para mejorar sus decisiones. Uno de los primeros interrogantes que surgen cuando utilizamos estas herramientas, es si realmente mejoran nuestra capacidad de decisión. Los trabajos pioneros de Meehl P. E. (1954) "*Clinical versus statistical prediction*"¹¹ y Goldberg L. R. (1970) "*Man versus model of man*"¹², comenzaron hace más de medio siglo a demostrar la superioridad de los modelos por sobre las decisiones de las personas, e incluso de los expertos. Los algoritmos son precisamente eso, modelos donde por medio de reglas y operaciones matemáticas y estadísticas se resuelve un problema específico. Se ha demostrado que, ante un problema específico, en una especialidad determinada y conociendo las preferencias del usuario, un *DSS* puede mejorar significativamente el desempeño humano en los procesos de decisión.

¹¹ Meehl, P. E. (1954). Clinical versus statistical prediction: A theoretical analysis and a review of the evidence.

¹² Goldberg, L. R. (1970). Man versus model of man: A rationale, plus some evidence, for a method of improving on clinical inferences. *Psychological bulletin*, 73(6), 422.

Esta mejora, según Kahneman D. *et al.* (2016)¹³, se atribuye a la capacidad de eliminar de estos sistemas, tanto los sesgos cognitivos, como el ruido estadístico de las decisiones humanas.

Los desarrollos tecnológicos se están expandiendo fuera de las empresas y organizaciones, brindando servicios a usuarios interesados en la compra de bienes o servicios. Greci R. T. y Todd P. A. (2002), argumentan que los *CDSS* (*Customer Decision Support System*) son parte integral de cualquier estrategia de ventas y marketing exitosa. Estos funcionan como un sistema experto en identificar las necesidades del usuario, guían al usuario a una solución adecuada y la explica o justifica para que pueda comprender la recomendación¹⁴. Los *CDSS* se presentan en forma de *RA* (*Agent Recommendation*) y *CM* (*Comparison Matrix*) facilitando la eficiencia en la búsqueda, recolección de la información y comparación de los atributos Häubl, G. y Trifts, V. (2000).

Westerman, S. J. *et al.* (2007)¹⁵ observan que las decisiones, cuando los participantes contaban con el apoyo de un *CDSS*, eran más uniformes y de mejor calidad.

De esta manera, si los sistemas de apoyo para decisiones de usuarios no expertos son cada vez más accesibles y tienen un mejor desempeño que los usuarios, debiéramos ver un aumento generalizado en la adopción de estas herramientas y sus recomendaciones. Existe sí, una tendencia a incorporar estas herramientas en la toma de decisión, sin embargo, las expectativas de los usuarios respecto de la precisión e infalibilidad de los algoritmos de recomendación generan el abandono de su utilización cuando estos fallan. El abandono ocurre incluso a pesar de fallar en menor medida que los recomendadores humanos y que las decisiones que toman los usuarios por sí mismos.

Dietvorst B. J., Simmons J. P. y Masey C. (2015)¹⁶, llevaron a cabo una investigación pionera de ese tópico, para conocer la actitud de los usuarios ante la falla de los pronósticos

¹³ Kahneman, D., Rosenfield, A. M., Gandhi, L., & Blaser, T. (2016). Noise. *Harvard Bus Rev*, 38-46.

¹⁴ Kol, O., & Lev-On, A. (2014). Online social networks and purchase decision making. Ministry of Economy, Jerusalem.

¹⁵ Westerman, S. J., Tuck, G. C., Booth, S. A., & Khakzar, K. (2007). Consumer decision support systems: Internet versus in-store application. *Computers in Human Behavior*, 23(6), 2928–2944. <https://bases.biblioteca.uca.edu.ar:2176/10.1016/j.chb.2006.06.006>

¹⁶ Dietvorst, B. J., Simmons, J. P., & Massey, C. (2015). Algorithm aversion: People erroneously avoid algorithms after seeing them err. *Journal of Experimental Psychology: General*, 144(1), 114.

generados por algoritmos. Observaron que los participantes abandonaron la utilización de los algoritmos luego de verlos fallar y a pesar de que dichos pronósticos eran superiores a los pronósticos humanos. En este mismo sentido, Hidalgo C. A., Orghian, D., Canals, J. A., De Almeida, F., & Martin, N (2021)¹⁷, luego de realizar una decena de experimentos con casi treinta mil participantes, concluyen que “juzgamos a los humanos por sus intenciones y a las maquinas por sus resultados”.

Pensamos que es conveniente diferenciar los errores producidos como consecuencia de una falla del algoritmo, de aquellos errores resultantes de un escenario adverso en el marco de decisiones tomadas en condiciones de incertidumbre.

Las fallas son corregibles, sin embargo, en situaciones de incertidumbre, incluso si el algoritmo funciona perfectamente, habrá recomendaciones que terminen en un desacierto.

La *Racionalidad Limitada* propuesta por Simon H. A. (1957)¹⁸, exponía que esta limitación en nuestra capacidad racional, se daba por nuestras dificultades en el acceso a toda la información y a nuestra reducida capacidad y velocidad de cálculo. Todas estas limitantes pueden ser superadas, o al menos acotadas, gracias a los algoritmos y los *DSS* en general.

El objetivo de esta tesis es comprender si el comportamiento de los participantes ante un resultado adverso a la recomendación, produce el mismo efecto que un error del algoritmo. En otras palabras, si los usuarios podrán distinguir, a la hora de juzgar un algoritmo de recomendación, entre una falla y un resultado adverso.

i. Teoría Decisional

La teoría de decisión es aquella que estudia cómo elegimos y cómo deberíamos elegir para alcanzar nuestros objetivos. Por esta razón, la teoría decisional está enriquecida por varios campos de estudios tales como la psicología, sociología, filosofía, neurociencia, administración, economía, estadística y matemática. Podríamos decir que, mientras la psicología y la sociología se ocupan de cómo son tomadas las decisiones en la realidad, las administración, economía, estadística y matemática intentan ser una herramienta para

¹⁷ Hidalgo, C. A., Orghian, D., Canals, J. A., De Almeida, F., & Martin, N. (2021). How humans judge machines. MIT Press.

¹⁸ Simon, H. (1957). A behavioral model of rational choice, in models of man, social and rational: mathematical essays on rational human behavior in a social setting. New York: Wiley.

ayudar a tomar la mejor decisión. Esto es básicamente la diferencia entre la teoría descriptiva o positiva y la teoría normativa. La teoría normativa usa la racionalidad o *Teoría de la Elección Racional* como marco teórico de elección. Para que un agente sea considerado racional este debe cumplir con los axiomas de completitud, independencia, transitividad y continuidad Von Neumann J., Morgenstern O. (1953). La completitud requiere que siempre, ante dos opciones, se tenga la capacidad de elegir o preferir una de ellas (que no sea indeterminado). La independencia asume que ante dos opciones presentadas juntas con una tercera opción irrelevante mantendrán el mismo orden de preferencia que cuando las dos se presentaron independientemente de la tercera. La transitividad implica consistencia, es decir que mi orden de preferencias no se altera, si A es preferido a B y B preferido a C entonces A es preferido a C. Por último, el axioma de continuidad implica que, si hay tres bienes A, B y C y se cumple que $A < B < C$ en términos de utilidad, entonces es posible encontrar una combinación entre A y B tal que el individuo está indiferente entre C y dicha combinación.

Las diferencias que hallamos entre las decisiones que tomamos y las que deberíamos tomar es una parte importante del argumento de esta tesis ya que suponemos que estas diferencias podrían tender a reducirse gracias a los avances de la tecnología.

“ Si los tomadores de decisiones humanos son tan racionales como se lo permiten sus limitadas capacidades computacionales y su información incompleta, entonces habrá una estrecha relación entre la teoría de la decisión normativa y la descriptiva.”²⁰

Una mayor utilización de herramientas *DSS*, podría acercar las decisiones que tomamos a las que deberíamos tomar dado nuestros objetivos. Reconocemos que las *DSS* son herramientas de ayuda que pueden hacer que nuestras decisiones sean más eficientes en el logro de nuestros objetivos.

²⁰ Simon, Herbert A., Rational Decision-Making in Business Organizations, Nobel Memorial Lecture, 8 December, 1978. Carnegie-Mellon University, Pittsburgh, Pennsylvania, USA

“If human decision makers are as rational as their limited computational capabilities and their incomplete information permit them to be, then there will be a close relation between normative and descriptive decision theory.”

Las nuevas tecnologías pueden influir en los distintos componentes de la decisión tales como:

1. Necesidad de decisión: identificación, búsqueda de información, evaluación etc.
2. Valuación de alternativas: probabilidades y preferencias
3. Decisión: fuente de autoridad y herramientas
4. Resultados de la decisión: escenarios de riesgo, incertidumbre e ignorancia

Según Hansson S. O. (1994) tomamos miles de decisiones en el día a día, pero lo hacemos sin demasiado análisis y discernimiento, de forma automática. Sin embargo, existen decisiones que se toman una, o pocas veces en la vida, las cuales son más complejas o nuevas para nosotros, y por lo tanto requieren de nuestra atención y dedicación.

Las fases de estas decisiones han sido divididas por distintos investigadores (Dewey J., Simon H. A., Brims O. 1962)²¹ en:

1. Identificación del problema
2. Obtención de información necesaria
3. Producción de posibles soluciones
4. Evaluación de dichas soluciones
5. Selección de la estrategia

Estos autores han planteado las fases de forma ordenadas y separadas una de otra, sin embargo, autores más recientes plantean que estas fases en general se suelen solapar y se llevan a cabo al mismo tiempo.

“Según Simon (1960), los ejecutivos pasan una gran parte de su tiempo en actividades de inteligencia, una fracción aún mayor en la actividad de diseño y una pequeña fracción en la actividad de elección entre diversas opciones”²². Sin embargo, la mayoría de la literatura de la teoría de decisión se enfoca en el sistema de elección entre las distintas opciones.

En lo que respecta a la elección en sí misma, las metodologías aplicadas, sean cual fueren, consisten en otorgar un valor y una probabilidad a cada opción y elegir el mejor resultado

²¹ Hansson, S. O. (1994). Decision Theory--A Brief Introduction.

²² Hansson, S. O. (1994). Decision Theory--A Brief Introduction

de la combinación entre ellos. La valuación, conocida como *Teoría de la Utilidad Esperada (TUE)*, se puede dividir entre el placer o la utilidad que cada una de las opciones nos representa y la probabilidad de que estas ocurran. Para la primera parte de la valuación, necesitamos un ordenamiento sistemático de cada una de las opciones. Este orden es llamado preferencias y en economía es expresado en la función de utilidad, . Paul Samuelson fue quien popularizó el concepto de *preferencias reveladas* que se utiliza para descifrar las preferencias de los consumidores según sus hábitos de compra. Las nuevas tecnologías nos permiten tener más información sobre gustos y costumbres de los consumidores de lo que se podía en el pasado. En decisiones económicas específicamente, solemos utilizar los precios, costos o beneficios, como indicador numérico para el ordenamiento. Para que la elección sea racional, la *TUE* exige el cumplimiento de los axiomas antes mencionados. La segunda parte de la valuación es la que adjudica una probabilidad al resultado de la elección. Debido a que la mayoría de nuestras decisiones se toman en un marco de incertidumbre, es conveniente realizar una diferenciación entre los distintos escenarios en el que se toman decisiones según Knight F. H. (1921):

1. Certidumbre, es decir conocemos con exactitud cuál será el resultado de nuestra decisión
2. Riesgo, tenemos un conocimiento exacto de las probabilidades de los resultados esperados
3. Incertidumbre, conocemos los posibles resultados, pero no podemos asignarle una cierta probabilidad o una probabilidad exacta
4. Ignorancia, no conocemos siquiera los resultados posibles. Este último incorporado por Taleb N. N. (2008)²³

“Parecería que la incertidumbre medible, o "riesgo" propiamente dicho, como lo llamaremos, es tan diferente de una inmensurable que en realidad no es incertidumbre en absoluto. En consecuencia, restringiremos el término "incertidumbre" a los casos del tipo no cuantitativo.”²⁴

²³ Taleb, N. N. (2008). *The Black Swans*.

²⁴ Knight, F. H. (2012). *Risk, uncertainty and profit*. Courier Corporation.

Las soluciones matemáticas o herramientas para la toma de decisiones se suelen utilizar en el marco de decisiones riesgosas. Incluso las decisiones en condiciones de incertidumbre pueden ser evaluadas mediante una asignación subjetiva de probabilidades.

Los criterios para evaluar las decisiones se han transformado en fórmulas matemáticas que se diferencian según las preferencias del individuo y del conocimiento o falta de conocimiento de las probabilidades, como, por ejemplo, el *criterio de Wald*, el *criterio de Hurwicz*, el *criterio Savage* y el *criterio del valor esperado*, entre otros²⁵:

Criterio de Wald / minimax-maximin / pesimista

Este criterio supone que, frente a los diversos estados de la naturaleza, sucederá el peor, por lo tanto, se debe elegir la opción que dé el mayor valor esperado en dicho escenario. Así el decisor tendrá certeza respecto de cuál será su peor resultado, y cualquier cambio sólo podrá mejorar su situación. Cuando los resultados son pérdidas, este enfoque recomienda elegir el mínimo de los máximos, denominándose *minimax*. Mientras que, si los resultados son ganancias, será el máximo de los mínimos, denominándose *maximin*.

Criterio optimista

Este criterio es opuesto al criterio de Wald, con este enfoque suponemos que de todos los estados de la naturaleza sucederá lo mejor, y se elige aquel que tenga el mayor valor.

Criterio de Hurwicz

Este enfoque busca una solución intermedia entre el criterio de Wald y el criterio optimista. Para ello, adjudica un índice de optimismo y un índice de pesimismo que se traduce en las probabilidades de cada escenario. Al utilizar estos índices subjetivos, existe el riesgo de ponderarlos equívocamente, por esta razón, se suelen estimar con varios índices y situar al decisor en un rango razonable de probabilidad.

“It will appear that a measurable uncertainty, or "risk" proper, as we shall use the term, is so far different from an unmeasurable one that it is not in effect an uncertainty at all. We shall accordingly restrict the term "uncertainty" to cases of the non-quantitative type”

²⁵ <https://www.eumed.net/ce/2014/competitividad-incertidumbre.html>

Criterio de Savage o costes de oportunidad

Este enfoque busca minimizar el arrepentimiento una vez conocido el estado de la naturaleza. Para ello, toma en cuenta el costo de oportunidad en la matriz de decisión, seleccionando aquel que sea menor.

La *aversión al riesgo*, surgida de la *TUE*, puede ser explicada ya que, nuestra satisfacción por el consumo de bienes, o la acumulación de capital, crece, pero no de manera lineal sino logarítmica. Esta característica psicológica fue tal vez el tema central en los inicios de la psicología científica, que se concentraba en las percepciones subjetivas de los diferentes tipos de estimulación física, como la luz, el calor, la gravedad, y otros. La llamada *función psicofísica* intenta medir la magnitud de la relación entre la intensidad de los cambios físicos y la intensidad de la percepción psicológica que resulta de ellos. Gustav Fechner, quien fue pionero en la investigación de la interacción entre mente y materia, llegó a la conclusión de que la función logarítmica podía describir esta relación. Fechner entendió que, frente a un estímulo físico que crece de manera geométrica, la percepción del individuo crecerá de manera aritmética. La actitud psicológica de los individuos frente al riesgo no es lineal, puede variar de individuo a individuo y entre situaciones económicas distintas (*state of wealth*).

No fue sino hasta la *Teoría de la Prospectiva*, Daniel Kahneman y Amos Tversky, que los distintos aspectos psicológicos en la toma de decisiones tomaron una mayor relevancia en la teoría económica. La *Teoría Prospectiva* es una rama de la psicología social y la economía del comportamiento que describe el comportamiento humano al tomar decisiones en condiciones de riesgo o incertidumbre. La teoría sostiene que las personas no estiman una adición a su capital de acuerdo con el monto de la suma, sino de acuerdo con el monto proporcional del incremento en relación con su capital inicial. Al elegir entre alternativas, las personas ponderan el valor sesgado de cada alternativa por la probabilidad también sesgada y eligen la alternativa que tenga el resultado más alto. Es decir, que tanto el valor, como la probabilidad, no son calculados como absolutos si no que se ven influenciados por distintos sesgos, como el sesgo de anclaje, el efecto de dotación, el sesgo de representatividad y el efecto marco, por nombrar algunos. La multiplicación del valor

subjetivo por la probabilidad permite, por ejemplo, hacer coincidir un plan de ahorro con la aversión al riesgo para el cliente y de su aversión a las pérdidas. El resultado puede predecir cuál de los programas el cliente verá como propuesta rentable.

ii. Teoría de la Racionalidad

La economía utiliza el supuesto de la racionalidad económica como pilar para comprender el comportamiento económico y humano. La disciplina de la economía puede mediante esta herramienta (*Homo Economicus*), hallar respuestas a una gran variedad de cuestiones humanas como fumar o casarse, entre otras.²⁷

El supuesto de la racionalidad ha sido sumamente criticado por economistas, quienes ven en él, no solo algo irreal, como todo modelo simplificador, sino también una influencia negativa en el comportamiento humano y del mercado.

La reciprocidad, la exogeneidad de los gustos y la racionalidad limitada son algunas de las críticas que ha recibido, las cuales pueden ser interpretadas como moldeadoras del concepto de racionalidad, sin embargo, también se le ha atribuido el supuesto de egoísmo, el cual genera un rechazo al modelo en su totalidad.

Según Wallacher J. (2004), la característica de este individuo/modelo, el *Homo Economicus* es, en primer lugar, el individualismo en las decisiones. Es decir, la teoría económica se construye por medio de individuos cuyas decisiones son transferidas al mercado y a la sociedad en general (*individualismo metódico*).

En segundo lugar, este individuo es guiado por su afán de lucro y beneficio personal sin tomar en cuenta las necesidades y preferencias del prójimo. El ámbito en el que se lleva a cabo esta toma de decisión está delimitado por sus preferencias y sus restricciones (económicas y sociales). Estas preferencias deben ser consistentes, y el individuo debería tener la capacidad de hacer un análisis racional de todas las opciones, ordenarlas según estas preferencias, y elegir la mejor opción²⁸.

²⁷ Becker, G. (1998). El enfoque económico de la conducta humana. Anuario de Filosofía Jurídica y Social, Sociedad Chilena de Filosofía Jurídica y Social.

²⁸ Wallacher, Johannes, 2004, “¿Despedida del homo oeconomicus?”, *Communio*, Año 11, N° 2, Buenos Aires

Más allá de estos supuestos, podemos agregar que el interés por el prójimo sí existe, pero solo en los casos en el que el accionar del individuo hacia el prójimo, le genera algún tipo de beneficio. En otras palabras, solo cuando hay un interés común o algún tipo de rédito por una acción empática hacia el otro, se producirá dicho acto.

Respecto a las preferencias, los economistas clásicos no intentan estudiar cuales son las bases que las generan, sino que son tomadas como exógenas y sabemos de ellas solo por medio de las acciones de los individuos.

iii. Críticas al *Homo Economicus*

Algunos economistas, también clásicos, no han criticado directamente el modelo, pero sí han intentado acotarlo.

Muchos de estos economistas percibieron que existía una diferencia sustancial entre la teoría y la realidad observada, entre el aspecto normativo y positivo. Simon H. A., como antes mencionamos, propuso la existencia de un individuo racional, pero con una racionalidad limitada. Estas limitaciones están dadas ya que, en la gran mayoría de los casos existen tres condicionantes: la información es incompleta, la toma de las decisiones se realiza sin tiempo suficiente y nuestra capacidad de procesar la información también es limitada.

A su vez, nuestras mentes también tienen limitaciones cognitivas. Todas estas limitaciones generan una distancia entre lo que la teoría predice y lo que los investigadores observan. Para superar estas limitaciones, Simon H. A.²⁹, argumenta que los individuos utilizan métodos heurísticos para la toma de decisiones. Estos métodos no se aplican solo a las decisiones individuales, sino que también surgen en el ámbito empresarial.

Podemos hallar una síntesis grafica del proceso de las decisiones empresariales en el libro *The Design of Business: Why Design Thinking is the Next Competitive Advantage* (2009) de Roger Martin.

²⁹ Simon, H. A. (1979). Rational decision making in business organizations. *The American economic review*, 69(4), 493-513.

Martin presenta el *embudo del conocimiento* (*the knowledge funnel*) como el proceso seguido por las empresas para innovar de manera más consistente y con éxito. El embudo del conocimiento está compuesto por tres fases:

Misterio → heurística → algoritmo.

La etapa misterio comprende la exploración del problema, luego se genera una regla de oro (etapa heurística), en la transición a la regla de oro el campo decisional se reduce a un tamaño manejable. En la etapa de algoritmo, la heurística, se convierte en una fórmula fija simplificando la complejidad del problema.

Este embudo marca cómo de la heurística, con todas sus falencias, pasamos a los algoritmos y la mejora en las decisiones.

Otro cuestionamiento importante respecto al modelo, es el carácter tautológico de las preferencias³⁰. Las preferencias de los individuos se asumen como exógenas y consistentes. Se genera un círculo vicioso cuando suponemos que las preferencias se trasladan a la elección, luego si existe algún cambio en la elección, los investigadores concluyen que las preferencias han cambiado³¹.

El siguiente cuestionamiento es acerca de nuestra capacidad de raciocinio. Nuestras capacidades de análisis de distintas situaciones y la toma de decisiones no solo son limitadas por las razones que expuso Simon H. A., sino que también se ven sesgadas por distintas cuestiones cognitivas.

En la *Teoría de la Prospectiva* se profundizó el análisis de los heurísticos en las decisiones bajo incertidumbre. “Los heurísticos son pautas de juicios de estimación sesgados, los sesgos subyacentes fueron catalogados por Tversky A. y Kahneman D. en accesibilidad, representatividad y anclaje”³². Podemos identificar que los individuos, a diferencia de las

³⁰ Wallacher, Johannes, 2004, “¿Despedida del homo oeconomicus?”, *Communio*, Año 11, N° 2, Buenos Aires

³¹ Becker sostiene que las preferencias son estables pero que no se refieren a productos específicos como una naranja o automóvil sino a los objetos subyacentes a estas preferencias. “Estas preferencias subyacentes son definidas en base a aspectos fundamentales de la vida como la salud, el prestigio, el placer sensual, la benevolencia o la envidia, que no siempre tienen una relación estable con bienes y servicios de mercado. La asunción de preferencias estables provee una base sólida para generar predicciones sobre respuestas a varios cambios y previene al analista de sucumbir a la tentación de fundamentar las inconsistencias entre sus predicciones y la realidad en el cambio de las preferencias”. Becker, Gary S., 1978. *The Economic Approach to Human Behavior*, The University of Chicago Press, Chicago.

³²Cortada de Kohan Nuria, Los sesgos cognitivos en la toma de decisiones, *International Journal of Psychological Research* 2008. ISSN 2011 – 7922 vol. 1, Nro 1, pp. 68-73.

empresas, cuentan solo con las reglas heurísticas, no llegan a la etapa de generar algoritmos como hacen las empresas según Roger Martin. Esto está cambiando, los individuos no desarrollan algoritmos para sus decisiones, pero sí hemos comenzado a utilizar algoritmos desarrollados por terceros.

III. El futuro del racionalismo

René Descartes fue uno de los artífices de la búsqueda de la verdad por medio del conocimiento. En su Discurso del método (1637) ayudó a establecer el método científico y formó parte de lo que se dio a conocer como la revolución científica. Esta revolución sentó las bases para que nuestras decisiones comenzaran a ser cada vez más razonadas. “El renacimiento hizo posible una revolución científica que permitió a los eruditos ver el mundo bajo una luz diferente. La religión, la superstición y el miedo fueron reemplazados por la razón y el conocimiento”³³. Las herramientas de la racionalidad siguen en desarrollo y las nuevas tecnologías son fundamentales en nuestros procesos de toma de decisiones. La fuente de autoridad de nuestras decisiones se encuentra en un proceso de traslado desde nuestros sentimientos y razonamientos que impuso el humanismo, a los sistemas de tecnología de la información Harari Y. N. (2016). Esta transferencia, es un paso más en nuestra búsqueda por racionalizar nuestras decisiones.

“Las personas pueden que abandonen sus propios juicios psicológicos y confíen en las computadoras cuando toman decisiones importantes en la vida, como elegir actividades, profesiones o incluso parejas románticas. Es posible que tales decisiones basadas en datos mejoren la vida de las personas.”³⁴

³³ Bernal J. D. (1937) Dialectical Materialism and Modern Science. *Science & Society* 2 (1): 58–66.

³⁴ Youyou, W., Kosinski, M., & Stillwell, D. (2015). Computer-based personality judgments are more accurate than those made by humans. *Proceedings of the National Academy of Sciences*, 112(4), 1036-1040. People might abandon their own psychological judgments and rely on computers when making important life decisions, such as choosing activities, career paths, or even romantic partners. It is possible that such data-driven decisions will improve people's lives

“Dado lo "prodigio del pensamiento del sistema uno", Kahneman sugiere que un papel muy útil para un sistema informático "inteligente" sería una especie de crítico por encima del hombro para ayudar a la toma de decisiones humana. Podría, dice, traer la perspectiva del pensamiento lento, con su análisis cuidadoso de la evidencia, para complementar y enriquecer el pensamiento rápido de los humanos.”³⁵

i. Tecnología y Decisiones

El objetivo de gran parte de las tecnologías de información es predecir el próximo paso del usuario. Existen causas y consecuencias, la aleatoriedad es resultado de la ignorancia, y, por lo tanto, reducir su magnitud es uno de los objetivos de las *IT*.

Al adoptar y transferir nuestra fuente de autoridad a la tecnología, y esta ser programada racionalmente, serán tal vez nuestras decisiones más predecibles y racionales.

Recapitularemos las críticas a la racionalidad del *Homo Economicus* para poder reverlas a la luz de los cambios tecnológicos:

1. Información imperfecta
2. Incapacidad de procesar en tiempos limitados
3. Tautología de las preferencias
4. Egoísmo
5. Sesgos cognitivos.

Entonces podemos ahora revisar la influencia de la tecnología en cada una de estas críticas.

ii. Tecnología, Información Imperfecta y Tiempos de Procesamiento

Si anteriormente podíamos hablar de información imperfecta o que el acceso a la información es limitado en la actualidad podemos hablar de información cuasi perfecta. La

³⁵ Lohr, S. (2015). Data-ism. Oneworld Publications.

“Given the “marvel of system-one thinking,” Kahneman suggests that a very useful role for an “intelligent” computer system would be a kind of over-the-shoulder critic to assist human decision making. It could, he says, bring the slow-thinking perspective, with its careful parsing of evidence, to supplement and enrich fast thinking by humans.”

toma de la mayor parte de las decisiones se realiza sin tiempo y nuestra capacidad de procesar la información también es limitada.

En la actualidad la capacidad computacional y la accesibilidad a esa capacidad, son de uso cotidiano. Como vimos, Simon H. A., sostenía que mejorando nuestra capacidad computacional acotaríamos la diferencia entre cómo tomamos decisiones y cómo deberíamos tomarlas.

iii. Tautología de las Preferencias

El proceso de toma de decisiones comienza siempre con la identificación de un problema y un objetivo. Este objetivo es intrínseco a cada individuo e identificarlo es el primer paso en la toma de decisiones.

En el análisis de casos empresariales, muchas veces, la falla no se encuentra en las herramientas utilizadas para solucionar el problema, sino en que se ha solucionado el problema equivocado. Es decir que, las empresas y los individuos, se equivocan en elegir y definir el o los objetivos³⁶.

La teoría de las *preferencias reveladas* fue propuesta por el economista estadounidense Paul Samuelson como método de análisis teórico de las opciones del consumo entre diversos productos y servicios. Este modelo asume que hay una cierta comprensión de las preferencias de los consumidores que se pueden inferir en función de los hábitos de compra de los consumidores. La información sobre gustos y preferencias se puede obtener de dos maneras: o bien mediante la pregunta directa a los consumidores o por medio de estudiar y conocer el consumo realizado.

El inconveniente es que conocer las preferencias puede ser sumamente complicado, puesto que la combinación de productos comparables es muy alta, y su vez, acceder a los gustos de miles de consumidores no resultaba económicamente viable. Sin embargo, el auge del consumo *online* y *offline* con pagos digitales ha permitido que las empresas comiencen a utilizar esta información para conocer a cada consumidor en un detalle cada vez mayor.

Nuestras *huellas digitales* son acumuladas y analizadas por sistemas de información y se conocen como *big data*. Incluso la pregunta directa al consumidor es más simple y cotidiana

³⁶ Nutt, P. C. (2002). Why decisions fail. San Francisco, CA: Barrett-Kohler Publishers.

ya que muchos sitios web y aplicaciones solicitan la calificación de productos y servicios por parte de sus usuarios. Aun sin un procedimiento activo por parte del usuario también es posible inducir sus gustos y preferencias con herramientas de análisis de estas huellas digitales.

Se puede crear un perfil de usuario gracias a la información digital que se acumula sobre sus gustos artísticos, sus ideas políticas, sus hábitos de consumo etc. y con ese perfil predecir sus próximas decisiones. Esto no soluciona las inconsistencias que puedan tener los gustos de los usuarios, pero la información que se recibe a nivel macro es estable y coherente en el tiempo.

iv. Tecnología y Sesgos Cognitivos

Los sesgos cognitivos expuestos en la *Teoría Prospectiva* demuestran que las decisiones bajo incertidumbre se toman a menudo por medio de conceptos heurísticos simplificadores³⁷.

En el marco de toma de decisiones en empresas, organizaciones y gobiernos, el proceso también se apoya en la utilización de softwares sofisticados. Un programador de *DSS* debe tener conocimiento sobre los procesos de toma de decisiones y cómo mejorarlos. Ejemplo de esto es una investigación realizada en Monash University por David Arnott³⁸, que utiliza como enfoque de construcción, los sesgos cognitivos para el diseño y desarrollo del *DSS*. Es decir que evalúa el proceso de toma de decisión bajo la lupa de los sesgos cognitivos específicos para luego *desesgarlos (debiasing)*³⁹. Mientras que la ciencia natural intenta comprender y describir la realidad, el diseño debe crear elementos que sirvan a los propósitos humanos.

Un aspecto de la teoría de la decisión importante para los analistas de sistemas involucrados en el desarrollo de *DSS*, es la predictibilidad en la toma de decisiones. Es decir, una forma de ver los sesgos cognitivos es tenerlos en cuenta como desviaciones predecibles de la racionalidad. Por ello se deben planear estrategias de *debiasing* como una de las categorías

³⁷ Kahneman, D., & Tversky, A. (1984). Choices, values, and frames. *American Psychologist*, 39(4), 341-350.

³⁸ Arnott, D. (2006). Cognitive biases and decision support systems development: a design science approach. *Information Systems Journal*, 16(1), 55-78.

³⁹ Debiasing es un procedimiento para reducir o eliminar los sesgos de las estrategias cognitivas de un tomador de decisiones. Keren, G. (1990) Cognitive aids and debiasing methods: can cognitive pills cure cognitive ills. In: *Cognitive Biases*, Caverni, J.P., Fabre, J.M. & Gonzalez, M. (eds), pp. 523–555. North-Holland, Amsterdam, the Netherlands.

de *ingeniería cognitiva* es decir es decir “la aplicación de la psicología cognitiva y disciplinas relacionadas para el diseño y operación de sistemas humano-máquina”⁴⁰.

En ese proyecto de desarrollo, se diseñó la herramienta sabiendo de las limitaciones cognitivas como enfoque de construcción. De esta manera se diseñó un *DSS* con el objetivo de *desesgar* el sesgo de *confirmación* que se identificó respecto de la decisión de cerrar una división de la empresa. El sesgo de *confirmación* es aquel por el cual se busca mayor evidencia sobre una decisión, que evidencias que la refute. “ El sesgo de confirmación actúa en contra de un principio fundamental del método científico, que sostiene que la información que refuta una hipótesis es más valiosa que la información que la respalda.”⁴¹. En la investigación realizada en Monash University por Arnott D. antes citada, se desarrolló un sistema que permitía y facilitaba información que refutara la decisión que se había tomado a priori. En ese proyecto específico el anhelo de superar los sesgos fue totalmente explícito.

Los sistemas de información y tecnologías de soporte para la toma de decisiones buscan racionalizar y *desesgar* las decisiones. En la actualidad nuestras decisiones cuentan con herramientas más racionales, científicas y matemáticas.

A diferencia de las herramientas matemáticas comunes, como las probabilidades, arboles de decisión, programación lineal y gráficos de visualización, a las nuevas tecnologías se le puede delegar decidir por nosotros.

Una vez que probemos un sistema o tecnología que nos ayude a tomar una decisión y los resultados sean positivos, creemos que tenderemos a confiar más en él y a delegarle nuestra decisión. Nosotros suponemos que la predictibilidad del individuo se fortalece gracias a esta delegación de la toma de decisión. Esto se debe a que las decisiones basadas en la tecnología tienen un resultado más predecible que el comportamiento humano sesgado, limitado y ruidoso.

⁴⁰ Wilson, K. M., Helton, W. S., & Wiggins, M. W. (2013). Cognitive engineering. *Wiley Interdisciplinary Reviews: Cognitive Science*, 4(1), 17-31.

⁴¹ Arnott, D. (2006). Cognitive biases and decision support systems development: a design science approach. *Information Systems Journal*, 16(1), 55-78.

“The confirmation bias acts against a fundamental principle of the scientific method, which holds that information that refutes a hypothesis is more valuable than information that supports it.”

Podremos predecir si crece la racionalidad en los sistemas de información y si la ratio de su utilización es creciente.

“La cuestión de cuándo confiar en la máquina, una mecánica o una virtual, un algoritmo de software, se discutirá repetidamente en el futuro. Las apelaciones a la eficiencia por sí solas no ayudaran. Los defensores de los automóviles autónomos recopilan estadísticas de seguridad y argumentos que suenan lógicos para impulsar su caso, sobre las tasas de accidentes y las debilidades humanas producto de la somnolencia, la distracción y la embriaguez. Esos argumentos ayudan, pero no hablan de los problemas de confianza y comodidad con las máquinas. Las personas no son agregados; todos experimentamos el mundo como individuos. Entonces, declarar que algo será bueno para la población, en promedio, no es del todo persuasivo. Lo que se necesitará es una narrativa que Danny Hillis, el experto en inteligencia artificial, describe como las máquinas que se explican a sí mismas, dando una explicación simplificada de cómo funcionan. Lo que también se necesita es tiempo, un umbral de experiencia acumulada de vivir con las máquinas que toman de decisiones, en la casa o en el camino, para alcanzar un nivel de comodidad.”⁴²

El creciente uso de algoritmos para la toma de decisiones se encuentra en auge en diversos campos de la actividad humana (Kahneman D. et al 2016)⁴³. Podemos citar algunos ejemplos,

⁴² Lohr, S. (2015). *Data-ism: The revolution transforming decision making, consumer behavior, and almost everything else*. New York: HarperCollins Publishers.

“The issue of when to trust the machine—a mechanical one or a virtual one, a software algorithm—is going to play out repeatedly in the future. Appeals to efficiency alone will not carry the day. Advocates for self-driving cars marshal safety statistics and logical-sounding arguments to push their case—about accident rates and the human foibles of drowsiness, distractedness, and drunkenness. Those arguments help, but they do not speak to the issues of trust and comfort with the machines. People are not aggregates; we all experience the world as individuals. So, declaring that something will be good for the population, on average, isn’t entirely persuasive. What will be needed is the storytelling that Danny Hillis, the artificial intelligence expert, describes as the machines explaining themselves, giving a simplified account of how they work. What is also needed is time—a threshold of accumulated experience of living with the decision-making machines, in the house or on the road, to reach a level of comfort”

⁴³ Kahneman, D., Rosenfield, A. M., Gandhi, L., & Blaser, T. (2016). Noise. *Harvard Bus Rev*, 38-46.

la creciente utilización de algoritmos en el trading en las distintas bolsas de valores, donde ya han superado más del 70% de las transacciones que se realizan diariamente (McGowan M. J. 2019). El surgimiento de sistemas automatizados basados en datos para informar toma de decisiones y regular el comportamiento conocido como “*Algocracy*” (Danaher, J. 2016). Y por último, el uso de algoritmos por parte de Netflix, para crear recomendaciones de series y películas, que logran que el 75% de la actividad de los usuarios se base en ellas⁴⁴. No todos los cambios que genera la tecnología han sido positivos. El crecimiento en la utilización de la tecnología y de la automatización en la sociedad moderna, ya sea en las empresas, los gobiernos, o para entretenimiento conciben nuevas incógnitas en la relación hombre-tecnología. Por un lado, la necesidad de asegurarnos que se han generado beneficios a causa de esta revolución tecnológica y al mismo tiempo, si esta ¿ha funcionado cómo se esperaba? ¿Si se ha adoptado en general y si ha creado nuevos problemas?

III. ¿La Tecnología Funciona Como se Esperaba?

Independientemente de los méritos de cualquier tecnología de apoyo en particular, está claro, a nuestro entender, que ella no simplemente reemplaza o apoya a la actividad humana, sino que también la transforma.

Heidegger M., quien fue uno de los filósofos más influyentes del siglo XX, es tal vez el filósofo mayormente identificado con los aspectos relacionados a la tecnología. Para Heidegger, la tecnología es la clave para entender nuestro tiempo actual, su texto "*The Question Concerning Technology*" (1954)⁴⁵, ha sido sumamente influyente en la filosofía de la tecnología. El análisis de Heidegger M., se basa en que la tecnología no es solo una herramienta para comprender lo que nos rodea, sino que es un elemento que se desarrolla independientemente a los deseos humanos y esto la transforma en un peligro. La tecnología

⁴⁴ http://www.wired.com/2013/08/qq_netflix-algorithm/

⁴⁵ Heidegger, M. (1954). The question concerning technology. *Technology and values: Essential readings*, 99-113.

puede acaparar todas las formas de ver nuestro entorno, monopolizando los medios a través de los cuales observamos e interpretamos el mundo⁴⁶.

Tenemos una visión más positiva respecto de la tecnología e incluso siendo pesimista no creemos que su avance pueda evitarse.

Filósofos más contemporáneos, como Don Ihde y Bruno Latour (1992), no encuentran viable esa disociación entre el objeto material y el individuo o sujeto. La unión de hombre y tecnología no se puede separar de forma artificial, pero tampoco se pueden sumar los componentes, su fusión genera un nuevo ente y no entes independientes que interactúan. Latour, utiliza el ejemplo de las armas de fuego: cuando se produce un atentado en una escuela de Estados Unidos, los activistas por el control de armas argumentan que esto no sucedería de no existir el arma, el objeto material. Los defensores de la libertad de portación de armas, argumentan que no es el arma quien ha cometido el atentado sino el sujeto que la utilizo. Nadie puede responsabilizar al arma por actuar sola y también se entiende que quien dispara no podría generar tanto daño de no contar con un arma de fuego. Latour argumenta que la tecnología no es neutral, es decir que, el objeto es un mediador que contribuye a alcanzar un fin. No podría haber atentado sin el sujeto, pero tampoco podría realizarse sin las capacidades mecánicas que tiene un arma de fuego. Un cuchillo, por ejemplo, no podría concretar el mismo fin, o por lo menos, no con ese nivel de eficiencia. De la fusión del individuo con el cuchillo surgiría un ente, una fusión completamente distinta a la fusión del sujeto con el arma de fuego.

Esta mediación entre el fin y el sujeto, posibilitada por la tecnología, se conoce como *mediación técnica*. Esta mediación no es neutral, puede ocurrir, que el objeto en sí mismo produce el deseo de llevar a cabo una acción, que antes de la existencia del objeto era imposible e impensable.

Existe un tercer componente o actor entre la unión de tecnología y hombre, y es quién diseña o crea la tecnología. El diseñador, cuando crea una nueva tecnología, tiene en mente un

⁴⁶ <https://www.futurelearn.com/courses/philosophy-of-technology>

objetivo para la utilización que se dará a su creación, un prototipo de usuario que lo utilizará, y una forma de utilización de esta. La forma en que el diseñador imagina o prescribe al usuario se conoce como *script*. El *script* o guion, es la materialización de un programa imaginario en una acción concreta. Los actores, como en una obra de teatro, deberían seguir el guion para que la acción ocurra como la imaginó el director. Sin embargo, los actores cuando utilizan la tecnología pueden salirse de él y crear una nueva acción no pensada ni anticipada por sus creadores. De esta forma, si retomamos el ejemplo de las armas quien las creó, pudo haber imaginado su utilización como defensa ante un enemigo o para cazar una presa, pero la fusión de la nueva tecnología con cada sujeto crea un nuevo ente, que puede tener un resultado único e inesperado.

La arquitectura con la que se diseñan los objetos y la tecnología, puede tener incluida una prescripción *built-in*, que condiciona el accionar de los individuos que la utilizan. Por ejemplo, una puerta giratoria nos obliga a ingresar de a uno:

“El concepto de guión, desarrollado hace una década por Madeleine Akrich (1992) y Bruno Latour (1992), desafía esta visión estrictamente funcional de la tecnología. Akrich y Latour introdujeron este concepto para describir los múltiples roles que juegan los artefactos tecnológicos en sus contextos de uso. Como una obra de teatro o una película, sostienen, las tecnologías poseen un "guión" en el sentido de que pueden prescribir las acciones de los actores involucrados. Las tecnologías pueden evocar ciertos tipos de comportamiento: un badén puede invitar a los conductores a conducir despacio, debido a su capacidad para dañar los amortiguadores; un automóvil puede exigirle a un conductor que use el cinturón de seguridad al negarse a arrancar si el cinturón no se usa; una taza de café de plástico tiene el texto "tírame después de usarla", mientras que una taza de porcelana "pide" que la limpien y la vuelvan a usar. Los artefactos tecnológicos pueden influir en el

comportamiento humano, y esta influencia puede entenderse en términos de guiones.”⁴⁷

Comprender las características de esta relación hombre – tecnología es vital para el diseño exitoso de nuevos sistemas. La implementación de tecnología inteligente que comenzó en dominios complejos como la aviación, la medicina y la energía nuclear ahora evoluciona en dominios más cotidianos y simples. Esta democratización de la ayuda tecnológica para la toma de decisiones no es un simple agregado, sino que cambia, transforma procesos y resultados.

Los ejemplos en la economía del comportamiento son muchos, ¿Que elegimos por defecto en el diseño de un formulario para donación de órganos?⁴⁸ ¿En qué lugar de la pantalla colocamos un banner?⁴⁹ o como veremos más adelante ¿En qué posición aparece un resultado de Google?

Si suponemos que los agentes económicos delegarán sus decisiones a herramientas tecnológicas, debemos ver cómo este proceso influye en la economía. Para eso debemos conocer la tasa de adopción de la tecnología, qué variables influyen en ella, si existen nuevos inconvenientes de funcionalidad una vez adoptada la tecnología y porque razones se deja de utilizarla.

i. Nuevos problemas que surgen por el uso de tecnología.

Cuando se incorporan sistemas de automatización, las investigaciones han demostrado que estas no simplemente reemplazan el trabajo humano, sino que lo modifica y en muchas

⁴⁷ Verbeek, P. P. (2006). Materializing morality: Design ethics and technological mediation. *Science, Technology, & Human Values*, 31(3), 361-380.

“The script concept, as developed about a decade ago by Madeleine Akrich (1992) and Bruno Latour (1992), challenges this strictly functional vision of technology. Akrich and Latour introduced this concept in order to describe the manifold roles technological artifacts play in their use contexts. Like a theater play or a movie, they hold, technologies possess a ‘script’ in the sense that they can prescribe the actions of the actors involved. Technologies are able to evoke certain kinds of behavior: a speed bump can invite drivers to drive slowly, because of its ability to damage the shock absorbers; a car can demand from a driver that he or she wear the safety belt by refusing to start if the belt is not used; a plastic coffee cup has the script ‘throw me away after use,’ whereas a porcelain cup ‘asks’ to be cleaned and used again. Technological artifacts can influence human behavior, and this influence can be understood in terms of scripts.”

⁴⁸ Johnson, E. J., & Goldstein, D. (2003). Do defaults save lives?.

⁴⁹ Benartzi, S. (2017). *The smarter screen: Surprising ways to influence and improve online behavior*. Penguin.

ocasiones, no de la forma y no con la intención que los diseñadores de los procesos habían proyectado. Además, son comunes los casos en que se mal utiliza o directamente no se utiliza la automatización⁵⁰.

La tecnología genera soluciones a problemas existentes, pero a su vez crea nuevos problemas. Los errores son uno de estos nuevos problemas y pueden causar grandes perjuicios. La pérdida de 136 billones de dólares en unos pocos minutos ocasionada por el *trading algorítmico* plasma este peligro⁵¹. Peña Marí R. menciona otros ejemplos inquietantes de tragedias producidas por fallas de algoritmos. En el año 1996, el cohete europeo Ariane V, se autodestruyó a pocos segundos de su primer vuelo debido a un error del software de control. Un “olvidó” del sistema informático del Ministerio de Salud del Reino Unido entre los años 2009 y 2018 dejó sin notificar a miles de mujeres para que se realicen el test final de un programa de prevención del cáncer de mama. Se estima que casi 300 fallecimientos podrían haberse evitado si el sistema no hubiera fallado. Por último, muy recientemente, dos aviones Boeing 737 Max, se han estrellado dejando cientos de víctimas fatales, debido a un diseño incorrecto del sistema de pilotaje automático que fuerza a la aeronave a inclinarse hacia tierra, cuando detecta que el avión sube demasiado vertical.

Para Parasuraman, R., y Manzey, D. H. (2010), otro de estos nuevos problemas es por ejemplo la *complacencia*, que se caracteriza por un bajo nivel de sospecha que se tiene de un sistema automático. Esta se traduce en una reasignación activa de la atención. La *complacencia*, así como los factores de atención y la confianza en la automatización, generan en el usuario una menor detección de las fallas del sistema que deben monitorear, en comparación con el control manual. La *complacencia* sucede cuando el usuario tiene que desempeñar múltiples tareas en paralelo, y las tareas manuales compiten por la atención del usuario, con las tareas automatizadas. El usuario confía que la tarea automática se realizara sin inconvenientes y por eso deja de prestar atención a la tarea automática y se enfoca solo en la parte manual. Si aumentan las fallas producto de la automatización, la *complacencia* ira desapareciendo. Si el problema persiste esa confianza se ira socavando hasta cruzar un umbral en el cual se perderá y se acabará la confianza en el sistema automático.

⁵⁰ Parasuraman, R., & Manzey, D. H. (2010). Complacency and bias in human use of automation: An attentional integration. *Human factors*, 52(3), 381-410.

⁵¹ <https://www.denverpost.com/2013/04/23/fake-report-erasing-136-billion-shows-markets-need-humans/>

El *sesgo de automatización* por su parte difiere de la *complacencia* en el sentido de que aquí no se compete por el recurso escaso de la atención. El sesgo de automatización se da por una confianza ciega en la infalibilidad de la tecnología y entonces genera errores de omisión o comisión cometidos por los usuarios por relajarse cuando utilizan tecnologías de decisión imperfectas.

El exceso de confianza en la herramienta y sus recomendaciones coloca a la tecnología en el primer recurso al que consultamos adquiriendo una funcionalidad heurística y desplazando a otros recursos de decisión a un segundo plano. Así es como se entiende que conductores cometen errores de navegación, o faltas de tránsito, debido a malas indicaciones de los navegadores.

En un experimento en Cornell University⁵² se decidió revisar cómo los usuarios seleccionaban un resumen (*abstract*) basándose en la posición en la que Google devolvía ese resumen. Los resultados mostraron que los usuarios *clikearon* los dos resúmenes mejores posicionados, en comparación con cualquier otro resumen, que en muchos casos eran más relevantes a la búsqueda.

Es innegable la influencia creciente que está adquiriendo en nuestras vidas *Google* en general y su buscador en particular. Para probar cómo estamos afectados por el sesgo de automatización, en una investigación de Pan B. *et al.* (2007), se crearon dos versiones del motor de búsqueda, una en la condición normal, es decir el servidor devolvía los resultados en su orden de clasificación según los devolvería *Google*, y otro, en una condición alterada en la cual, el servidor intercambió las posiciones de los resúmenes. En la condición alterada, el servidor invirtió el orden de los resúmenes en la primera página de resultados para que los resúmenes que estaban posicionados más abajo aparezcan en las primeras posiciones y aquellos que estaban en las últimas aparezcan en las primeras. Se analizaron los clics y el seguimiento visual en todas las páginas y los determinantes respecto sobre que focalizo el usuario y los resúmenes donde hizo clic. Tanto el resultado de la selección de los resúmenes,

⁵² Pan, B., Hembrooke, H., Joachims, T., Lorigo, L., Gay, G., & Granka, L. (2007). In google we trust: Users' decisions on rank, position, and relevance. *Journal of computer-mediated communication*, 12(3), 801-823.

así como los datos obtenidos del seguimiento visual de los participantes en la condición alterada indicaron un exceso de confianza en el ranking devuelto por *Google*. Esto quedó evidenciado por la constante elección de los dos primeros resúmenes posicionados en ambas condiciones. Los participantes vieron los dos resúmenes mejor clasificados con mayor frecuencia, e hicieron clic en el resumen posicionado número uno la mayor parte del tiempo. La conclusión es que nuestro nivel de confianza en *Google* es tan alto que no distinguimos cuando el algoritmo fue alterado y seguimos seleccionando los resúmenes en las primeras posiciones incluso cuando los resúmenes eran menos relevantes para la búsqueda.

Los problemas de exceso de confianza, complacencia y sesgo de automatización se pueden ver como uso indebido de la automatización y recomendación, es decir, como una consecuencia del comportamiento relacionado con una dependencia inadecuada a la tecnología. Esto puede ser más grave aún si en lugar de complacencia, hablaríamos de condescendencia o deferencia donde el usuario adopta los deseos de terceros.

A diferencia del mal uso, la tecnología puede también tener desventajas o falencias intencionales. Debemos tener en cuenta que quien desarrolla la tecnología, tiene sus propios intereses, sus prejuicios y sesgos. Entonces la simple pregunta de si la tecnología nos está ayudando a mejorar en nuestras decisiones se suscribe a quien decide que es lo correcto o mejor.

La mayoría de los sistemas de recomendaciones y automatización, cualesquiera sean, han sido desarrollados por empresas privadas, con intereses económicos. Un ejemplo de este tipo de accionar lo podemos hallar con la empresa American Airlines cuando adquirió el servicio de *booking* SABRE y manipuló el algoritmo para que los operadores escogieran los vuelos de American por sobre otros, que podrían haber sido más beneficios para el cliente⁵³.

También, aunque más lentamente, los gobiernos están usando la tecnología para mejorar sus propios objetivos. Este es el caso del *Behavioural Insights Team*, también conocido como la

⁵³ Sandvig, C., Hamilton, K., Karahalios, K., & Langbort, C. (2014). Auditing algorithms: Research methods for detecting discrimination on Internet platforms. *Data and discrimination: converting critical concerns into productive inquiry*, 22.

Unidad de Nudge de 10 Downing Street. Establecido en el año 2010, se compone por un pequeño grupo de economistas del comportamiento que intentan aplicar conocimientos académicos a la política pública británica, con el objetivo final de alentar a las personas a tomar mejores decisiones por sí mismas, y en algunos casos con la ayuda de herramientas tecnológicas. Toda regulación tiene implícitamente un objetivo para direccionar decisiones y comportamientos así sean multas, subsidios, cárcel, deportación etc. El *Behavioral Insights Team* utiliza los *Nudges* y la economía conductual para intentar direccionar las decisiones de las personas.

En el marco del rol gubernamental en cuanto a direccionar decisiones, se abre un debate filosófico. ¿Debe el gobierno decidir por las personas qué es lo mejor para ellos? Thaler R. H. y Sunstein C. R. (2008)⁵⁴ incorporan el concepto de *Paternalismo Libertario* para mostrar que, si sabemos que podemos influenciar en las decisiones de las personas, entonces nuestras intenciones, es decir las de aquellos que desarrollan los *Nudges*, son de suma importancia.

Utilizando el ejemplo de una cafetería, Thaler y Sunstein describen los distintos tipos de objetivos que se pueden buscar:

1. Que los clientes coman sano
2. Que los clientes ahorren dinero
3. Maximizar las ganancias de la cafetería
4. Una mezcla de objetivos
5. No tener ningún objetivo

El conflicto de intereses es intrínseco y en este aspecto el *paternalismo libertario* reside en la afirmación de que es legítimo que el diseño de la arquitectura de decisión intente influir en el comportamiento de las personas para que “sus vidas sean más largas, sanas y mejores”. De esta forma, se defienden los esfuerzos por parte de las instituciones privadas y del gobierno, para orientar las decisiones de las personas en direcciones que mejorarán sus vidas

⁵⁴ Leonard, T. C. (2008). Richard H. Thaler, Cass R. Sunstein, *Nudge: Improving decisions about health, wealth, and happiness*.

según ellos mismos lo consideran siempre y cuando el objetivo sea transparente para los involucrados.

Sin embargo, no todos concuerdan en que el *paternalismo libertario* es la mejor opción⁵⁵. Incluso bajo la premisa de que se cuenta con las mejores intenciones, si el dueño de la cafetería ayuda a combatir la obesidad de sus clientes, puede que estos coman menos y entonces deba subir los precios ¿Qué es mejor entonces?

Una serie de autores⁵⁶ y trabajos, aseguran que los algoritmos que hoy ya están decidiendo por nosotros, son opacos, no regulados y no están abiertos a cambios. En muchos casos son propensos a acentuar prejuicios ya instalados en la sociedad, y en otros, son el factor disparador de profecías autocumplidas.

El *sesgo algorítmico* se produce cuando los prejuicios y sesgos de los programadores o usuarios se trasladan al algoritmo. Casos resonantes como la aparición de monos o gorilas como resultado de las búsquedas en *Google* para Michelle Obama, o personas Afroamericanas, generaron una gran controversia⁵⁷. Estos casos no indican que *Google* como empresa sea racista, sino que el racismo consciente o inconsciente de usuarios y programadores se traslada a la función del algoritmo.

Teniendo en cuenta lo expuesto sobre las debilidades del apoyo tecnológico, la calificación de la mejora o no de las decisiones con herramientas como agentes de recomendación, o sistemas automáticos puede transformarse en una discusión filosófica.

En lo que respecta a nuestra capacidad, podemos afirmar que las personas somos malos tomadores de decisiones. Es decir, los algoritmos pueden estar sesgados, cometer errores o incluso tener intereses ocultos. Pero lo que nos debería interesar es la comparación con los sistemas que siguen basándose solo en personas. En todos los estudios importantes la mejora, comparativamente respecto al desempeño humano, siempre ha sido favorable a la tecnología.

⁵⁵ Mitchell, G. (2004). Libertarian paternalism is an oxymoron. *Nw. UL Rev.*, 99, 1245.

⁵⁶ O'Neil, C. (2017). *Weapons of math destruction: How big data increases inequality and threatens democracy*. Broadway Books.

Eubanks, V. (2018). *Automating inequality: How high-tech tools profile, police, and punish the poor*. St. Martin's Press.

⁵⁷ <http://edition.cnn.com/2009/TECH/11/25/google.michelle.obama.controversy-2/>
<https://www.usatoday.com/story/tech/2015/07/01/google-apologizes-after-photos-identify-black-people-as-gorillas/29567465/>

Desde el punto de vista práctico si una decisión mejora los resultados en algunos aspectos y no empeora en ninguno, entonces no debería existir incentivo para tomar esa decisión.

En términos comparativos, es clara la superioridad de la tecnología sobre la decisión humana, lo que no nos exonera de buscar formas para deshacernos de los sesgos, errores y resultados no éticos en los algoritmos de toma de decisiones.

El campo de la ética y la moral en el diseño de algoritmos está en auge, y es un eje central de las desarrolladoras de tecnología, sobre todo por la poca tolerancia a los errores y decisiones amorales producto de algún algoritmo. Esto es, en comparación con la tolerancia a los errores y decisiones amorales de las personas.

La tecnología proporciona la vanguardia para el avance científico, y su incorporación a nuestra vida cotidiana, ha sido desarrollada por mentes mejores que aquella con la que venimos equipados.

Según Meserve, L. A. (1998)⁵⁸, existen al menos dos desventajas en la adopción creciente de herramientas tecnológicas y el consiguiente crecimiento en la confianza que nos genera la tecnología. En primer lugar, dejamos de enseñar y de aprender nuevos conocimientos, un ejemplo de este fenómeno se denomina el *efecto Google*, por el cual tendemos a olvidar conocimientos ya que sabemos que podemos encontrarlos rápidamente en el buscador. La delegación de tareas y conocimiento en un tercero, como puede ser un algoritmo, conlleva a la pérdida de nuestras propias habilidades en ese dominio y a la transferencia de ese conocimiento a las futuras generaciones, ya que se ha convertido en innecesaria. En segundo lugar, la expectativa que tenemos de la tecnología, y consecuentemente, del mundo que nos rodea, es que podemos conseguir todo más rápido, más grande, mejor y obteniendo un beneficio económico.

ii. Adopción de las recomendaciones

Si los algoritmos son mejores que las personas en muchas tareas, entonces la gente debería elegir los algoritmos por sobre las personas para dichas tareas, sin embargo, esto no ocurre en todos los casos.

⁵⁸ Meserve, L. A. (1998). The problem with relying on technology.

En la investigación de Dietvorst B. J., Simmons J. P. y Massey C. (2015)⁵⁹, se demostró que los algoritmos basados en modelos matemáticos predicen con mayor precisión el futuro que los pronosticadores humanos, ahora bien, cuando los decisores debían elegir entre usar un pronosticador humano, o un algoritmo estadístico, a menudo elegían el pronosticador humano. Los investigadores denominaron a este fenómeno *algorithm aversion*. Las personas se oponen a los algorítmicos después de verlos fallar, incluso cuando los ven superando a los humanos. Esto se debe a que las personas pierden más rápidamente la confianza en los algoritmos que en los humanos luego de verlos cometer el mismo error.

En una amplia variedad de sectores que generan y trabajan con pronósticos, los expertos siguen siendo reticentes a usar algoritmos, a menudo optando por utilizar pronósticos de inferior calidad generados por un humano, en lugar de pronósticos superiores pero generados por un algoritmo.

Las variables que pueden afectar la probabilidad de que los pronosticadores utilicen un algoritmo son: su complejidad, el grado de transparencia, el grado de involucramiento en su construcción y la experiencia en el uso del algoritmo, entre otros.

De todas formas, la aversión al algoritmo parece ser consistente en cuanto a nuestra intolerancia al error. En todos los casos analizados, aun viendo que los pronosticadores humanos cometían el doble de errores, la confianza en los algoritmos decrecía en mayor medida luego de que se cometía un error, en comparación con como decrecía la confianza con los errores humanos.

En dichos experimentos, esta aversión le costó a los participantes dinero y es probable que la no utilización de algoritmos, también le cueste a la sociedad en general, por esta razón, encontrar las formas de mitigar esa aversión puede significar una ganancia para la sociedad. En una investigación subsiguiente⁶⁰ los autores hallaron que las personas elegirán usar los pronósticos de un algoritmo imperfecto con mayor frecuencia cuando pueden modificarlos, incluso si son capaces de realizar pequeños ajustes en esos pronósticos.

⁵⁹ Dietvorst, B. J., Simmons, J. P., & Massey, C. (2015). Algorithm aversion: People erroneously avoid algorithms after seeing them err. *Journal of Experimental Psychology: General*, 144(1), 114.

⁶⁰ Dietvorst, B. J., Simmons, J. P., & Massey, C. (2016). Overcoming algorithm aversion: People will use imperfect algorithms if they can (even slightly) modify them. *Management Science*, 64(3), 1155-1170.

Los pronosticadores que incluyen la capacidad de ajustar los pronósticos de un algoritmo producen que los usuarios sientan que se desempeñan mejor que aquellos que no lo hacen y esto conduce a un mejor rendimiento a largo plazo.

En comparación con los participantes que no pudieron modificar los pronósticos del modelo, los participantes que pudieron modificar los pronósticos del modelo manifestaban mayor confianza en los pronósticos del modelo en relación con los suyos propios. Los participantes que pudieron modificar los pronósticos de un algoritmo imperfecto reportaron una mayor satisfacción con su proceso de pronóstico, y le atribuyeron un mejor desempeño, en comparación con los participantes que no pudieron modificar los pronósticos del algoritmo. Otros elementos que pueden generar una mayor o menor adopción de los algoritmos son la familiaridad con su uso, la confianza cognitiva y la confianza emocional en un RA, ya sea como una ayuda para la decisión o como un agente delegado⁶¹.

La superioridad para pronosticar no se circunscribe a campos racionales y meramente lógicos o matemáticos. Se suele argumentar que ningún algoritmo podrá competir con los humanos en campos subjetivos como el arte y el humor. Pero incluso en estos dominios, como puede ser predecir qué bromas⁶² van a gustarle a un participante, los algoritmos mediante un breve entrenamiento han tenido mejor rendimiento que los humanos y no cualquier humano, sino que personas cercanas como familiares y amigos de los participantes que podían conocer bien sus gustos y preferencias.

Para Yeomans M. *et al.* (2017), en un dominio subjetivo, donde los humanos deberían tener una gran ventaja: como una composición musical, pintar un cuadro o predecir qué bromas les gustarán a las personas, han tenido un desempeño inferior a los algoritmos, y a pesar de esto las predicciones realizadas por humanos fueron mayormente adoptadas por los participantes.

En dicho estudio se les solicitó a los participantes que calificaran cuán simple les resultaba comprender el proceso de recomendación, al expresar su acuerdo con dos afirmaciones: "Pude entender por qué el recomendador pensó que me gustarían esas bromas" y "Es difícil

⁶¹ Komiak, S. Y., & Benbasat, I. (2006). The effects of personalization and familiarity on trust and adoption of recommendation agents. *MIS quarterly*, 941-960.

⁶² Yeomans, M., Shah, A., Mullainathan, S., & Kleinberg, J. (2017). Making sense of recommendations. *Journal of Behavioral Decision Making*.

para mí explicar cómo el recomendador escogió esos chistes". Los participantes calificaron a los recomendadores humanos como más sencillos de entender que los recomendadores basados en algoritmos.

Existe una relación significativa entre estas creencias y la tendencia de los participantes en adoptar o rechazar las recomendaciones.

En general, las personas suelen juzgar un sistema de recomendación no solo por lo que recomienda, sino por cómo lo recomienda y qué capacidad tiene el usuario de comprender cuál es el proceso para determinar una recomendación.

Los investigadores utilizan la *Theory of Reasoned Action* para clasificar tres tipos comunes de confianza: creencia de confianza, intención de confianza y disposición a confiar⁶³.

De acuerdo con *TRA*, la actitud de una persona a comportarse de cierta forma es resultado de la evaluación emocional de las consecuencias de su accionar o comportamiento que son frutos de sus creencias.

Komiak S. Y. y Benbasat I. (2006) exponen que la dotación inicial de confianza cuando se utiliza por primera vez el *RA* es completamente distinta a la confianza que se genera en la segunda iteración, y luego se estabiliza. Esto por supuesto ocurre, siempre y cuando, el *RA* tenga un buen desempeño.

La confianza cognitiva en la competencia y la confianza cognitiva en la integridad del *RA*, impactan de diferente manera en las intenciones de adoptar las recomendaciones.

Si bien ambas creencias de confianza cognitiva afectan las intenciones de adoptar a través de la confianza emocional, la creencia en la integridad es más importante que la creencia de competencia para determinar la intención de adoptar como herramienta de ayuda para la decisión, mientras que la creencia de competencia es más influyente en la intención de adoptar, como agente delegado.

Estos resultados parecen indicar la existencia de procesos emocionales que producen directamente la confianza emocional, que se suman a los procesos cognitivos que producen confianza cognitiva que luego a su vez contribuyen a la confianza emocional.

⁶³ Komiak, S. Y., & Benbasat, I. (2006). The effects of personalization and familiarity on trust and adoption of recommendation agents. *MIS quarterly*, 941-960.

En una serie de experimentos, Logg J. M.⁶⁴ muestra otro tipo de condicionantes para la adopción de los algoritmos. La confianza excesiva o el nivel de confianza en el propio conocimiento atenúan la dependencia o utilización de los algoritmos. Para las decisiones objetivas, los participantes preferían el asesoramiento algorítmico y para las decisiones subjetivas, los participantes preferían el asesoramiento de las personas.

⁶⁴ Logg, J. M. (2017). Theory of Machine: When do people rely on algorithms?

IV. Evidencia experimental

La motivación de las preguntas que expondremos a continuación es analizar la relación de los usuarios con la tecnología y cómo el uso de esta modela y/o altera las decisiones de los individuos.

El agente económico, *Homo Economicus*, con sus aciertos y falencias se ve desafiado por la irrupción de la tecnología de la información y la democratización de las computadoras y *Smartphones*. Creemos que los individuos tenderán cada vez más a basar sus decisiones en herramientas tecnológicas. Por esta razón, comprender cómo se relacionan los individuos / usuarios con las *IT* en el proceso de decisión, es de suma importancia para entender las decisiones en el futuro próximo.

1. ¿La exposición a las herramientas tecnológicas modifican la forma en que decidimos?
2. Las recomendaciones emitidas por estas herramientas, ¿son valoradas por los usuarios?
3. ¿Existe una curva de aprendizaje positiva tanto en la utilización como en la adopción de las recomendaciones?
4. ¿Mejora el desempeño o el rendimiento económico, ante la exposición y la utilización de herramientas tecnológicas?
5. ¿Si las decisiones se toman en un marco de riesgo o incertidumbre, se modifican las respuestas anteriores?

Los experimentos que hemos diseñados tienen el objetivo de medir la influencia del apoyo tecnológico en la toma de decisión. Específicamente si los resultados adversos producto de la naturaleza de los escenarios de riesgo e incertidumbre derivan en un abandono de las recomendaciones, así como sucede con las fallas de los algoritmos.

i. Sección I – Experimento de programación de viaje descripción y objetivos.

a. Introducción

En el primer experimento pedimos programar un viaje de 7 estaciones de tal manera que su costo sea el menor posible.

Los experimentos I y III están inspirados en el libro de Brian Christian y Tom Griffiths (2016)⁶⁹ sobre la utilización de algoritmos en la vida cotidiana.

El experimento se realizó en condiciones de certidumbre, es decir que la recomendación del algoritmo era exacta y no tenía fallas. Por definición los participantes podían, en el mejor de los casos, igualar el nivel de ejecución del algoritmo, pero nunca superarlo. Pretendíamos analizar la curva de adopción de las recomendaciones del algoritmo a medida que los participantes se iban familiarizando con él y percibiendo su utilidad, así como su predisposición a pagar por consultarlo. Siguiendo los atributos citados en *TAM*, *UTAUT* y *RA*, supusimos que las variables significativas para predecir la predisposición a pagar serían la experiencia con el algoritmo, es decir la cantidad de iteraciones con el mismo, el ahorro logrado al consultar el algoritmo, la facilidad de uso y la capacidad de cada participante de programar la ruta más económica por sus propios medios. Además, queríamos observar si existían diferencias en el comportamiento de los participantes según las variables demográficas de género y edad.

Pudimos observar un aumento en la predisposición a pagar (*willingness to pay*) a medida que los participantes se familiarizaban con el algoritmo. Este crecimiento estaba signado por un fuerte aumento luego de la primera iteración y luego un aumento moderado en las siguientes iteraciones. El rápido crecimiento de la confianza en el algoritmo ya ha sido observado por varios autores Komiak S. Y., Benbasat I. (2006).

No encontramos relación significativa entre el ahorro que generaba el algoritmo y la predisposición a pagar. Sin embargo, encontramos relación significativa entre lo pagado en la iteración anterior, que resultaba del sorteo de un dado, y la predisposición a pagar. Esta relación podría ser explicada por el efecto anclaje o precio de referencia desarrollados por la *Teoría Prospectiva*.

⁶⁹ Brian Christian and Tom Griffiths, *Algorithms to Live By: The Computer Science of Human Decisions* by ISBN-13: 978-1627790369

Por último, encontramos que las mujeres estuvieron dispuestas a pagar más en promedio que los hombres. La mayor confianza en el algoritmo por parte de las mujeres se observó también en los siguientes experimentos.

b. Método del experimento

En este primer experimento, la intuición puede hacer creer a los participantes que es una tarea sencilla pero la realidad es que existen 720 combinaciones posibles, algo difícil de realizar en pocos minutos y sin errores. Ante la respuesta del algoritmo, será sencillo comprobar o percibir si el usuario ahorra dinero cuando lo utiliza. El algoritmo simplemente genera las 720 combinaciones en segundos (algo imposible para una persona) y muestra la combinación más económica.

En el experimento, el participante debe programar 6 viajes para medir si existen cambios en la tasa de adopción de las recomendaciones del algoritmo a medida que se familiariza con su uso. Para poder medir cómo va cambiando la utilidad percibida, utilizamos como indicador el precio que los participantes estuvieron dispuestos a pagar por su uso.

Suponemos que la mejora en el desempeño del participante, gracias al algoritmo, irá aumentando su confianza y la utilidad percibida.

El experimento fue enviado a distintas personas a través del siguiente enlace:

https://script.google.com/macros/s/AKfycbx96BQyURXfLkgV_NLZsTuWZw9M77pgbFkwFrodnbSH8L2ooeU/exec y también fue publicado en la plataforma de ingreso de la Universidad Blas Pascal de Córdoba.

Para ver en detalle el ejercicio se debe ingresar al link y participar o bien consultar el protocolo de los experimentos en el [Anexo III](#).

En total completaron el experimento 59 personas (30 mujeres y 29 hombres, con una edad promedio de 39 años).

En el experimento los participantes comienzan con un balance de \$1200 y ellos deben programar las rutas más económicas. Luego tienen la posibilidad de consultar el algoritmo, pero para ello deben ofrecer una suma entre \$0 y \$6 (enteros, sin centavos).

Para aproximarnos al valor real que los participantes le asignan al algoritmo, el precio final se fija aleatoriamente por sorteo (utilizando un dado virtual). Si lo que ofrecieron era igual o

mayor a lo sorteado accedieron al algoritmo, pero pagando solo el precio sorteado. Esta adaptación del modelo de *Becker–DeGroot–Marschak method (BDM)*⁷⁰ nos permite saber con mayor precisión el valor real que se le asigna al algoritmo.

Esto se logra ya que, en este método, cada postor maximiza su utilidad esperada ofreciendo el verdadero valor que le asigna al producto o servicio. El método elimina el incentivo de los participantes a sobrevalorar o infravalorar la oferta. Sin embargo, debemos considerar que no necesariamente los participantes ejecutaron la estrategia dominante como veremos más adelante.

c. Resultados

En este primer experimento pudimos observar un crecimiento promedio en la predisposición a pagar sumas positivas para consultar el algoritmo. En el 94% de las iteraciones los participantes ofrecieron pagar sumas mayores a cero por el algoritmo y las sumas fueron subiendo en cada iteración con mayor potencia entre la iteración 1 y la 2. Las mujeres ofrecieron en promedio más dinero por consultar el algoritmo.

De las 354 decisiones (59 participantes por 6 iteraciones cada uno) se activó el algoritmo en 262 ocasiones (74%) es decir que los participantes estuvieron dispuestos a pagar más o igual a lo que salió sorteado en el dado. Por otra parte, en 332 ocasiones (94%) estuvieron dispuestos a pagar algo mayor que cero.

Solo 10 participantes en 14 ocasiones (4,2%) lograron generar la ruta más económica por sus propios medios antes de consultar el algoritmo.

⁷⁰Becker, G. M., DeGroot, M. H., & Marschak, J. (1964). Measuring utility by a single-response sequential method. *Behavioral science*, 9(3), 226-232.

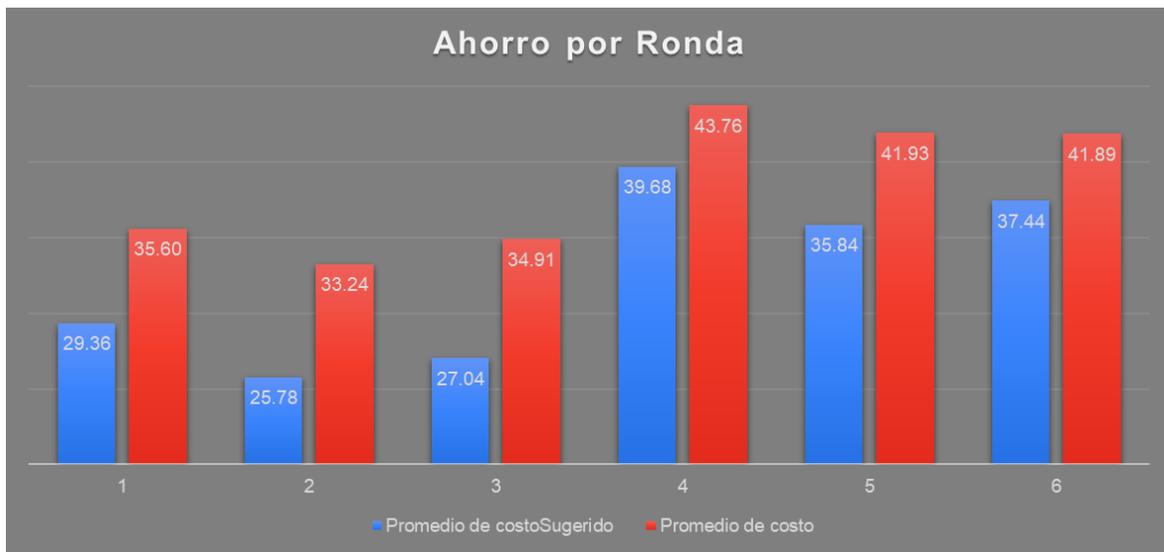
Tabla 1 - Estadística descriptiva de las variables⁷¹

Variable	Obs	Media	Desv. Est.	Min	Max	Descripción
Costo	341	38.60	6.42	25.78	54.5	Costo del viaje programado por el participante
costoSugerido	262	32.82	5.43	25.78	39.68	Recomendación del algoritmo, es el costo mínimo por el que se puede programar el viaje
EstAhorro	354	8.00	9.28	0	47	Estimación del participante del ahorro que puede generar el algoritmo (utilidad percibida por el participante)
pagoCliente	354	3.95	1.88	0	6	Pago ofrecido por el participante. Valores \$0 a \$6
Edad	354	33.67	18.21	0	73	Edad del participante
Balance	354	984.02	9.56	947.94	1011.02	Resultado final del ejercicio \$1.200, menos los costos de viajes y consultas

El primer punto, es analizar si el algoritmo agrega valor en comparación con la programación de la ruta realizada por el participante. El costo promedio del viaje programado por los participantes fue de \$38.60, mientras que el costo promedio del viaje programado por el algoritmo fue de \$32,82. En todas las iteraciones los promedios de los viajes programados por los participantes fueron más costosos que los programados por el algoritmo.

⁷¹ El resto de las variables recolectadas se adjuntan en el [Anexo I](#)

Gráfico 1 – Promedio costo programado por algoritmo y por los participantes



Podemos observar que en promedio el algoritmo logro ahorrar casi \$6 por ronda y, además, logró generar ahorro en todas y cada una las rondas. Por esa razón los participantes, en caso de percibirlo, deberían haber estado dispuestos a ofrecer en promedio \$6.

Esta estrategia les significaría asegurarse la consulta del algoritmo y ahorrar costos, debido a que el pago final se fijaba por medio del sorteo del dado, con lo cual, a pesar de ofrecer 6\$, en promedio hubieran pagado sólo 3,5\$.

Sin embargo, la predisposición a pagar fue menor, el promedio general de oferta fue cercano a los 4\$ (3,95\$) con mayor predisposición a pagar por parte de las mujeres.

Esta tendencia de las mujeres se observó también en los siguientes dos experimentos, donde la autopercepción de las mujeres en su capacidad para decidir fue menor que la de los hombres y esto podría explicar en parte la mayor aceptación de las recomendaciones de los algoritmos.

Las diferencias de género, tanto en las habilidades auto percibidas, como en la brecha de las capacidades y la autopercepción, se ven en distintos campos de la investigación económica. Los hombres tienden a sobreestimar su capacidad, mientras que las mujeres tienden a subestimar su capacidad (Beyer S. 1990)⁷². Los hombres son más propensos a percibir que son mejores en matemáticas que las mujeres con calificaciones matemáticas iguales (Correll

⁷² Beyer, S. (1990). Gender differences in the accuracy of self-evaluations of performance. Journal of personality and social psychology, 59(5), 960.

SJ. 2001)⁷³. Paglin M. y Rufolo A. M. (1990) afirman que esa percepción respecto de las matemáticas podría ser el que genera la propensión de las mujeres a elegir carreras universitarias no relacionadas con las ciencias exactas y en consecuencia explicar en parte la brecha salarial de género entre los graduados universitarios. Koellinger P. *et al.* (2009) encuentran que la menor propensión de las mujeres a iniciar negocios que los hombres, está altamente correlacionada con los niveles más bajos de optimismo y autoconfianza de las mujeres y con mayores niveles de miedo al fracaso. En toma de decisiones como las presentadas en los tres experimentos las respuestas están basadas en algoritmos, matemáticos y exactos, las mujeres pueden haber percibido que era mejor confiar en ellos que decidir por cuenta propia.

Tabla 2 - Diferencia de pago por género

Grupo	Obs	Media	Error Est.	Desv. Est.	[95% Intervalo Conf.]	
Mujeres	180	4.14	0.13	1.75	3.88	4.40
Hombres	174	3.75	0.15	1.99	3.46	4.05
combinado	354	3.95	0.09	1.88	3.75	4.15
dif ⁷⁴		0.38	0.19		-0.006	0.77

La hipótesis nula es que no existen diferencias en el pago de la consulta al algoritmo por género. Realizamos la prueba de comparación de medias para asegurarnos de que la diferencia es significativa. Rechazamos la hipótesis nula de que la diferencia de los promedios es igual a cero comprobando que la diferencia es positiva ($P\text{-value} = 0.0268$).

Podemos observar también que en todas las rondas las mujeres estuvieron dispuestas a pagar más que los hombres excepto en la primera ronda. Esto muestra una mayor cautela al principio y un rápido aprendizaje por parte de las mujeres.

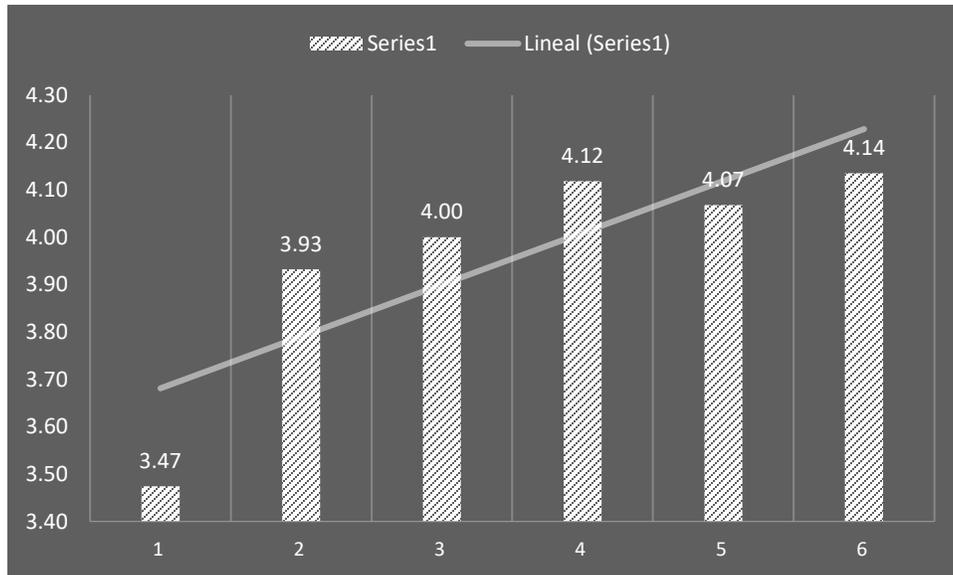
⁷³ LARC, I. Evaluation of gender inequities in Latin American neuroscience community.

⁷⁴ Dif = Media (Mujeres) - Media (Hombres); $t = 1.9366$; degrees of freedom = 352

Tabla 3 – Promedio por género y ronda

Ronda	Promedio Mujeres	Promedio Hombres
1	3.46	3.48
2	4.13	3.72
3	4.2	3.79
4	4.33	3.89
5	4.36	3.75
6	4.36	3.89

Gráfico 2 – Oferta de pago por ronda



Promedio de pago ofrecido por ronda

Se puede observar una tendencia creciente a pagar más a medida que avanza el ejercicio. Se observa una disminución sólo entre la ronda 4 y 5. Esto puede haber ocurrido debido a que en la ronda 4 es donde menos ahorro generó el algoritmo en promedio (4,08\$), en comparación con el ahorro promedio en el resto de las rondas (6,91).

Queremos verificar la hipótesis de que la oferta del participante, es decir su predisposición a pagar por el uso del algoritmo, depende de la experiencia: es decir, del número de iteraciones

expresada en la variable *ronda*, la estimación del posible ahorro que generará el algoritmo expresado en la variable *EstAhorro* y el *sexo* del participante.

La hipótesis nula es que la predisposición a pagar por el uso del algoritmo no crecerá a medida que haya mayor iteración con el mismo.

Lo que intentamos probar es que a medida que el usuario vea el beneficio del uso tenderá a utilizar el algoritmo y a adoptar en mayor medida la recomendación. También la utilidad percibida, creemos, será determinante de la predisposición a pagar por el algoritmo.

La diferencia entre mujeres y hombres pierde significancia cuando en la regresión introducimos estas otras variables independientes.

Tabla 4 – Regresión de la oferta para utilizar el algoritmo

PagoCliente	Coef.	Error Est.	Z	P>z	[95% Intervalo Conf.]	
EstAhorro	0.02	0.01	2.10	0.036	0.001	0.04
Ronda	0.10	0.03	2.75	0.006	0.028	0.17
Cons	3.40	0.24	13.75	0.000	2.922	3.89

Podemos observar que ambas variables son significativas y rechazamos las hipótesis nulas.

Es llamativo que el coeficiente de *EstAhorro* que representa la utilidad percibida, o el posible ahorro percibido, sea tan bajo, debería esperarse un impacto mayor. Sin embargo, esta anomalía puede explicarse, en parte, debido a la gran dispersión de la variable *EstAhorro* (\$0 a \$47) que no puede darse en la variable dependiente, la cual está acotada entre \$0 y \$6⁷⁵. A pesar de que el promedio del ahorro esperado era de \$8, los participantes estuvieron dispuestos a pagar \$4. Esta diferencia entre la predisposición a pagar como resultado de una pregunta abierta, y la oferta real sugerida con la metodología *BDM*, ya fue comprobada en otros experimentos⁷⁶. Una de las posibles explicaciones es que, al preguntar sobre el precio,

⁷⁵ Cuando quitamos de las observaciones las valoraciones extremas la variable pierde significatividad

⁷⁶ Wertenbroch, K., & Skiera, B. (2002). Measuring consumers' willingness to pay at the point of purchase. *Journal of marketing research*, 39(2), 228-241.

Noussair, C., Robin, S., & Ruffieux, B. (2004). Revealing consumers' willingness-to-pay: A comparison of the BDM mechanism and the Vickrey auction. *Journal of economic psychology*, 25(6), 725-741.

estamos enfocando al participante en un atributo particular y esto puede hacerlo más sensible al precio que a otros atributos, como pueden ser la comodidad y el ahorro de tiempo.

Por otro lado, vemos que la variable *Ronda* es significativa, pero queremos asegurarnos de que el cambio es significativo en todas las iteraciones y no solo en el paso entre la ronda 1 y 2, donde se puede observar el mayor aumento en la suma que estuvieron predispuestos a pagar, que luego sigue aumentando en las siguientes rondas, pero en menor medida. Realizamos el test de comparación de medias pareadas y vemos que existe diferencia significativa entre la media de la ronda 1 y 2 (*t-test* $T=2,91 > 1,67$), pero luego las diferencias con las siguientes rondas no son significativas.

Tabla 5 - Regresión de la oferta para utilizar el algoritmo sin primera oferta

PagoCliente	Coef.	Error Est.	z	P>z	[95% Intervalo Conf.]	
EstAhorro	0.02	0.01	1.86	0.063	-0.001	0.048
Ronda	0.03	0.04	0.83	0.406	-0.051	0.127
Cons	3.70	0.28	12.98	0.000	3.144	4.263

Se puede observar también que, al eliminar la primera ronda de la base de datos, pierde significatividad la variable. Es decir, que existe un aprendizaje significativo únicamente entre la ronda 1 y 2 y luego el aumento de la predisposición a pagar no es significativo.

Esto coincide con el trabajo anteriormente citado de Komiak y Benbasat, que muestra que la confianza aumenta rápidamente luego de la primera iteración con el RA y que luego se estabiliza:

“...cada participante respondió una pregunta sobre el nivel de confianza después del primer, segundo y tercer uso del RA para comprar los tres productos, respectivamente. El nivel de confianza informado después de usar el RA por primera vez fue significativamente diferente al informado después de usarlo por segunda vez, mientras que los niveles de confianza después del segundo y tercer uso, respectivamente, no fueron significativamente

diferentes, lo que indica que el nivel de confianza alcanzó un nivel estable después de tres interacciones.”⁷⁷

Estos investigadores analizan los niveles de confianza iniciales que se forman después de que los usuarios tienen una primera experiencia con agentes de recomendación en línea. Si bien reconocen la importancia de la naturaleza evolutiva de la confianza, la importancia de la confianza inicial se basa en dos razones principalmente. En primer lugar, cuando los usuarios no están familiarizados con los agentes de recomendación durante el contacto inicial, sus percepciones de incertidumbre y riesgo sobre el uso de agentes son especialmente elevados, por lo tanto, se necesita una confianza inicial suficiente en los agentes para superar estas percepciones. La dotación de confianza inicial puede crecer o cambiar con el tiempo y con iteraciones repetidas (McKnight D. H. *et al.* 1998, 2002). Es fundamental la confianza inicial por parte de los usuarios para la adopción de la tecnología, así como también lo son, la utilidad percibida y la facilidad de uso percibida.

No encontramos una relación significativa entre el ahorro bruto de las iteraciones anteriores, es decir el costo de la ruta programada por el participante en la iteración anterior menos el costo de la ruta programada por el algoritmo, y la predisposición a pagar. Tampoco fue significativa la relación entre la predisposición a pagar y el ahorro neto, determinado por el ahorro bruto menos lo que se pagó por consultar el algoritmo (como resultado del sorteo del dado), sin embargo, lo pagado en la iteración anterior como resultado del sorteo del dado, tuvo nivel de significancia. En consecuencia, analizamos los datos y pudimos observar esta anomalía: El coeficiente de la variable *dadoant*, entendido como el resultado del sorteo anterior fue positivo y significativo.

⁷⁷Komiak, S. Y., & Benbasat, I. (2006). The effects of personalization and familiarity on trust and adoption of recommendation agents. *MIS quarterly*, 941-960.

“...each participant answered a question about trust level after the first, second, and third use of the RA to shop for the three products, respectively. The trust level reported after using the RA for the first time was significantly different than that reported after using it for the second time, while the trust levels after the second and the third use, respectively, were not significantly different, indicating that the trust level reached a stable level after three interactions.”

Tabla 6 – Regresión con nueva variable independiente

PagoCliente	Coef.	Error Est.	Z	P>z	[95% Intervalo Conf.]	
EstAhorro	0.025	0.012	2.06	0.040	0.001	0.049
Dadoant	0.105	0.044	2.38	0.017	0.018	0.192
Cons	3.591	0.263	13.63	0.000	3.075	4.108

La explicación posible podría ser el sesgo de anclaje que ha sido comprobado en entornos donde no debería existir correlación entre los números proporcionado por los investigadores y las valuaciones por parte de los participantes. El número de teléfono del participante (Russo J. E. y Shoemaker P. J. 1989), los dos últimos dígitos del número de su seguro social (Ariely D., Loewenstein G. y Prelec D., 2003) y especialmente los números aleatorios como resultado de un sorteo de ruleta (Tversky A. y Kahneman D. 1974) influyeron en el juicio de valor de los participantes.

d. Conclusión

Como conclusión del primer experimento, podemos observar un rápido aumento de la confianza entre la ronda 1 y 2, y una mayor predisposición a pagar por parte de las mujeres. La predisposición para pagar también crece en las siguientes iteraciones, pero de manera no significativa y tiene una baja correlación con la estimación del potencial ahorro por usar el algoritmo.

Por último, vemos un ajuste según el resultado del sorteo anterior. Esto puede ocurrir por el sesgo de anclaje o por pensar que el experimento no era realmente aleatorio.

Investigamos también que las variables ahorro, la suma pagada y edad y encontramos que no eran significativas. Las distintas pruebas estadísticas están documentadas en el [Anexo I](#).

ii. Sección II – Experimento de elección de seguro, descripción y objetivos.

a. Introducción

En decisiones que se toman en condiciones de riesgo o incertidumbre, los agentes pueden tomar una buena decisión y obtener un mal resultado. Es importante, entonces, analizar cómo interpretarán y reaccionarán los usuarios de los *Agentes de Recomendación* ante una situación de esta índole, es decir, cuando sean ayudados por un algoritmo para tomar una decisión, pero luego de adoptar dicha recomendación el resultado sea adverso. ¿Dejarán de adoptar las recomendaciones que los algoritmos ofrezcan? ¿Tenderán a responsabilizar al algoritmo?

En el segundo experimento, se pidió a los participantes que decidieran qué plan de seguro preferían contratar, los cuales se diferenciaban entre sí, únicamente en la suma de la franquicia y la prima a pagar. Existe una relación negativa entre ambas, a mayor franquicia menor prima y viceversa. El usuario puede adoptar la recomendación del algoritmo y en caso de enfrentar un escenario adverso a la recomendación, puede percibir que la recomendación no ha sido buena.

En decisiones con resultados inciertos cuyas soluciones están basadas en probabilidades, la decisión puede ser la correcta matemáticamente en el largo plazo, pero una experiencia negativa en el corto plazo puede hacernos desestimar la recomendación. Por ejemplo, estadísticamente no es conveniente comprar un billete de Quini-6, sin embargo, sería difícil persuadir al ganador del último sorteo de que cometió un error.

Un ejemplo de este tipo de decisiones con resultados inciertos es la adquisición de seguros y el nivel de franquicia que se adquiere. En la práctica existe una preferencia marcada de los consumidores por las pólizas de seguro con franquicia baja o sin franquicia. Una serie de experimentos han demostrado que las personas tienden a subestimar el valor de una póliza con franquicia, y que el grado de subestimación aumenta con el tamaño de la franquicia. Al fijar el precio de una póliza con franquicia, primero se considera el precio de una póliza de cobertura total, luego, “anclan” la franquicia y la comparan con la resta del precio de la póliza de cobertura completa y el precio de la cobertura con franquicia. A modo de ejemplo, si comparamos dos coberturas, una con prima de \$10.000 y franquicia de \$20.000, y otra con una prima de \$11.000 y franquicia de \$5.000, el asegurado suele hacer el cálculo de que está abonando \$1.000 extras por un aumento en la cobertura de \$15.000. Sin embargo, no ajustan la cobertura suficientemente para tener en cuenta el hecho de que hay sólo una pequeña

posibilidad de que la franquicia se aplique a sus pagos⁷⁸. Además del efecto anclaje que genera la póliza sin franquicia, distintas investigaciones tratan el papel de las franquicias en las decisiones de seguros. La evidencia empírica sugiere que las personas prefieren franquicias bajas⁷⁹, quizás porque piensan que esto aumenta sus probabilidades de cobrar la póliza viendo en la compra de seguro una inversión y no un gasto. Otros investigadores, han demostrado que, al considerar la compra de pólizas de seguro, las personas no se comportan de manera racional, (Kunreuther H. C. *et al.* 1977) y que se pueden explicar las preferencias por franquicias bajas como resultado de la *aversión al arrepentimiento* (Braun M. y Muermann A. 2004), el efecto de *encuadre* (Johnson *et al.* 1993) y el deseo de eliminar preocupaciones y no los posibles daños, (Kahneman D. y Tversky A. 1979).

En una serie de experimentos⁸⁰, se examinó si la franquicia es efectivamente distinguible por los asegurados y su impacto en la decisión de cobertura, y si su efecto desaparece cuando se presenta la misma situación de decisión sin referencia a franquicias o seguros.

Se presentó una decisión en dos contextos diferentes, apuesta y seguro:

Apuesta

1. Una pérdida segura de \$ 10.
2. Una probabilidad del 1% de perder \$ 1,000.

Seguro

1. Pagar una prima de seguro de \$ 10.
2. Permanecer expuesto a un peligro de perder \$ 1,000 con una probabilidad del 1%.

El 56% de los participantes prefirió la pérdida segura cuando se presentó en el contexto de apuesta frente al 81% en el contexto de seguro.

Es decir que la influencia del contexto o *encuadre* es fuerte en cuestión de seguros, donde la política de baja franquicia se percibió como más atractiva que cuando la misma opción se presentó de una manera puramente matemática sin referencia a seguros y franquicias.

⁷⁸ Shapira, Z., & Venezia, I. (2008). On the preference for full-coverage policies: Why do people buy too much insurance?. *Journal of Economic Psychology*, 29(5), 747-761.

⁷⁹ Pashigian, B. P., L. L. Schkade, and G. H. Menefee, "The Selection of an Optimal Deductible for a Given Insurance Policy," *The Journal of Business*, Vol. 39 (1966).

⁸⁰ Schoemaker, P. J. (1982). The expected utility model: Its variants, purposes, evidence and limitations. *Journal of economic literature*, 529-563.

El formato y los efectos de contexto parecen sintomáticos de la tendencia de las personas a recurrir a estrategias simplificadoras, o a obtener pistas del contexto más amplio del problema. Esta tendencia hace que los asegurados compren más seguros del necesario, incluso cuando unas simples reglas matemáticas, podrían ayudarlos a entender que es un error⁸¹. Si un usuario aceptara el consejo del algoritmo de comprar menos cobertura, entonces al tener una pérdida y tener que abonar más franquicia, podría lamentarse de su decisión y de haber aceptado dicha recomendación.

En el experimento II, quisimos observar y analizar lo que sucede con el índice de adopción de las recomendaciones del algoritmo de seguros cuando el participante tiene una pérdida (en forma aleatoria). Suponemos que existen diferencias en la adopción y rechazo de algoritmos que dan una recomendación, si las condiciones son de certidumbre, riesgo o incertidumbre. El planeamiento del viaje en el experimento I, genera un resultado correcto para todos los casos por su formato de certidumbre, en cambio, la planificación del nivel de franquicia del seguro, en el experimento II, se da en un marco de riesgo que a corto plazo puede tener resultados adversos.

Por otro lado, quisimos evaluar la percepción de los participantes respecto de sus capacidades y la del algoritmo y ver si los resultados aleatorios influyeron en estas percepciones. Diferentes estudios muestran consistentemente que nuestras percepciones, expectativas y juicios están sesgados a favor de nosotros mismos (Babcock L. 1995; Loewenstein G. 1992)⁸². Este sesgo, denominado *Sesgo de Autoservicio*, es aquel por el cual solemos atribuirnos los éxitos y depositar en terceros nuestros fracasos o a la mala suerte, Zuckerman (1979). Por ejemplo, en el estudio de Ross M. y Sicoly F. (1979)⁸³, los investigadores solicitaron a las parejas casadas que estimaran el porcentaje de tareas domésticas que realizaban en relación a su cónyuge. Después de que cada uno de ellos realizó una autoevaluación, se compararon con las evaluaciones realizadas por sus parejas y el resultado obtenido fue una diferencia del

⁸¹ Para ver un ejemplo simple y real del sobrepago que pagan los asegurados por cubrir riesgos pequeños consultar [Anexo II](#).

⁸² Babcock L, Loewenstein G 1997. Explaining Bargaining Impasse: The Role of Self-Serving Biases, *Journal of Economic Perspectives*, 11, 109-126. Babcock L, Loewenstein G, Issacharoff S, Caramer C. 1995. Biased judgment of fairness in bargaining. *American Economic Review*, 85, 1337-1343

⁸³ Ross, M., & Sicoly, F. (1979). Egocentric biases in availability and attribution. *Journal of personality and social psychology*, 37(3), 322.

cient por ciento entre ambas evaluaciones. La explicación a este fenómeno es que, cada uno de los miembros de la pareja se enfoca, de manera egocéntrica, en su parte de las tareas domésticas y evalúa en exceso la medida en que las realiza.

Este no es el único sesgo que provocan los resultados de una decisión. El *Outcome Bias* es aquel sesgo por el cual se evalúa una decisión según su resultado, y no de acuerdo con la información y los medios con los que se contaba al momento de la decisión. Estamos acostumbrados a que un conductor que cruza un semáforo en rojo reciba solo una multa, mientras que un conductor que cruza un semáforo en rojo y colisiona contra otro matando a un tercero, será enviado a la cárcel por homicidio culposo. Ambos conductores han tomado la misma decisión y sin embargo por una cuestión aleatoria, otro automóvil cruzo en el mismo momento, se lo juzga de forma más severa por el resultado. El *consecuencialismo ético*, es decir cuando juzgamos nuestras acciones en función de sus resultados (positivos o negativos) y el *Moral Luck*, es decir cuando responsabilizamos o premiamos a una persona por el resultado de una acción a pesar de no haber tenido el control total de la situación, suelen enfatizar únicamente las malas decisiones o malos resultados, aunque existen cuatro combinaciones posibles: buena decisión con buen resultado, buena decisión con mal resultado, mala decisión con buen resultado y mala decisión con mal resultado. Bernard Williams en su libro "*Moral Luck*"⁸⁴ comenta el caso en el cual, un conductor de un camión que produce la muerte de un niño se sentirá culpable a pesar de haber actuado con cautela y ser consciente de que no fue responsable del accidente, y afirma que esto será diferente para el acompañante o un tercero que presencié el incidente.

Ese remordimiento lo denomina *Agent Regret* y es distinto del *Regret* propiamente dicho.

La naturaleza de esta sensación negativa es producto del hecho de que, a diferencia del acompañante y el testigo, el conductor, estuvo involucrado en la acción. Es decir, Williams, explica que el conductor se auto juzgará pensando cómo podría haber actuado de manera diferente.

El *Agent Regret* se manifiesta de manera más potente cuanto más cercana fue la potencial intervención del individuo. Cada uno de los involucrados tiene una distancia distinta de los escenarios contrafactuales posibles. A mayor cercanía mayor sensación de arrepentimiento.

⁸⁴ Williams, B. (1981). *Moral luck: philosophical papers 1973-1980*. Cambridge University Press.

La intermediación o exposición a un algoritmo o agente de recomendación, puede llegar a modificar la sensación de culpabilidad y arrepentimiento, así como la auto atribución del éxito o del fracaso. Al final del experimento analizamos las percepciones de los participantes y cómo influyó en ellos la aceptación o rechazo de las recomendaciones. Consideramos que, en el experimento del seguro, la adopción de las recomendaciones se verá influida por el resultado de los sorteos de cada participante. Aquellos que experimenten un resultado malo en los sorteos, creemos, tenderán a omitir las recomendaciones subsiguientes del algoritmo adjudicando la falla a un error del algoritmo o a su incompetencia.

b. Método del experimento

Se programaron 10 iteraciones por participante para que la mayoría experimente alguna pérdida.

El algoritmo genera la recomendación utilizando una fórmula que minimiza la pérdida esperada de la suma entre prima y el pago de franquicia multiplicado por la probabilidad de tener que pagar dicha franquicia. Utilizamos la esperanza matemática y una función de utilidad lineal⁸⁵, no cóncava. Al ser obligatoria la compra del seguro y las sumas de las franquicias relativamente bajas, creemos razonable no introducir el factor de aversión al riesgo en el algoritmo. Quisimos que la recomendación sea precisa, sin tener en cuenta factores psicológicos de las preferencias de los participantes en términos de bienestar, como pueden ser la aversión al riesgo, al arrepentimiento y a las pérdidas.

El experimento fue enviado a distintas personas a través del siguiente enlace: https://script.google.com/macros/s/AKfycbzums9kqcNToPGQtf66Dz4-KNhraLMzjtpBWWVEFpJGA_KUMx0/exec y también fue publicado en la plataforma de ingreso de la Universidad Blas Pascal de Córdoba.

Los participantes del ejercicio comienzan con una dotación virtual de \$1200 y deben elegir, en cada una de las 10 rondas, un plan de seguros con distintos niveles de prima y franquicia

⁸⁵ Con un coeficiente de aversión al riesgo de 1,2, los planes de seguros recomendados hubiesen sido los mismos que con el coeficiente 1 de neutralidad ante riesgo. Si bien el coeficiente puede variar dependiendo del nivel de ingresos, tiempo y otros factores para dominios acotados los valores de coeficientes hallados en distintas investigaciones varían entre 1,43 de Schmidt y Traub (2002), 2,25 de Tversky y Kahneman (1992) y 3,06 de Bleichrodt et al. (2001)

(planes A, B, C y D). Las pérdidas varían entre \$75 a \$600, las primas entre \$15 y \$85 y las franquicias entre \$0 y \$700.

En cada ronda, el participante cuenta con un número de tres dígitos en el que cada dígito toma valores del 1 al 6. Luego participa de un sorteo que, en caso de coincidir el número sorteado, o coincidir una parte, con el número que participa en esa ronda, generan una pérdida para el participante.

Para entender mejor el experimento describimos la primera iteración del experimento.

Números que participan del sorteo			
1	Centena	Decena	Unidad
Número participante	2	3	1
Número sorteado	-	-	-

Planes de seguros				
Planes	A	B	C	D
Prima	\$0	\$15	\$20	\$45
Franquicia	\$600	\$100	\$50	\$0

Pérdidas según coincidencias	
Coincidencias	Pérdida
No coincide unidad	\$0
Unidad	\$200
Unidad y decena	\$250
Unidad, decena y centena	\$500

Podemos observar cuatro planes de seguros, con primas que varían entre \$0 y \$45 y franquicias que varían entre \$600 y \$0. Por otra parte, están estipuladas las pérdidas que se generan en caso de que el sorteo arroje coincidencias con el número participante, en este ejemplo el número participante es 2 3 1. Es decir, la unidad **1** la decena **3** y la centena **2**. Si la unidad sorteada es **1** entonces sufre una pérdida pequeña y debe pagar la franquicia. Si además de la unidad coincide el sorteo de la decena **3** entonces su pérdida será mediana, si por último coincide también en la centena **2** la pérdida será máxima.

Los sorteos funcionan al igual que una quiniela, las pérdidas van aumentando mientras más coincidencias existan, es decir que, si no coincide la unidad no hay pérdida, si coincide solo

la unidad la pérdida es pequeña, si coincide la unidad y la decena la pérdida es mediana y si coinciden la unidad, la decena y la centena, la pérdida es la máxima.

Las pérdidas de la primera iteración varían entre \$200 y \$500 pero el participante abonara, el menor valor entre la pérdida y la franquicia. Supongamos que el sorteo arroja la pérdida mediana de \$250 y el participante había elegido el plan B, entonces el participante abonara solo \$100 de franquicia que es la parte que asume el asegurado en la pérdida.

Veamos algunos ejemplos de sorteos:

Planes	A	B	C	D
Prima	\$0	\$15	\$20	\$45
Franquicia	\$600	\$100	\$50	\$0

1	Centena	Decena	Unidad
Número participante	2	3	1
Número sorteado	5	5	3

Se sorteó el número y resulto ser 5 5 3 (enmarcado en verde), es decir ninguna coincidencia y por lo tanto no hubo pérdida.

1	Centena	Decena	Unidad
Número participante	2	3	1
Número sorteado	1	3	1

Ahora supongamos otro ejemplo en el que el sorteo arrojó el número 1 3 1 (enmarcado en verde), es decir coincidiendo la decena y la unidad y por lo tanto generó una pérdida de \$250 (mediana). De todas formas, el participante pagara solo la franquicia según el plan que eligió. Si eligió el plan C pagara solo \$20 y \$230 pagara la aseguradora.

1	Centena	Decena	Unidad
Número participante	2	3	1
Número sorteado	2	3	5

Seguimos con el ejemplo anterior, donde participa el número 2 3 1, si la unidad sorteada no es 1 entonces el participante no pierde nada sin importar qué número salga sorteado en la decena y en la centena, como en este ejemplo donde coinciden decena y centena pero no coincide la unidad.

Los resultados posibles y sus probabilidades son los siguientes:

Cuadro 1

Pérdida	Probabilidad	Centena	Decena	Unidad
Ninguna	83,3%	No coincide	No coincide	No coincide
		✓	No coincide	No coincide
		No coincide	✓	No coincide
		✓	✓	No coincide
Pérdida pequeña	13,8%	No coincide	No coincide	✓
		✓	No coincide	✓
Pérdida mediana	2,3%	No coincide	✓	✓
Pérdida grande	0,46%	✓	✓	✓

Elegimos números del 1 al 6 para dificultar el cálculo de probabilidades. Las probabilidades de coincidencia de un número de tres dígitos son intuitivamente fáciles de calcular ($1/1000$), en cambio, esa misma coincidencia con dígitos del 1 al 6 es de $1/216$, un cálculo más complejo para la mayoría de las personas. De esta manera logramos que el algoritmo contribuya con los participantes ayudándolos a decidir mejor. Los 4 posibles escenarios son: 0 coincidencias, 1, 2 y 3 dígitos coincidentes, con probabilidades de $5/6$, $5/36$ ⁸⁶, $5/216$ ⁸⁷ y $1/216$ ⁸⁸ respectivamente.

En cada iteración se le exige al participante elegir un plan de seguro para cubrir las posibles pérdidas. Los planes se diferencian solo en prima y franquicia, a mayor franquicia menor prima y viceversa. Una vez que el participante elige su plan de seguro, el algoritmo recomienda un plan basándose en minimizar la suma de prima y el pago de la franquicia multiplicado por la probabilidad de que el sorteo arroje una pérdida. La recomendación del algoritmo puede coincidir o no con la elección original del participante, y en caso de no coincidir el participante deberá decidir, antes del sorteo, si continúa con la cobertura que él eligió o prefiere adoptar la cobertura recomendada.

Para ver en detalle el experimento se debe ingresar al link y participar, o bien consultar el protocolo de los experimentos en el [Anexo III](#).

⁸⁶ $(1/6*5/6)$

⁸⁷ $(1/6*1/6*5/6)$

⁸⁸ $(1/6*1/6*1/6)$

c. Resultados

En total, completaron el experimento 38 participantes (22 mujeres y 16 hombres con una edad promedio de 37 años).

De las 380 iteraciones (38 participantes por 10 iteraciones cada uno), en 177 ocasiones (46%), los participantes eligieron el mismo plan de seguro que recomendaba luego el algoritmo y por lo tanto no tuvieron que decidir entre su elección original y la recomendación. En las otras 203 iteraciones, donde existía diferencia entre la elección original y la recomendación, en 143 ocasiones (70%) los participantes mantuvieron su elección original y solo en 60 ocasiones (30%) aceptaron la recomendación del algoritmo. Las recomendaciones se veían representadas de dos formas según la elección original del participante:

1. Aumentar la franquicia, es decir tomar más riesgo (se recomendó en 162 ocasiones).
2. Achicar la franquicia, es decir tomar menos riesgo (se recomendó en 41 ocasiones).

El algoritmo recomienda un plan específico en cada ronda y esa recomendación se expresa cómo aumentar o achicar la franquicia dependiendo de la elección original del participante. Los planes recomendados por el algoritmo eran aquellos que minimizaban la suma de la prima más el pago de franquicia o pérdida, el menor de estos, multiplicado por las probabilidades de las pérdidas, es decir ninguna, pequeña, mediana y grande. Recordemos que la recomendación del algoritmo supone neutralidad al riesgo.

$$\text{Mínimo} \left\{ \begin{array}{l} [A = Prima_a + 0.138 * (Min(Fr_a; PP)) + 0.023 * (Min(Fr_a; PM)) + 0.0046 * (Min(Fr_a; PG))] \\ [B = Prima_b + 0.138 * (Min(Fr_b; PP)) + 0.023 * (Min(Fr_b; PM)) + 0.0046 * (Min(Fr_b; PG))] \\ [C = Prima_c + 0.138 * (Min(Fr_c; PP)) + 0.023 * (Min(Fr_c; PM)) + 0.0046 * (Min(Fr_c; PG))] \\ [D = Prima_d + 0.138 * (Min(Fr_d; PP)) + 0.023 * (Min(Fr_d; PM)) + 0.0046 * (Min(Fr_d; PG))] \end{array} \right.$$

Donde:

A, B, C y D son los planes de seguros ofrecidos

Prima = es la prima que debe pagar el participante. El subíndice indica la prima de cada plan

Fr = franquicia que paga el participante en caso de pérdida. El subíndice indica la franquicia de cada plan

PP = Pérdida pequeña, coinciden solo la unidad sorteada

PM = Pérdida mediana coinciden la unidad y la decena sorteada

PG = Pérdida grande, coinciden los números sorteados unidad, decena y centena

Algunos planes dispuestos eran menos convenientes que otros porque no generaban el debido descuento en la prima a quien tomara más riesgo/franquicia. Un caso extremo, por ejemplo, encontramos en la ronda 2 donde el plan B ofrecía un seguro con una prima de \$40 y una franquicia de \$45 mientras el plan C ofrecía un seguro con una prima de \$55 y una franquicia de \$40. Es decir, que quien eligiera el plan C estaría pagando \$15 más (\$55 - \$40) por una cobertura extra de \$5 (\$45 - \$40). Este por supuesto no sucede a menudo, pero en el mercado se ofrecen franquicias que para que sean convenientes para el asegurado se debe suponer que tendrán una probabilidad del 100% o más de tener un siniestro en el periodo asegurado (ver en el [Anexo III](#)).

En los 380 sorteos, los participantes tuvieron 65 pérdidas, de los cuales 54 fueron pérdidas pequeñas, 9 pérdidas medianas y 2 pérdidas grandes.

Cuadro 2

Elección original	Recomendación del algoritmo	Acepto/Rechazo	Pérdida
Coinciden 177 (46%)			Hubo pérdida 35
			No hubo pérdida 142
No coinciden 203 (54%)	Tomar más riesgo (aumentar la franquicia) 162 (80%)	Acepto 41 (25%)	Hubo pérdida 5
			No hubo pérdida 36
	Rechazo 121 (75%)	Hubo pérdida 20	
		No hubo pérdida 101	
	Tomar menos riesgo (achicar la franquicia) 41 (20%)	Acepto 19 (46%)	Hubo pérdida 2
			No hubo pérdida 17
	Rechazo	Hubo pérdida	

		22 (54%)	3
			No hubo pérdida 19

En el cuadro 2 podemos observar que hay cuatro situaciones en el que resultado es adverso a la recomendación del algoritmo:

1. El algoritmo recomienda tomar más riesgo (franquicia), el participante acepta la recomendación y el sorteo genera una pérdida. Esto sucedió en 5 ocasiones donde los participantes pagaron más franquicia por aceptar la recomendación.
2. El algoritmo recomienda tomar más riesgo (franquicia), el participante rechaza la recomendación y el sorteo genera una pérdida. Esto sucedió en 20 ocasiones donde los participantes habrían pagado más franquicia de haber aceptado la recomendación.
3. El algoritmo recomienda tomar menos riesgo (franquicia), el participante acepta la recomendación y el sorteo no genera una pérdida. Esto sucedió en 17 ocasiones donde los participantes pagaron más prima por aceptar la recomendación.
4. El algoritmo recomienda tomar menos riesgo (franquicia), el participante rechaza la recomendación y el sorteo no genera una pérdida. Esto sucedió en 19 ocasiones donde los participantes hubieran pagado más prima de haber aceptado la recomendación.

Como veremos más adelante las dos primeras situaciones, relacionadas con el pago de franquicias, generan un impacto negativo en la confianza en el algoritmo. Sin embargo, no sucede lo mismo con las últimas dos situaciones relacionadas con el pago de primas.

Pudimos comprobar la superioridad del algoritmo en la mejora de los resultados económicos. En las situaciones en que el participante tuvo que decidir entre su elección original y la recomendación del algoritmo la suma de las primas de las recomendaciones eran por un total de \$4.133 mientras que la prima elegida originalmente por los participantes era por un total de \$7.550, un ahorro potencial de prima de \$3.417. El ahorro en la prima implicaba tomar mayor riesgo y eso producía un costo extra de \$545 en franquicias. Como resultado de las recomendaciones que, sí fueron adoptadas, se generó un ahorro en prima de \$893 (\$2.152 prima original – \$1.259 prima recomendada) y un aumento neto en el pago de franquicia de \$165. En total el algoritmo generó un ahorro neto de \$728, \$893 de ahorro de prima menos

\$165 por aumento en el pago de franquicias. De haber adoptado las recomendaciones en las otras 143 ocasiones en la que rechazaron la recomendación, hubiesen generado un ahorro de \$2.524 (\$5.398 prima original – \$2.874 prima recomendada) y un aumento neto en el pago de franquicia de \$380, es decir que el algoritmo hubiera generado un ahorro neto de \$2.144. Sin embargo, sabemos que no es suficiente la superioridad del algoritmo para su adopción. Podemos encontrar en el libro de Richard Thaler, *Misbehaving*, un ejemplo de esto. Thaler expone el caso de un software gratuito, desarrollado por *The New York Times*, basado en un algoritmo creado por Brian Burke para decidir qué hacer en el *4th down* en la liga de fútbol americano *NFL*, si intentar ir por la distancia faltante, o patear el balón. La coincidencia entre las recomendaciones del algoritmo del *NYT* y las decisiones adoptadas es casi nula, a pesar de superar ampliamente en resultados a las recomendaciones de los directores técnicos.

Al igual que en el experimento I buscamos analizar si a medida que se va usando el algoritmo, se incrementa la adopción de las recomendaciones, además, se pretende descubrir si esto sufre alguna modificación cuando se genera una pérdida comparativa con la elección original. A diferencia del experimento de Dietvorst B. J. *et al*⁸⁹ aquí el algoritmo no comete errores, sin embargo, como las decisiones se toman en un escenario de riesgo, donde la recomendación es buena a largo plazo, pero puede generar pérdidas en el corto plazo, puede ser percibida como un error.

Analizamos si existe una relación significativa entre la cantidad de iteraciones y la tasa de adopción de las recomendaciones mediante la variable *Acepta* la cual describe si el participante acepta la recomendación del algoritmo y adquiere esa cobertura, esta es una variable *dummy* que toma valores de 1 y 0. Debido a que *Acepta* es la variable dependiente y es una variable *dummy*, utilizamos la función *Probit* que mejor se adecua a este tipo de distribución. Al igual que en el experimento I suponemos que a medida que vayan aumentando el número de iteraciones, plasmada en la variable *Ronda*, ira aumentando el nivel de aceptación. Pero además creemos que esto puede cambiar cuando el participante

⁸⁹ Dietvorst, B. J., Simmons, J. P., & Massey, C. (2015). Algorithm aversion: People erroneously avoid algorithms after seeing them err. *Journal of Experimental Psychology: General*, 144(1), 114.

tenga un resultado adverso. Generamos la regresión *Probit* para investigar la incidencia del número de iteraciones en la probabilidad de aceptar la recomendación.

Tabla 7 – Regresión *Probit* aceptación como función del número de ronda

Acepta	Coef.	Error Est.	z	P>z	[95% Intervalo Conf.]	
Ronda	-0.03	0.02	-1.20	0.23	-0.087	0.021
Cons	-0.82	0.16	-4.97	0.000	-1.14	-0.49

Pseudo R2 = 0.228

Obtenemos que la variable *ronda* (las iteraciones) no es significativa por lo que aceptamos la hipótesis nula de que no tiene una relación con la aceptación de la recomendación. Es decir, no observamos una curva de aprendizaje y de confianza en el algoritmo como pudimos observar en el experimento I.

Sin embargo, sí pudimos observar un cambio significativo de comportamiento luego de que el sorteo generaba una pérdida y la recomendación del algoritmo había sido tomar más riesgo. Es decir que, si bien las rondas no iban incrementando la confianza y la aceptación de las recomendaciones, luego de que el algoritmo recomendaba tomar mayor riesgo y el sorteo generaba una pérdida esa confianza inicial decaía de manera significativa. De las 380 iteraciones, se realizaron 297 hasta que el participante enfrentó esa situación y 83 luego de ella. En el gráfico 3 se ve una caída de casi el 125% en el nivel de aceptación de la recomendación y un aumento de 37% en el rechazo de la recomendación luego de estos escenarios adversos a la recomendación. Este cambio es significativo como se puede observar en la tabla 8.

Gráfico 3 – Cambio en la tasa de aceptación y rechazo

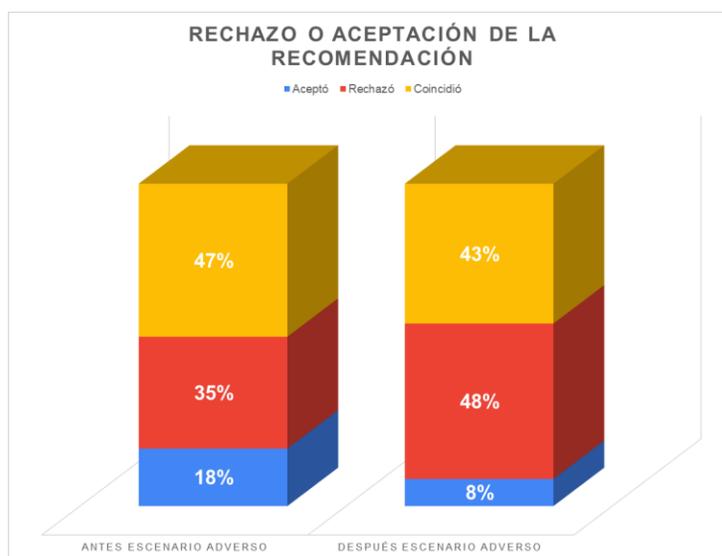


Tabla 8 – test de chi2 sobre aceptación y rechazo antes y después de escenario adverso

	Antes	Después	Total
	297	83	380
Rechazó	103	40	143
Esperada	111.8	31.2	
Coincidió	141	36	177
Esperada	138.4	38.7	
Aceptó	53	7	60
Esperada	46.9	13.1	

P-value=0.030

Por otro lado, observamos que la probabilidad de aceptar la recomendación del algoritmo depende también del tipo de recomendación. La variable *BajFran*, que representa la recomendación del algoritmo de bajar la franquicia respecto de la cobertura original elegida por el participante (Variable *dummy*, valores 1 y 0) fue significativa. Es decir, tomar menos riesgo en comparación con la elección original. Observamos en el cuadro 2 que cuando la recomendación es bajar el riesgo, es decir disminuir el monto de la franquicia, existe una mayor predisposición a aceptar la recomendación. Se puede observar que cuando la recomendación fue aumentar el nivel de franquicia, es decir, tomar más riesgo, hubo una muy baja aceptación (25%) y cuando la recomendación fue bajar la franquicia/riesgo hubo mayor aceptación (46%). Esto se corresponde con la baja aceptación general de las recomendaciones

si tenemos en cuenta que, en 162 ocasiones (80%), el algoritmo recomendó a los participantes aumentar la franquicia con respecto a la que eligieron originalmente.

Tabla 9 - test de chi2 sobre aceptación y rechazo por tipo de recomendación

	Subir franquicia	Bajar franquicia	Total
Total	162	41	203
Rechazo Esperada	121 127.6	22 15.4	143
Acepto Esperada	41 53.5	19 6.5	60

P-value= 0,0025

Por último, sospechamos que la variable *sexo*, que diferencia la aceptación o rechazo según el género, tiene significancia.

Tabla 10 – Aceptación por género

	Rechazó	Aceptó	Coincidió	Total
Mujeres	82	26	112	220
Hombres	61	34	65	160
Total	143	60	177	380

De las 203 iteraciones en las que hubo que decidir, las mujeres tuvieron una tasa de aceptación del 24% y los hombres de casi el 36%. Sin embargo, si tomamos en cuenta también las coincidencias podemos ver que las mujeres decidieron igual que el algoritmo en 63% de las iteraciones, levemente más que los hombres (62%). Al realizar el análisis de significancia sobre la variable *Rechaza* observamos que no hay diferencia significativa (ver [Anexo I](#)). Esto indica que en realidad la menor aceptación por parte de las mujeres fue resultado de una mayor coincidencia con lo que luego recomendaba el algoritmo en comparación con los hombres. Diferentes investigaciones han mostrado un mayor apetito de riesgo por parte de los hombres (Powell M. y Ansig D. 1997; Agnew J., Balduzzi P. y Sundén A. 2003 y Wang A. 2009). Las elecciones de coberturas diferían según el género, los hombres tendieron a elegir, antes de la recomendación, las coberturas con más franquicia.

d. Análisis de las percepciones

Introducir un agente de recomendación en el proceso de decisión puede derivar en que se juzgue al agente por los resultados y no por la recomendación en sí misma. Según la investigación de Dietvorst B. J. *et al* se produce *aversión al algoritmo* en caso de que el algoritmo se equivoque, falle. En ese sentido, Hidalgo C. A. *et al.* en la investigación “*How Human Judge Machines*”⁹⁰, llegan a la conclusión de que juzgamos a los humanos por sus intenciones y a las maquinas por sus resultados⁹¹. A diferencia de estas investigaciones, en nuestro experimento el algoritmo no tiene fallas y la comparación no es entre la recomendación de una maquina/algoritmo y la recomendación de un tercero humano sino en comparación con nuestra propia capacidad de decisión. Para ello, al final del experimento se hicieron diferentes preguntas cualitativas, con el fin de evaluar los distintos aspectos de los *sesgos de autoservicios y de outcome*.

Las preguntas cualitativas al final de experimento eran las siguientes:

1. “¿Cómo calificas tu capacidad para elegir los planes de seguro?”

Nota: Antes de elegir, debe saber que 1 significa muy baja capacidad, 5 significa excelente capacidad”

2. “¿Cómo calificas la capacidad del algoritmo para aconsejarte en la elección de los planes de seguro?”

Nota: Antes de elegir, debe saber que 1 significa muy baja capacidad, 5 significa excelente capacidad”

3. “¿Estas arrepentido de los planes de seguro que elegiste?”

Nota: Antes de elegir, debe saber que 1 significa no estoy arrepentido, 5 significa estoy muy arrepentido”

⁹⁰ Hidalgo, C. A., Orghian, D., Canals, J. A., De Almeida, F., & Martín, N. (2021). *How Humans Judge Machines*. MIT Press.

⁹¹ Uno de los escenarios consiste en una familia tiene un humano o un robot encargado de limpiar su casa. Un día, la familia descubre que el robot usó la bandera nacional para limpiar el baño. Este es un escenario donde se analiza la dimensión moral de la pureza y la lealtad, la bandera es un símbolo nacional sagrado, pero también representa lealtad y es un símbolo de autoridad. Por todas estas razones es un tipo muy complejo de dilema moral. No es como si alguien estuviera hiriendo a otro donde es más fácil de entender la dimensión moral. Entender cuál es la transgresión. En este escenario, encuentran que, la gente juzga a los humanos con más dureza en muchos aspectos. Les agrada más la máquina que el humano, encuentran que la acción de los humanos es menos correcta moralmente y es más probable que quieran contratar un robot nuevamente que contratar a ese humano nuevamente.

4. “¿Qué crees influyó más en la decisión?”

Nota: Antes de elegir, debe saber que 1 significa solo lo que yo pensé/creí, 5 significa hice exactamente lo que me recomendó el algoritmo”

5. “¿A qué le atribuyes los resultados?”

Nota: Antes de elegir, debe saber que 1 significa solo mis propias decisiones, 5 significa solo a la suerte o mala suerte”

El rango de valuación que de las preguntas de percepción al final del experimento eran del 1 al 5.

Tabla 11 - Estadística descriptiva de las variables

Variable	Media	Desv. Est.	Min	Max	Descripción
Capacidad	3.55	0.71	2	5	Percepción de la capacidad auto percibida para decidir en el experimento.
Algoritmo	3.65	0.95	1	5	Percepción de la capacidad del algoritmo para recomendar en el experimento.
Arrepentimiento	1.71	0.72	1	3	Percepción del arrepentimiento por las decisiones tomadas en el experimento.
Influencia	2.02	0.96	1	5	Percepción de la influencia del algoritmo en las decisiones tomadas en el experimento.
Azar	2.81	1.29	1	5	Percepción del azar en los resultados experimento.

Realizamos un análisis descriptivo de los resultados de las valuaciones de las percepciones. Al contar con 38 participantes en el experimento, se vio afectada la significatividad estadística, sin embargo, los resultados son sugerentes y en gran medida consecuentes con lo esperado.

Podemos ver que, en promedio, la gente evaluó mejor la capacidad del algoritmo por sobre la capacidad propia. La capacidad promedio percibida del algoritmo fue de 3,65 que es mayor a la capacidad promedio auto percibida que fue de 3,55. Esto sucede a pesar de la baja aceptación de las recomendaciones, si tomamos en cuenta las iteraciones en la que coincidía

la recomendación con la elección original, solo un total del 63% se decidió igual que el algoritmo, ya sea por coincidencia o por aceptación.

La *Influencia* percibida promedio fue de 2,02, es decir la gente se percibió poco influida por el algoritmo. Esta percepción concuerda con la realidad ya que sólo en una pequeña proporción aceptaron las recomendaciones.

El *Arrepentimiento* promedio fue de 1,71 y el valor máximo fue 3, nadie calificó su nivel de arrepentimiento en 4 o 5. La percepción del *Azar* tuvo un promedio de 2,81, es decir una leve tendencia a afirmar que el azar tenía menor influencia en los resultados que las propias decisiones.

Para entender mejor los sesgos de *outcome* y *autoservicio* realizamos un análisis de la relación entre el balance final del participante y sus percepciones. El balance final de los participantes fue el resultado de los \$1.200 con que iniciaban el experimento menos la prima, que en promedio fue de \$294, y las franquicias pagadas que en promedio fueron de \$148. Sin embargo, la volatilidad de las franquicias pagadas fue mayor y eso hizo que ese componente sea más importante en el balance final, como veremos más adelante. El análisis de las correlaciones lo utilizamos como indicador de las relaciones entre las variables y esto es debido a la limitación en la cantidad de observaciones. Además, observamos en algunas variables una correlación débil, pero creemos que los signos nos sirven como indicador del tipo de influencia entre las variables.

Tabla 12 -Relación entre el *Balance* y las valuaciones de percepción

	Coefficiente de correlación
Capacidad	0,188
Algoritmo	0,167
Arrepentimiento	-0,218
Influencia	0,342
Azar	0,018

Pudimos observar que la variable *Balance* tiene un coeficiente positivo, tanto en la capacidad auto percibida, como en la percepción de la capacidad del algoritmo. En otras palabras, a

mejor resultado mejor percepción de las capacidades. Cabe destacar que el coeficiente de capacidad auto percibida es mayor al del algoritmo con lo cual se fortalece la idea de que tendemos a adjudicarnos mayor mérito cuando los resultados son positivos. En ese mismo sentido vemos una relación negativa entre los *Balances* y el arrepentimiento, a peor *Balance* final mayor arrepentimiento. Sin embargo, los sesgos de *outcome* y *autoservicio* se ven debilitados por la percepción de la *Influencia* y el *Azar*. Vemos una relación positiva entre *Azar* y *Balance*, que se traduce en que, a mayor *Balance* mayor percepción de que fue obra del azar y viceversa. Lo mismo sucede con la percepción de influencia del algoritmo, a mejor *Balance* se atribuye más influencia al algoritmo en contradicción con lo esperado por los sesgos.

Para entender mejor si realmente los participantes han tenido valuaciones sesgadas, es importante desglosar los *Balances* finales separando la suerte, por un lado, de la calidad de las decisiones por el otro. Los *Balances*, en nuestro experimento, dependían de dos factores, la calidad de las decisiones sobre la cobertura adquirida por los participantes y la suerte o mala suerte en los sorteos que generaban las pérdidas. La calidad del tipo de decisiones la pudimos medir por medio de la variable *Rechaza*. Si el participante elegía exactamente lo mismo que el algoritmo, ya sea por coincidencia o por aceptación de la recomendación, podríamos decir que la calidad de sus decisiones fue perfecta. Entonces, mientras más rechazó las recomendaciones menor calidad de decisión demostró. La suerte o mala suerte la medimos por las franquicias pagadas, que fueron resultado de los sorteos que tuvo cada participante y que recolectamos en la variable *Suerte*.

Nuestra hipótesis es que no debería existir ninguna relación entre la variable *Suerte* y las distintas preguntas de percepción puesto que el resultado de los sorteos era completamente aleatorio y no debería influir en la percepción de las capacidades de los participantes, el algoritmo y su influencia y el nivel de arrepentimiento. Respecto de la variable *Rechaza* esperamos que la mayor coincidencia con el algoritmo se perciba como mayor capacidad del participante y a mayor rechazo menor capacidad del algoritmo y su influencia.

Los *Balances* finales de los participantes dependían en mayor medida de los sorteos, es decir de la suerte que, de la *Prima*, que dependía de las decisiones. El coeficiente de correlación

de los *Balances* con la *Prima* era de 0,37 y con las franquicias pagadas producto de los sorteos de 0,85.

Analizamos el impacto de las variables *Suerte* y *Rechaza* en las percepciones finales de los participantes, así como las variables demográficas de sexo y edad.

Tabla 13 – Percepción según suerte

	Coefficiente de correlación
Capacidad	0,197
Algoritmo	-0,084
Arrepentimiento	-0,075
Influencia	0,315
Azar	-0,050

La variable *Suerte* es el resultado acumulado de las franquicias pagadas por los participantes, producto de los sorteos y van de \$0 a -\$485.

Podemos observar que la capacidad auto percibida de los participantes tiene relación positiva con la buena *Suerte*. Esto concuerda con lo postulado por los sesgos de *outcome* y *autoservicio* donde el resultado influye en la evaluación de la decisión y en la auto atribución del resultado. Una buena racha de sorteos donde no hubo pérdidas mejora el puntaje que los participantes adjudican a su propia capacidad de decidir y una mala racha de sorteos bajara la autopercepción de la capacidad del participante. Lo contrario sucede con la valuación del algoritmo y las pérdidas de los participantes, es decir que, mientras mayor fue la pérdida, mayor percepción de la capacidad del algoritmo. Los participantes que tuvieron buena suerte calificaron al algoritmo como menos capaz, tal vez sintiendo que era menos necesario su uso. Existe evidencia de que tendemos a culpar a terceros, en muchas ocasiones por cuestiones de azar que no controlamos, especialmente cuando delegamos en ellos nuestras decisiones. Según Gurdal M. Y. *et al.* (2013)⁹² castigamos con el voto a políticos por un desempeño económico deficiente que no puede atribuirse a sus decisiones (Converse P. E. 1964), accionistas culpan a los gerentes generales despidiéndolos más durante las recesiones que durante los periodos de expansión (Jenter D. y Kanaan F. 2011) e incluso los managers de

⁹² Gurdal, M. Y., Miller, J. B., & Rustichini, A. (2013). Why blame?. *Journal of Political Economy*, 121(6), 1205-1247.

fútbol son despedidos en mayor medida por los resultados de los últimos partidos que por los resultados a largo plazo⁹³.

En un marco de delegación de decisiones a agentes tecnológicos, los consumidores tienden a culpar a los sistemas de recomendación de compras online por los resultados negativos y tienden a atribuirse el mérito personal por los positivos⁹⁴. En la investigación de Hidalgo *et al.* anteriormente citada, no solo se castiga más severamente a las máquinas por los resultados negativos, sino que incluso en los positivos persiste la intención de reemplazar a las máquinas por humanos. Es decir que, en nuestro experimento, no solo el resultado adverso influyó en el posterior rechazo, sino que la buena suerte pudo haber fortalecido la percepción de buenas decisiones por parte de los participantes y la falta de necesidad de acudir al algoritmo.

Observamos también un mayor nivel de arrepentimiento cuando el resultado de los sorteos no favoreció al participante. Por último, adjudican mayor peso al azar quienes peor suerte tuvieron, es decir que la buena suerte es percibida por el participante como resultado de sus decisiones. Sin embargo, la percepción de la *Influencia* del algoritmo no va en el sentido esperado por los sesgos, adjudicando mayor influencia de algoritmo cuando tuvieron más suerte, aunque es la correlación más débil.

Luego evaluamos las percepciones según la calidad de las decisiones medida en la variable *Rechaza*. Deberíamos esperar una relación positiva entre calidad de decisión y percepción de capacidad. La variable *Rechaza* es la proporción de veces que el participante rechazó la recomendación en las 10 iteraciones y tiene valores entre 0 y 0,8.

Tabla 14 – Percepción según nivel de rechazo de las recomendaciones

	Coefficiente de correlación
Capacidad	-0,038
Algoritmo	-0,566
Arrepentimiento	0,119
Influencia	-0,207
Azar	-0,236

⁹³ d'Addona, S., & Kind, A. (2014). Forced manager turnovers in English soccer leagues: a long-term perspective. *Journal of Sports Economics*, 15(2), 150-179

⁹⁴ Moon, Y. (2003). Don't blame the computer: When self-disclosure moderates the self-serving bias. *Journal of Consumer Psychology*, 13(1-2), 125-137.

Observamos que, respecto de la capacidad auto percibida la correlación no fue muy marcada. La calidad de las decisiones, que evaluamos con la variable *Rechaza*, nos indica que los participantes evaluaron levemente mejor su propia capacidad cuando menos rechazaron las recomendaciones. Además, como era de esperar aquellos que más rechazaron las recomendaciones evaluaron peor la capacidad del algoritmo y menor su influencia. Por otra parte, a mayor rechazo hubo menor nivel de arrepentimiento y menor percepción del papel del azar en los resultados.

Zeelenberg M. *et al.* (2000)⁹⁵ subrayan la diferencia entre arrepentimiento y decepción. El arrepentimiento se origina de las comparaciones entre lo que sucedió como resultado de la decisión y el resultado que podría haber sucedido de haber elegido otra de las alternativas, mientras que la decepción ocurre por comparar entre el resultado de la decisión que tomamos y el resultado que podría haber ocurrido si hubiera ocurrido otro estado de la naturaleza.

Sin duda la cobertura elegida se relaciona con la decisión *per se*, mientras que las pérdidas son distintos estados de la naturaleza. En lo que respecta al arrepentimiento en las decisiones de seguro, se pueden vivenciar dos tipos de arrepentimientos: haber comprado poco seguro y sufrir una pérdida (arrepentimiento), o haber comprado demasiado seguro y no sufrir pérdidas (decepción). En la práctica, según se ve en distintos estudios⁹⁶, pareciera que la compra de seguro está guiada por la previsión del arrepentimiento no de la decepción, es decir, comprar poco seguro. En nuestros resultados pareciera que el arrepentimiento esta dado *ex-post*, por haber contratado poco seguro. Lo podemos expresar de esta manera: a mayor aceptación, mayor arrepentimiento. Esto ocurre a pesar de que, como detallamos al principio, el algoritmo, logró ahorrar dinero a los participantes y puede deberse a la diferencia que existe en la percepción de nuestros actos cuando se trata de una comisión o una omisión.

⁹⁵ Zeelenberg, M., Van Dijk, W. W., Manstead, A. S., & vanr de Pligt, J. (2000). On bad decisions and disconfirmed expectancies: The psychology of regret and disappointment. *Cognition & Emotion*, 14(4), 521-541.

⁹⁶ Braun, M., & Muermann, A. (2004). The impact of regret on the demand for insurance. *Journal of Risk and Insurance*, 71(4), 737-767.

Cohen, Alma and Einav, Liran, "Estimating Risk Preferences from Deductible Choice" (2007). *Harvard Law School John M. Olin Center for Law, Economics and Business Discussion Paper Series*. Paper 582. http://lsr.nellco.org/harvard_olin/582

Pashigian, B. P., Schkade, L. L., & Menefee, G. H. (1966). The selection of an optimal deductible for a given insurance policy. *The Journal of Business*, 39(1), 35-44.

Las personas favorecen omisiones perjudiciales sobre comisiones igualmente perjudiciales (Spranca M., Minsk E. y Baron J. 1991)⁹⁷. Ritov I. y Baron J. (1992) exploraron el sesgo de omisión y hallaron que las personas valoran mejor las omisiones, tanto en el plano moral, como en el económico⁹⁸. En nuestro ejercicio, no aceptar la recomendación es la omisión, el *statu quo*, mientras que aceptar, involucra realizar un cambio.

Según Richard Thaler, la arquitectura del marco donde se toman las decisiones puede cambiar los resultados de forma contundente. En este contexto, la elección por defecto, es decir, lo que el sistema impone cuando el decisor no elige, es la herramienta más potente. Donar o no donar órganos debería ser una decisión sensible y de gran importancia que involucra cuestiones religiosas, costumbres, imaginar la propia muerte e imaginar los deseos de familiares, entre otras cuestiones. Sin embargo, sabemos que la mayoría es reticente a elegir, y las autoridades que impusieron como defecto la donación, han salvado miles de vida. Por esta razón, suponemos que, en caso de haber invertido la situación, es decir primero el algoritmo recomendaba y luego el participante decidía, probablemente se hubiera observado mayor aceptación.

Analizamos también cómo las variables demográficas influyeron en las percepciones de los participantes. De los 38 participantes 22 eran mujeres y 16 eran hombres.

Tabla 15 – Percepción según género

	Hombres	Mujeres
Capacidad	3,63	3,50
Algoritmo	3,44	3,82
Arrepentimiento	1,56	1,82
Influencia	2,00	2,05
Azar	3,00	2,68

Las mujeres, subestimaron su propia capacidad y sobreestimaron la capacidad el algoritmo con respecto a los hombres, también manifestaron sentirse menos artífices de los resultados,

⁹⁷ Spranca, M., Minsk, E., & Baron, J. (1991). Omission and commission in judgment and choice. *Journal of experimental social psychology*, 27(1), 76-105.

⁹⁸Ritov, I., & Baron, J. (1992). Status-quo and omission biases. *Journal of risk and uncertainty*, 5(1), 49-61.

creyéndose levemente más influenciadas por el algoritmo.

Vemos que los hombres expresaron mayores niveles de confianza en sus propias capacidades. El exceso de confianza es una creencia injustificada en la exactitud de las respuestas y puede ser el resultado de desestimar la evidencia contradictoria y se da en mayor medida en los hombres, Koriat A., Lichtenstein S. y Fischhoff B. (1980). Además, el *sesgo de autoservicio* también puede ser resultado de una diferencia de puntos de vista sobre lo que se considera justo, Babcock L. y Loewenstein G. (1997), entonces la puntuación de la percepción puede variar según el sentido de justicia con uno mismo que también suele ser diferente entre hombres y mujeres. Por último, las expectativas sobre el comportamiento propio y el comportamiento de otros agentes, en nuestro caso la expectativa de nuestra autoevaluación, pueden sufrir sesgos de género, Eckel C. C. y Grossman P. J. (2002). En nuestra cultura, los hombres son educados para demostrar seguridad mientras que las mujeres para demostrar modestia⁹⁹. Estas expectativas de género pueden afectar la autoestima, la confianza, la asunción de riesgos y la cooperación.

Las mujeres valoraron el algoritmo positivamente en mayor medida que los hombres. Se puede pensar que confiar en un algoritmo desconocido es hacer una apuesta, arriesgarse. Por lo tanto, Chaudhuri A. y Gangadharan L. (2007) sostienen que la confianza tiene un elemento de toma de riesgos calculada, pero también puede considerarse una virtud social Fukuyama F. (1995). Aunque los resultados generales son mixtos, en la mayoría de los estudios, los hombres muestran, en promedio, un comportamiento más confiado que las mujeres¹⁰⁰. La mayor confianza de las mujeres fue solo declarativa puesto que no se tradujo en mayor adopción de las recomendaciones.

Las mujeres muestran un mayor grado de arrepentimiento a pesar de que no hubo diferencias significativas en los balances finales. Entonces suponemos que el grado de arrepentimiento puede estar relacionado con la menor autoconfianza que manifestaron las mujeres¹⁰¹.

⁹⁹ Lichtenstein, S., & Fischhoff, B. (1981). The Effects of Gender and Instructions on Calibration. DECISION RESEARCH EUGENE OR.

¹⁰⁰Chaudhuri, A., & Gangadharan, L. (2007). An experimental analysis of trust and trustworthiness. Southern Economic Journal, 959-985.

¹⁰¹ Markman, G. D., Baron, R. A., & Balkin, D. B. (2005). Are perseverance and self-efficacy costless? Assessing entrepreneurs' regretful thinking. Journal of Organizational Behavior: The International Journal of Industrial, Occupational and Organizational Psychology and Behavior, 26(1), 1-19.

Por último, analizamos las percepciones según las edades de los participantes quienes tenían entre 17 y 63 años.

Tabla 16 – Percepción según edad

	Coefficiente de correlación
Capacidad	-0,169
Algoritmo	0,178
Arrepentimiento	-0,125
Influencia	0,167
Azar	0,241

Observamos aquí que los más jóvenes se auto percibieron más capaces que los mayores y valoraron menos capaz el algoritmo respecto a los mayores. Esto es contrario a investigaciones que hallaron coeficientes negativos¹⁰² o no encuentran significancia en la relación entre la edad y la confianza en la tecnología (Rogers W. A., Sindi A. A., Lucas C. *et al.*) Además, a mayor edad los participantes percibieron al azar como más influyente que los jóvenes, sintiendo menos arrepentimiento y mayor influencia del algoritmo.

e. Conclusión

En la hipótesis original suponíamos que habría un crecimiento en los niveles de adopción de las recomendaciones a medida que avanzaba el experimento. Si bien no pudimos corroborar una curva de adopción creciente con cada iteración, sí pudimos observar una caída mayor en la adopción de las recomendaciones siguientes luego de un escenario adverso a la recomendación del algoritmo respecto a tomar más riesgo/franquicia. Deducimos que un mal resultado genera el mismo efecto de *aversión al algoritmo* que cuando el algoritmo comete un error. Es decir, el participante no diferencia una mala recomendación de un mal resultado. Esto no sucedió cuando el escenario adverso era a la recomendación de tomar menos riesgo/franquicia.

¹⁰² Chung, J. E., Park, N., Wang, H., Fulk, J., & McLaughlin, M. (2010). Age differences in perceptions of online community participation among non-users: An extension of the Technology Acceptance Model. *Computers in Human Behavior*, 26(6), 1674-1684.

Pudimos observar también que hubo una mayor aceptación de las recomendaciones cuando la recomendación era bajar el riesgo, es decir, elegir un seguro con mayor prima y menor franquicia.

No hubo diferencias significativas en el rechazo de las recomendaciones según los factores demográficos de género y edad, pero sí en las preguntas cualitativas de auto percepción. Observamos una menor capacidad auto-percibida y mayor percepción de la utilidad del algoritmo y su influencia por parte de las mujeres y en relación con la edad.

Por último, la suerte o la mala suerte influyo en la mayoría de las preguntas cualitativas afirmando los sesgos de *Outcome* y *Autoservicio*. Es decir, mayor adjudicación del éxito y desvinculación del fracaso que en gran medida fueron azarosos.

iii. Sección III – Experimento en condiciones de incertidumbre descripción y objetivos.

a. Introducción

En el tercer experimento pusimos a prueba la elección y la recomendación de un algoritmo en un escenario de incertidumbre, es decir no se conocen las probabilidades ni los resultados posibles. Los conceptos de riesgo e incertidumbre suelen confundirse, y por ello ya hemos mencionado la diferenciación realizada por Knigh F. H.. Denominamos decisiones en condiciones de riesgo cuando las probabilidades de escenarios futuros son conocidas o se les puede asignar una probabilidad. En la incertidumbre no conocemos las probabilidades de estos escenarios. A diferencia del experimento II aquí se desconocen las probabilidades de cada elección y los posibles pagos y en ese marco quisimos observar si existían diferencias entre la adopción de recomendaciones en condiciones de riesgo y en condiciones de incertidumbre. En condiciones de riesgo como en el experimento II, los participantes pueden haber realizado cálculos intuitivos o incluso exactos dependiendo de sus capacidades estadísticas. En el experimento III, como veremos a continuación, esos cálculos no son posibles.

El objetivo, al igual que en el experimento II, era observar si un resultado adverso, por adoptar la recomendación del algoritmo, generaba una menor adopción de las siguientes recomendaciones. Supusimos que el participante iría adoptando las recomendaciones del algoritmo en mayor medida en cada ronda. Sin embargo, en caso de adoptar la recomendación del algoritmo y tener un resultado adverso producto del azar, podría percibir esto como una mala recomendación y dejar de adoptar las siguientes recomendaciones.

El experimento, así como el algoritmo propuesto, se basan en el *problema de la secretaria*¹⁰³. El problema de la secretaria consiste en elegir la secretaria mejor calificada entre n postulantes que son entrevistadas una por una en orden aleatorio. Se debe decidir sobre cada postulante en particular inmediatamente después de la entrevista, contratarla o no contratarla. Si se decide no contratarla, la decisión es irrevocable y la postulante no puede ser contratada luego de entrevistar a otras postulantes. Se trata de encontrar la estrategia óptima entre recabar más información y el riesgo de dejar pasar a la mejor candidata en el proceso de

¹⁰³ Ferguson, T. S. (1989). Who solved the secretary problem?. *Statistical science*, 4(3), 282-289.

búsqueda de esa información. La estrategia óptima desarrollada para este problema es entrevistar y no contratar al primer 37%¹⁰⁴ de las postulantes con el objetivo de recabar información y luego contratar la primera postulante que supere en sus calificaciones a las ya entrevistadas hasta ese momento.

El libro “*Algorithm to live by*”, anteriormente mencionado, propone la utilización de este simple algoritmo para el alquiler de departamentos, o incluso pareja para casarse, donde, de manera similar, ocurre como en el *problema de la secretaria* en el que dejar pasar una oferta no se puede revertir. La elección de departamento y de pareja para casarse, suelen producir un escenario en el cual, si no se concreta el trato en ese momento y se deja pasar la oportunidad, ya no se puede volver atrás y concretarlo.

En este experimento, replicamos un escenario similar al *problema de la secretaria*. Pedimos a los participantes obtener la mayor suma de dinero entre 19 ofertas por una obra de arte en cada una de 5 rondas. La función objetivo del algoritmo es elegir la mejor oferta, pero no se explicó a los participantes cómo funcionaba el mismo. Desde el punto de vista de los participantes el algoritmo es opaco, no saben cómo funciona y en que basa sus recomendaciones. Cabe destacar que si bien la función objetivo busca detectar la mejor oferta, como efecto secundario logra aceptar, en promedio, mejores ofertas que sin su utilización. Al existir 19 ofertas, el algoritmo deja pasar las 7 primeras ofertas (37%) y luego recomendará aceptar la primera oferta que supere a las anteriores.

Las chances originales de aceptar la mejor oferta en el caso de 19 ofertas, eligiendo cualquier oferta al azar es de aproximadamente 5%¹⁰⁵, y utilizando el algoritmo las chances mejoran a casi 40%, Sin embargo, en el 60% de los casos, el algoritmo no recomendará la mejor oferta e incluso puede llegar a recomendar aceptar ofertas por sumas de dinero muy bajas.

b. Método del experimento

Se realizaron 5 rondas del experimento por participante, en cada ronda el participante debe vender una obra de arte de la cual no tiene conocimiento de su valor real.

¹⁰⁴ $1/e = 0,36787944$

¹⁰⁵ $1/19 = 0,052263158$

Existen 19 ofertas en cada ronda que se van descubriendo una por vez. Las sumas ofertadas se presentan en el cuadro 3 del [Anexo III](#) ordenadas de mayor a menor en cada ronda. Sin embargo, se programó el orden de aparición de las ofertas en cada ronda de forma aleatoria de tal manera que ningún participante vio el mismo orden de ofertas. Cabe destacar también que el monto de las ofertas se asignó de forma aleatoria con una fórmula de Excel¹⁰⁶ que contemplaba un máximo y un mínimo en cada ronda. En cada ronda se van descubriendo una por una las ofertas y el participante debe decidir si acepta la oferta y vende la obra de arte o si quiere seguir evaluando las siguientes ofertas. En caso de querer seguir recibiendo ofertas, no puede obtener o aceptar la oferta que ya dejó pasar. Es decir, oferta que no se acepta en el momento, se pierde. Tiene a su disposición también el algoritmo que le recomendara si le conviene rechazar la oferta o aceptarla. De cualquier forma, la decisión final es del participante.

Para ver en detalle el ejercicio se debe ingresar al enlace y participar o bien consultar el protocolo de los experimentos en el [Anexo III](#).

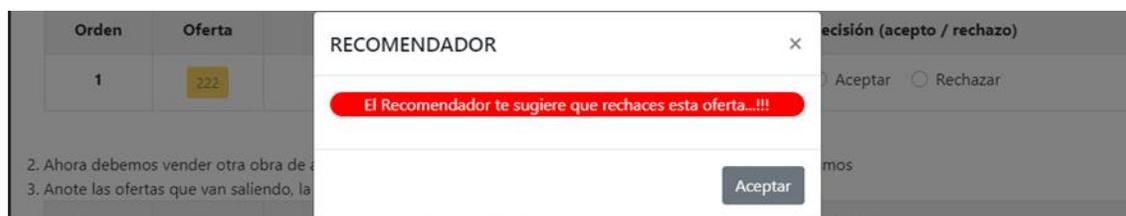
El participante visualiza las ofertas una por vez y luego debe pedir la recomendación antes de decidir si aceptar o rechazar la oferta.

Orden	Oferta	Recomendación	Decisión (acepto / rechazo)
1	?	<input type="button" value="Recomendar"/>	<input type="radio"/> Aceptar <input type="radio"/> Rechazar

Se revela la oferta, que en este ejemplo es de \$222

Orden	Oferta	Recomendación	Decisión (acepto / rechazo)
1	222	<input type="button" value="Recomendar"/>	<input type="radio"/> Aceptar <input type="radio"/> Rechazar

Se pide la recomendación del algoritmo que en este caso me recomienda rechazar la oferta.

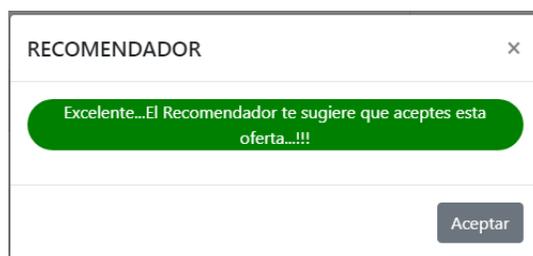


¹⁰⁶ Se aplicó la fórmula "ALEATORIO.ENTRE" el mínimo y el máximo de cada ronda. Las ofertas de cada ronda se detallan en el Anexo III.

El participante decide rechazar la oferta y entonces se revelaba la siguiente oferta, así hasta que acepta una.

Orden	Oferta	Recomendacion	Decision (acepto / rechazo)
1	222	Recomendar	<input type="radio"/> Aceptar <input checked="" type="radio"/> Rechazar
2	303	Recomendar	<input type="radio"/> Aceptar <input checked="" type="radio"/> Rechazar

Cuando aparece una oferta que el algoritmo recomienda aceptar, la recomendación aparece de la siguiente forma:



Una vez que se acepta una oferta se revelan las demás ofertas de manera tal que el participante podía ver todas las ofertas de la ronda para evaluar su desempeño relativo.

Deseábamos averiguar si los usuarios valoraran esta mejora entre la estrategia de elegir al azar una oferta cualquiera, con probabilidad de 5% de elegir la mejor, o adoptar las recomendaciones del algoritmo con probabilidad del 40%, de elegir la mejor oferta. O si verán en ese 60% de las veces que el algoritmo no logra conseguir la mejor oferta como un error del algoritmo y comenzarán a rechazar sus recomendaciones.

El experimento fue enviado a distintas personas a través del siguiente enlace: <https://script.google.com/macros/s/AKfycbwSVduMoC1qNRPyuIR0I2PE5nJQqSyT0yzFFJHl2pV7JocvRCI/exec> y también fue publicado en la plataforma de ingreso de la Universidad Blas Pascal de Córdoba.

En total completaron el experimento 33 personas (19 mujeres y 14 hombres, con una edad promedio de 35 años). El experimento consistía en obtener la mayor suma de dinero de las ofertas y los participantes debían aceptar, en cada una de las 5 rondas, alguna de las 19 ofertas recibidas. El balance final de cada participante era la suma de las ofertas aceptadas en cada

una de las 5 rondas. El balance mínimo y máximo posible eran de \$1.791 y \$3.318 respectivamente.

De las 165 iteraciones (33 participantes por 5 rondas cada uno) solo en 59 ocasiones se adoptó la recomendación del algoritmo de aceptar la oferta. En las otras 106 iteraciones (64%) no se adoptó, pero mayormente (93 de las 106 iteraciones) no fue por no adoptar la recomendación de aceptar la oferta, sino que se aceptó una oferta que el algoritmo recomendaba rechazar. En conversaciones informales con algunos participantes surgió el comentario que el experimento pareció ser tedioso y los participantes decidieron aceptar ofertas en las primeras iteraciones, antes que el algoritmo alcanzara a recomendarles aceptar.

La recomendación de aceptar en las 59 ocasiones adoptadas se dio en promedio en la oferta número 13. En el resto de las iteraciones, el promedio de aceptación fue en la oferta número 7, este factor de impaciencia les costó en promedio \$234 a los participantes. “La relación entre la impaciencia y el costo económico ha sido estudiada por diferentes autores: Ventura L. (2003); Kirby K. N. y Petry N. M. (2004); Borghans L. y Golsteyn B. H. H. (2005); y Eckel C. et al. (2005)”¹⁰⁷. Por otro lado, esto pudo ser producto de la desconfianza en el algoritmo o la tendencia del comportamiento humano, observado en distintas investigaciones¹⁰⁸, que muestran que somos propensos a detenernos prematuramente durante las primeras etapas del proceso de búsqueda de mejores opciones. En nuestro experimento solo se trataba de la impaciencia a recibir una recomendación o servicio, sin tener que elegir entre dos gratificaciones distintas en el tiempo. Existe un importante nivel de investigación en lo que respecta a la impaciencia de los usuarios que detallamos en el [Anexo I](#), pero no en el marco de los modelos *TAM*, *UTAUT* y los *RA* como en nuestro caso.

c. Resultados

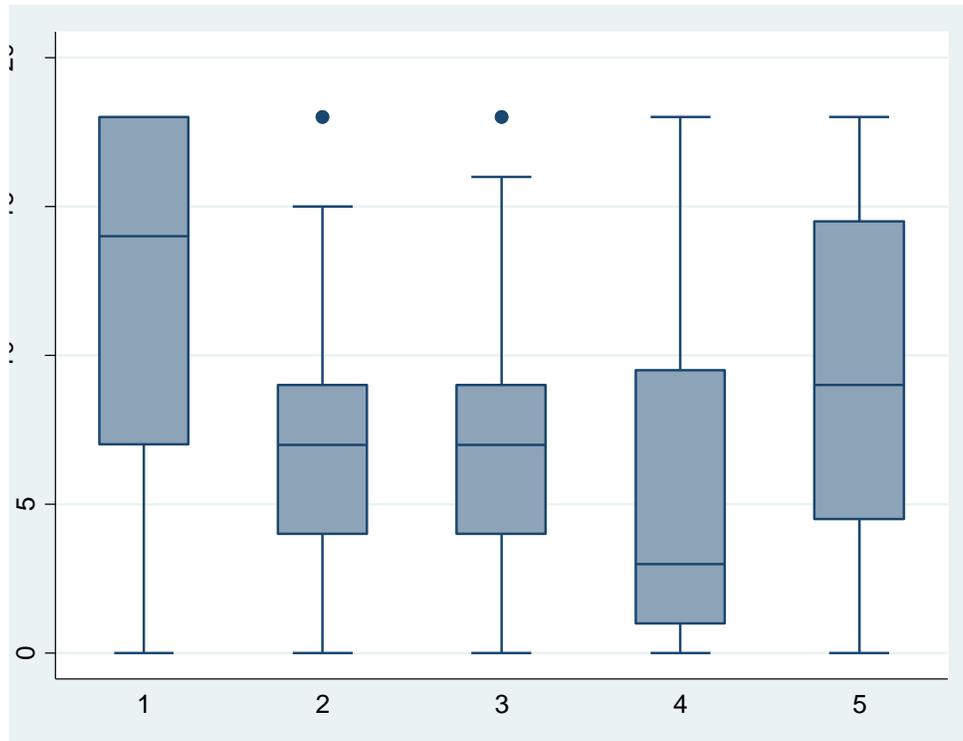
Observamos que el orden de aparición de oferta aceptada (Valores 1 a 19), va bajando a medida que avanza el experimento, es decir se aceptan las ofertas más tempranas a medida que avanzan las rondas.

¹⁰⁷ Sunde, U., Dohmen, T., Falk, A., & Huffman, D. (2007). Are risk aversion and impatience related to cognitive ability?.

¹⁰⁸ Palley, A. B., & Kremer, M. (2014). Sequential search and learning from rank feedback: Theory and experimental evidence. *Management Science*, 60(10), 2525-2542.

Bearden, J. N., Rapoport, A., & Murphy, R. O. (2006). Sequential observation and selection with rank-dependent payoffs: An experimental study. *Management Science*, 52(9), 1437-1449.

Gráfico 5 – Aceptación de oferta según orden de aparición y ronda



Observamos una tendencia a aceptar cada vez más rápido las ofertas. En el eje de la Y se observa el orden de aparición de oferta aceptada que va de la primera oferta a la oferta número 19. En el eje de las X se observa el número de ronda que va de la primera a la quinta ronda.

Vemos una tendencia a la baja en el número de orden de oferta aceptada es decir que a medida que avanzaba el experimento, los participantes iban perdiendo la paciencia para esperar mejores ofertas. En la ronda 5 vemos un cambio en esta tendencia y la oferta aceptada aumenta de la oferta número 6 en la ronda 4 a la oferta número 10 en la ronda 5 y hay también un aumento en la tasa de adopción de la recomendación del algoritmo de 7 adopciones en la ronda 4 a 10 adopciones en la ronda 5. La razón que encontramos para este cambio de comportamiento es que en la ronda 4 fue donde mayor diferencia económica hubo entre la recomendación del algoritmo y la elección de los participantes sin la recomendación. Esta diferencia en la ronda 4 fue de \$146 mientras que en las rondas anteriores fue menor a \$48.

Si evaluamos el desempeño del algoritmo podemos ver que, cuando se adoptó la recomendación del algoritmo, el ranking de oferta aceptada fue de 4,74 y en el resto de las iteraciones fue en el ranking 6,5, donde 1 significa la mejor oferta y 19 la oferta más baja. De las 59 iteraciones en que se adoptó la recomendación del algoritmo, en 26 (44%) ocasiones, se eligió la mejor oferta mientras que en las 106 que no se adoptó la recomendación solo en 20 (19%) se eligió la mejor oferta.

El desempeño de los participantes fue bastante bueno ya que, eligiendo una oferta cualquiera al azar, el ranking promedio debería haber sido 10 y solo el 5% de las veces deberían haber seleccionado la mejor oferta. Al conversar con algunos participantes encontramos dos razones por las cuales creemos que los resultados de los participantes fueron superiores a lo esperado:

1. Comentaron que intuitivamente entendieron que las ofertas no serían mayores a \$999 y eso bajó el nivel de incertidumbre del experimento. Esto no necesariamente debía ser así, pero en realidad la oferta máxima programada fue de \$980 en la ronda 4.
2. Utilizaron la estrategia de ver algunas ofertas y luego elegir, lo cual es mejor que elegir aleatoriamente. Por ejemplo, un participante comentó que veía las primeras 4 ofertas para entender cuanto ofrecían en cada ronda y luego decidía.

Investigamos las variables que creemos influyen en la probabilidad de adoptar¹⁰⁹ la recomendación del algoritmo. Primero comprobamos si existe un aumento en la confianza en el algoritmo a medida que los participantes lo utilizaban y se familiarizaban con el mismo. La variable *Ronda*, que es el número de iteración resultó ser ambigua¹¹⁰ respecto a su significancia, pero su signo negativo indicó lo contrario a lo que suponíamos, es decir menor adopción de las recomendaciones del algoritmo con cada ronda. Esto pudo ser también como resultado de la impaciencia para esperar la recomendación, anteriormente mencionada. La variable *Sexo* fue significativa en la probabilidad de adoptar la recomendación siendo las mujeres más propensas a adoptar las recomendaciones. Por último, queríamos saber si un escenario adverso a lo recomendado por el algoritmo podía influir negativamente en la

¹⁰⁹ Utilizaremos el termino adoptar para diferenciar de aceptar que lo utilizamos para aceptar la oferta

¹¹⁰ En uno de los modelos fue significativa y en otro no.

adopción de las recomendaciones en las siguientes rondas. A pesar de que el algoritmo fue, en promedio, mejor que los participantes en las situaciones donde por azar la mejor oferta aparecía en las primeras 7 ofertas el desempeño del algoritmo no fue muy bueno. Dietvorst B. J. *et al.* (2015) sostienen que el *algorithm aversion* se da cuando los usuarios entienden que el algoritmo no es perfecto a lo que Benbasat I. *et al.* (2020) adhieren, pero creen que es una definición acotada. En algunos casos es una aversión innata, antes de experimentar una falla del algoritmo¹¹¹ y en nuestro experimento no hay falla o error, hay escenarios adversos. Por ejemplo, si por azar la mejor oferta aparecía en las 7 primeras ofertas, estaba programado dejar pasar y aceptar siempre la última oferta puesto que ninguna de las ofertas superaría la mejor oferta que apareció en las primeras 7. Además, en algunas ocasiones aparece una mejor oferta que las primeras 7 sin ser esta la rankeada en el primer lugar. Como resultado de esto, si bien el ranking promedio de las 59 iteraciones donde se adoptó la recomendación fue mejor que cuando no se adoptó la recomendación, en 33 ocasiones no se recomendó la mejor oferta. El no lograr la mejor oferta pudo haber sido percibido como un error del algoritmo. Entonces definimos una matriz para diferenciar los posibles escenarios de la experiencia del participante en la ronda anterior y analizar cómo influyen en la probabilidad de adoptar la siguiente recomendación del algoritmo. En este experimento, así como en cualquier decisión en condiciones de incertidumbre, uno puede tomar una buena decisión y tener un buen o un mal resultado o tomar una mala decisión y tener un buen o un mal resultado. Siguiendo esta clasificación podemos ver dos situaciones (de cuatro) en la que el participante pudo sentirse decepcionado por la recomendación del algoritmo: adopto la recomendación y tuvo un mal resultado o no adoptó la recomendación y tuvo un buen resultado. En ambos casos puede percibir que el algoritmo no está recomendando bien. Por ejemplo, si el algoritmo recomienda no aceptar una oferta y el participante la acepta de todas formas y resulta ser la mejor oferta vera la recomendación como un error o falla. Lo mismo sucede si el algoritmo recomienda aceptar una oferta y el participante la acepta y resulta ser una oferta que no está entre las mejores.

¹¹¹ Longoni, C., A. Bonezzi and C. K. Morewedge. (2019). "Resistance to Medical Artificial Intelligence." *Journal of Consumer Research* , 46(4), 629-650.

Por un lado, calificamos como buena decisión cuando el participante adoptó la recomendación y como mala decisión cuando no lo hizo. Cabe aclarar que nos referimos a que adoptó, cuando siguió la recomendación del algoritmo de principio a fin en la ronda es decir fue rechazando las ofertas que el algoritmo recomendaba rechazar y aceptó la que recomendaba aceptar.

La calificación de buen o mal resultado era más compleja porque dependía de la expectativa del participante. Si, por ejemplo, esperaban que el algoritmo sea perfecto y lograra siempre aceptar la mejor oferta, cuando obtuviera una oferta menor podían ver esto como un error o falla. Sin embargo, podía ser que la expectativa era lograr una de las 5 mejores ofertas y en ese caso un mal resultado sería solo cuando la oferta aceptada no estaba entre ellas. Entonces generamos varias clasificaciones de lo que podrían haber considerado como escenarios adversos y sentirse decepcionados por el algoritmo:

- *DecepR1* – cuando no se obtiene la oferta rankeada número 1.
- *DecepR3* – cuando no se obtiene la oferta rankeada entre las mejores 3 ofertas.
- *DecepR5* – cuando no se obtiene la oferta rankeada entre las mejores 5 ofertas.

Los posibles escenarios en cada ronda eran los siguientes:

- *Good Decision Bad Outcome* – en esta situación los participantes adoptaron las recomendaciones del algoritmo, pero tuvieron un resultado decepcionante (según la clasificación de resultado).
- *Bad Decision Good Outcome* – en esta situación los participantes no adoptaron las recomendaciones del algoritmo, pero tuvieron un buen resultado.
- *Bad Decision Bad Outcome* – en esta situación los participantes no adoptaron las recomendaciones del algoritmo, y tuvieron un resultado decepcionante (según la clasificación de resultado).
- *Good Decision Good Outcome* – en esta situación los participantes adoptaron las recomendaciones del algoritmo, y tuvieron un buen resultado

La tabla 17 muestra la clasificación de las decisiones de los participantes según si adoptaron la recomendación o no y según si la oferta aceptada fue decepcionante o satisfactoria. Los escenarios resaltados en rojo pudieron ser percibidos por los participantes como fallas del

algoritmo. Las distintas clasificaciones de la variable *Decep* nos ayudan a medir la sensibilidad de los participantes al impacto de los resultados en la adopción de las siguientes recomendaciones.

A modo de ejemplo, interpretamos la fila de *DecepR5* de la siguiente manera: en 12 ocasiones los participantes adoptaron la recomendación del algoritmo y obtuvieron una oferta rankeada 6 o menor (GDBO). En 44 ocasiones no adoptaron la recomendación del algoritmo y a pesar de eso obtuvieron un buen resultado es decir una de las ofertas rankeadas en las primeras 5 posiciones (BDGO). En 39 ocasiones no adoptaron la recomendación del algoritmo y obtuvieron un mal resultado es decir una de las ofertas rankeadas 6 o menor (BDBO). Por último, en 37 ocasiones los participantes adoptaron la recomendación del algoritmo y obtuvieron una oferta rankeada en las primeras 5 posiciones (GDGO).

Tabla 17 – Clasificación de las recomendaciones según adopción y resultado

Escenario	GDBO	BDGO	BDBO	GDGO	Obs.
DecepR1	28	16	67	21	132
DecepR3	13	42	41	36	132
DecepR5	12	44	39	37	132

Verificamos las variables que sospechamos influyen en la probabilidad de adoptar la recomendación. Creamos dos modelos y seleccionamos la clasificación *DecepR5* cuyo *p-value* resulto significativo en combinación con las demás variables. Medimos la probabilidad de adoptar la recomendación del algoritmo según el *Sexo*, la *Ronda*, el haber tenido un resultado adverso en la ronda anterior y el haber adoptado la recomendación en la ronda anterior.

Tabla 18 – Adopción de recomendación del algoritmo modelos I y II

Variable	Modelo I	Modelo II
Sexo <i>P-value</i>	0.63 (0.003)	0.58 (0.022)
DecepR5 <i>P-value</i>	-0.59 (0.011)	-0.77 (0.006)
Ronda <i>P-value</i>	-0.20 (0.008)	-
Adopt1 <i>P-value</i>	-	0.62 (0.013)
Const <i>P-value</i>	0.15 (0.957)	-0.87 (0.000)

Pseudo R2	0.1003	0.1478
Obs.	132	132

El modelo utilizado es una regresión *logit* cuyo objetivo es calcular la probabilidad de adoptar la recomendación según las distintas variables.

Modelo I:

$Adopta = \alpha + \beta * Sexo - \gamma * DecepR5 - \delta * Ronda + \mu$
$Adopta = 0.15 + 0.63 * Sexo - 0.59 * DecepR5 - 0.20 * Ronda + \mu$

El haber adoptado la recomendación del algoritmo en la ronda anterior y obtener una oferta rankeada entre la 6 y la 19 así como también el no haber adoptado la recomendación del algoritmo y obtenido una oferta rankeada entre la 1 y la 5 disminuyen la probabilidad de adoptar la recomendación en la siguiente ronda (*Coef. -0.59; P-value 0.011*).

Observamos una diferencia significativa en el comportamiento según el género. De las 95 iteraciones de las mujeres, en 43 ocasiones (45%), adoptaron la recomendación de aceptar, por su parte, en las 70 iteraciones de los hombres, sólo lo hicieron en 16 (23%) ocasiones. Hemos mencionado las numerosas investigaciones respecto de las variables explicativas en las diferencias de confianza y de autopercepción entre hombres y mujeres que podrían aplicarse a estos resultados. La mayor confianza de las mujeres en los algoritmos, podría ser una herramienta para acotar por ejemplo la brecha salarial en caso de utilizar algoritmos de negociación. Para ejemplificar esto cabe citar la investigación de Ayres, I. y Siegelman, P. (1995)¹¹² que comparó la compra de autos *offline*, donde mujeres y algunas minorías, pagaban en promedio más que los hombres blancos, por los mismos autos con la investigación de Morton, F. S., Zettelmeyer, F. y Silva-Risso, J. (2003)¹¹³ que probó que esta brecha se reducía en la compra online. Esta investigación muestra el potencial de la utilización de la tecnología para reducir la brecha financiera de género. Los atributos observados en nuestros experimentos sobre las mujeres pueden ser explotados positivamente para mejorar sus decisiones en general y sus finanzas en particular. Es decir, los algoritmos

¹¹² Ayres, I., & Siegelman, P. (1995). Race and gender discrimination in bargaining for a new car. *The American Economic Review*, 304-321.

¹¹³ Morton, F. S., Zettelmeyer, F., & Silva-Risso, J. (2003). Consumer information and discrimination: Does the Internet affect the pricing of new cars to women and minorities?. *Quantitative marketing and Economics*, 1(1), 65-92.

ayudan a tomar mejores decisiones y las mujeres confían más en los algoritmos que los hombres.

En el modelo II quisimos medir también si el haber adoptado la recomendación en la ronda anterior tenía algún efecto en la probabilidad de adoptar en la siguiente.

Modelo II:

$Adopta = \alpha + \beta * Sexo - \gamma * DecepR5 - \delta * Adopt1 + \mu$
$Acepta = -0.87 + 0.58 * Sexo - 0.77 * AdversoR5 + 0.72 * Adopt1 + \mu$

Este modelo mejora el R^2 de 0.10 a 0.15 y hace que la constante pase a ser significativa. Sin embargo, la variable *Ronda* pierde significancia (*p-value* 0.337) y por esa razón la eliminamos del modelo.

Los coeficientes no deben ser interpretados como una regresión común y por eso obtuvimos las derivadas para conocer el efecto marginal de cada variable en la probabilidad de adoptar la recomendación. En nuestro modelo esos efectos son: *Sexo* 0.18, *Adopt1* 0.19 y *DecepR5* - 0.23. En otras palabras, según los resultados obtenidos en nuestra regresión *logit* las mujeres tienen 18% más de probabilidad de adoptar la recomendación, el haber adoptado la recomendación en la ronda anterior aumenta la probabilidad de adoptar la recomendación en la siguiente ronda en un 19% y la probabilidad de adoptar la recomendación luego de un escenario adverso, definido con el umbral de las 5 mejores ofertas, disminuye un 24%.

d. Análisis de las percepciones

Al igual que en el experimento 2, queremos analizar si existe relación entre los resultados, que en gran medida son azarosos, y los *sesgos de autoservicios* y *de outcome*. Para ello, al final del experimento se realizaron diferentes preguntas, que evalúan los distintos aspectos de estos sesgos.

Las preguntas cualitativas al final de experimento eran las siguientes:

1. “¿Cómo calificas tu capacidad para decidir si aceptar la oferta o rechazarla?”

Nota: Antes de elegir, debe saber que 1 significa muy baja capacidad, 5 significa excelente capacidad”

2. “¿Cómo calificas la capacidad del algoritmo para aconsejarte si aceptar o rechazar?

Nota: Antes de elegir, debe saber que 1 significa muy baja capacidad, 5 significa excelente capacidad”

3. ¿Estas arrepentido de las decisiones que tomaste?

Nota: Antes de elegir, debe saber que 1 significa no estoy arrepentido, 5 significa estoy muy arrepentido”

4. “¿Qué crees influyó más en la decisión?

Nota: Antes de elegir, debe saber que 1 significa solo lo que yo pensé/creí, 5 significa hice exactamente lo que me recomendó el algoritmo”

5. “¿A qué le atribuyes los resultados?

Nota: Antes de elegir, debe saber que 1 significa solo mis propias decisiones, 5 significa solo a la suerte o mala suerte”

Realizamos un análisis descriptivo de los resultados de las valuaciones de las percepciones. Al contar con 33 participantes en el experimento, se vio afectada la significatividad estadística, sin embargo, los resultados son sugerentes y en gran medida consecuentes con lo esperado.

Podemos ver que como sucedió en el experimento II, en promedio, la gente evaluó mejor la capacidad del algoritmo por sobre la capacidad propia. La capacidad promedio percibida del algoritmo fue de 3,37 levemente mayor a la capacidad promedio auto percibida que fue de 3,35.

La Influencia percibida promedio fue de 2,78, es decir los participantes percibieron poco influidos por el algoritmo.

El Arrepentimiento promedio fue de 2,25 y el valor máximo fue 4, nadie calificó su nivel de arrepentimiento en 5. Al igual que en el experimento II no se ven altos niveles de arrepentimiento. La percepción del Azar tuvo un promedio de 2,78, es decir una leve tendencia a afirmar que el azar tenía menor influencia en los resultados que las propias decisiones.

El rango de valuación que de las preguntas de percepción al final del experimento eran del 1 al 5.

Tabla 20 – Estadística descriptiva de las variables

Variable	Media	Desv. Est.	Min	Max	Descripción
Capacidad	3.34	0.99	1	5	Percepción de la capacidad auto percibida para decidir en el experimento.
Algoritmo	3.37	1.11	1	5	Percepción de la capacidad del algoritmo para recomendar en el experimento.
Arrepentimiento	2.25	1.06	1	4	Percepción del arrepentimiento por las decisiones tomadas en el experimento.
Influencia	2.78	1.05	1	5	Percepción de la influencia del algoritmo en las decisiones tomadas en el experimento.
Azar	2.78	1.16	1	5	Percepción del azar en los resultados experimento.

Tabla 21 – Relación entre el *Balance* y las valuaciones de percepción

	Coefficiente de correlación
Capacidad	0.047
Algoritmo	-0.199
Arrepentimiento	-0,173
Influencia	0,005
Azar	-0,444

Observamos una vez más una relación positiva entre el *Balance* y la capacidad auto percibida pero una relación débil. Es interesante destacar que, en este caso, a diferencia del experimento II existe una correlación negativa entre el *Balance* y la percepción de capacidad del algoritmo. Aquellos que obtuvieron un buen balance final percibieron menos capaz al algoritmo a pesar de la mejora en las ofertas aceptadas. Como era de esperar a mejor balance menores niveles de arrepentimiento menor percepción de que los resultados fueron producto del azar. La auto adjudicación del éxito y la atribución a factores externos, como la suerte, del fracaso es parte de la *Teoría de la Atribución* desarrollada por Heider F. *et al.* En economía conductual se realizaron numerosas investigaciones sobre el papel de la suerte en el *sesgo de autoservicio*, Rotter J. I. (1966), Feather N. T. y Simon J. G. (1971), Wortman C.

B. (1973) por ejemplo, encontraron que los sujetos que supuestamente tuvieron éxito en alguna tarea tenían menos probabilidades de atribuir su desempeño a la suerte que los sujetos que fracasaron. Se considera este sesgo como un mecanismo de defensa de la autoestima.

Por su parte, el nivel percibido de influencia del algoritmo casi no tuvo correlación con el balance final.

En comparación con el experimento II, la correlación de la variable *Balance* con las percepciones son del mismo signo excepto en la capacidad percibida del algoritmo siendo en experimento III de -0,199 y en el experimento II de 0,167. Las demás correlaciones confirman el *outcome bias*, aumentando la percepción de la capacidad propia disminuyendo el nivel de arrepentimiento y la influencia del azar. Además, vemos como indicador de la presencia del *sesgo de autoservicio*, la relación negativa de la variable *Balance* y la percepción del azar, es decir que cuando mayor era el *Balance* menor era la percepción de que este dependía del azar y mayor la adjudicación a las decisiones propias.

Para determinar si las percepciones están sesgadas por el resultado final del *Balance* debemos separar, también en esta ocasión, entre la calidad de decisión de participante y la buena o mala suerte que tuvo. La capacidad del participante se observa en la cantidad de veces que adopto la recomendación en las 5 rondas. Aquel participante que adoptara siempre la recomendación podríamos decir que su calidad de decisión fue perfecta. Por otra parte, la suerte dependía de dos factores, la suerte cuando adoptó la recomendación del algoritmo y la suerte cuando decidió por sí mismo sin esperar la recomendación. Como detallamos anteriormente, al utilizar el algoritmo el participante podría tener mala suerte si la mejor oferta aparecía en las 7 primeras ofertas que según estaba programado dejaba pasar para luego aceptar la primera oferta que supere a estas. Cuando esto sucedía el algoritmo recomendaba aceptar siempre la última oferta puesto que ninguna de las ofertas superaría la mejor oferta que apareció en las primeras 7. Para entender mejor el impacto de la mala suerte en el resultado cuando se utilizó el algoritmo cabe resaltar que si bien el ranking promedio de las 59 iteraciones donde se adoptó la recomendación fue de 4,76, en 16 ocasiones la mejor oferta apareció al principio y obligó al algoritmo a recomendar la última oferta con un ranking promedio de 12,81 mientras que en las otras 43 ocasiones el ranking promedio fue de 1,76. La suerte, cuando decidió por sí mismo, la definimos según si la oferta aceptada era mayor o

menor a la mediana de ofertas. Sin ninguna estrategia esperamos que la oferta promedio aceptada fuera la mediana de cada ronda¹¹⁴. De esta manera la variable *Suerte* está definida por las diferencias entre las ofertas aceptadas y la mediana cuando decidió por sí mismo y la diferencia entre la mediana y la oferta que recomendó el algoritmo cuando la mejor oferta estaba en las primeras 7 que aparecieron.

Tabla 22 – Relación entre Suerte y percepciones

	Coefficiente de correlación
Capacidad	0.10
Algoritmo	-0.70 ¹¹⁵
Arrepentimiento	-0.01
Influencia	-0.40 ¹¹⁶
Azar	-0.27

Podemos observar que a mayor suerte del participante se percibió más capaz y percibió al algoritmo como menos capaz fortaleciendo la presencia de los sesgos. También percibió que el experimento dependía menos de azar y se sintió menos arrepentido. Sin embargo, a diferencia del experimento II se percibió menos influido por el algoritmo cuando el azar jugó a su favor.

Respecto de la calidad de las decisiones tomadas por los participantes utilizamos la tasa de adopción de las recomendaciones como indicador. A mayor adopción mejor calidad de decisión del participante.

¹¹⁴ Probablemente los participantes siguieron una estrategia subóptima como se detalló en la página 85

¹¹⁵ Relación estadísticamente significativa (*p-value* 0.000)

¹¹⁶ Relación estadísticamente significativa (*p-value* 0.024)

Tabla 23 – Relación entre adopción y percepciones

	Coefficiente de correlación
Capacidad	-0.11
Algoritmo	0.45 ¹¹⁷
Arrepentimiento	-0.22
Influencia	0.57 ¹¹⁸
Azar	-0.14

Observamos que, respecto de la capacidad auto percibida la correlación con la tasa de adopción fue negativa. La calidad de las decisiones, nos indica que los participantes evaluaron peor su propia capacidad cuando más adoptaron las recomendaciones de aceptar la oferta. Además, como era de esperar aquellos que más adoptaron esas recomendaciones evaluaron mejor la capacidad del algoritmo y mayor su influencia. Por otra parte, a mayor adopción hubo menor nivel de arrepentimiento y menor percepción del papel del azar en los resultados.

Analizamos también las variables demográficas de género y edad. Al igual que en el experimento II observamos una diferencia de género en la capacidad auto percibida y la capacidad del algoritmo.

Tabla 24 – Percepción según género

	Hombres	Mujeres
Capacidad	3.62	3.16
Algoritmo	3.31	3.42
Arrepentimiento	2.15	2.32
Influencia	2.31	3.11
Azar	2.69	2.84

Al igual que en el experimento II las mujeres, subestimaron su propia capacidad y sobreestimaron la capacidad el algoritmo con respecto a los hombres, también manifestaron sentirse menos artífices de los resultados, creyéndose levemente más influenciadas por el

¹¹⁷ Relación estadísticamente significativa (*p-value* 0.008)

¹¹⁸ Relación estadísticamente significativa (*p-value* 0.000)

algoritmo. Vemos también mayor arrepentimiento por parte de las mujeres y mayor percepción del azar en los resultados. Más allá de que las mujeres adoptaron en mayor medida la recomendación, tuvieron también más “paciencia” en general. La oferta promedio aceptada por las mujeres, en la que no adoptaron la recomendación, fue la 7,17, y la de los hombres 6,78. Esta pequeña diferencia de paciencia, tuvo un impacto en el ranking de la oferta aceptada de casi una posición, de 6 a 7 respectivamente.

Por último, analizamos la percepción según la edad de los participantes que fueron entre 19 y 68 años.

Tabla 25 – Percepción según edad

	Coefficiente de correlación
Capacidad	0.063
Algoritmo	0.244
Arrepentimiento	0.031
Influencia	0.152
Azar	0.079

Podemos observar una correlación positiva de todas las percepciones con la *edad*. Esto ocurre a diferencia del experimento II que tenían coeficientes negativos en la capacidad auto percibida, así como en la percepción de arrepentimiento. Sin embargo, estos dos coeficientes son bajos.

e. Conclusión

No observamos una curva de adopción creciente con cada iteración. Sin embargo, sí pudimos observar una caída en la tasa de adopción de las recomendaciones siguientes luego de un escenario adverso. Cuando el participante había adoptado la recomendación del algoritmo y por cuestiones de azar el escenario era adverso a la recomendación, estos adoptaban en menor medida las siguientes recomendaciones. Estos resultados coinciden con los resultados del experimento II. Es decir que los participantes comienzan con un cierto nivel de confianza en los algoritmos, pero esta cae luego de un escenario adverso a la recomendación.

Observamos que los participantes no siempre tuvieron paciencia a esperar la recomendación del algoritmo de aceptar la oferta que se tradujo en un peor desempeño. Este resultado enfatiza la importancia de la facilidad de uso como atributo necesario para la adopción de la tecnología y los algoritmos.

Hubo diferencias significativas en la adopción de las recomendaciones según el género, así como en las preguntas cualitativas de auto percepción. Observamos que las mujeres adoptaron en mayor medida las recomendaciones del algoritmo y adicionalmente se percibieron menos capaces y percibieron en mayor medida la utilidad del algoritmo y su nivel de influencia sobre sus decisiones.

La suerte o la mala suerte influyo en todas las preguntas cualitativas en el sentido esperado por los sesgos de *Outcome* y *Autoservicio*.

VI. Conclusiones Generales

La hipótesis original de la tesis consistía en demostrar que la curva de aprendizaje en la utilización de los algoritmos, es decir a mayor cantidad de iteraciones, mayor adopción de las recomendaciones del algoritmo, se podía ver modificada por una mala experiencia con el algoritmo producto del azar, no de la calidad de la recomendación.

Evaluamos si la curva de aprendizaje se modificaba en los experimentos II y III, luego de que un resultado aleatorio perjudicara al participante por haber adoptado la recomendación del algoritmo

En el experimento I, en un marco de decisiones de certidumbre, observamos un aprendizaje rápido y luego estabilidad. En los experimentos II y III esto no ocurrió, e incluso, a pesar de que las iteraciones no fueron significativas en la tasa de adopción de las recomendaciones, el signo del coeficiente fue negativo, es decir que, disminuyó la adopción del algoritmo con cada iteración.

En el experimento II se comprobó, que un mal resultado genera una disminución en la adopción de las siguientes recomendaciones, es decir que, los usuarios no lograron percibir la diferencia entre la calidad de la decisión, y los resultados que, a corto plazo, pudieron ser adversos.

En el experimento III, tampoco se pudo corroborar la curva de aprendizaje¹¹⁹, y también vimos una caída en la tasa de adopción luego de un mal resultado producto del azar. Creemos que los usuarios de sistemas de recomendación pueden tener la misma interpretación y el mismo comportamiento observado cuando un algoritmo falla que cuando el algoritmo no falla, pero el escenario es adverso por cuestiones de azar. Este punto es crucial en el desarrollo y la adopción de sistemas de recomendación porque las condiciones de riesgo e incertidumbre pueden ser tan o más comunes que las fallas o errores de los sistemas y a diferencia de estos no pueden ser corregidos.

Pudimos además evidenciar que la impaciencia para esperar la recomendación del algoritmo, subrayando la importancia de la facilidad de uso de los algoritmos, y del costo que la impaciencia les generó a los participantes.

¹¹⁹ Tomamos el modelo II que tiene un R^2 y la constante con mayor significatividad.

Por otra parte, los experimentos han resultado reveladores en aspectos que podrían aplicarse para futuras investigaciones:

Como primer punto, vemos que, en cada uno de los experimentos, el algoritmo logró mejorar los resultados de los participantes, y podrían haber mejorado aún más, de haber sido adoptados en más ocasiones. Esta condición de superioridad del algoritmo es necesaria para su adopción, pero también pudimos corroborar que no es suficiente.

Es decir que la superioridad de los algoritmos por sí sola no alcanza para la adopción de estos, es necesario que los usuarios entiendan cómo funcionan, puedan involucrarse en el proceso, confíen en quién desarrolló el algoritmo y que resulte fácil de utilizar, entre otros factores.

Como segundo aspecto a destacar, hemos observado que los beneficios de la utilización de algoritmos en la vida cotidiana, puede que beneficie de manera distinta a los diferentes tipos de usuarios. En nuestros experimentos las mujeres han sido más propensas a adoptar las recomendaciones del algoritmo en los experimentos I y III, y en el experimento II, si tomamos en cuenta que también existía la posibilidad de coincidir con la recomendación, las mujeres decidieron igual que el algoritmo levemente más que los hombres. Las mujeres se auto percibieron menos capaces que los hombres, y percibieron más capaz al algoritmo y su influencia en las decisiones que los hombres.

Hemos mencionado las numerosas investigaciones respecto de la autoconfianza como variable explicativa en las diferencias de sueldo entre hombres y mujeres que podrían aplicarse a estos resultados. Los atributos observados en nuestros experimentos sobre las mujeres pueden ser explotados positivamente para mejorar sus decisiones en general y sus finanzas en particular. Es decir, los algoritmos ayudan a tomar mejores decisiones y las mujeres confían más en los algoritmos que los hombres. La mayor confianza de las mujeres en los algoritmos, podría ser una herramienta para acotar dicha brecha, por ejemplo, en caso de utilizar algoritmos de negociación.

El tercer y último punto por destacar es que, los balances obtenidos por los participantes tuvieron coeficientes de correlación con las preguntas de percepción que en su mayoría fortalecieron la idea de la presencia de sesgos de *autoservicio* y de *outcome*. La capacidad auto percibida tuvo relación positiva con los balances finales y relación negativa con el nivel

de arrepentimiento. Respecto de la capacidad percibida del algoritmo obtuvimos resultados mixtos entre los experimentos II y III. En otras palabras, los resultados positivos fortalecieron la percepción de haber tomado buenas decisiones, y el grado de arrepentimiento fue menor.

VII. Anexo I

Experimento I

Las variables de este experimento fueron las siguientes:

Variable	Descripción
<i>id</i>	Número aleatorio asignado a cada participante
<i>pregunta</i>	Número de ronda / iteración. Valores 1 a 6
<i>Costo</i>	Costo del viaje programado por el participante
<i>pagoItinerario</i>	Estimación del ahorro que puede generar el algoritmo antes de consultar
<i>pagoCliente</i>	Disposición a pagar por consultar el algoritmo. Valores 0\$ a 6\$
<i>dado</i>	Número sorteado aleatoriamente. Valores 1 a 6 y el pago es según lo sorteado
<i>activo</i>	1 si pudo consultar el algoritmo 0 si no. Variable <i>dummy</i>
<i>costoSugerido</i>	Costo mínimo del viaje sugerido por el algoritmo
<i>CostoMaximo</i>	Costo máximo posible
<i>ahorro</i>	$costo - costoSugerido$
<i>sexo</i>	1 mujer 0 hombre. Variable <i>dummy</i>
<i>edad</i>	Edad del participante
<i>balance</i>	Resultado final del ejercicio 1.200\$ menos los costos de viajes y consultas

1. Como primer paso indicamos en Stata que estamos trabajando con datos de panel, donde *id* es la variable transversal y *pregunta* la variable tiempo

Xtset	id ronda
panel variable:	id (strongly balanced)
time variable:	ronda, 1 to 6
delta:	1 unit

2. Evaluamos la regresión GLS con las variables que sospechamos son significativas

Random-effects GLS regression	Number of obs	262
Group variable: id	Number of groups	57
R-sq:	Obs per group:	
within = 0.0338	min	1
between = 0.1273	Avg	4.6
overall = 0.0279	max	6
	Wald chi2(4)	11.18
corr(u_i, X) = 0 (assumed)	Prob > chi2	0.0480

pagoCliente	Coef.	Error Est.	Z	P>z	[95% Intervalo Conf.]	
EstAhorro	.0137188	.0108805	1.26	0.207	-.0076066	.0350441
ronda	.0932672	.0387058	2.41	0.016	.0174053	.1691291
ahorro	-.008677	.0168965	-0.51	0.608	-.0417934	.0244395
edad	.0064083	.0147788	0.43	0.665	-.0225577	.0353742
l.sexo	.2983386	.321401	0.93	0.353	-.3315957	.9282729
_cons	3.77152	.6543172	5.76	0.000	2.489082	5.053958

Observamos que solo la variable ronda es significativa y queremos asegurar de que no sea sólo entre la primer y segunda ronda. Además, al eliminar las variables menos significativas, pagoItinerario adquiere significancia.

Experimento II

El resto de las variables colectadas son las siguientes:

Variable	Descripción
<i>id</i>	Número aleatorio asignado a cada participante
<i>difper</i>	Diferencia en la pérdida por el pago de franquicia entre la cobertura original y la cobertura recomendada.
<i>Pereal</i>	La pérdida por franquicia según la elección final del participante.

<i>Aumfran</i>	Recomendación del algoritmo de aumentar la franquicia respecto de la cobertura original. Variable dummy, valores 1 y 0
<i>Bajfran</i>	Recomendación del algoritmo de bajar la franquicia respecto de la cobertura original. Variable dummy, valores 1 y 0
<i>Difpri</i>	Diferencia entre la prima del algoritmo respecto de la prima de la cobertura original
<i>Coinc</i>	Coinciden la recomendación del algoritmo y la cobertura original elegida por el participante. Variable <i>dummy</i> , valores 1 y 0
<i>Algoritmo</i>	Percepción de la capacidad del algoritmo para recomendar en el experimento. Valores de 1 a 5
<i>Arrepentimiento</i>	Percepción del arrepentimiento por las decisiones tomadas en el experimento. Valores de 1 a 5
<i>Inluencia</i>	Percepción de la influencia del algoritmo en las decisiones tomadas en el experimento. Valores de 1 a 5
<i>Azar</i>	Percepción del azar en los resultados experimento. Valores de 1 a 5
<i>sexo</i>	1 mujer 0 hombre. Variable dummy
<i>edad</i>	Edad del participante
<i>Balance</i>	Resultado final del ejercicio 1.200\$ menos las primas pagadas y las franquicias

- 1 Indicamos en Stata, al igual que en el primer experimento, que estamos trabajando con datos de panel donde *id* es la variable transversal y *pregunta* la variable tiempo

Xtset	id ronda
panel variable:	id (strongly balanced)
time variable:	ronda, 1 to 10
delta:	1 Unit

- 2 Tests de Chi cuadrado

	Hombres	Mujeres	
	160	220	Total
Rechazo	61	82	143
Esperada	60.2	82.8	
Coincidió	65	112	177
Esperada	74.5	102.5	
Acepto	34	26	60
Esperada	25.3	34.7	

P-value=0.025

	Mantener o subir	Bajar franquicia	
	339	41	Total
Rechazo	121	22	143
Esperada	127.6	15.4	
Coincidió	177	0	177
Esperada	159.7	19.1	
Acepto	41	19	60
Esperada	53.5	6.5	

P-value=0.000

	Hombres	Mujeres	Total
No Rechazo	99	138	237
Esperada	99.8	137.2	
Rechazo	61	82	143
Esperada	60.2	82.8	
	160	220	

P-value=0.866

Experimento III

Las variables recolectadas en el experimento fueron las siguientes:

Variable	Descripción
<i>id</i>	Número aleatorio asignado a cada participante
<i>Tabla</i>	Número de ronda / iteración. Valores 1 a 5
<i>valor</i>	Valor de la oferta aceptada
<i>Ranking</i>	Jerarquía de propuesta aceptada. Valores 1 a 19
<i>Nro oferta</i>	Número de propuesta aceptada. Valores 1 a 19
<i>Acept</i>	Acepta la recomendación del algoritmo. Variable <i>dummy</i> , valores 1 y 0
<i>Capacidad</i>	Percepción de la capacidad auto percibida para decidir en el experimento. Valores de 1 a 5
<i>Algoritmo</i>	Percepción de la capacidad del algoritmo para recomendar en el experimento. Valores de 1 a 5
<i>Arrepentimiento</i>	Percepción del arrepentimiento por las decisiones tomadas en el experimento. Valores de 1 a 5
<i>Influencia</i>	Percepción de la influencia del algoritmo en las decisiones tomadas en el experimento. Valores de 1 a 5
<i>Azar</i>	Percepción del azar en los resultados experimento. Valores de 1 a 5
<i>sexo</i>	1 mujer 0 hombre. Variable <i>dummy</i>
<i>edad</i>	Edad del participante
<i>balance</i>	Resultado final del ejercicio suma de las ofertas aceptadas

1. Nuevamente indicamos en Stata que estamos trabajando con datos de panel donde *id* es la variable transversal y *Tabla* de tiempo

Xtset	id Ronda
panel variable:	id (strongly balanced)
time variable:	Ronda, 1 to 5
delta:	1 unit

2. Luego, investigamos qué variables pueden influir en la probabilidad de aceptar la recomendación. Debido a que *Acepta* es la variable dependiente, y es una variable *dummy*, utilizaremos la función *Probit* que mejor se adecua a este tipo de distribución

Iteration	0:	Log likelihood	=	-106.68992
Iteration	1:	Log likelihood	=	-82.396732
Iteration	2:	Log likelihood	=	-82.171817
Iteration	3:	Log likelihood	=	-82.171503
Iteration	4:	Log likelihood	=	-82.171503

Probit regression	Number of obs	163
	LR chi2(4)	49.04
	Prob > chi2	0.0000
Log likelihood = -82.171503	Pseudo R2	0.2298

Accept	Coef.	Std. Err.	Z	P>z	[95% Intervalo Conf.]
Ronda	-.0976275	.0792195	-1.23	0.218	-.2528949 .0576398
sexo	.5501726	.2405042	2.29	0.022	.078793 1.021552
edad	.0099037	.0105504	0.94	0.348	-.0107747 .0305822
Nroferta	.1131374	.0206341	5.48	0.000	.0726954 .1535794
_cons	-1.765323	.5358791	-3.29	0.001	-2.815627 -.715019

3. Impaciencia

La impaciencia, no se produjo por una elección inter-temporal como en el experimento *Stanford marshmallow experiment*¹²⁰ y otros subsiguientes como Kirby et al¹²¹, quienes

¹²⁰ Mischel, W., Ebbesen, E. B., & Raskoff Zeiss, A. (1972). Cognitive and attentional mechanisms in delay of gratification. *Journal of personality and social psychology*, 21(2), 204.

¹²¹ Kirby, K. N., Winston, G. C., & Santiesteban, M. (2005). Impatience and grades: Delay-discount rates correlate negatively with college GPA. *Learning and individual Differences*, 15(3), 213-222.

realizaron una serie de experimentos donde estudiantes universitarios debían decidir entre dos premios con distintas tasas de descuento inter-temporales, y encontraron una fuerte relación entre la paciencia y la capacidad cognitiva medida por las notas del GPA de los participantes.

Borghans, Meijers y Weel ¹²², ponen en duda si la capacidad cognitiva es la que impulsa la paciencia para posponer un beneficio. “En un esfuerzo por determinar si los diferentes tipos de personas responden de manera diferente a los incentivos financieros, encontraron que los parámetros como las bajas tasas de descuento y la baja aversión al riesgo, están asociados con fuertes respuestas a los incentivos. Por otro lado, las características psicológicas favorables, como la motivación para el desempeño y el auto control, se asocian con respuestas más bajas a los incentivos financieros.”

¹²² Borghans, L., Meijers, H., & Ter Weel, B. (2008). The role of noncognitive skills in explaining cognitive test scores. *Economic inquiry*, 46(1), 2-12.

VIII. Anexo II

La siguiente cotización se realizó el día 11/04/2020 basada en mis datos personales y mi auto.

The screenshot displays three insurance plans side-by-side. The first plan, 'iúnigoBASE', has a monthly premium of \$2.142 and a market average of \$2.520. The second plan, 'iúnigoMÁS', has a monthly premium of \$3.840 and includes 'Terceros completo + cristales + granizo'. The third plan, 'iúnigoFULL', is selected (marked '+ Elegido') and has a monthly premium of \$5.278, 'Todo riesgo', and a deductible of \$27,000. A 'Contratá online' button is visible at the bottom right.

Plan	Precio mensual	Ahorros	Cobertura
iúnigoBASE	\$2.142	-	Responsabilidad civil + totales.
iúnigoMÁS	\$3.840	\$3.840,49	Terceros completo + cristales + granizo.
iúnigoFULL	\$5.278	\$5.278,06	Todo riesgo. Tu franquicia: \$27.000

La cotización es de 5.278\$ por mes, con una franquicia de 27.000\$. El cotizador coloca los 27.000\$ como default, pero permite cambiar el monto de la franquicia.

The screenshot shows a dropdown menu titled 'Seleccioná la franquicia'. It lists various deductible amounts and their corresponding monthly premiums. The \$10,000 option is selected.

Franquicia	Precio mensual
\$10.000	(\$6.735 ¹⁷ por mes)
\$11.000	(\$6.494 ¹⁸ por mes)
\$12.000	(\$6.401 ³¹ por mes)
\$13.000	(\$6.311 ⁶⁸ por mes)
\$14.000	(\$6.225 ¹⁸ por mes)
\$15.000	(\$6.141 ⁷² por mes)
\$16.000	(\$6.061 ¹⁸ por mes)
\$17.000	(\$5.992 ⁸⁹ por mes)
\$18.000	(\$5.852 ⁵⁵ por mes)
\$19.000	(\$5.783 ³⁸ por mes)
\$20.000	(\$5.719 ⁹⁶ por mes)

Elegimos arbitrariamente la franquicia más baja para mostrar el cálculo matemático.



La diferencia en la prima mensual entre los dos niveles de franquicia será igual a 1.457\$ (6.735\$ - 5.278\$), es decir, pagaríamos una prima anual extra de 17.484\$ un tanto mayor a la diferencia entre las franquicias que es 17.000\$ (27.000\$ - 10.000\$). Para que a un asegurado le conviniese adquirir la cobertura con la franquicia más baja, debería estar seguro de que en ese año tendrá una probabilidad del 100% de tener un siniestro con daños mayores a 27.000\$. Otra forma de presentar el absurdo económico de comprar una franquicia tan baja es la comparación entre lo que se paga por cada parte de la cobertura.

Podemos descomponer la prima en dos partes:

1. 5.278\$ por la cobertura de siniestros, con un límite de hasta 6 millones¹²³ de pesos
2. 1.457\$ por la cobertura extra de 17.000\$

Desconocemos la proporción de personas que compra con franquicia baja, pero en el mercado en general la norma es esa. El mero hecho de colocar la franquicia más alta como default ya es un gran paso a favor de los asegurados.

¹²³ Cobertura legal vigente

IX Anexo III

Protocolo de los experimentos

En todos los experimentos se envió un mail, o se colocó este texto en una plataforma para ser leído por el participante:

“Estimada/o,

Te envío este link para que participes de un ejercicio que forma parte de mi tesis doctoral en economía:

https://script.google.com/macros/s/AKfycbx96BQyURXfLkgV_NLZsTuWZw9M77pGbFkwFrodnbSH8L2o0eU/exec

Te pido por favor lo realices cuando estés tranquilo y frente a una computadora. Es importante leer las instrucciones y ver el video explicativo.

El ejercicio dura unos 20 minutos aproximadamente y puede resultar divertido, si lo tomas como un juego.

Hay un pequeño premio en dinero para quienes obtengan los mejores resultados. Si querés participar del premio te pido me envíes un mail con el resultado que obtuviste al final del ejercicio donde dice "Balance".

Desde ya muchas gracias, y estoy a disposición ante cualquier duda o sugerencia.

Sebastián Visotsky”

Experimento I

Planeamiento de ruta

Introducción

Usted está por participar de un experimento académico para una tesis de economía. Para ello debe imaginarse que usted es un agente de turismo y debe programar un viaje por 7 ciudades (**las ciudades A, B, C, D, E, F, G, H**). Su objetivo es que todo el itinerario sea lo menos costosos posible. Se sale siempre desde la ciudad A y se debe pasar por todas las ciudades, es decir 6 viajes/tramos.

Para contestar este cuestionario puede utilizar computadoras y teléfonos con acceso a internet. Tiene a su disposición, luego de cada pregunta, un algoritmo que le ayudara con las preguntas de "programación de ruta". El algoritmo es un conjunto de cálculos que hemos programado para encontrar la mejor solución para este problema. Sin embargo, el uso del algoritmo no es gratuito, se paga.

Se le entregará **1200\$** virtuales y estará obligado a participar de todas las rondas del cuestionario. De esos 1200\$ se irán descontando los costos del viaje que programe o los costos del viaje sugerido por el algoritmo y el pago por utilizar el algoritmo. Su objetivo es retener la mayor cantidad de dinero, con el dinero virtual que quede en su poder podrá participar de un sorteo por 500\$ (de verdad, no virtuales) entre los participantes (mientras más dinero más chances) y el participante que retenga la mayor suma recibirá sin sorteo 500\$.

- Sus datos y respuestas serán anónimos.
- No haremos preguntas capciosas ni intentaremos engañarlo.
- Las preguntas son simples y le pedimos haga un esfuerzo por intentar tomar las decisiones de la manera en que lo haría en una situación real.
- El ejercicio es individual.
- Cualquier duda o consulta, envíenos un correo a sebi.visotsky@gmail.com.

Luego aparece un video instructivo con un ejemplo para que el participante entienda cómo realizar el ejercicio:

• Mira el siguiente video para ver cómo funciona. [DEMOSTRACION](#)

B	\$ 0	\$ 27,96	\$ 5,98	\$ 26,8	\$ 3,24	\$ 4,65
C	\$ 27,96	\$ 0	\$ 18,54	\$ 10,54	\$ 15,94	\$ 2,8
D	\$ 5,98	\$ 18,54	\$ 0	\$ 23,08	\$ 15,82	\$ 5,64
E	\$ 26,8	\$ 10,54	\$ 23,08	\$ 0	\$ 21,18	\$ 4,16
F	\$ 3,24	\$ 15,94	\$ 15,82	\$ 21,18	\$ 0	\$ 26,16
G	\$ 4,65	\$ 2,8	\$ 5,64	\$ 4,16	\$ 26,16	\$ 0

8. Seleccione las rutas de interés.

Viaje 1 ? ▾ Viaje 2 ? ▾ Viaje 3 ? ▾ Viaje 4 ? ▾ Viaje 5 ? ▾ Viaje 6 ? ▾

Costo

9. ¿Cuánto crees es lo mas barato que se puede pagar por todo el itinerario?

\$

Primero debe completar sexo y edad, y luego procede a realizar 6 rondas de programación como la siguiente:

1. Programar el siguiente viaje para que cueste lo menos posible. Se sale de A y debe pasar por todas las ciudades. No vuelve al punto A es decir 6 viajes

Cuadro tarifario 1	B	C	D	E	F	G
A	\$ 9,42	\$ 5,98	\$ 9,46	\$ 8,36	\$ 7,2	\$ 10,04
B	\$ 0	\$ 2,98	\$ 4,28	\$ 7,62	\$ 6,72	\$ 7,3
C	\$ 2,98	\$ 0	\$ 6,54	\$ 9,66	\$ 3,32	\$ 6,52
D	\$ 4,28	\$ 6,54	\$ 0	\$ 7,96	\$ 8,84	\$ 4,78
E	\$ 7,62	\$ 9,66	\$ 7,96	\$ 0	\$ 5,64	\$ 9,58
F	\$ 6,72	\$ 3,32	\$ 8,84	\$ 5,64	\$ 0	\$ 9,36
G	\$ 7,3	\$ 6,52	\$ 4,78	\$ 9,58	\$ 9,36	\$ 0

2. Seleccione las rutas de interés.

? ? ? ? ? ?

El participante procede a colocar una ciudad en cada uno de los casilleros de “Viaje 1, Viaje 2, etc.”, según lo que considera puede hacer el viaje más económico.

2. Seleccione las rutas de interés.

C E B F G ?

3. ¿Cuánto más barato crees que se puede pagar por todo el itinerario?

\$

Te permitimos ahora consultar el algoritmo “Programación de Ruta”. Para ello debes ofrecer pagar por el servicio entre 1\$ y 6\$. Se arrojará un dado y el número que salga será el precio mínimo. Si ofreciste igual o por arriba de ese precio podrás usar el algoritmo al precio que salió sorteado.

? 0 

4. ¿Activar el algoritmo?

Si

Cuando termina de programar, en el botón de “Costo” aparecerá el costo total de los viajes por las 7 ciudades acorde a su programación.

2. Seleccione las rutas de interés.

Viaje 1 C ▾ Viaje 2 E ▾ Viaje 3 B ▾ Viaje 4 F ▾ Viaje 5 G ▾ Viaje 6 D ▾

\$ 44.12

3. ¿Cuánto más barato crees que se puede pagar por todo el itinerario?

\$

Te permitimos ahora consultar el algoritmo "Programación de Ruta". Para ello debes ofrecer pagar por el servicio entre 1\$ y 6\$. Se arrojará un dado y el número que salga será el precio mínimo. Si ofreciste igual o por arriba de ese precio podrás usar el algoritmo al precio que salió sorteado.

Pago ? ▾ Dado 

4. ¿Activar el algoritmo?

Sí

En la pregunta 3, el participante debe estimar cuánto más barato cree se puede programar el itinerario. Luego, donde dice pago, debe elegir cuánto está dispuesto a pagar por consultar el algoritmo. En caso de no querer consultar puede saltar esa parte.

2. Seleccione las rutas de interés.

Viaje 1 C ▾ Viaje 2 E ▾ Viaje 3 B ▾ Viaje 4 F ▾ Viaje 5 G ▾ Viaje 6 D ▾

\$ 44.12

3. ¿Cuánto más barato crees que se puede pagar por todo el itinerario?

\$

Te permitimos ahora consultar el algoritmo "Programación de Ruta". Para ello debes ofrecer pagar por el servicio entre 1\$ y 6\$. Se arrojará un dado y el número que salga será el precio mínimo. Si ofreciste igual o por arriba de ese precio podrás usar el algoritmo al precio que salió sorteado.

Pago ? ▾ Dado 

4. ¿Activar el algoritmo?

Sí

Luego de elegir el pago, el participante debe presionar el dado, si lo sorteado es igual o menor a lo que está dispuesto a pagar, el algoritmo se activa y puede consultarlo.

Pago 6 ▾ Dado 2 

4. ¿Activar el algoritmo?
 Sí

[Programación de Ruta](#)

5. Si utilizaste el algoritmo verás las rutas recomendadas y su costo

Sugeridos	-	-	-	-	-	-
Costo Sugerido	x			Costo Máximo	x	

6. Con el algoritmo ahorraste:

\$

Luego presiona “Programación de Ruta”, y el algoritmo le recomendará la mejor combinación y le mostrará cuál es el costo sugerido, también cuál podría haber sido el costo máximo y cuánto ahorró utilizando el algoritmo

4. ¿Activar el algoritmo?
 Sí

[Programación de Ruta](#)

5. Si utilizaste el algoritmo verás las rutas recomendadas y su costo

Sugeridos	E	F	C	B	D	G
Costo Sugerido	29.36			Costo Máximo	52.54	

6. Con el algoritmo ahorraste:

\$

En caso de que lo ofrecido sea menor al sorteo, el participante no podrá usar el algoritmo.

1\$ y 6\$. Se arrojará un dado y el número que salga será el precio mínimo. Si ofreciste igual o por arriba de ese precio podrás usar el algoritmo al precio que salió sorteado.

Pago 1 Dado 4 

4. ¿Activar el algoritmo?
 Si

Programación de Ruta

5. Si utilizaste el algoritmo verás las rutas recomendadas y su costo

Sugeridos	-	-	-	-	-	-
Costo Sugerido	x			Costo Máximo	x	

6. Con el algoritmo ahorraste:

\$ 0

Al ofrecer menos de lo sorteado, el algoritmo no puede ser activado.

Experimento II

Encuesta II

Introducción

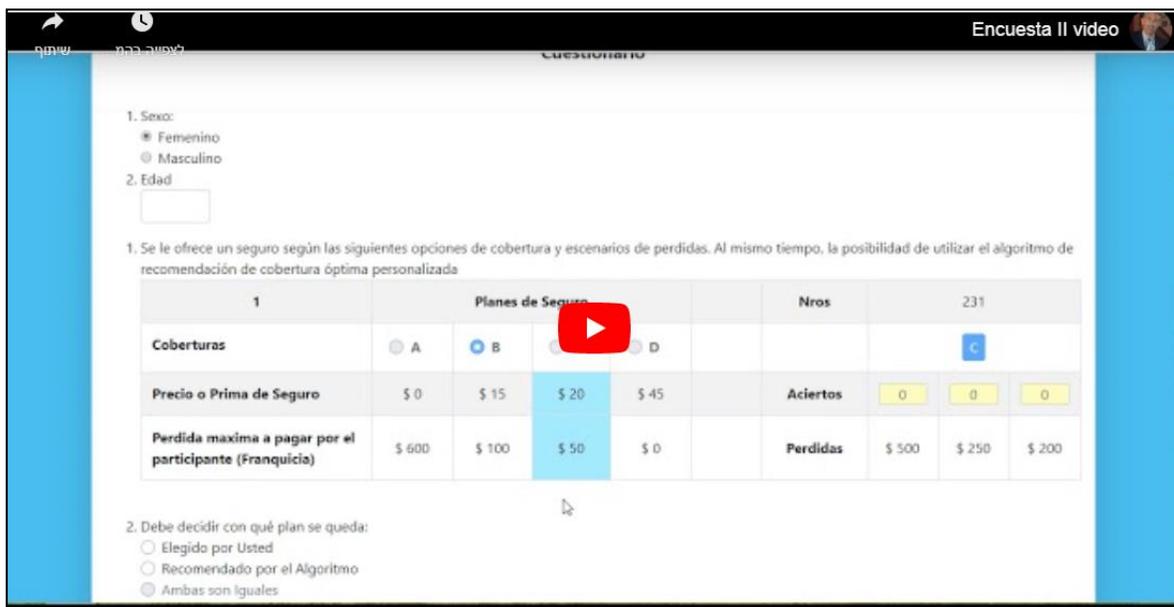
Usted está participando en un experimento académico para una tesis de economía. Para ello usted debe imaginarse que usted va a participar de un juego de quiniela en el cual quien acierta los números pierde dinero (a diferencia de la quiniela real en el cual quien acierta gana). Para contestar este cuestionario puede utilizar computadoras y celulares con acceso a internet. En cada sorteo se le pedirá elegir un plan de seguro que cubrirá las posibles pérdidas. Tiene a su disposición, luego de cada elección de plan de seguro, un algoritmo que le recomendará que plan elegir (botón "Recomendador"). Los planes dicen cuál es la prima o precio a pagar por la cobertura y cuanto es la pérdida máxima o franquicia que pagara en caso de perder dinero en el sorteo. La franquicia es la parte de la pérdida que usted debe pagar, pérdidas que son mayores a ese monto las cubrirá la aseguradora. Por ejemplo, supongamos que usted participa con el número 253 y eligió el plan de seguros "A" por una prima de 50\$ y una pérdida máxima/franquicia de 200\$ es decir la parte que paga uds en caso de pérdida y por arriba de esta pérdida los paga la aseguradora. Las pérdidas estipuladas para este sorteo son de 100\$ si coincide el último dígito, 250\$ si coinciden los dos últimos y 500\$ si coinciden los tres dígitos. Ahora veamos que puede suceder en distintos escenarios:

- Sale sorteado el número: 2 2 1 no coincide el ultimo dígito sorteado (1) con el dígito que participábamos (3 del 2 5 3).
- Sale sorteado el número: 4 2 3 que coincide el ultimo dígito sorteado (3) con el dígito que participábamos (3 del 2 5 3) es decir perdemos 100\$. Como la pérdida máxima/franquicia que no cubre el seguro es de 200\$ debo pagar los 100\$.
- Sale sorteado el número: 4 5 3 que coincide los dos últimos dígitos sorteado (5 3) con los dígitos con los que participábamos (5 3 del 2 5 3) es decir perdemos 250\$. Como la pérdida máxima/franquicia que no cubre el seguro es de 200\$ debo pagar solo 200\$ y el resto los paga el seguro.
- Sale sorteado el número: 2 5 3 que coincide con el número completo con el que participábamos (2 5 3) es decir perdemos 500\$. Como la pérdida máxima/franquicia que no cubre el seguro es de 200\$ debo pagar solo los 200\$ y el resto lo paga el seguro.

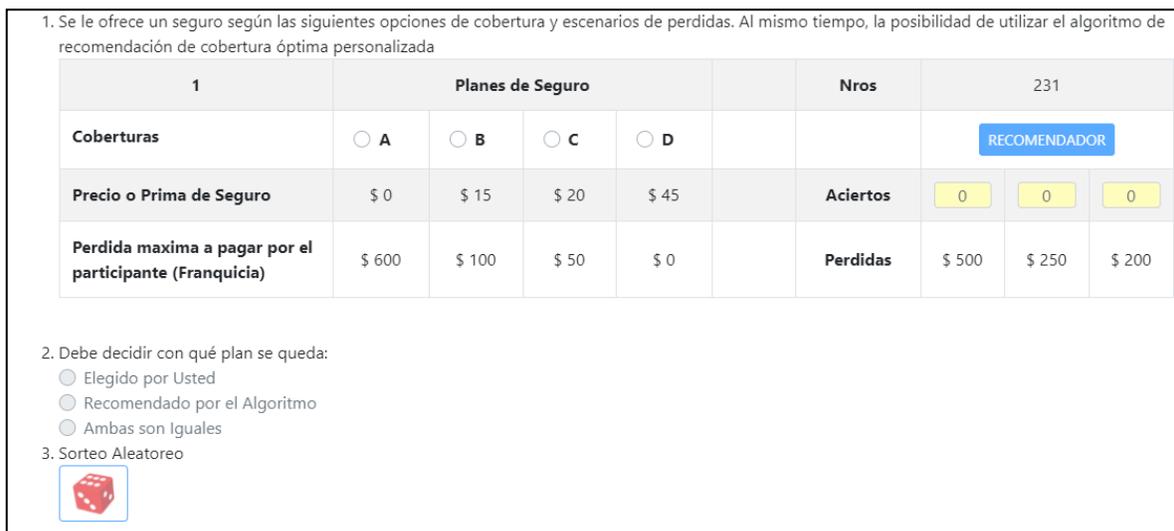
Se les entregará 1200\$ virtuales y estará obligado a participar de cada ronda del cuestionario. Su objetivo es retener la mayor cantidad de dinero, con el dinero virtual que quede en su poder podrá participar de un sorteo por 500\$ (de verdad, no virtuales) entre los participantes (mientras más dinero más chances) y el participante que retenga la mayor suma recibirá sin sorteo 500\$.

- Sus datos y respuestas serán anónimos.
- No haremos preguntas capciosas ni intentaremos engañarlo.
- Las preguntas son simples y le pedimos haga un esfuerzo por intentar tomar las decisiones de la manera en que lo haría en una situación real.
- El ejercicio es individual
- Cualquier duda o consulta, envíenos un correo a sebi.visotsky@gmail.com.
- A continuación, mostraremos un ejemplo de cómo realizar el ejercicio.
- Mira el siguiente video para ver cómo funciona. [DEMOSTRACION](#)

Luego aparece un video instructivo con un ejemplo para que el participante entienda cómo realizar el ejercicio:



Primero debe completar sexo y edad y luego procede a realizar 10 rondas de elección como la siguiente:



Supongamos que el participante elige la cobertura “D”, luego de eso, el botón “RECOMENDADOR” se habilita, y el participante presiona para recibir la recomendación del algoritmo

recomendación de cobertura óptima personalizada

1	Planes de Seguro				Nros	231		
Coberturas	<input type="radio"/> A	<input type="radio"/> B	<input type="radio"/> C	<input checked="" type="radio"/> D		RECOMENDADOR		
Precio o Prima de Seguro	\$ 0	\$ 15	\$ 20	\$ 45	Aciertos	0	0	0
Perdida máxima a pagar por el participante (Franquicia)	\$ 600	\$ 100	\$ 50	\$ 0	Perdidas	\$ 500	\$ 250	\$ 200

1. Se le ofrece un seguro según las siguientes opciones de cobertura y escenarios de pérdidas. Al mismo tiempo, la posibilidad de utilizar el algoritmo de recomendación de cobertura óptima personalizada

1	Planes de Seguro				Nros	231		
Coberturas	<input type="radio"/> A	<input type="radio"/> B	<input type="radio"/> C	<input checked="" type="radio"/> D		C		
Precio o Prima de Seguro	\$ 0	\$ 15	\$ 20	\$ 45	Aciertos	0	0	0
Perdida máxima a pagar por el participante (Franquicia)	\$ 600	\$ 100	\$ 50	\$ 0	Perdidas	\$ 500	\$ 250	\$ 200

2. Debe decidir con qué plan se queda:

- Elegido por Usted
- Recomendado por el Algoritmo
- Ambas son Iguales

En este caso el algoritmo recomienda la cobertura “C”, por eso, en la pregunta 2, la opción “Ambas son iguales” se anula. Si la elección y la recomendación hubieran sido iguales se habrían anulado las otras opciones.

Ahora el participante debe elegir si mantiene su elección original, es decir cobertura “D” o adopta la recomendación del algoritmo y elige la cobertura “C”. Supongamos que eligió mantener su elección original, ahora se habilita el dado para realizar el sorteo que determinará si sufrirá alguna pérdida.

1	Planes de Seguro				Nros	231
Coberturas	<input type="radio"/> A	<input type="radio"/> B	<input type="radio"/> C	<input checked="" type="radio"/> D		<input checked="" type="radio"/> C
Precio o Prima de Seguro	\$ 0	\$ 15	\$ 20	\$ 45	Aciertos	0 0 0
Perdida maxima a pagar por el participante (Franquicia)	\$ 600	\$ 100	\$ 50	\$ 0	Perdidas	\$ 500 \$ 250 \$ 200

2. Debe decidir con qué plan se queda:

Elegido por Usted
 Recomendado por el Algoritmo
 Ambas son Iguales

3. Sorteo Aleatoreo



4. Perdida segun:

Su Elección: 0 Algoritmo: 0

En esta primera ronda, el participante juega con el número 231 enmarcado en rojo arriba. Cuando aprieta el dado, aparecerán aleatoriamente 3 números en los espacios enmarcados en azul. Si el número sorteado coincide en uno o más dígitos, las pérdidas serán las indicadas abajo.

1	Planes de Seguro				Nros	231
Coberturas	<input type="radio"/> A	<input type="radio"/> B	<input type="radio"/> C	<input checked="" type="radio"/> D		<input checked="" type="radio"/> C
Precio o Prima de Seguro	\$ 0	\$ 15	\$ 20	\$ 45	Aciertos	5 3 1
Perdida maxima a pagar por el participante (Franquicia)	\$ 600	\$ 100	\$ 50	\$ 0	Perdidas	\$ 500 \$ 250 \$ 200

2. Debe decidir con qué plan se queda:

Elegido por Usted
 Recomendado por el Algoritmo
 Ambas son Iguales

3. Sorteo Aleatoreo



4. Perdida segun:

Su Elección: 0 Algoritmo: 50

En este caso coincidieron los últimos dos dígitos “3 1” y por eso, la pérdida real será de \$250. Sin embargo, la franquicia de la cobertura “D”, que eligió el participante es cero, y no percibirá ninguna pérdida.

En el punto 4 se muestra automáticamente las pérdidas que tiene el participante enmarcado en rojo y también la pérdida que habría tenido el participante de haber elegido la recomendación del algoritmo (en azul).

En este caso para el balance final se descontará lo que pagó de prima, \$45 y nada más, porque la franquicia fue de cero pesos. Si hubiera elegido la cobertura “C”, se habría descontado la prima de \$20 más \$50 de franquicia.

Esto se repite 9 veces más con distintas primas, franquicias y pérdidas.

Luego se hacen cinco preguntas cualitativas sobre la percepción del participante:

41. ¿Cómo calificas tu capacidad para elegir los planes de seguro?
Nota: Antes de elegir, debe saber que 1 significa muy baja capacidad, 5 significa excelente capacidad

Valoración Selección...

42. ¿Cómo calificas la capacidad del algoritmo para aconsejarte en la elección de los planes de seguro?
Nota: Antes de elegir, debe saber que 1 significa muy baja capacidad, 5 significa excelente capacidad

Valoración Selección...

43. ¿Estas arrepentido de los planes de seguro que elegiste?
Nota: Antes de elegir, debe saber que 1 significa no estoy arrepentido, 5 significa estoy muy arrepentido

Valoración Selección...

44. ¿Qué crees influenció más en la decisión?
Nota: Antes de elegir, debe saber que 1 significa solo lo que yo pensé/creí, 5 significa hice exactamente lo que me recomendó el algoritmo

Valoración Selección...

45. ¿A qué le atribuyes los resultados?
Nota: Antes de elegir, debe saber que 1 significa solo mis propias decisiones, 5 significa solo a la suerte o mala suerte

Por último, se presiona el botón “Balance” para obtener el resultado final del experimento, donde se descontarán todas las primas y todas las franquicias pagadas.

45. ¿A qué le atribuyes los resultados?
Nota: Antes de elegir, debe saber que 1 significa solo mis propias decisiones, 5 significa solo a la suerte o mala suerte

Valoración Selección...

Balance 782

Enviar

Experimento III

Encuesta III

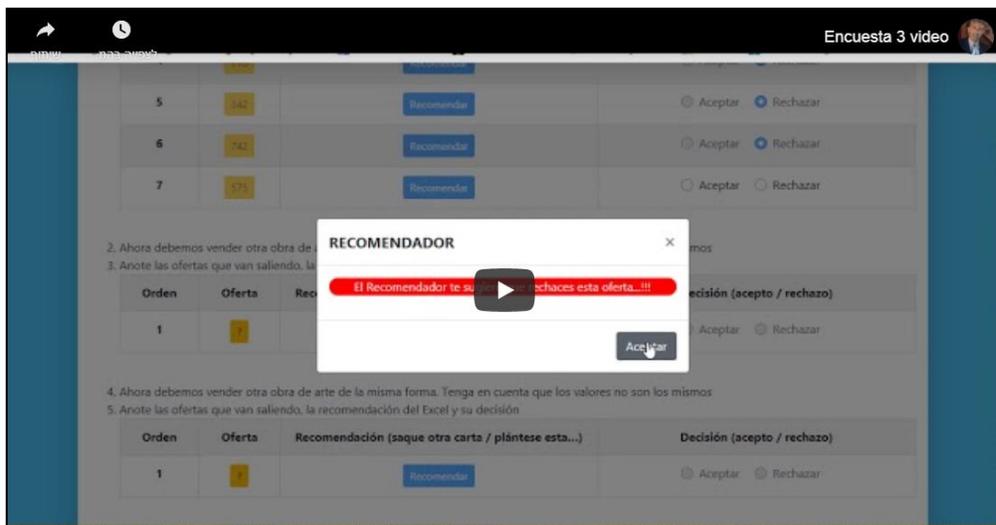
Introducción

Para contestar este cuestionario puede utilizar las computadoras con acceso a internet. Su objetivo es obtener la mayor cantidad de dinero. Con el dinero que quede en su poder participará de un sorteo por 500\$ entre los participantes y el participante que obtenga la mayor suma recibirá sin sorteo 500\$.

- Sus datos y respuestas serán anónimos.
- No haremos preguntas capciosas ni intentaremos engañarlo.
- Las preguntas son simples y le pedimos haga un esfuerzo por intentar tomar las decisiones de la manera en que lo haría en una situación real.
- El ejercicio es individual
- Cualquier duda o consulta, envíenos un correo a sebi.visotsky@gmail.com.
- A continuación, mostraremos un ejemplo de cómo realizar el ejercicio.
- Mira el siguiente video para ver cómo funciona. [DEMOSTRACION](#)

En cada una de las 5 rondas del ejercicio, usted desea vender una obra de arte, pero de la cual no tiene conocimiento de su valor real. Existen 19 personas que han hecho 19 ofertas que se irán descubriendo una por vez. Usted deberá decidir si acepta la oferta y vende la obra de arte o si quiere seguir viendo las siguientes ofertas. En caso de querer seguir viendo ofertas no podrá obtener o aceptar la oferta que ya dejó pasar. Es decir, oferta que no se acepta en el momento se pierde. Tienen a su disposición también el botón de "Recomendar" que le recomendará si le conviene rechazar la oferta o aceptarla. De cualquier forma, la decisión es suya y el "Recomendar" solo sugiere. Tenga en cuenta que quien programo el botón "Recomendar" tampoco conoce las ofertas y queremos evaluar si da buenas o malas recomendaciones.

Luego aparece un video instructivo con un ejemplo para que el participante entienda cómo realizar el ejercicio:



Primero debe completar sexo y edad, y luego procede a realizar 5 rondas de elección como la siguiente:

1. Sexo:
 Femenino
 Masculino

2. Edad

1. Anote las ofertas que van saliendo, la recomendación del Algoritmo y su decisión

Orden	Oferta	Recomendación	Decisión (acepto / rechazo)
1	?	<input type="button" value="Recomendar"/>	<input type="radio"/> Aceptar <input type="radio"/> Rechazar

En cada ronda hay 19 ofertas que se van revelando una por vez, en cada oferta el participante debe decidir si acepta la oferta o la rechaza. Para revelar la oferta se debe presionar en el botón “?”.

Anote las ofertas que van saliendo, la recomendación del Algoritmo y su decisión

Orden	Oferta	Recomendación	Decisión (acepto / rechazo)
1	222	<input type="button" value="Recomendar"/>	<input type="radio"/> Aceptar <input type="radio"/> Rechazar

Antes de decidir, debe presionar el botón de “Recomendar” para recibir la recomendación del algoritmo. Luego de eso se le habilita la posibilidad de aceptar o rechazar.

1. Anote las ofertas que van saliendo, la recomendación del Algoritmo y su decisión

Orden	Oferta	Recomendación	Decisión (acepto / rechazo)
1	222		<input type="radio"/> Aceptar <input type="radio"/> Rechazar

RECOMENDADOR

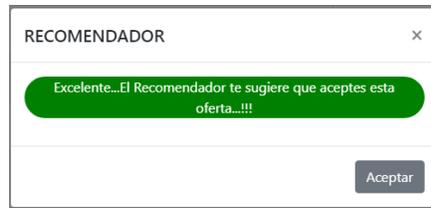
El Recomendador te sugiere que rechaces esta oferta...!!!

2. Ahora debemos vender otra obra de...

3. Anote las ofertas que van saliendo, la...

En caso de que el recomendador sugiera aceptar, el participante no está obligado a hacerlo. Aceptar o rechazar siempre será la decisión del participante, y sólo está obligado a consultar el algoritmo.

La recomendación se verá de la siguiente manera:



Si el participante decide rechazar la oferta aparece una nueva oferta, y ya no podrá aceptar la primera.

Una vez que se rechaza una oferta, no se puede cambiar esa decisión.

Orden	Oferta	Recomendación	Decisión (acepto / rechazo)
1	222	Recomendar	<input type="radio"/> Aceptar <input checked="" type="radio"/> Rechazar
2	?	Recomendar	<input type="radio"/> Aceptar <input type="radio"/> Rechazar

Este proceso se repite una y otra vez con las 19 ofertas. El proceso termina cuando se acepta una oferta, si no se acepta ninguna de las primeras 18, la oferta número 19 será aceptada.

Orden	Oferta	Recomendación	Decisión (acepto / rechazo)
1	222	Recomendar	<input type="radio"/> Aceptar <input checked="" type="radio"/> Rechazar
2	303	Recomendar	<input type="radio"/> Aceptar <input checked="" type="radio"/> Rechazar
3	323	Recomendar	<input type="radio"/> Aceptar <input checked="" type="radio"/> Rechazar
4	193	Recomendar	<input type="radio"/> Aceptar <input checked="" type="radio"/> Rechazar
5	209	Recomendar	<input type="radio"/> Aceptar <input checked="" type="radio"/> Rechazar
6	190	Recomendar	<input type="radio"/> Aceptar <input checked="" type="radio"/> Rechazar

Cuando se acepta una oferta, termina el proceso y se muestra el resto de las ofertas que aún no habían sido descubiertas.

10	213	Recomendar	<input checked="" type="radio"/> Aceptar <input type="radio"/> Rechazar
11	252	Recomendar	<input type="radio"/> Aceptar <input type="radio"/> Rechazar
12	181	Recomendar	<input type="radio"/> Aceptar <input type="radio"/> Rechazar
13	223	Recomendar	<input type="radio"/> Aceptar <input type="radio"/> Rechazar
14	199	Recomendar	<input type="radio"/> Aceptar <input type="radio"/> Rechazar
15	288	Recomendar	<input type="radio"/> Aceptar <input type="radio"/> Rechazar
16	168	Recomendar	<input type="radio"/> Aceptar <input type="radio"/> Rechazar
17	234	Recomendar	<input type="radio"/> Aceptar <input type="radio"/> Rechazar
18	169	Recomendar	<input type="radio"/> Aceptar <input type="radio"/> Rechazar
19	256	Recomendar	<input type="radio"/> Aceptar <input type="radio"/> Rechazar

Luego se hacen cinco preguntas cualitativas sobre la percepción del participante:

10. ¿Cómo calificas tu capacidad para decidir si aceptar la oferta o rechazarla?
Nota: Antes de elegir, debe saber que 1 significa muy baja capacidad, 5 significa excelente capacidad

Valoración

11. ¿Cómo calificas la capacidad del algoritmo para aconsejarte si aceptar o rechazar?
Nota: Antes de elegir, debe saber que 1 significa muy baja capacidad, 5 significa excelente capacidad

Valoración

12. ¿Estas arrepentido de las decisiones que tomaste?
Nota: Antes de elegir, debe saber que 1 significa no estoy arrepentido, 5 significa estoy muy arrepentido

Valoración

13. ¿Qué crees influencia más en la decisión?
Nota: Antes de elegir, debe saber que 1 significa solo lo que yo pensé/creí, 5 significa hice exactamente lo que me recomendó el algoritmo

Valoración

14. ¿A qué le atribuyes los resultados?
Nota: Antes de elegir, debe saber que 1 significa solo mis propias decisiones, 5 significa solo a la suerte o mala suerte

Por último, se aprieta el botón “Balance” para obtener el resultado final del experimento donde se suman las ofertas aceptadas.

13. ¿Qué crees influyó más en la decisión?

Nota: Antes de elegir, debe saber que 1 significa solo lo que yo pensé/creí, 5 significa hice exactamente lo que me recomendó el algoritmo

Valoración Selecciona...

14. ¿A qué le atribuyes los resultados?

Nota: Antes de elegir, debe saber que 1 significa solo mis propias decisiones, 5 significa solo a la suerte o mala suerte

Valoración Selecciona...

Balance 874

Enviar

Cuadro 3 – ofertas en cada ronda

Ranking	Ronda 1	Ronda 2	Ronda 3	Ronda 4	Ronda 5
1	\$323	\$771	\$660	\$980	\$584
2	\$303	\$769	\$635	\$977	\$579
3	\$288	\$769	\$598	\$888	\$569
4	\$256	\$768	\$576	\$805	\$545
5	\$253	\$763	\$561	\$797	\$531
6	\$252	\$747	\$554	\$774	\$523
7	\$248	\$738	\$547	\$772	\$499
8	\$239	\$736	\$503	\$762	\$479
9	\$234	\$710	\$498	\$718	\$470
10	\$222	\$697	\$475	\$705	\$414
11	\$222	\$696	\$469	\$691	\$371
12	\$213	\$687	\$449	\$654	\$305
13	\$209	\$671	\$441	\$643	\$242
14	\$199	\$670	\$422	\$613	\$221
15	\$193	\$661	\$416	\$602	\$197

16	\$190	\$643	\$415	\$597	\$167
17	\$181	\$637	\$414	\$572	\$166
18	\$169	\$608	\$406	\$567	\$151
19	\$168	\$607	\$396	\$472	\$148

X. Bibliografía

1. Arnott, D., & Pervan, G. (2005). A critical analysis of decision support systems research. *Journal of information technology*, 20(2), 67-87.
2. Arnott, D. (2006). Cognitive biases and decision support systems development: a design science approach. *Information Systems Journal*, 16(1), 55-78.
3. Arnott, D., & Pervan, G. (2016). A critical analysis of decision support systems research revisited: the rise of design science. In *Enacting Research Methods in Information Systems* (pp. 43-103). Palgrave Macmillan, Cham
4. Ayres, I., & Siegelman, P. (1995). Race and gender discrimination in bargaining for a new car. *The American Economic Review*, 304-321.
5. Babcock L, Loewenstein G 1997. Explaining Bargaining Impasse: The Role of Self-Serving Biases, *Journal of Economic Perspectives*, 11, 109-126. Babcock L, Loewenstein G, Issacharoff S, Caramer C. 1995. Biased judgment of fairness in bargaining. *American Economic Review*, 85, 1337-1343
6. Beatty, S.E., & Smith, S.M. (1987). External search effort: An investigation across several product categories. *Journal of Consumer Research*, 14, 83-95.
7. Becchetti, Leonardo, *Beyond the homo economicus*, University of Rome Tor Vergata - AICCON working paper n.97 Novembre 2011
8. Becker, Gary S., 1978. *The Economic Approach to Human Behavior*, The University of Chicago Press, Chicago
9. Benartzi, S. (2017). *The smarter screen: Surprising ways to influence and improve online behavior*. Penguin.
10. Berg, J., Dickhaut, J., & McCabe, K. (1995). Trust, reciprocity, and social history. *Games and economic behavior*, 10(1), 122-142.
11. Borghans, L., Meijers, H., & Ter Weel, B. (2008). The role of noncognitive skills in explaining cognitive test scores. *Economic inquiry*, 46(1), 2-12.
12. Bowie, Norman E., 2004, "Desafiando el Paradigma Egoísta", en *Ética de los Negocios*, EDUCA; Buenos Aires
13. Braun, M., & Muermann, A. (2004). The impact of regret on the demand for insurance. *Journal of Risk and Insurance*, 71(4), 737-767

14. Brian Christian and Tom Griffiths, *Algorithms to Live By: The Computer Science of Human Decisions* by ISBN-13: 978-1627790369.
15. Byrnes, J. P., Miller, D. C., & Schafer, W. D. (1999). Gender differences in risk taking: a meta-analysis. *Psychological bulletin*, 125(3), 367.
16. Calabrese, J. L. (1999). Ampliando las fronteras del reduccionismo. *Deducción y sistemas no lineales. Psicoanálisis AP de BA*, 21(3), 431-453.
17. Chai, L.T., Ling, K.C. & Piew, T.H. (2010). The effects of shopping orientations, online trust and prior online purchase experience toward customers' online purchase intention. *International Business Research*, 3(3), 63-76
18. Cohen, A., & Einav, L. (2007). Estimating risk preferences from deductible choice. *American economic review*, 97(3), 745-788.
19. Danziger, S., Levav, J., & Avnaim-Pesso, L. (2011). Extraneous factors in judicial decisions. *Proceedings of the National Academy of Sciences*, 108(17), 6889-6892.
20. Dietvorst, B. J., Simmons, J. P., & Massey, C. (2015). Algorithm aversion: People erroneously avoid algorithms after seeing them err. *Journal of Experimental Psychology: General*, 144(1), 114.
21. Dietvorst, B. J., Simmons, J. P., & Massey, C. (2016). Overcoming algorithm aversion: People will use imperfect algorithms if they can (even slightly) modify them. *Management Science*, 64(3), 1155-1170.
22. Elster, J. (1991). *Juicios salomónicos: las limitaciones de la racionalidad como principio de decisión*. Gedisa.
23. Eubanks, V. (2018). *Automating inequality: How high-tech tools profile, police, and punish the poor*. St. Martin's Press.
24. Fasolo, B., McClelland, G. H., & Lange, K. A. (2005). The Effect of Site Design and Interattribute Correlations on Interactive Web-Based Decisions.
25. Ferguson, T. S. (1989). Who solved the secretary problem? *Statistical science*, 4(3), 282-289.
26. Gallagher, J. (2014). Learning about an infrequent event: evidence from flood insurance take-up in the United States. *American Economic Journal: Applied Economics*, 206-233.
27. Greci, R. T., & Todd, P. A. (2002). Solutions-driven marketing. *Communications of the ACM*, 45(3), 64-71.
28. Harari, Y. N. (2016). *Homo Deus: A brief history of tomorrow*. Random House.

29. Haubl, G., & Trifts, V. (2000). Consumer decision making in online shopping environments: The effects of interactive decision aids. *Marketing Science*, 19(1), 4-21
30. Heidegger, M. (1954). The question concerning technology. *Technology and values: Essential readings*, 99-113.
31. Hidalgo, C. A., Orghian, D., Canals, J. A., De Almeida, F., & Martín, N. (2021). *How Humans Judge Machines*. MIT Press.
32. Kahneman, D. (2012). *Pensar rápido, pensar despacio*. Debate.
33. Keren, G. (1990). Cognitive aids and debiasing methods: can cognitive pills cure cognitive ills? *Advances in Psychology*, 68, 523-552.
34. King, W. R., & He, J. (2006). A meta-analysis of the technology acceptance model. *Information & management*, 43(6), 740-755.
35. Kirby, K. N., Winston, G. C., & Santiesteban, M. (2005). Impatience and grades: Delay-discount rates correlate negatively with college GPA. *Learning and individual Differences*, 15(3), 213-222.
36. Knight, F. H. (2012). *Risk, uncertainty and profit*. Courier Corporation.
37. Kol, O., & Lev-On, A. (2014). *Online social networks and purchase decision making*. Ministry of Economy [Hebrew], Jerusalem.
38. Komiak, S. Y., & Benbasat, I. (2006). The effects of personalization and familiarity on trust and adoption of recommendation agents. *MIS quarterly*, 941-960.
39. Kunreuther, H. C., Pauly, M. V., & McMorrow, S. (2013). *Insurance and behavioral economics: Improving decisions in the most misunderstood industry*. Cambridge University Press.
40. Landro, A. (2010). *Acerca de la Probabilidad: La interpretación del concepto de azar y la definición de probabilidad*.
41. Lempert, P. (2006). Caught in the Web. *Progressive Grocer*, 85, 12-18.
42. Leonard, T. C. (2008). Richard H. Thaler, Cass R. Sunstein, *Nudge: Improving decisions about health, wealth, and happiness*
43. Lin, W.B. (2008). Factors influencing online and post-purchase behavior and construction of relevant models. *Journal of International Consumer Marketing*, 20(3-4), 23-38.
44. Lohr, S. (2015). *Data-ism: The revolution transforming decision making, consumer behavior, and almost everything else*. New York: HarperCollins Publishers.

45. Logg, J. M. (2017). Theory of Machine: When do people rely on algorithms?
46. Marsha, R.L., & Bloch, P.H. (1986), After the new wears off: The Temporal context of product involvement. *Journal of Consumer Research*, 13, 280-285.
47. Massaro, A., Panarese, A., Gargaro, M., Colonna, A., & Galiano, A. (2021). A Case Study of Innovation in the Implementation of a DSS System for Intelligent Insurance Hub Services. *Technology*, 9(1), 14-23.
48. McCosh, A. M., & Correa-Pérez, B. A. (2006). The optimization of what?. In *Intelligent decision-making support systems* (pp. 463-481). Springer, London.
49. Meserve, L. A. (1998). The problem with relying on technology.
50. Mischel, W., Ebbesen, E. B., & Raskoff Zeiss, A. (1972). Cognitive and attentional mechanisms in delay of gratification. *Journal of personality and social psychology*, 21(2), 204.
51. Mitchell, G. (2004). Libertarian paternalism is an oxymoron. *Nw. UL Rev.*, 99, 1245.
52. Montero. R (2005): Test de Hausman. Documentos de Trabajo en Economía Aplicada. Universidad de Granada. España
53. Morton, F. S., Zettelmeyer, F., & Silva-Risso, J. (2003). Consumer information and discrimination: Does the Internet affect the pricing of new cars to women and minorities? *Quantitative marketing and Economics*, 1(1), 65-92.
54. Musen, M. A., Middleton, B., & Greenes, R. A. (2014). Clinical decision-support systems. In *Biomedical informatics* (pp. 643-674). Springer, London.
55. O'Neil, C. (2017). *Weapons of math destruction: How big data increases inequality and threatens democracy*. Broadway Books.
56. Pan, B., Hembrooke, H., Joachims, T., Lorigo, L., Gay, G., & Granka, L. (2007). In google we trust: Users' decisions on rank, position, and relevance. *Journal of computer-mediated communication*, 12(3), 801-823
57. Parasuraman, R., & Manzey, D. H. (2010). Complacency and bias in human use of automation: An attentional integration. *Human factors*, 52(3), 381-410.
58. Pashigian, B. P., Schkade, L. L., & Menefee, G. H. (1966). The selection of an optimal deductible for a given insurance policy. *The Journal of Business*, 39(1), 35-44.
59. Payne JW, Bettman JR, Schkade DA (1999) Measuring constructed preferences: Towards a building code. *Journal of Risk and Uncertainty* 19(1-3):243–270.

60. Pereira, R. E. (2001). Influence of query-based decision aids on consumer decision making in electronic commerce. *Information Resources Management Journal (IRMJ)*, 14(1), 31-48.
61. Peterson, R.A., & Merino, M.C. (2003). Consumer information search behavior and the Internet. *Psychology and Marketing*, 20(2), 99-121.
62. Petty, R.E & Cacioppo, J.T. (1981). Issue involvement as a moderator of the effects on attitude of advertising content and context. *Advances in Consumer Research*, 8, 20-24.
63. Pires, G., Stanton, J., & Eckford, A. (2004). Influences on the perceived risk of purchasing online. *Journal of Consumer Behaviour*, 4(2), 118- 131
64. Power, D. (2004). Decision support systems: From the past to the future. *AMCIS 2004 Proceedings*, 242.
65. Reith, G. (2005). *The age of chance: Gambling in Western culture*. Routledge.
66. Ross, M., & Sicoly, F. (1979). Egocentric biases in availability and attribution. *Journal of personality and social psychology*, 37(3), 322.
67. Rubinstein, A. (1998). *Modeling bounded rationality*. MIT press.
68. Sandvig, C., Hamilton, K., Karahalios, K., & Langbort, C. (2014). Auditing algorithms: Research methods for detecting discrimination on Internet platforms. *Data and discrimination: converting critical concerns into productive inquiry*, 22.
69. Samuelson, P. A. (1948). Consumption theory in terms of revealed preference. *Economica*, 15(60), 243-253.
70. Sarter, N. B., & Schroeder, B. (2001). Supporting decision making and action selection under time pressure and uncertainty: The case of in-flight icing. *Human factors*, 43(4), 573-583.
71. Sen, A. K. (1977). Rational fools: A critique of the behavioral foundations of economic theory. *Philosophy & Public Affairs*, 317-344.
72. Schafer, J. B., Konstan, J. A., & Riedl, J. (2002, November). Meta-recommendation systems: user-controlled integration of diverse recommendations. In *Proceedings of the eleventh international conference on Information and knowledge management* (pp. 43-51). ACM.
73. Schoemaker, P. J. (1982). The expected utility model: Its variants, purposes, evidence and limitations. *Journal of economic literature*, 529-563
74. Shapira, Z., & Venezia, I. (2008). On the preference for full-coverage policies: Why do people buy too much insurance? *Journal of Economic Psychology*, 29(5), 747-761.

75. Simon, Herbert A., Rational Decision-Making in Business Organizations, Nobel Memorial Lecture, 8 December 1978. Carnegie-Mellon University, Pittsburgh, Pennsylvania, USA
76. Sparrow, B., Liu, J., & Wegner, D. M. (2011). Google effects on memory: Cognitive consequences of having information at our fingertips. *science*, 1207745.
77. Thaler, R. H., & Ganser, L. J. (2015). *Misbehaving: The making of behavioral economics*. New York: WW Norton.
78. Thaler, R. H., Sunstein, C. R., & Pavillet, M. F. (1949). *Nudge*.
79. Taleb, N. N. (2007). *The black swan: The impact of the highly improbable*. Random House.
80. Todd, P., & Benbasat, I. (1999). Evaluating the impact of DSS, cognitive effort, and incentives on strategy selection. *Information Systems Research*, 10(4), 356-374.
81. Tversky, Amos and Daniel Kahneman (1986), "Rational Choice and the Framing of Decisions", *Journal of Business* 59:251-278.
82. Vollmer, C., & Precourt, G. (2008). *Always On: Advertising, Marketing, and Media in an Era of Consumer Control*. New York: McGraw-Hill.
83. Wallacher, Johannes, 2004, "¿Despedida del homo oeconomicus?", *Communio*, Año 11, N° 2, Buenos Aires
84. Weber, M. (1998). *La ética protestante y el espíritu del capitalismo* (No. 135). Ediciones AKAL.
85. Wilkie, W.L. (1990). *Consumer Behavior*. New York: John Wiley & Sons.
86. Williams, B. (1981). *Moral luck: philosophical papers 1973-1980*. Cambridge University Press.
87. Yeomans, M., Shah, A., Mullainathan, S., & Kleinberg, J. (2017). Making sense of recommendations. *Journal of Behavioral Decision Making*.