

## Artificial Intelligence (AI) as a tool for predicting the financial culture of a country

La Inteligencia Artificial (IA) como herramienta de predicción de la cultura financiera de un país

David Borreguero Arias\*

<https://orcid.org/0009-0009-9587-6833> (ORCID iD)

Rey Juan Carlos University (Spain)

Raúl Gómez-Martínez

<https://orcid.org/0000-0003-3575-7970> (ORCID iD)

Rey Juan Carlos University (Spain)

Julio Alard Josemaría

<https://orcid.org/0000-0003-1882-7375> (ORCID iD)

ESIC University (Spain)

Camilo Prado-Román

<https://orcid.org/0000-0002-1540-0643> (ORCID iD)

Rey Juan Carlos University (Spain)

Borreguero Arias, D.; Gómez-Martínez, R.; Alard Josemaría, J.; & Prado-Román, C. (2024). Artificial Intelligence (AI) as a tool for predicting the financial culture of a country. *Journal of Management and Business Education*, 7(3), 477-491. <https://doi.org/10.35564/jmbe.2024.0027>

\*Corresponding author: david.borreguero@esic.edu

Language: English

Received: 21 Jul 2024 / Accepted: 14 Oct 2024

**Funding.** The authors received no financial support for the research, authorship, and/or publication of this article.

**Ethical Statement.** The authors confirm that the data collection for the research was conducted anonymously and that there was no possibility of identifying the participants.

**Declaration of conflicting interests.** The authors declared no potential conflicts of interest with respect to the research, authorship, and/or publication of this article.

**CRedit author statement.** All authors have contributed equally to all parts of the work.

---

## ABSTRACT

Artificial Intelligence (AI) currently presents different applications that allow, through data processing, the possibility of learning, predicting and adopting solutions in different fields of knowledge including the financial field. This research essay aims to analyze the capacity of Artificial Intelligence (AI) and supervised learning to predict the level of financial culture that individuals possess. For this purpose, 11 predictors previously selected for their possible influence on financial culture, are proposed and compared with the target variable (level of financial culture). The results obtained show that each of the 11 individual-level predictors correlate with the level of financial culture that each individual claim to have. In this respect, a general high or very high perception of the target variable is shown. However, considering the accuracy of the reference, the research shows that as the number of predictors is smaller, the accuracy of the reference decreases.

**Keywords.** Artificial Intelligence (AI), Financial Literacy, Supervised Learning, Machine Learning, Predictive Analysis.

## RESUMEN

La Inteligencia Artificial (IA) presenta actualmente diferentes aplicaciones que permiten a través del procesamiento de datos, la posibilidad de aprender, predecir y adoptar soluciones en diferentes campos de conocimiento, entre los que se encuentra el ámbito financiero. Este trabajo de investigación tiene como objetivo analizar la capacidad de la Inteligencia Artificial (IA) y el aprendizaje supervisado para predecir el nivel de cultura financiera que poseen los individuos de un país. Para ello se proponen 11 predictores previamente seleccionados por su posible influencia en la cultura financiera y se comparan con la variable objetivo (nivel de cultura financiera). Los resultados obtenidos ponen de manifiesto que cada uno de los 11 predictores a nivel individual se correlacionan con el nivel de cultura financiera que cada individuo afirma tener. En este sentido se evidencia con carácter general una percepción, alta o muy alta de la variable objetivo. No obstante, atendiendo a la precisión del modelo el trabajo pone en evidencia que a medida que el número de predictores es menor la precisión del modelo disminuye.

**Palabras clave.** Inteligencia artificial (IA), Cultura Financiera, Aprendizaje Supervisado, Machine Learning, Análisis Predictivo.

## INTRODUCCIÓN

Los constantes cambios y la rápida evolución de la tecnología en el contexto actual hacen necesario una adecuada y constante formación para poder tomar decisiones acertadas a nivel personal y profesional. El terreno financiero no está exento de estos cambios tecnológicos que también afectan al conocimiento y a las decisiones que se adopten en este campo. Por este motivo, se hace necesario alcanzar las competencias y habilidades específicas para la toma correcta de decisiones a nivel financiero (Parne, 2021). En este sentido, Domínguez (2022) afirma que es recomendable contar con una cultura financiera sólida que nos permita gestionar correctamente nuestro dinero y evitar, de este modo, las malas decisiones financieras.

Por otra parte, la cultura financiera se ha convertido en un actor principal a la hora de determinar la prosperidad económica de los individuos. Entre los puntos cruciales de conocimiento se pueden situar, el interés compuesto, la inflación y el riesgo y su diversificación. Aspectos que, en este tipo de sociedad donde el consumo es una de sus señas de identidad, suponen saber implementar

---

distintas estrategias de compra, la comparación de precios entre los diferentes productos, así como recabar información relevante de todo este proceso (Domínguez, 2022)

Sin embargo, el último informe de competencias financieras elaborado por (PISA, 2022) establece una preocupante carencia de cultura financiera a nivel global. Según dicho informe España con una puntuación de (473), se situaría ligeramente por encima de la media de los países que participaron en el mismo (472), pero por debajo de la media de la Unión Europea (474) y muy lejos de los países punteros como Japón (536), Corea (527) o Estonia (510). El informe citado viene a evidenciar, entre otras cosas, la existencia de una brecha educativa en el ámbito económico - financiero dado el escaso conocimiento que presenta la sociedad europea en su conjunto (European Commission, 2023). Este desconocimiento puede originar una serie de consecuencias negativas para los individuos como la falta de planificación financiera, la incapacidad de generar ahorros suficientes para atender a situaciones de emergencia, el desconocimiento de los riesgos a la hora de invertir, etc.

Hoy los avances tecnológicos permiten que herramientas como la Inteligencia Artificial (IA) puedan contribuir a predecir y mejorar esta cultura financiera. Y ello, porque gracias a los algoritmos automáticos o Machine Learning, la Inteligencia Artificial (IA) puede aportar la percepción interna de los comportamientos financieros, de tal manera que contribuya a cambiar los patrones que los ciudadanos tienen preconcebidos para entender y comprender mejor el mundo de las finanzas.

Y ello porque la Inteligencia Artificial (IA) actúa con mayor rapidez, flexibilidad y precisión que las técnicas econométricas tradicionales (Mullainathan y Spiess, 2017). Esto se debe a que los algoritmos de aprendizaje automático identifican patrones y correlaciones entre las diferentes variables financieras al poder estudiar la perspectiva del gasto de los individuos, sus costumbres de ahorro, sus inversiones, y de esta manera entender y predecir su comportamiento financiero. Es decir, podría ayudar a tomar decisiones financieras informadas como, por ejemplo, qué acciones comprar, cuándo vender, así como establecer alertas sobre los posibles riesgos o las fluctuaciones del mercado (Alonso y Carbó, 2022). Por otro lado, la Inteligencia Artificial (IA) puede aconsejar, personalizar recomendaciones, enseñar estrategias únicas para mejorar nuestra situación financiera o sugerir acciones para reducir deuda. Además, mediante el uso de aplicaciones móviles o tutoriales interactivos, permite ampliar nuestra cultura financiera; detectando posibles fraudes y riesgos en los ámbitos financieros.

Hay que señalar también que los datos proporcionados por la Inteligencia Artificial (IA) permitirían comprender por qué se toma una determinada decisión financiera y no otra, qué factores influirán en dicha decisión y cómo se podrán modificar para obtener mejores resultados, de esta manera, la información financiera que nos aporta pueda interpretarse con mayor facilidad por un sector de la población mucho más amplio.

Por todo lo expuesto anteriormente, la utilización de la Inteligencia Artificial (IA) y el análisis predictivo supone un avance para predecir y mejorar la cultura financiera proporcionando información útil y, a priori, una mayor precisión y optimización de los resultados obtenidos.

## **MARCO TEÓRICO**

Antes de profundizar en los beneficios de la Inteligencia Artificial (IA) y el análisis predictivo debemos comprender el significado de ambos conceptos. La concepción del término Inteligencia Artificial (IA) se remonta a la década de 1940. Sin embargo, no es hasta 1956 cuando el término fue acuñado por el informático y matemático John McCarthy durante la Conferencia de Dartmouth. Para McCarthy et al. (1955) conciben la Inteligencia Artificial (IA) como la ciencia y la ingeniería de hacer máquinas inteligentes, especialmente programas de computadora inteligente. Más recientemente el Consejo de Estabilidad Financiera (2017), define la Inteligencia Artificial (IA)

---

como el conjunto de teorías y de algoritmos que permiten a las computadoras desarrollar tareas que requieren capacidades propias de la inteligencia humana y, en ocasiones, mejorarlas.

Por otro lado, el concepto de análisis predictivo comprende la utilización de algoritmos y técnicas estadísticas para llevar a cabo predicciones cuantitativas y tendencias futuras relacionadas con el comportamiento de los individuos frente a estímulos o situaciones específicas. Esta predicción se realiza mediante el análisis de un gran volumen de datos históricos e información en tiempo real (Espino, 2017) lo que permite identificar pautas de conducta con una mayor rapidez y precisión. Por ello, se podría entender que los conceptos son complementarios, en el sentido que hablar de análisis predictivo cobra mayor relevancia si se hace referencia al tiempo, al aprendizaje computacional o Machine Learning. Como rama de la Inteligencia Artificial (IA), el aprendizaje computacional se basa en el estudio de un modelo definido en base a unos datos. Para ello, utilizan algoritmos o técnicas estadísticas que les ayudan a detectar patrones significativos en los datos empleados (Centeno, 2020).

A modo de ejemplo, si se pretende programar una máquina para poder filtrar correos electrónicos no deseados, una posible solución sería hacer memorizar a la máquina aquellos correos marcados como no deseados por el usuario en el pasado. De este modo, al recibir un correo electrónico, la máquina efectuará una búsqueda en el conjunto de correos seleccionados como no deseados anteriormente y si encuentra alguna coincidencia con alguno de ellos lo eliminará. En caso contrario, lo moverá a la bandeja de entrada del usuario. A pesar de ello, el aprendizaje por memorización resulta incompleto ya que la máquina carece de capacidad para etiquetar los correos electrónicos no vistos por el usuario. Para superar esta nueva problemática se propone introducir el aprendizaje intuitivo, es decir, la máquina debe ser capaz de pasar de los ejemplos individuales proporcionados por el usuario a una generalización más amplia. Para ello, los usuarios deberán escanear los correos electrónicos anteriores considerados como no deseados y seleccionar aquellas palabras que consideran susceptibles de aparecer en estos correos. Así, al llegar un nuevo correo electrónico, la máquina será capaz de predecir su calificación atendiendo al conjunto de palabras proporcionadas por el usuario y proceder en consecuencia (Shalev - Shwartz y Ben, 2014). Sin embargo, el aprendizaje intuitivo genera, en determinadas ocasiones, una cadena de eventos que refuerzan la asociación de una acción a una causa, de manera incorrecta (Skinner, 1948).

Si extrapolamos el ejemplo anterior al motivo del presente artículo, podríamos hacer que la Inteligencia Artificial (IA) memorizase datos históricos sobre comportamientos financieros de los individuos de un país, tales como la inversión o patrones de ahorro y gasto de los individuos en el pasado. De este modo, a medida que la Inteligencia Artificial (IA) fuera recibiendo y memorizando nuevos datos financieros, buscaría similitudes con los comportamientos anteriores y, si encontrase coincidencias, podría predecir tendencias futuras (Cachón Rodríguez, et al, 2019; Gómez Martínez et al, 2024). Sin embargo, como hemos visto anteriormente, este enfoque de aprendizaje por memorización es limitado, ya que la Inteligencia Artificial (IA) no es capaz por sí misma de etiquetar ni interpretar nuevos comportamientos financieros que no haya visto antes. Por este motivo, se propone introducir el aprendizaje intuitivo. Es decir, la Inteligencia Artificial (IA) debe ser capaz de generalizar a partir de ejemplos individuales proporcionados por los individuos. Por ejemplo, los individuos podrían proporcionar aquellos datos que consideren importantes relacionados con diferentes comportamientos financieros y señalar factores que consideren de especial relevancia, como la educación financiera, el estado de ánimo, la confianza en el sistema bancario, o la influencia de eventos económicos globales. Así, la Inteligencia Artificial (IA) sería capaz de predecir la cultura financiera de los individuos de un país basándose en los patrones identificados por cada uno de los individuos de manera individualizada. No obstante, este aprendizaje también puede tener limitaciones. Por ejemplo, si la Inteligencia Artificial (IA) asocia incorrectamente un aumento de la inversión a un evento económico determinado, podría predecir de manera equivocada futuros comportamientos financieros basándose en esa asociación incorrecta.

---

A diferencia de los seres humanos, las máquinas carecen de sentido común para desechar estas conclusiones incorrectas, por lo que resulta esencial proporcionarles algoritmos de aprendizaje adecuados para proteger a estos programas de llegar a dichas conclusiones. La adecuación de estos algoritmos de aprendizaje dependerá de la cantidad de datos que tengamos a nuestra disposición, es decir, a mayor cantidad de datos más adecuado será el algoritmo utilizado (Jordan y Mitchell, 2015).

Por todo lo expuesto anteriormente, el campo del aprendizaje computacional o Machine Learning se ha ramificado en varios subcampos que ocupan diferentes tipos de labores de aprendizaje. No obstante, a efectos del presente artículo, nos vamos a centrar en dos: el aprendizaje supervisado y el no supervisado (Díaz, 2021).

El primero consiste en encontrar la relación existente entre una variable de entrada y una variable de salida, es decir se basa en decirle al algoritmo que vamos a utilizar el resultado que queremos obtener para un determinado valor. Para ello, será necesario entrenar al algoritmo a través de muchos ejemplos para que, siempre que se den las condiciones óptimas, sea capaz de generar un resultado “razonable” incluso para aquellos ejemplos de prueba que no ha visto antes (Rojas, 2020; Sandoval, 2018). Dicho de otro modo, el algoritmo es capaz de generalizar su conocimiento mediante la observación (Del Barrio, 2022). Desde un punto de vista financiero, estos algoritmos se entrenan utilizando un conjunto de datos etiquetados que contienen información sobre diferentes variables financieras y resultados observados. Estos modelos de aprendizaje son utilizados para predecir tendencias y resultados futuros tal como señalan Gimeno y Marqués (2022).

Queremos señalar que el modelo utilizado en este trabajo de investigación se basa en el aprendizaje supervisado. Esta técnica, conocida como bosque aleatorio o Random Forest, utiliza algoritmos de aprendizaje computacional o Machine Learning de uso común para crear diagramas de construcciones lógicas que nos ayudan a resolver el problema planteado (Caruana y Niculescu - Mizil, 2006; Hastie et al., 2009). Para Parra (2019) se trata de una técnica de carácter explicativo que utiliza un proceso de división secuencial, iterativo y descendente, y que, a partir de una variable dependiente, forma grupos homogéneos definidos específicamente mediante combinaciones de variables independientes en las que incluyen la totalidad de los casos recogidos en la muestra.

En cuanto al aprendizaje no supervisado, esta parte de un conocimiento basado únicamente en variables de entrada, pero sin la existencia de variables de salida, es decir, no existe la necesidad de explicarle al sistema que resultados queremos obtener. La dificultad que presentan este tipo de algoritmos es que no tienen ningún ejemplo de respuesta con el que determinar si este algoritmo está actuando correctamente (Bishop, 2007; Naeem et al., 2023). Sin embargo, una de las ventajas que presentan este tipo de aprendizajes es que los conjuntos de datos para entrenar suponen un menor coste a la hora de conseguirlos. En el ámbito financiero, este tipo de aprendizaje se enfoca en identificar diferentes patrones y estructuras ocultas en conjuntos de datos financieros sin la necesidad de etiquetas (Irigoin y Morales, 2024). Es por eso por lo que este algoritmo puede resultar útil para clasificar clientes en diferentes grupos atendiendo a sus características financieras, ofreciendo a los mismos una mayor personalización en el servicio.

De acuerdo con lo anteriormente señalado, los distintos modelos de aprendizaje expuestos en este trabajo nos van a proporcionar una serie de algoritmos evolutivos que nos ayudarán a obtener soluciones dinámicas ideales en una sociedad en constante cambio, y muchas veces de forma automática. Tanto la Inteligencia Artificial (IA) como el Machine Learning serán capaces de predecir el nivel de cultura financiera de los individuos, tomar decisiones financieras informadas a corto y largo plazo, así como reducir los riesgos que pudieran estar asociados a las mismas.

---

## METODOLOGÍA

El presente estudio se enfoca en investigar los predictores que influyen en el nivel de cultura financiera de los participantes. Se utiliza una encuesta que recopila datos sobre 11 predictores seleccionados previamente por su relevancia teórica y su posible influencia en la cultura financiera.

La Prospect Theory (Kahneman y Tversky, 1979) nos ofrece una visión detallada de como los individuos toman decisiones en entornos de incertidumbre usando atajos heurísticos y prejuicios que pueden desviarse de los principios básicos de la probabilidad. Por este motivo, la cultura financiera está intrínsecamente vinculada con estos conceptos ya que describe los conocimientos, comportamientos y actitudes que los individuos tienen hacia el dinero y las finanzas más allá de las fórmulas matemáticas tradicionales (Housel, 2020). Esta cultura financiera se forma a lo largo del tiempo y está influenciada por diversos predictores, como la educación, la experiencia personal, el entorno socioeconómico, las emociones y los factores demográficos como la edad, el género y el estado civil de los individuos.

Desde una perspectiva demográfica podemos observar como la edad, el género, la formación y el estado civil desempeña un papel fundamental en la cultura financiera de los individuos. Las diferentes edades de los individuos de la población ponen de manifiesto unas experiencias y conocimientos financieros determinados, lo que influye directamente en como perciben y manejan el riesgo. Es por eso por lo que los jóvenes suelen ser más propensos a asumir riesgos financieros debido a un horizonte temporal más largo, mientras que las personas en etapas más avanzadas de su vida suelen ser más conservadoras (Hospidio et al., 2021). Igualmente, las diferencias de género en la toma de decisiones financieras también pueden estar influenciadas por la cultura financiera (Trejos et al., 2021). Otro de los predictores que tiene un importante impacto en la cultura financiera es el nivel de formación de los individuos. Una adecuada formación permite a los individuos tomar decisiones financieras más informadas y seguras. Además, los individuos con mejor formación tienden a desarrollar mejores habilidades de planificación y gestión del dinero, es decir, son capaces de elaborar con mayor facilidad presupuestos, planificar sus finanzas de cara al futuro y manejar cualquier imprevisto financiero que les pueda surgir (Comisión Nacional del Mercado de Valores y Ministerio de Asuntos Económicos y Transformación Digital, 2021). De igual forma, el estado civil también puede influir en la cultura financiera a través del impacto emocional. Según Damián y Sánchez (2024) las personas en relaciones estables pueden sentirse más apoyadas y seguras, lo que puede influir positivamente en su comportamiento financiero. Sin embargo, un estudio realizado por Aguiar y Zagalaz (2022) demostró que las mujeres casadas en España tienen un menor nivel de competencias financieras en comparación con los hombres casados. Este mismo estudio revela que no existen diferencias significativas entre hombres y mujeres solteros.

Por otro lado, las emociones representan una poderosa fuerza capaz de influir en nuestras decisiones financieras del día a día. Determinadas situaciones, como los resultados deportivos, el clima o el estado de ánimo, posibilitan que nuestras decisiones económico – financieras varíen considerablemente.

Los resultados deportivos es otro de los predictores que influye directamente en la cultura financiera de los individuos ya que repercute en su estado de ánimo y, por ende, en las decisiones financieras. Por este motivo, las victorias deportivas tienen un impacto significativo en el optimismo de los individuos y su disposición a asumir riesgos, mientras que las derrotas pueden tener el efecto contrario. Así, si un inversor acaba de ver ganar a su equipo estaría más inclinado a realizar inversiones arriesgadas. Numerosos autores analizan el efecto del cambio del estado de ánimo y su influencia en los mercados en diferentes deportes: en fútbol (Ashton et al., 2010; Beremunt et al., 2006; Dermirhan, 2013; Gómez y Prado, 2014;), en la NFL americana (Chang et al., 2012), en el rugby (Boyle y Walter, 2003) o en el cricket (Mishra y Smyth, 2010).



---

Al mismo tiempo, los cambios climáticos pueden afectar al estado de ánimo de los individuos, lo que a su vez puede influir en sus decisiones financieras. Por eso, los días en los que hace sol el estado de ánimo de los individuos mejora, lo que les empuja a tomar decisiones óptimas y arriesgadas, mientras que los días lluviosos pueden tener un efecto más cauteloso y conservador. En esta línea Hirshleifer y Shumway (2003) afirman que las mañanas soleadas son las que de verdad ayudan a los mercados financieros. De este modo, la rentabilidad anual alcanzada en las sesiones con cielo despejado en Nueva York era del 24,8%, mientras que en los días lluviosos era del 8,7% de media.

De igual forma, el estado de ánimo tiene un impacto directo a la hora de tomar decisiones financieras por parte de los individuos. Es decir, individuos con un estado de ánimo positivo se verán empujados a asumir mayores riesgos en sus decisiones financieras, mientras que individuos cuyo estado de ánimo sea negativo pueden optar por decisiones más conservadoras. En este sentido, Harding y He (2011) realizaron un experimento para determinar si el estado de ánimo de los inversores afectaba a las decisiones de inversión. Los resultados de este experimento muestran como los inversores inducidos en un estado de ánimo positivo son cada vez menos adversos al riesgo que los inversores inducidos en un estado de ánimo negativo. Este fenómeno se alinea con la Prospect Theory (Kahneman y Tversky, 1979a) que sugiere que las emociones pueden llevar a desviaciones de la racionalidad económica.

La variable objetivo, el nivel de cultura financiera se mide en una escala ordinal que varía de 1 a 4, donde 1 representa un nivel bajo y 4 un nivel alto de cultura financiera.

La recolección de datos se realiza a través de una encuesta distribuida por redes sociales a la comunidad universitaria. Los participantes responden preguntas relacionadas con los 11 predictores y la variable objetivo, el nivel de cultura financiera. Se garantiza la confidencialidad y anonimato de los participantes.

Los datos recolectados se analizan utilizando un enfoque de aprendizaje automático. Se emplea un modelo de Random Forest para explorar la relación entre los predictores y el nivel de cultura financiera. Este modelo es particularmente adecuado para manejar múltiples predictores y no linealidades en los datos. Además, se realiza una validación cruzada de 10 particiones para evaluar la capacidad predictiva del modelo y reducir el riesgo de sobreajuste.

Para evaluar la importancia relativa de los predictores en la predicción del nivel de cultura financiera, se lleva a cabo un análisis de importancia de características. Este análisis permite identificar los predictores más influyentes y comprender mejor su impacto en la variable objetivo. Además, se implementa un enfoque de eliminación de predictores, donde se eliminan sucesivamente los predictores menos importantes y se evalúa cómo varía la precisión del modelo.

Teniendo esto en cuenta la hipótesis de estudio de este trabajo es:

H0: Las características personales de los individuos son capaces de predecir el nivel de cultura financiera.

Las estadísticas por analizar son:

- TP Rate (Tasa de Verdaderos Positivos): Es la proporción de casos positivos que fueron correctamente identificados por el modelo como positivos. Cuanto más alto sea este valor, mejor será la capacidad del modelo para identificar correctamente los casos positivos.
- FP Rate (Tasa de Falsos Positivos): Es la proporción de casos negativos que fueron incorrectamente identificados como positivos por el modelo. Un valor bajo es deseable, ya que indica que el modelo hace menos errores al clasificar los casos negativos como positivos.
- Precision (Precisión): Es la proporción de casos positivos identificados correctamente por el modelo entre todos los casos identificados como positivos por el modelo. Cuanto más alto sea este valor, menor será el número de falsos positivos.

- Recall (Recuperación): Es la proporción de casos positivos identificados correctamente por el modelo entre todos los casos positivos en el conjunto de datos. Cuanto más alto sea este valor, menor será el número de falsos negativos.
- ROC Area (Área bajo la Curva ROC)\*\*: Es una medida de la capacidad discriminativa del modelo. Cuanto más cercano esté este valor a 1, mejor será la capacidad del modelo para distinguir entre las clases positiva y negativa.
- PRC Area (Área bajo la Curva Precision-Recall)\*\*: Es otra medida de la capacidad del modelo para clasificar correctamente las instancias positivas. Al igual que el área bajo la curva ROC, un valor más cercano a 1 indica un mejor rendimiento del modelo.

Las métricas utilizadas para evaluar la precisión del modelo son Recall, Roca Area y PRC Área. La interpretación de esta métrica puede variar dependiendo del contexto y del problema específico, pero aquí hay algunas pautas generales:

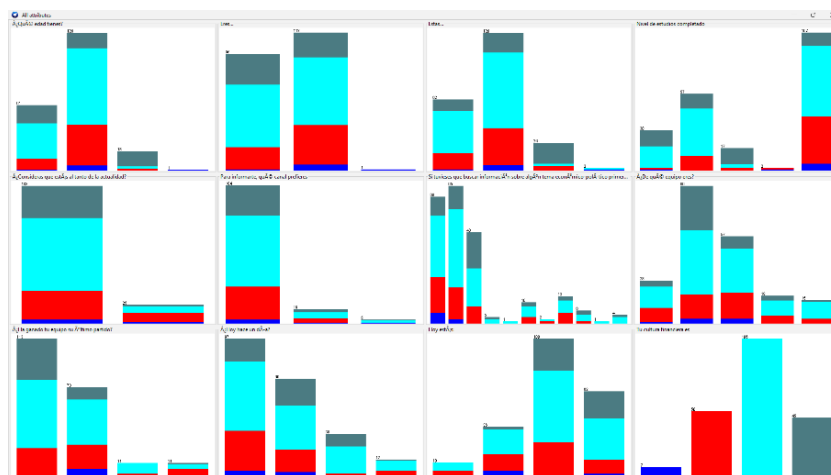
- 0: Si la métrica es cero, significa que el modelo no tiene capacidad para distinguir entre las clases positivas y negativas. Esencialmente, el modelo está prediciendo al azar.
- Entre 0 y 0,5: Este rango indica un rendimiento deficiente del modelo. Significa que la precisión es más baja que la tasa de verdaderos positivos, lo cual es peor que un enfoque aleatorio.
- Entre 0,5 y 0,7: En este rango, el modelo tiene una capacidad predictiva limitada, pero puede ofrecer algún valor. Sin embargo, se considera que la precisión y la tasa de verdaderos positivos aún no son ideales.
- Entre 0,7 y 0,9: Este rango indica un buen rendimiento del modelo. El modelo es capaz de proporcionar una buena precisión a medida que aumenta la tasa de verdaderos positivos.
- Entre 0,9 y 1: Un área bajo la curva PRC por encima de 0.9 se considera excelente. Indica que el modelo tiene una alta precisión incluso a altas tasas de verdaderos positivos, lo cual es altamente deseable en muchas aplicaciones.

Validaremos H0 si las métricas recall, área ROC y área PRC con mayores a 0,5, aunque calificaremos como modelos eficientes aquellos que muestren métricas por encima de 0,7.

## RESULTADOS

Los valores obtenidos en las 208 encuestas recopiladas a lo largo del mes de noviembre de 2023 se muestran en las siguientes figuras.

**Figura 1. Resultados encuesta cultura financiera**





---

Analizando cada uno de los predictores delimitados para la muestra y su relación con la percepción del nivel de cultura financiera indicado de manera individual por los encuestados podemos sacar las siguientes conclusiones:

Las edades comprendidas entre menos de 24 años (62%) y de 25 a 44 años (29%) representan el (91%) de la muestra, esto no nos puede resultar extraño ya que la encuesta se realizó a través de las redes sociales de la comunidad universitaria donde la mayoría de los individuos que cursan estudios universitarios están comprendidos entre esas edades. Cabe resaltar que el 66% de los encuestados menores de 24 años afirman tener una cultura financiera alta o muy alta, siendo esta tendencia similar en el resto de los rangos. Sin embargo, según los datos facilitados por el Eurobarómetro, pese a que el 30% de los españoles cree tener conocimientos financieros altos, solo el 13% demuestra tenerlos (European Commission, 2023).

Si distinguimos por género, los resultados obtenidos muestran como el 80% de los hombres encuestados afirma tener unos conocimientos financieros altos o muy altos, por un 67% de mujeres, lo que supone una diferencia de 13 puntos porcentuales (Hospido et al., 2021). Por otra parte, aquellos individuos que afirman estar casados declaran tener una percepción de sus conocimientos financieros muy alta (75%), por un 14% y 16% de individuos que manifiestan estar solteros o en pareja. Del mismo modo, los individuos con un mayor nivel educativo tienen una percepción de sus conocimientos financieros más alta. Es decir, a medida que los individuos se van formando tienen una mejor percepción de sus competencias financieras. Por ejemplo, el (93%) de los individuos encuestados que han cursado un postgrado tienen una percepción alta o muy alta de sus conocimientos financieros, por un 0% con educación inferior a bachillerato.

Por otro lado, el 88% de los individuos encuestados manifestó estar al día de la actualidad. La percepción de estos individuos de sus competencias financieras es alta o muy alta (76%) respecto de aquellos que afirman no estar al día de la actualidad (44%). El medio preferido por los encuestados para estar actualizados es Internet, esto contrasta con la pérdida de peso que han tenido las familias y los docentes a la hora de impartir conocimientos financieros. Sin embargo, según los datos de la encuesta aquellos individuos que utilizan los medios escritos (periódicos) para mantenerse informados presentan una percepción de su conocimiento financiero mayor (80%) que los que utilizan los medios digitales (74%) o la radio (63%). En relación con este predictor, las dos principales fuentes de información dentro de los medios escritos son El País y el Mundo representando un 52% de la muestra. Los encuestados que consultan estos medios escritos presentan una percepción financiera alta o muy alta.

Además, se analizaron predictores relacionados con el equipo preferido o si tu equipo había ganado o no su último partido. Como datos reseñables, podemos decir que aquellas personas que contestaron sentir predilección por el Real Madrid o FC Barcelona (80%) presentan una mejor percepción de su conocimiento financiero que los del Atlético de Madrid u otro equipo (64%, 73% respectivamente). Esta misma línea siguen los resultados de aquellos cuyo equipo hubiera ganado o perdido (80%) respecto de los que empataron o no eran seguidores de este deporte (45%, 65% respectivamente)

Por último, los predictores relacionados con el estado del tiempo y del ánimo reflejan que aquellos que contestaron en un día lluvioso (90%) y su estado de ánimo era muy bueno tienen una mejor percepción financiera que el resto de los individuos de la muestra.

En la Tabla 1 se presenta los resultados de un análisis de un modelo de clasificación de Random Forest para predecir el nivel de cultura financiera utilizando diferentes conjuntos de predictores.

La última columna de la Tabla 1 indica qué predictores se incluyeron en cada conjunto de datos. Por ejemplo, "Todos los predictores (1-11)" significa que se utilizaron todos los predictores disponibles en el estudio, mientras que las otras filas muestran los resultados al eliminar ciertos predictores específicos. Por lo tanto, estos resultados muestran cómo varía el rendimiento del modelo al eliminar diferentes predictores del conjunto de datos. Por ejemplo, parece que eliminar

el predictor "estado de ánimo" mejora ligeramente la precisión y el área bajo la curva ROC, mientras que eliminar "percepción actualidad" resulta en un descenso significativo en varias métricas de rendimiento del modelo.

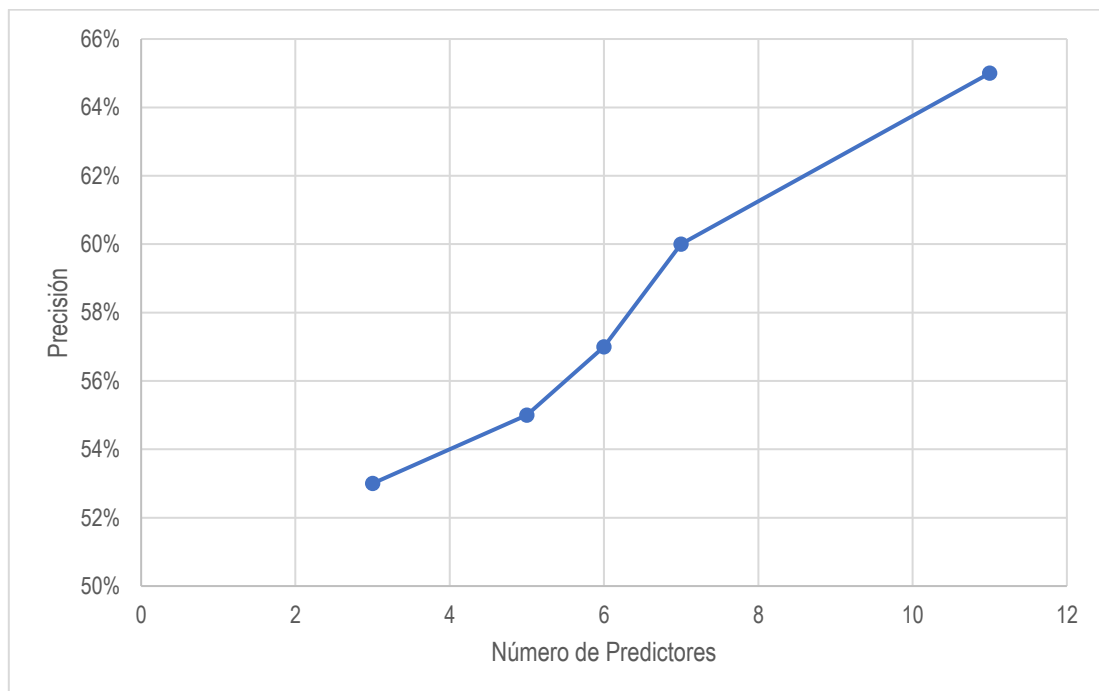
**Tabla 1.** Resultados validación cruzada random forest

| TP Rate | FP Rate | Precision | Recall | ROC Area | PRC Area | Predictores                           |
|---------|---------|-----------|--------|----------|----------|---------------------------------------|
| 0,659   | 0,241   | 0,667     | 0,66   | 0,78     | 0,68     | Todos los predictores (1-11)          |
| 0,601   | 0,276   | 0,607     | 0,60   | 0,75     | 0,64     | Sin estado de ánimo (1-7)             |
| 0,567   | 0,311   | 0,566     | 0,57   | 0,73     | 0,60     | Sin genero (1; 3-7)                   |
| 0,553   | 0,325   | 0,525     | 0,55   | 0,69     | 0,55     | Sin estado civil (1; 4-7)             |
| 0,534   | 0,451   | 0,432     | 0,53   | 0,52     | 0,39     | Sin percepción actualidad (1; 4; 6-7) |

La escala de colores nos indica qué estadísticos son superiores al 0,5 (en amarillo) y superiores a 0,7 (en verde), siendo rojo el resto de los casos, los cuales no validan la hipótesis H0 de este estudio. Se observa que todos los modelos entrenados tienen capacidad predictiva, excepto el PRC Área del último modelo entrenado con solo 4 predictores. Estos resultados no permiten validar la hipótesis de estudio.

Observamos además que se va degradando la precisión de los modelos a medida que vamos reduciendo los predictores incluidos en el entrenamiento del modelo, con una tasa de acierto de reales positivos que va del 66% cuando tenemos todos los predictores a una tasa del 53% cuando solo se predice con 4 variables (Figura 2).

**Figura 2.** Evolución de la precisión (fuente: elaboración propia)



---

## DISCUSIÓN, CONCLUSIONES E IMPLICACIONES

La cultura financiera se basa en un conjunto de conocimientos económico-financieros que todas las personas deberían dominar para resolver los problemas cotidianos de su día a día. Conceptos como inflación, tipo de interés o diversificación del riesgo aparecen cada vez con mayor asiduidad en informativos, programas de actualidad y tertulias por lo que su conocimiento y comprensión resulta fundamental para una sociedad cada vez más compleja desde un punto de vista económico. Sin embargo, los últimos informes revisados relacionados con el nivel de cultura financiera tanto del mundo en general, como de España en particular arrojan datos preocupantes. Centrándonos en España, podemos observar cómo a pesar de que la percepción de los encuestados sobre su nivel de cultura financiera es alta, menos de la mitad demuestra poseer dichos conocimientos (European Commission, 2023; PISA, 2022).

Es en este punto donde surge la necesidad de encontrar una herramienta que nos permita predecir con la mayor efectividad y precisión posible el nivel de cultura financiera de los individuos. En el contexto actual, donde la digitalización está cada vez más presente en nuestras vidas, la Inteligencia Artificial (IA) se ha vuelto una herramienta clave a la hora de predecir, analizar e interpretar información. El crecimiento exponencial de datos a los que los individuos y organizaciones tienen acceso, así como los avances de aprendizaje automático hacen de esta tecnología una ventaja competitiva a la hora de predecir patrones y tomar decisiones financieras informadas.

Por consiguiente, una vez contextualizado el enfoque del presente artículo, se realizó un trabajo de investigación que trata de evidenciar la capacidad que la Inteligencia Artificial (IA) tiene para predecir el nivel de cultura financiera de los individuos que participaron en la muestra. Para ello, se recogió información sobre 11 predictores previamente seleccionados por su posible influencia en la cultura financiera y se compararon con la variable objetivo (nivel de cultura financiera) medida en una escala ordinal que varía del 1 al 4. Esta comparación se realizó utilizando un modelo Random Forest. Además, para evaluar la capacidad predictiva del modelo y reducir el riesgo de sobreajuste se llevó a cabo una validación cruzada de 10 particiones.

Los resultados obtenidos en el presente estudio ponen de manifiesto que, analizados cada uno de los 11 predictores de manera individual y relacionados con el nivel de cultura financiera que cada individuo de la muestra afirma tener existe una percepción, con carácter general, alta o muy alta de la variable objetivo. Esto contrasta con los informes mencionados a lo largo del estudio. No obstante, atendiendo a la precisión del modelo podemos observar cómo a medida que el número de predictores es menor la precisión del modelo disminuye.

Esto deja abierto nuevas vías de investigación como puede ser la necesidad de comprobar la hipótesis inicial, la formulación de predictores, más precisos, basados en los resultados obtenidos, la consideración de una nueva metodología de estudio o la utilización de una muestra mayor. La revisión de cualquiera de estos factores puede influir positivamente en la capacidad para validar la hipótesis.

En resumen, la Inteligencia Artificial (IA) será capaz de predecir a través de un algoritmo, una variable que será generalmente binaria, con unos parámetros de flexibilidad total y sin que exista ninguna relación preestablecida entre esas variables para generar los resultados correspondientes. Y esto podrá suponer un importante avance respecto de las técnicas econométricas tradicionales.

---

## REFERENCIAS

- Aguiar, I., y Zagalaz, J. R. (2021). *Women and Financial Literacy in Spain. Does Marital Status Matter?* Journal of Women & Aging, 34(6), 785–799. <https://doi.org/10.1080/08952841.2021.1991194>
- Alonso, A., y Carbó, J.M. (2022). *Inteligencia Artificial y Finanzas: Una alianza Estratégica (Artificial Intelligence and Finance: A Strategic Alliance)*. Banco de España. Occasional Paper No. 2222. <https://doi.org/10.2139/ssrn.4252710>
- Ashton, J. K., Gerrard, B., y Hudson, R. (2010). *¿Do National Soccer Results Really Impact on The Stock Market?* Applied Economics, 43(26), 3709–3717. <https://doi.org/10.1080/00036841003689762>
- Berument, H., Ceylan, N. B. y Gozpinar, E. (2006). *Performance Of Soccer on The Stock Market: Evidence from Turkey*. The Social Science Journal, 43(4), 695–699. <https://doi.org/10.1016/j.soscij.2006.08.021>
- Bishop, C. (2007). *Pattern Recognition and Machine Learning*. New York, NY: Springer.
- Boyle, G. y Walter, B. (2003). *Reflected Glory and Failure: International Sporting Success and The Stock Market*. Applied Financial Economics, 13, 225–235. <https://doi.org/10.1080/09603100210148230>
- Cachón Rodríguez, G., Gomez Martinez, R., Martinez-Navalon, J.-G., & Prado-Roman, C. (2019). *Artificial intelligence to predict loyalty to university*. Journal of Management and Business Education, 2(1), 17–27. <https://doi.org/10.35564/jmbe.2019.0003>
- Caruana, R., y Niculescu-Mizil, A. (2006). *An Empirical Comparison of Supervised Learning Algorithms*. Association for Computing Machinery, New York, NY, USA, 161–168. <https://doi.org/10.1145/1143844.1143865>
- Centeno, A. (2020). *Big Data. Técnicas de Machine Learning para la Creación de Modelos Predictivos para Empresas*. [Trabajo Fin de Carrera, Universidad Pontificia de Comillas]. Repositorio Comillas. <http://hdl.handle.net/11531/45878>
- Chang, S., Chen, S., Chou, R. K. y Lin, Y. (2012). *Local Sports Sentiment and Returns of Locally Headquartered Stocks: A Firm-Level Analysis*. Journal of Empirical Finance, 19(3), 309–318. <https://doi.org/10.1016/j.jempfin.2011.12.005>
- Comisión Nacional del Mercado de Valores y Ministerio de Asuntos Económicos y Transformación Digital. (2021). *Plan de Educación Financiera 2022 – 2025*. Banco de España.
- Consejo de Estabilidad Financiera (2017). *Artificial Intelligence and Machine Learning in Financial Services*. [P011117.pdf \(fsb.org\)](https://www.fsb.org/P011117.pdf)
- Damián, Z. Y., y Sánchez, J. A. (2024). *Educación, Cultura e Inclusión Financiera: Una Revisión Bibliográfica*. Actas del VIII Congreso de Investigación, Desarrollo e Innovación de la Universidad Internacional de Ciencia y Tecnología. <https://doi.org/10.47300/actasidi-unicyt-2023-29>
- Del Barrio, D. (2022). *Aplicación del Aprendizaje Automático en Modelos de Materia Activa*. [Proyecto Fin de Carrera, E.T.S.I. Industriales, Escuela Técnica Superior de Ingenieros Industriales]. Archivo digital UPM. <https://oa.upm.es/70193>
- Demirhan, D. (2013). *Stock Market Reaction to National Sporting Success: Case of Istanbul Stock Exchange*. Pamukkale Journal of Sport Sciences, 4(3), 107–121.
- Díaz, J. (2021). *Aprendizaje Automático y Aprendizaje Profundo*. Ingeniare. Revista Chilena de Ingeniería, 29(2), 180-181. <https://dx.doi.org/10.4067/S0718-33052021000200180>

- 
- Domínguez, J.M. (2022). *La Cultura Financiera en la Sociedad Española: Conocimientos, Competencias y Hábitos Financieros*. Panorama Social, n.º 35. <https://dialnet.unirioja.es/servlet/articulo?codigo=8683126>
- European Commission (2023). *Monitoring the Level of Financial Literacy in the EU*. Flash Eurobarometer 525. <https://europa.eu/eurobarometer/surveys/detail/2953>
- Espino, C. (2017). *Análisis Predictivo: Técnicas y Modelos Utilizados y Aplicaciones del Mismo – Herramientas Open Source que Permiten su Uso*. [Trabajo Fin de Grado, Universitat Oberta de Catalunya]. Repositori Institucional O2. <http://hdl.handle.net/10609/59565>
- Gimeno, R., y Marqués, J.M. (2022). *Tradición e Inteligencia Artificial: Oportunidades y Retos del Machine Learning para los Servicios Financieros*. ICE, Revista De Economía, (926). <https://doi.org/10.32796/ice.2022.926.7403>
- Gómez, R. y Prado, C. (2014). *Sentimiento del Inversor, Selecciones Nacionales de Fútbol y su Influencia Sobre Sus Índices Nacionales*. Revista Europea de Dirección y Economía de la Empresa, 23(3), 99-114. <https://doi.org/10.1016/j.redee.2014.02.001>
- Gómez Martínez, R., Medrano-García, M. L., & Aznar-Sánchez, T. (2024). Artificial intelligence to predict university master's program recommendations. *Journal of Management and Business Education*, 7(1), 25–36. <https://doi.org/10.35564/jmbe.2024.0002>
- Harding, N. y He, W. (2011). *Investor Mood and The Determinants of Stock Prices: An Experimental Analysis*. Accounting and Finance, Forthcoming. <http://dx.doi.org/10.2139/ssrn.1786344>
- Hastie, T., Tibshirani, R., y Friedman, J. H. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. New York, NY: Springer.
- Hirshleifer, D. y Shumway, T. (2003). *Good day Sunshine: Stock Returns and The Weather*. Journal of Finance, 58, 1009–1032. <https://doi.org/10.1111/1540-6261.00556>
- Hospido, L., Machelett, M., Pidkuyko, M. y Villanueva, E. (2021). *Encuesta de Competencias Financieras (ECF)*. Banco de España. <https://doi.org/10.53479/34752>
- Housel, M. (2020). *The Psychology of Money. Timeless Lessons on Wealth, Greed, and Happiness*. Harriman House.
- Irgoin, U., y Morales, C. (2024). *El Machine Learning en las Finanzas*. Mount Scopus Journal. <https://hcommons.org/deposits/item/hc:68005>
- Jordan, J.M., y Mitchell, T.M. (2015). *Machine Learning: Trends, Perspectives, and Prospects*. Science 349, 255-260. <https://doi.org/10.1126/science.aaa8415>
- Kahneman, D. y Tversky, A. (1979). *Prospect Theory: An Analysis of Decisions Under Risk*. Econometrica, 47(2), 263–291. <https://doi.org/10.2307/1914185>
- McCarthy, J., Minsky, M., Rochester, N., y Shannon, C.E. (1955). *A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence*. AI Magazine, 27(4), 12 - 14. <https://doi.org/10.1609/aimag.v27i4.1904>
- Mishra, V., y Smyth, R. (2010). *An Examination of The Impact of India's Performance in One-Day Cricket Internationals on The Indian Stock Market*. Pacific-Basin Finance Journal, 18(3), 319–334. <https://doi.org/10.1016/j.pacfin.2010.02.005>
- Mullainathan, S., y Spiess, J. (2017). *Machine Learning: An Applied Econometric Approach*. Journal of Economic Perspectives, 31 (2), 87 – 106. <https://doi.org/10.1257/jep.31.2.87>
- Naeem, S., Ali, A., Anam, S., y Munawar, M. (2023). *An Unsupervised Machine Learning Algorithms: Comprehensive Review*. International Journal of Computing and Digital Systems. <http://dx.doi.org/10.12785/ijcds/130172>
- Rojas, E. M. (2020). *Machine Learning: Análisis de Lenguajes de Programación y Herramientas para Desarrollo*. Revista Ibérica de Sistemas e Tecnologías de Informação, Nº (E28), 586-599.
- Sandoval, L. J. (2018). *Algoritmos de Aprendizaje Automático para Análisis y Predicción de Datos*. Revista Tecnológica; no. 11.
-

- 
- Trejos, D. F., Osorio, S. L., Corrales, L. V., y Duque, P. (2021). *Toma de Decisiones Financieras: Perspectivas de Investigación*. Revista de Ingenierías Interfaces, vol. 4, no. 1, pp. 1 – 22. <https://dialnet.unirioja.es/servlet/articulo?codigo=8661426>
- Parne, P. (2021). *Artificial Intelligence & Machine Learning Role in Financial Services*. Advances In Machine Learning. <https://doi.org/10.5121/csit.2021.111504>
- Parra, F. (2019). *Estadística y Machine Learning con R*. Editorial Académica Española. <https://bookdown.org/content/2274/bibliografia.html>
- PISA (2022). *Competencia Financiera. Informe Español*. Instituto Nacional de Evaluación Educativa. [https://www.libreria.educacion.gob.es/libro/pisa-2022-competencia-financiera-informe-espanol\\_184455/](https://www.libreria.educacion.gob.es/libro/pisa-2022-competencia-financiera-informe-espanol_184455/)
- Shalev-Shwartz, S., y Ben-David, S. (2014). *Understanding Machine Learning: From Theory to Algorithms*. Cambridge: Cambridge University Press. <https://doi.org/10.1017/CBO9781107298019>
- Skinner, B.F. (1948). *Superstition in the pigeon*. Journal of Experimental Psychology, 38 (2), 168 – 172. <https://doi.org/10.1037/h0055873>

## ANEXO

### Anexo Formulario de Preguntas

La encuesta se ha distribuido a través de varios formularios online accesible a través de Google Forms. El formulario está formado por las siguientes preguntas:

- Nivel de Cultura Financiera (Target):
  1. Tu cultura financiera es (1-4)
- Predictores de características personales
  2. ¿Qué edad tienes?
    - Menos de 24 años
    - De 25 a 44 años
    - De 45 a 64 años
    - Más de 65 años
  3. ¿Cuál es tu género?
    - Hombre
    - Mujer
    - Otro
  4. ¿Cuál es tu Estado Civil Actual?
    - Solter@
    - Casad@
    - Divorciad@
    - En pareja
    - Otro
  5. Nivel de estudios completado
    - Primaria
    - ESO
    - Bachiller - Formación Profesional (Grado Medio)
    - Estudio de Grado
    - Postgrado
    - Doctorado



- 
6. ¿Consideras que estás al tanto de la actualidad?
    - Sí
    - No
  7. Para informarte, qué canal prefieres
    - Medios digitales (Internet)
    - Medios escritos (Periódico)
    - Radio o televisión
  8. Si tuvieses que buscar información sobre algún tema económico-político primero consultarías en
    - El País
    - El Mundo
    - 20 Minutos
    - El Español
    - ABC
    - El Confidencial
    - La Razón
    - Ok Diario
    - El Periódico
    - La Vanguardia
    - El Correo
    - La Voz de Galicia
    - Otros
  9. ¿De qué equipo eres?
    - Real Madrid
    - FC Barcelona
    - Atlético de Madrid
    - Otro
    - No soy seguidor de este deporte
  10. ¿Ha ganado tu equipo su último partido?
    - Sí
    - No
    - Empate
    - No sigo a ninguno
  11. ¿Hoy hace un día?
    - Soleado y radiante
    - Nublado
    - Llueve
    - Nieva
  12. Hoy estás (1-4)
    - Muy triste
    - Triste
    - Contento
    - Muy contento