

INTELIGENCIA ARTIFICIAL COMO HERRAMIENTA DE ANÁLISIS EN GESTIÓN VALUE

RAÚL GÓMEZ MARTÍNEZ

raul.gomez.martinez@urjc.es

*Universidad Rey Juan Carlos, Departamento de Economía de la Empresa
Paseo de los Artilleros s/n, 28032 Madrid (España)*

CAMILO PRADO ROMÁN

camilo.prado.roman@urjc.es

*Universidad Rey Juan Carlos, Departamento de Economía de la Empresa
Paseo de los Artilleros s/n, 28032 Madrid (España)*

LUIS JAVIER SAZ PEÑAS

lj.saz.2016@alumnos.urjc.es

*Universidad Rey Juan Carlos, Departamento de Economía de la Empresa
Paseo de los Artilleros s/n, 28032 Madrid (España)*

Recibido (23/01/2020)

Revisado (13/05/2020)

Aceptado (06/10/2020)

RESUMEN: A pesar de que es asumido que los valores con ratios más bajos son valores baratos y deben tener un mejor rendimiento que el mercado la “gestión value” ha tenido problemas para batir al mercado sistemáticamente. En este estudio pretendemos identificar si la inteligencia artificial puede ser una herramienta útil en la “gestión value” y puede identificar qué valores o carteras van a batir al mercado. Con este propósito se han realizado diferentes entrenamientos de un modelo de inteligencia artificial que utiliza los ratios como predictores, mientras que la variable objetivo toma los valores “bate/no bate” al mercado. Los resultados obtenidos para el Mercado Español y Americano muestran que la capacidad predictiva del modelo supera el 60% de tasa de acierto y que una cartera diseñada por un sistema experto basado en inteligencia artificial es capaz de batir al Ibex 35. Por lo tanto, la inteligencia artificial es una herramienta útil para la gestión de activos con perfil value, ya sea como herramienta para ayudar en la investigación del analista o como motor de un sistema experto que diseñe carteras con el objetivo de batir al mercado.

Palabras clave: Inteligencia Artificial, Redes Bayesianas, Inversión Value, factores, gestión de activos.

ABSTRACT: Although it is assumed that the securities with lower ratios are cheaper and should perform better than the market, "value investment" has not been able to beat the market. In this study, we try to identify if artificial intelligence can be a useful tool in "value investment" and can identify which securities or portfolios are going to beat the market. For this purpose, different trainings have been carried out on an artificial intelligence model that uses ratios as predictors, while the target variable takes the values "beat /don't beat" the market. The results obtained for the Spanish and American market show that the predictive capacity of the model exceeds 60% and that a portfolio designed by an expert system based on artificial intelligence is able of beating Ibex 35. Therefore, artificial intelligence is a useful tool for managing assets with a value profile, either as a tool to aid the analyst's research or as the engine of an expert system that designs portfolios with the aim of beating the market.

Keywords: Artificial Intelligence, Bayesian Networks, Value Investment, factors, asset management.

1. Introducción

El debate entre los partidarios de la gestión pasiva contra los partidarios de la gestión activa está captando la atención de los participantes en el mundo de los fondos de inversión y de la gestión de activos.

La gestión pasiva de un fondo de inversión tiene como objetivo construir una cartera que replique el comportamiento de un determinado índice. El gestor debe ser cuidadoso al incluir en su cartera los mismos valores que componen el índice en la proporción adecuada para que la evolución del valor liquidativo de la cartera sea lo más parecida posible a la evolución del índice a replicar. La principal ventaja de los fondos índice es que ofrecen a sus partícipes un alto grado de diversificación a bajo coste por lo que constituyen el vehículo ideal para aquellos inversores que quieran tener una exposición a una bolsa entera de manera económica. Las comisiones de gestión de estos fondos suelen ser bajas ya que no necesitan un departamento de análisis. Al no tener posiciones en liquidez y estar invertidos totalmente en mercado se aprovechan más en los mercados fuertemente alcistas.

Los fondos de gestión activa utilizan diferentes estrategias con el objetivo de batir a un índice de referencia o benchmark. Dos de las técnicas más utilizadas son la del “top-down” y la del “bottom-up”. Los gestores que realizan un análisis top-down para seleccionar las acciones que componen su cartera, van de una perspectiva más alta bajando hasta lo más concreto, empiezan por analizar el escenario macroeconómico de las áreas en las que invierte el fondo. En base al análisis de la situación actual de los mercados y de las posibles tendencias futuras, deciden la distribución de activos para el fondo. Por ejemplo, pueden decidir, en base a las buenas perspectivas que manejen para el sector financiero, que una determinada proporción de la cartera del fondo esté invertida en acciones del sector bancario siendo más representativa la exposición al sector que los valores individuales.

Por el contrario, los gestores bottom-up o “stockpickers” invierten eligiendo los valores que les parecen más atractivos atendiendo a la situación concreta de la empresa sin prestar especial atención a factores macroeconómicos o a tener una distribución equilibrada de la cartera por sectores. Las técnicas utilizadas por estos gestores son muy variadas, algunos gestores se basan en el “análisis técnico”, basado en el estudio de los movimientos de los precios o gráficos mientras que otros gestores utilizan el “análisis fundamental” de las compañías, examinando sus cuentas de resultados y la proyección estimada de sus flujos para calcular su valor teórico que indicará si la empresa está sobrevalorada o infravalorada (Briganti, 2001).

A pesar de que la gestión activa, tiene como objetivo batir al mercado, sólo el 21% de los gestores logran batir a la bolsa española en un plazo de 10 años (Moreno, 2018) lo cual indica que el análisis realizado no es todo lo preciso que podría ser o que no cuenta con las herramientas adecuadas a la hora de anticipar la gestión del valor seleccionado.

En la medida en la que la valoración de empresas es considerada “un arte” la gestión value queda vinculada a la capacidad del gestor, experiencia e intuición para valorar correctamente las empresas objetivo y realizar la selección adecuada por lo que el factor humano es totalmente relevante (Gómez, 2014).

El estilo de gestión value tiene su origen en las inconsistencias que presenta el marco teórico de la gestión moderna de carteras y se puede considerar como uno de los caminos seguidos por la evolución de los primeros modelos CAPM formulados por Markowitz (1952), Sharpe (1964) y Lintner (1965) y la vía intermedia entre gestión activa y gestión pasiva. La falta de capacidad de este modelo para explicar las contradicciones entre sus postulados y la constatación empírica de los mismos, permiten el desarrollo de nuevos enfoques como “Asset Pricing Theory” (APT) formulado por Ross (1976).

Fama y French (1992) consiguen integrar dos de las principales inconsistencias del CAPM, tamaño y valoración, en un modelo de tres factores que permite una mejor explicación de los rendimientos del mercado que la formulada por el CAPM que se basa en un único elemento (beta de los activos). La exposición a estos dos factores permite obtener una prima de rendimiento sobre el mercado a cambio de soportar prolongados períodos con una rentabilidad inferior al mismo en los “malos tiempos” según formulación de Ang (2014).

Aparte de estos factores, hay muchos otros factores que han demostrado ser relevantes a la hora de determinar si un activo está caro o barato, y por tanto si va a tener una evolución mejor o peor que el índice de referencia representativo de la evolución del mercado. La pregunta que surge es cómo utilizar estos factores y cómo ponderar su efecto sobre la rentabilidad de las acciones para anticipar si van a batir al

mercado o no. En este artículo proponemos utilizar la inteligencia artificial para resolver esta cuestión, desarrollando modelos que cuantifican y predicen la evolución de los valores utilizando como predictores los factores.

2. Marco teórico

Podemos considerar el modelo de Fama y French como una superación del CAPM formulado por Treynor (1961), Sharpe (1964) y Lintner (1965) y que tiene su base en los trabajos de Markowitz (1952) sobre maximización de retorno minimizando el riesgo.

El CAPM se formula asumiendo que en una situación de equilibrio el riesgo específico es diversificado por lo que el rendimiento de un activo viene determinado exclusivamente por su beta, es decir su sensibilidad sobre el riesgo de mercado. La formación de este modelo es:

$$E(R_i) = R_f + \beta (E(R_m) - R_f) \quad (1)$$

donde:

- $E(R_i)$: Es la rentabilidad esperada del activo "i"
- R_f : Es la rentabilidad de referencia que ofrece un activo sin riesgo
- β : Es la sensibilidad del activo "i" al riesgo de mercado
- $E(R_m) - R_f$: Es la prima de riesgo medida como el diferencial entre la rentabilidad esperada del mercado y la rentabilidad del activo sin riesgo.

Diferentes pruebas empíricas refutaron esta igualdad, constatándose una serie de anomalías que no se podían explicar con la formulación original del modelo.

Dentro de estas anomalías destacaríamos:

- i. Efecto Tamaño, documentada por Banz (1981) que demuestra que el CAPM no está bien especificado ya que en promedio las firmas "más pequeñas del NYSE presentan un retorno ajustado por riesgo superior al de las grandes".
- ii. Efecto Precio, formuladas a través de la comparación de un dato contable con la cotización de la compañía. El "factor value" se basa en que una selección de acciones que cotizan a múltiplos más bajos va a batir al mercado. Fue enunciado por Graham y Dodd en 1934 y ha presentado distintas especificaciones según el parámetro contable seleccionado, entre las que señalaremos:
 - a) Basu (1983) comparando precio y beneficios, ratio PER.
 - b) Chan, Hamao y Lakonishok (1991) que relaciona el valor contable de las compañías con su cotización.
 - c) Litzenberger y Ramaswamy (1979) a través de la rentabilidad por dividendo.

Por lo tanto, el factor valoración cuestiona los resultados del CAPM independientemente de la comparación utilizada, tanto stock, es decir balance, como flujo, como en el caso del dividendo o el beneficio.

A la hora de explicar este exceso de rentabilidad de los factores estudiados las hipótesis se dividen en dos líneas según Lakonishok, Shleifer y Vishny (1994):

- El exceso de rentabilidad se explica como recompensa de un riesgo no diversificable consistente en un peor comportamiento en períodos de crisis económica, una menor liquidez o un peor perfil crediticio.
- El exceso de retorno se explica porque los inversores más ingenuos extrapolan crecimientos pasados y están dispuestos a pagar múltiplos más elevados por las compañías con "glamour". Bender, Briand, Melas y Subramanian (2013) exponen una explicación adicional y consiste en las restricciones de algunos gestores para incorporar ciertos activos a sus carteras, por ejemplo, las compañías de baja capitalización al estar condicionados por su benchmark.

Según Ang (2014) el inversor está dispuesto a sacrificar esa prima de retorno a cambio de asegurar un rendimiento en los "malos tiempos", es decir la utilidad de los retornos positivos es mayor en momentos de crisis económicas (recesión) que en momentos de bonanza económica.

A las razones para su mejor comportamiento (exposición al ciclo y extrapolación) mencionadas anteriormente se ha añadido Zhang (2005) en el que señala que el mayor riesgo inherente a este tipo de

compañías viene ligado a la existencia de una estructura productiva no escalable y que por lo tanto las hace más sensibles al ciclo.

El efecto tamaño fue documentado por Banz (1980). En este artículo se apunta que la prima por tamaño puede deberse a la asimetría de información disponible sobre los valores pequeños o a la existencia de una prima de posible adquisición por una compañía mayor. Así mismo destacan dos características adicionales de este factor, por un lado, no es constante en el tiempo y por otro se concentra en las empresas de menor tamaño.

Los dos factores estudiados en este artículo como desarrollo del modelo propuesto por Fama y French (1993) son el factor “value” y el factor “size” llegando a la siguiente expresión:

$$E(R_i) = R_f + \beta_3 (E(R_m) - R_f) + \beta_s \text{SMB} + \beta_v \text{HML} \quad (2)$$

donde:

- $E(R_i)$: Es la rentabilidad esperada del activo “i”
- R_f : Es la rentabilidad de referencia que ofrece un activo sin riesgo
- $E(R_m) - R_f$: Es la prima de riesgo medida como el diferencial entre la rentabilidad esperada del mercado y la rentabilidad del activo sin riesgo.
- SMB: Es la medida de tamaño (“size”)
- HML: Es la medida del factor “value” según la ratio book-to-market

Según se detalla en su página web la diferencia entre la rentabilidad de mercado y el activo sin riesgo ($R_m - R_f$), mide el exceso de retorno del mercado ponderado por capitalización de todas las firmas incorporadas en los mercados NYSE, AMEX O NASDAQ a las que se resta el interés de la letra del tesoro a un mes. Por lo tanto, la metodología de Fama y French consiste en formar carteras con exposición a los factores:

Para el factor valor utiliza el portfolio HML que se compone de una posición larga equiponderada en Small value + Big value y una posición corta en Small growth + Big growth con pesos al 50%.

Para el factor growth utiliza la cartera SMB que toma una posición larga equiponderada en Small Value + Small neutral + Small growth y otra corta en Big Value + Big neutral + Big growth.

A la hora de elegir estos dos factores hemos tenido en cuenta que cumplieren los principios propuestos por Berkin y Swedroe (2016) en su trabajo sobre factores de inversión:

- Persistencia
- Globalidad
- Que sea factible invertir en ellos
- Intuitivo
- Robustez

Para estudiar la persistencia de esta rentabilidad adicional de los valores con ratios bajos hemos tomado dos ámbitos de estudio, uno internacional y otro local.

Por un lado, nos hemos remontado al año 1971, incluyendo de esta forma el período post años 60. En cuanto a la globalidad trabajamos con la base de Fama y French que cubre con la misma metodología los mercados norteamericanos, Asia, Europa, Pacífico y el mercado global. En cuanto a la factibilidad de invertir en ellos la inversión valor es fácilmente accesible a través del empleo de ETFs o bien fondos dedicados, en cuanto a la inversión en pequeñas vs grandes el mercado americano permite segmentar la inversión a través de índices especializados como el Russell 3000. Su carácter intuitivo se puede comprobar en las explicaciones anteriormente reseñadas y que unen su rentabilidad a la exposición al ciclo o al riesgo. Por último, la robustez de los mismos queda explicitada por la diversidad de indicadores a través de los cuales se puede explicitar (PER, precio valor contable, rentabilidad por dividendo). Teniendo esto en cuenta entrenamos un modelo de inteligencia artificial en el que los predictores son los factores medidos por Fama y French y la variable objetivo si un valor cotizado bate o no bate al mercado.

Hay que tener en cuenta que las empresas que cotizan en el mercado bursátil español a ratios más bajos incorporan un mayor riesgo y por lo tanto un mayor rendimiento como recompensa (Fama y French, 1992), además son valores que el mercado no sigue por su mal comportamiento anterior (Lakonishok, Shleifer y

Vishny 1994). Siguiendo este argumento se podría desarrollar un sistema experto basado en inteligencia artificial que calculase estadísticamente la probabilidad de un valor de batir al Ibex el próximo año.

3. Hipótesis, metodología y datos

La hipótesis que se desarrolla en este artículo es sencilla:

H0: La inteligencia artificial puede identificar qué valores o carteras van a batir al mercado.

Para contrastar esta hipótesis hemos realizado dos estudios, en el primero analizaremos si las variables macroeconómicas pueden predecir un mayor retorno del estilo de gestión value en su conjunto, en el segundo analizaremos si la inteligencia artificial nos permite seleccionar una cartera de valores concretos que batan al mercado. Con la finalidad de dar mayor validez a estas propuestas se han seleccionado dos marcos geográficos, Estados Unidos a la hora de evaluar el estilo de gestión value y la bolsa española a la hora de seleccionar una cartera de valores.

Teniendo en cuenta que la variable objetivo tiene dos posibles valores (bate/no bate) un sistema aleatorio sin ninguna capacidad predictiva tendría una tasa de acierto del 50% (como tirar una moneda al aire). Por lo tanto, validaremos esta hipótesis si los modelos de inteligencia artificial presentan tasas de acierto superiores al 50%.

Para validar esta hipótesis se ha construido un modelo de inteligencia artificial basado en redes bayesianas donde los predictores son los factores registrados por Fama y French, así como las ratios anuales de cada una de las empresas cotizadas en el Mercado Continuo Español. Para ambos modelos la variable objetivo es si la empresa bate o no bate al Ibex.




Figura 1. Ejemplo de Red Bayesiana

Una red bayesiana es un modelo probabilístico en un grafo acíclico dirigido que representa un conjunto de variables aleatorias y sus dependencias condicionales. Por ejemplo, una red bayesiana puede representar las relaciones probabilísticas entre enfermedades (variable objetivo) y síntomas (predictores). Dados los síntomas, la red puede ser usada para computar la probabilidad de que el paciente esté enfermo. En nuestro caso los predictores son los ratios de los valores cotizados en la Bolsa Española y la variable objetivo la probabilidad de que ese valor tenga una rentabilidad superior a la del Ibex 35. Cada uno de los nodos de la red bayesiana representa variables aleatorias que pueden ser elaboradas de diferente manera. Las aristas representan dependencias condicionales; los nodos que no se encuentran conectados representan variables las cuales son condicionalmente independientes de las otras. Cada nodo tiene asociado una función de probabilidad que toma como entrada un conjunto particular de valores de las variables padres del nodo y devuelve la probabilidad de la variable representada por el nodo. Para ilustrar este concepto con un ejemplo, supongamos una situación en la que podría llover hoy y podría llover mañana, ¿cuál es la probabilidad de que llueva en ambos días? La lluvia en dos días consecutivos no son eventos independientes con probabilidades aisladas. Si llueve en un día, es más probable que llueva el siguiente. Resolver un problema de este tipo implica determinar las posibilidades de que llueva hoy, y luego determinar la probabilidad de que llueva mañana, dependiendo de la probabilidad de que llueva hoy. Estas son conocidas como

"probabilidades conjuntas". Supongamos que $P(\text{lluvia hoy}) = 0.20$ y $P(\text{lluvia mañana dado que llueve hoy}) = 0.70$. La probabilidad de tales eventos conjuntos está determinada por:

$$P(E_1, E_2) = P(E_1)P(E_2|E_1) \quad (3)$$

Así trabajando con estas probabilidades se puede construir la red bayesiana como la que se representa en la Figura 1 (Niedermayer, 2017).

A partir de la red Bayesiana construida podremos validar la hipótesis anterior desde dos perspectivas:

- **Retrospectiva:** Entrenaremos el modelo con el 80% de los datos de la muestra, reservando el 20% de los datos para su validación. Dado que la variable objetivo es booleana y sólo puede tomar dos valores excluyentes (si/no), si la tasa de acierto del modelo, sobre la muestra de validación, es superior al 50% habremos validado la hipótesis H_0 .
- **Prospectiva:** Entrenamos el modelo con todos los datos disponibles hasta el año 2018 (último año para el que la variable objetivo ha sido observada) y utilizamos el modelo para predecir la probabilidad de que cada uno de los valores del Mercado Continuo bata al Ibex 35, a partir de los ratios estimados para 2019. Con los valores que el modelo ha indicado que van a batir al Ibex construimos una cartera y comparamos la rentabilidad observada de esa cartera a lo largo de 2019 con la rentabilidad del Ibex. Si la cartera creada por el modelo obtiene una rentabilidad superior al Ibex 35 esto reforzaría la validación retrospectiva de la hipótesis H_0 .

Inteligencia Artificial en el Mercado Americano

A la hora de desarrollar este modelo se han tenido en cuenta los siguientes requerimientos:

1. Disponer de una base de datos lo suficientemente prolongada en el tiempo como para estimación *sample in / sample out* robusta. En este sentido el estudio se extiende desde el año 1971 al 2018 (47 años) de los cuales un 80% se ha dedicado al aprendizaje del modelo y un 20% a la comprobación de los resultados.
2. Disponer de una batería de factores explicativos que estuviese justificada en la teoría financiera.

Los indicadores que se han utilizado para entrenar al modelo cubren tres vertientes diferentes de la evolución de la economía

La evolución de la economía se ha recogido a través de dos series de indicadores que recogen su aspecto real (Índice de Producción Industrial, Indicador adelantado de la OCDE e Indicador de la Actividad Nacional desarrollado por la Fed de Chicago) y financieros (Tipo efectivo de la Reserva Federal, pendiente entre los tipos a 10 años y 3 meses, evolución del tipo a 10 años y la cotización del índice bursátil Standard and Poor's 500).

De esta forma se combinan indicadores de *hard data* (producción industrial como variable que recoge la evolución de actividad real manufacturera en Estados Unidos) con indicadores anticipados como el anticipado de la OCDE que mediante técnicas estadísticas anticipan los puntos de giro de la economía. Por último, el Índice de actividad industrial que calcula la Reserva Federal de Chicago es un resumen amplio de la evolución de la economía americana que combina 85 variables que incluyen producción y renta, datos de empleo, consumo personal y vivienda, así como ventas, órdenes e inventarios. La posible influencia de las variables monetarias sobre la evolución de los factores se recoge a través de la evolución de la masa monetaria y del índice de precios de producción industrial.

Desde el punto de vista de los indicadores financieros hemos tomado:

- Tipo efectivo de la Reserva Federal, como resumen de la actuación del banco central a través del tipo rector de la economía americana. Este tipo refleja la actuación de la política monetaria en Estados Unidos y el sesgo de la Reserva Federal (restrictivo si está por encima del tipo de equilibrio o bien acomodaticio en el caso contrario).
- El segundo indicador manejado es la pendiente entre el tipo a 10 años y el de los tres meses, en efecto, la pendiente de la curva es uno de los indicadores más fiables de la proximidad de recesión si toma valores negativos (curva invertida).

- El tercer indicador es el tipo a 10 años del bono del gobierno USA que refleja la evolución a largo plazo del tipo a corto plazo de la economía y una prima (term premium) por asumir el riesgo de duración. El comportamiento del bono a 10 años es especialmente relevante en los últimos años en los que la política de relajación cuantitativa a través de la compra de bonos por parte del banco central ha deprimido el valor de la prima de plazo.

Por último, la aversión al riesgo está presente a través del *equity yield premium* y del índice de condiciones financieras. El primero se define como el diferencial entre el ratio per de la bolsa y el activo libre de riesgo es una medida de la aversión o proclividad del inversor a asumir riesgo (si el diferencial es reducido) o no (en el caso de que este haya aumentado). Este ratio fue enunciado por el antiguo presidente de la Reserva Federal, Alan Greenspan, como aproximación de valoración bursátil. Por otro lado, el índice de condiciones financieras se define por la Reserva Federal como "una medida exhaustiva de periodicidad semanal de las condiciones financieras en los mercados monetarios, de deuda y de renta variable y del sistema bancario, tanto tradicional como en la sombra de Estados Unidos". Valores positivos del NFCI indican unas condiciones financieras más restrictivas que el promedio mientras que valores negativos señalan un relajamiento de estas.

El análisis de las hipótesis se ha realizado a través de un análisis de redes bayesianas que podemos definir como un modelo gráfico probabilístico "que representa un conjunto de variables y sus dependencias" (Gómez, Prado y Menéndez, 2017), en línea con los expuesto por Friedman y Koller (2003) que consideran una red bayesiana como "la representación compacta de una distribución de probabilidades a través de la independencia condicional".

Se implementa a través de un gráfico dirigido acíclico, cuyos nodos son variables y se relacionan a través de flechas. Por último, existe una distribución condicional para cada nodo dado el valor que tomen sus padres.

La base estadística de las redes es el teorema de Bayes, que nos permite incorporar información adicional a una probabilidad inicial, en efecto, sean $P(A)$ la probabilidad inicial de un suceso y $P(B)$ la probabilidad de un suceso adicional, el teorema de Bayes define la $P(A/B)$ como el cociente entre la $P(A)$ x $P(B/A)$ y la probabilidad del suceso B.

En la red bayesiana propuesta para este artículo el procedimiento utilizado ha sido efectuar un pronóstico del comportamiento de los dos factores estudiados (variable objetivo) el mes siguiente a realizar el pronóstico en términos de "bate" vs "no bate", significando en el caso de "bate" que el factor tiene un resultado positivo en el mes, siendo la información adicional suministrada la evolución de los indicadores económicos.

El análisis estadístico se ha realizado con el software dVelox desarrollado por Apara y que permite reflejar gráficamente las redes bayesianas con el fin de analizar las dependencias de la variable objetivo¹.

Esta herramienta de data mining entrena el modelo mediante la ejecución de un workflow que es una secuencia de nodos en el que cada uno realiza una función específica. El workflow diseñado para este estudio sigue estos pasos:

1. La lectura de datos que tal como se ha citado anteriormente, consta de variables predictivas y una variable objetivo que toma los valores "bate" o "no bate".
2. El siguiente paso del software es la fase de auditoría del nodo de fichero plano con el fin de analizar la calidad de los datos de la muestra.
3. El siguiente paso es la discretización de las variables predictivas al número de rangos deseados.
4. Por último, se entrena el modelo de redes bayesianas a través del algoritmo denominado en dVelox "Objetivo Causa Óptimo". Este algoritmo se ejecuta en dos fases:
 - a. En la primera se entrena una red bayesiana forzando la relación de causalidad de todas las variables predictivas sobre la variable objetivo, aunque esta sea muy pequeña

¹ Para más información visitar: www.apara.es

- b. En la segunda fase, mediante un algoritmo de fuerza bruta, se van quitando y añadiendo variables predictivas del modelo hasta que se llega al modelo que maximiza la medida de calidad predictiva definida.

Metodológicamente a la hora de tratar la posible multicolinealidad de las variables no se realizó un estudio previo dejando libertad al modelo para establecer esta característica, adicionalmente el período de aprendizaje fue único y por tanto todos los pronósticos se han realizado con la misma información (1971 a 2007). De esta forma reducimos la posibilidad de data mining tanto a la hora de seleccionar las variables como del período estudiado.

La fuente de los datos sobre la evolución de los factores se ha obtenido de la página del profesor French de la Universidad de Dartmouth. Esta página recoge datos desde el año 1926 hasta la actualidad².

Los datos económicos se han obtenido primordialmente de la página web de la Reserva Federal de Saint Louis (FRED), de Chicago y de Nueva York, así como la del Consejo de la Reserva Federal y de la OCCDE. Adicionalmente se ha accedido a la información proporcionada por el profesor Shiller en su página de la Universidad de Yale³.

Inteligencia Artificial en el Mercado Español

Para entrenar el modelo se han descargado todos los datos disponibles de ratios fundamentales de los valores cotizados en el Mercado Continuo. La fuente de datos es Facset y la descarga se ha realizado desde la página web del diario El Economista⁴. Este diario ofrece ratios observados desde el año 2015 hasta el 2018 y los ratios estimados para el año 2019 tal y como se observa en la Figura 2. El entrenamiento y validación de los modelos se hizo a fecha 1 de enero de 2019.

Los predictores del modelo son las siguientes variables para cada empresa “i” de la muestra, en el año “t”:

- BPA: Beneficio por acción
- RPD Rentabilidad por Dividendo
- D Dividendo pagado
- PER Ratio precio beneficio
- RN Rentabilidad Neta de la Empresa
- DN Deuda Neta de la Empresa
- L Ratio de apalancamiento
- VCA Valor contable de la acción
- PBVR Ratio precio sobre valor contable
- EBITDA Earnings Before Interest Taxes Depreciation and Amortization
- ROE Rentabilidad sobre recursos propios
- EV/Ebitda Ratio Valor de Empresa sobre EBITDA
- EV Valor de Mercado de la empresa
- Sector Sector económico en el que está clasificada la empresa

Y la variable objetivo es:

- BATE Si/No

Después de un minucioso ejercicio de limpieza de dato erróneo y filtrado, se han recopilado un *dataset* de 541 líneas con ratios que abarcan desde 2014 hasta 2019, de las cuales 453 líneas han sido utilizadas para entrenar el modelo con datos anuales que van desde 2014 hasta 2018.

² Ver: <http://mba.tuck.dartmouth.edu/pages/faculty/ken.french/index.html>

³ Ver: <http://www.econ.yale.edu/~shiller/>

⁴ Para más información visitar <https://www.eleconomista.es/mercados/mercado-continuo>

ACCIONA

Precio **81,54** Variación ▼ **-0,39%** Var. **-0,32€** Vol (títulos): **104.061**

RESUMEN	NOTICIAS	PERFIL	VER MÁS ^			
	2015	2016	2017	2018	2019	2020
BPA (en €)	3,62	6,22	4,38	4,38	5,01	5,38
Rentabilidad por dividendo	3,17%	3,52%	3,66%	3,83%	4,01%	4,13%
Dividendo neto (en €)	2,29	2,88	3,00	3,14	3,28	3,38
PER (veces)	21,85	11,24	15,52	16,89	16,32	15,21
Beneficio neto (millones de €)	207,20	351,98	220,00	290,00	274,00	295,00
Deuda neta (millones de €)	5.159,00	5.131,10	5.224,39	4.662,50	4.664,95	4.772,00
Valor de los activos (por número de acciones)	61,01	66,91	65,70	62,71	63,80	64,64
Ebitda (millones de €)	1.174,00	1.192,00	1.275,00	1.230,00	1.208,85	1.253,47
Rentabilidad sobre recursos propios	5,93%	9,30%	6,67%	6,98%	7,86%	8,33%
EV / Ebitda (veces)(*)	8,68	8,03	7,49	7,61	8,16	7,96

Información ofrecida por: **FACTSET**

(*) Capitalización más deuda entre beneficio antes de impuestos y amortizaciones

Figura 2. Captura de pantalla de la fuente de datos para el modelo del mercado local

Fuente: www.eleconomista.es

4. Resultados

La red bayesiana entrenada para validar la hipótesis de este estudio es la que se muestra en las siguientes imágenes (en vista 3D, Figura 3, y 2D, Figura 4, respectivamente) donde se observan los flujos de relaciones entre las variables predictoras y la variable objetivo que indica si en ese periodo la cartera “value” bate o no bate al mercado.




Figura 3. Modelo IA 3D. Variable objetivo. Bate/No bate cartera “Value”

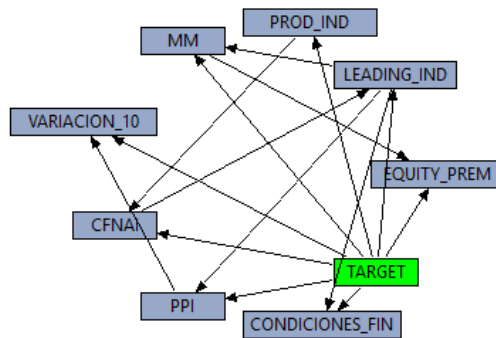


Figura 4. Modelo IA 2D. Variable objetivo. Bate/No bate cartera “Value”

La matriz de confusión y los estadísticos de este modelo son los recogidos en la Tabla 1:

Tabla 1. Matriz de confusión modelo IA. Variable objetivo. Bate/No bate cartera “Value”

ESTADISTICAS CARTERA FACTOR VALUE					
Valor Variable Objetivo	Tasa acierto	Predicción	ks	test f	Área ROC
NO BATE	58.60%	60.70%	20%	59.60%	68.50%
BATE	61.40%	59.30%	20%	60.30%	68.50%
MATRIZ DE CONFUSION					
	NO BATE	BATE	TOTAL		
NO BATE	34	24	58		
BATE	22	35	57		
TOTAL	56	59	115		

La red bayesiana entrenada para predecir si la cartera “size” de Fama y French bate o no bate al mercado en función de los predictores propuestos es la que se muestra en las Figuras 5 y 6:

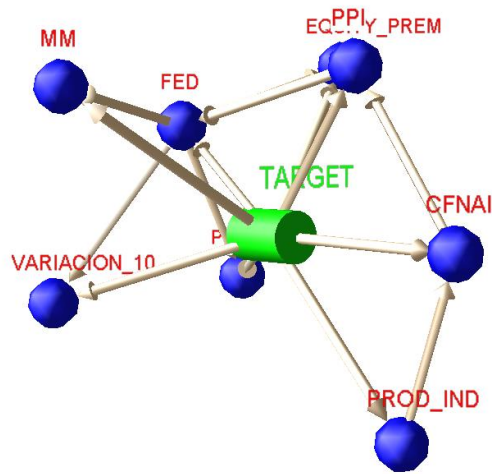


Figura 5. Modelo IA 3D. Variable objetivo. Bate/No bate cartera "Size"

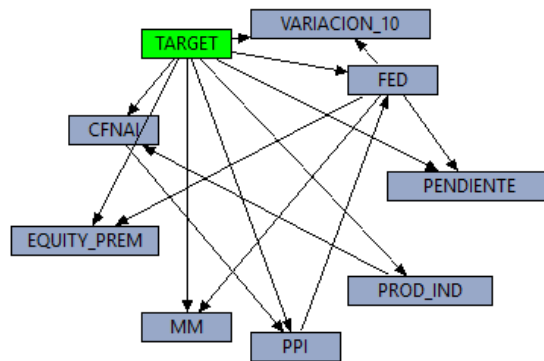


Figura 6. Modelo IA 2D. Variable objetivo. Bate/No bate cartera "Size"

La matriz de confusión y estadísticos de este modelo son los recogidos en la Tabla 2:

Tabla 2. Matriz de confusión modelo IA. Variable objetivo. Bate/No bate cartera "Size"

ESTADISTICAS CARTERA FACTOR SIZE					
Valor Variable Objetivo	Tasa acierto	Predicción	ks	test f	Área ROC
NO BATE	57.10%	65.50%	20.60%	61.00%	63.90%
BATE	63.50%	55.00%	20.60%	58.90%	63.90%
MATRIZ DE CONFUSION					
	NO BATE	BATE	TOTAL		
NO BATE	36	27	63		
BATE	19	33	52		
TOTAL	55	60	115		

A la hora de contextualizar estos resultados mencionaremos que:

- Factor Value:** Los resultados obtenidos presentan una tasa de acierto del 60% y si desglosamos por aciertos entre bate y no bate vemos que los porcentajes son equilibrados, 58.6% y 61,4%. Por otra parte, la evaluación del área ROC 68,5% se aleja de los resultados aleatorios y se sitúa cerca del umbral 0.7 de estudios de utilidad.

- **Factor Size:** Las tasas de acierto para bate y no bate se sitúan en 57,1% y 63,5%, nuevamente porcentajes de éxito muy equilibrados en torno al acierto total (60%) en este caso el Área Roc, aunque lejos del 50% (suceso aleatorio) se aleja del umbral del 0.7.

Desde nuestro punto de vista la consistencia de la tasa de acierto en ambos factores, así como en los resultados "bate vs no bate", es una distancia significativa sobre un resultado puramente aleatorio (50%) lo que nos permite validar la hipótesis planteada, es decir, existe una relación entre los indicadores de ciclo económico y la alternancia de factor y adicionalmente es posible utilizar la inteligencia artificial como predictor de este comportamiento.

Extrapolando este estudio al Mercado Bursátil Español llegamos al siguiente modelo entrenando con el 80% de la muestra y reservando el 20% de la misma para la validación del modelo. Para la **validación retrospectiva** de la hipótesis se ha construido la red bayesiana que se muestra en la Figura 7. Se observa que las variables Sector y PBVR eran redundantes con el resto de predictores y no incrementaban la capacidad predictiva del modelo, por eso no aparecen en el grafo de la imagen.




Figura 7. Modelo IA 2D. Variable objetivo. Bate/No bate cada valor del Mercado Continuo

El resultado de la validación realizada con la muestra reservada es el que se muestra en la Tabla 3, según los estadísticos calculados por dVeloX.

Tabla 3. Matriz de confusión modelo IA. Variable objetivo. Bate/No bate cada valor del mercado continuo”

ESTADÍSTICAS CARTERA FACTOR SIZE					
Valor Variable Objetivo	Tasa acierto	Predicción	ks	test f	Área ROC
NO BATE	80,0%	63.2%	34.3%	70.6%	66.4%
BATE	54.3%	73.5%	34.3%	62.5%	66.4%
MATRIZ DE CONFUSION					
	NO BATE	BATE	TOTAL		
NO BATE	36	9	45		
BATE	21	25	46		
TOTAL	57	34	91		

Observamos en la Tabla 3, utilizando la información estadística de dVeloX, que el modelo ha acertado al 80% los valores que efectivamente no han batido al Ibex 35 dentro de la muestra reservada, mientras que el modelo ha acertado en los valores que han batido al 54%. Atendiendo a la matriz de confusión generada la tasa de acierto global del modelo es del 67%.

Por lo tanto, a tenor de los resultados observados validamos la hipótesis H0.

Cartera propuesta por el modelo para batir al Ibex en 2019

Teniendo en cuenta que le modelo anterior ha mostrado una buena capacidad predictiva nos planteamos si este modelo se podría utilizar para construir un sistema experto que automáticamente diseñase carteras de “perfil value” con el objetivo de batir al Ibex 35 como índice de referencia. Así incluimos el 100% de la muestra en el entrenamiento del modelo, el cual utilizamos para predecir la variable objetivo (bate o no bate) a partir de las ratios estimados para 2019.

El modelo entrenado para la validación prospectiva, utilizado todos los datos disponibles desde 2014 hasta 2018, cuenta con 11 predictores y es el que se muestra en la Figura 8. Utilizado dicho modelo, los valores que van a batir al Ibex 35 en 2019 según el modelo y los datos previstos por Facset son los que se muestran en la relación de la Tabla 4.

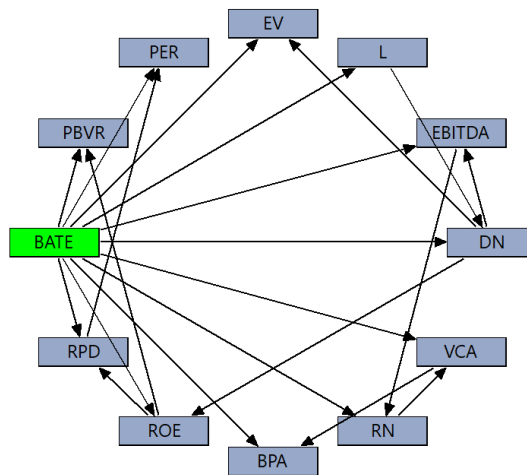


Figura 8. Modelo IA 2D. Variable objetivo. Bate/No bate cada valor del Mercado Continuo (100% de la muestra)

Tabla 4. Valores con probabilidad de batir al Ibex 35 en 2019 según el Modelo IA

Valor	Pred.	Acierto	Prob. BATE	Prob. NO BATE	Año	Título	Sector
?	SI	?	50,38%	49,62%	2019	ALMIRALL	Salud
?	SI	?	54,59%	45,41%	2019	AMADEUS	Tecnológico
?	SI	?	57,42%	42,58%	2019	ENDESA	Suministros
?	SI	?	50,38%	49,62%	2019	FAES FARMA	Salud
?	SI	?	57,42%	42,58%	2019	IAG	Transporte
?	SI	?	50,38%	49,62%	2019	INM.COLONIAL	Servicios
?	SI	?	57,42%	42,58%	2019	NATURGY	Suministros
?	SI	?	99,96%	0,04%	2019	QUABIT	Bienes de capital
?	SI	?	50,38%	49,62%	2019	REALIA BUSSINESS	Servicios
?	SI	?	65,22%	34,78%	2019	TELEFONICA	Servicios

Si configurásemos una cartera con estos 10 valores (Tabla 5), repartiendo el capital en la misma proporción en cada uno de ellos, tendríamos una rentabilidad al cierre de 2019 del 12,63% mientras que el Ibex 35 ha cerrado un con rentabilidad del 11,82%.

Tabla 5. Rendimiento en 2019 de la Cartera IA

Título	Sector	Precio al cierre de 2018	Precio al cierre de 2019	Variación
ALMIRALL	Salud	13,19 €	14,64 €	10,99%
AMADEUS	Tecnologico	60,84 €	72,80 €	19,66%
ENDESA	Suministros	20,13 €	23,79 €	18,18%
FAES FARMA	Salud	2,97 €	5,00 €	68,35%
IAG	Transporte	6,92 €	7,22 €	4,34%
INM.COLONIAL	Servicios	8,14 €	11,36 €	39,64%
NATURGY	Suministros	22,26 €	22,40 €	0,63%
QUABIT	Bienes de capital	1,30 €	1,00 €	-22,92%
REALIA BUSSINESS	Servicios	0,91 €	0,93 €	2,64%
TELEFONICA	Servicios	7,34 €	6,23 €	-15,16%
	TOTAL			12,63%
IBEX		8.539,90	9.549,20 €	11,82%

5. Conclusiones

La “gestión value” ha demostrado a lo largo de la historia que puede dar rendimientos superiores a los que ofrece el mercado seleccionando aquellos valores que están más baratos atendiendo a diferentes factores y/o ratios. En este estudio hemos explorado la posibilidad de utilizar la inteligencia artificial para cuantificar la probabilidad que tiene una cartera o un valor para batir al mercado en un periodo determinado.

Con este objetivo se han realizado varios entrenamientos sobre un modelo de inteligencia artificial que utilizaba en todos los casos ratios y/o factores de diferentes valores o carteras como predictores de una misma variable objetivo bate/no bate al mercado. En este estudio nos hemos centrado en el Mercado Español tomando el Ibex 35 como índice de referencia.

La capacidad predictiva que ha mostrado tener el modelo en sus diferentes entrenamientos con el 80% de la muestra, sobre el 20% libre para la validación, ha superado el 60% de tasa de acierto, por lo que entendemos que la inteligencia artificial es una buena herramienta para predecir si un valor o cartera va a batir al mercado, y se acepta la hipótesis de estudio de este artículo.

Este artículo pone de manifiesto la utilidad de la inteligencia artificial en la industria de la gestión de activos, pudiéndose convertir en el futuro en una herramienta de ayuda a gestores e inversores, ya sea como soporte al análisis realizado a nivel profesional o como sustitutivo del gestor desarrollando sistemas expertos que configuren carteras de forma totalmente automatizada. Como primera experiencia descrita en este artículo, la cartera propuesta por este modelo para el mercado bursátil español ha sido capaz de batir al Ibex 35 en 2019.

A diferencia de los modelos clásicos como el CAPM y el modelo de tres factores de Fama y French que están basados en un modelo econométrico de regresión lineal, los modelos basados en inteligencia artificial basados en redes bayesianas llevan asociada una probabilidad en cada predicción. Esto hace que se pueda calibrar el sistema experto y tomar sólo las decisiones de inversión para los que el modelo ofrezca una mayor fiabilidad de acierto.

No obstante, queda mucho camino por recorrer y hay limitaciones que deben ser superadas, sobre todo en lo relativo a perfeccionar los factores utilizados como predictores, así como extender el estudio a más activos y más mercados. No obstante, la principal aportación de este estudio es que muestra que se puede afrontar la gestión value desde un nuevo punto de vista, aprovechando la potencia analítica de la inteligencia artificial. Bajo este enfoque hemos desarrollado el primer sistema inteligente (o “robot”, término que suele ser utilizado en medios de comunicación divulgativos) que es capaz de configurar carteras utilizando

exclusivamente inteligencia artificial, con el objetivo de batir al Ibex. En su primer intento el robot ha conseguido su objetivo.

Referencias Bibliográficas

- Ang, A. (2014). *Asset management: A systematic approach to factor investing*. Oxford University Press.
- Banz, R. W. (1981). The relationship between return and market value of common stocks. *Journal of financial economics*, 9(1), 3-18.
- Basu, S. (1977). Investment performance of common stocks in relation to their price-earnings ratios: A test of the efficient market hypothesis. *The journal of Finance*, 32(3), 663-682.
- Basu, S. (1981). The relationship between earnings' yield, market value and return for NYSE common stocks: Further evidence. *Journal of Financial Economics* 12, 129–156.
- Bender, J., Briand, R., Melas, D., & Subramanian, R. A. (2013). Foundations of factor investing. Available at SSRN 2543990.
- Berkin, A.L. y Swedroe, L.E. (2016), *Your Complete Guide to Factor-Based Investing: The Way Smart Money Invests Today*.
- Briganti, M. G. (2001). ¿Gestión activa o gestión pasiva? Morningstar: <http://www.morningstar.es/es/news/23618/%C2%BFgesti%C3%B3n-activa-o-gesti%C3%B3n-pasiva.aspx>
- Chan, L.K.C., Hamao, Y. & Lakonishok, J. (1991), "Fundamentals and Stock Returns in Japan", *The Journal of Finance*, vol. 46, no. 5, pp. 1739-1764.
- Fama, E. F., y French, K. R. (1992). The cross-section of expected stock returns. *The Journal of Finance*, 47(2), 427-465.
- Fama, E.F. y French, K.R. (1993), Common risk factors in the returns on stocks and bonds. *Journal of Finance* 51, 55–84.
- Friedman, N. & Koller, D. (2003), "Being Bayesian About Network Structure. A Bayesian Approach to Structure Discovery in Bayesian Networks" in *Machine Learning Springer*, pp. 95-125.
- Graham, B., & Dodd, D. L. (1934). *Security Analysis*. New York: Whittlesey House.
- Gómez Martínez, R. (2014). *Métodos aplicados de valoración de empresas*. Madrid: Delta.
- Gómez-Martínez, R., Prado-Román, C., & Moreno, R. M. (2017). Investing in Shares of Europe Football Clubs: Definitely, an Alternative Investment. In *Sports Management as an Emerging Economic Activity* (pp. 183-192). Springer, Cham.
- Lakonishok, J., Shleifer, A. y Vishny, R.W. (1994), "Contrarian Investment, Extrapolation, and Risk", *The Journal of Finance*, vol. 49, no. 5, pp. 1541-1578.
- Lintner, J. (1975). The valuation of risk assets and the selection of risky investments in stock portfolios and capital budgets. In *Stochastic optimization models in finance* (pp. 131-155). Academic Press.
- Lintner, J. (1965), "The Valuation of Risk Assets and the Selection of Risky Investments in Stock Portfolios and Capital Budgets", *The review of economics and statistics*, vol. 47, no. 1, pp. 13-37.
- Litzenberger, R. H., & Ramaswamy, K. (1979). The effect of personal taxes and dividends on capital asset prices: Theory and empirical evidence. *Journal of financial economics*, 7(2), 163-195.
- Markowitz, H. (1952), "Portfolio Selection", *The Journal of Finance*, vol. 7, no. 1, pp. 77-91.
- Montier, J. (2007). The illusion of knowledge or is more information better information? In, *Behavioural investing: A practitioner's guide to applying behavioural finance*. Oxford, UK: John Wiley & Sons Ltd. doi, 10, 9781118673430.
- Montier, J. (2010). *Value investing: tools and techniques for intelligent investment*. John Wiley & Sons..
- Moreno, M. (2018). El 79% de los fondos de bolsa española no bate al mercado a 10 años. Cinco Días: https://cincodias.elpais.com/cincodias/2018/07/02/mercados/1530541155_206680.html
- Niedermayer D. (2008), "An Introduction to Bayesian Networks and Their Contemporary Applications" *Innovations in Bayesian Networks. Studies in Computational Intelligence*, vol 156, ed. Springer.
- Ross, S. A. (1976). The arbitrage theory of capital asset pricing. *Journal of Economic Theory*, vol 13, n0. 3, pp 341-360. doi:[https://doi.org/10.1016/0022-0531\(76\)90046-6](https://doi.org/10.1016/0022-0531(76)90046-6)

Sharpe, W.F. (1964), "Capital Asset Prices: A Theory of market equilibrium under conditions of ", *The Journal of Finance*, vol. 19, no. 3, pp. 425-442.

Treynor, J. L. (1961). Market value, time, and risk. *Time, and Risk* (August 8, 1961).

Zhang, L.U. (2005), "The Value Premium", *The Journal of Finance*, vol. 60, no. 1, pp. 67-103.