

ARTICULO ORIGINAL

Redes neuronales para predecir el comportamiento del conjunto de activos financieros más líquidos del mercado de valores peruano

Neural networks to predict the behavior of the most liquid financial asset set of the peruvian securities market

Bellido, B.¹; *Schwarz, M.²

¹Universidad de Lima. Peru

RESUMEN

La presente investigación tiene como propósito identificar una herramienta de inteligencia artificial basada en redes neuronales para predecir el comportamiento de rendimiento y riesgo del conjunto de activos financieros basados en acciones que reflejen con mayor exactitud el movimiento bursátil del mercado de valores peruano. La investigación identificó inicialmente el activo financiero más apropiado para estimar los valores de rendimiento y riesgo de la cartera de acciones 50% más líquida del mercado peruano en el período 2010-2016. A partir del activo seleccionado se utilizó la técnica de redes neuronales artificiales con un perceptrón multicapa con regresión configurado con 3 capas (21,85,2) usando una función de activación logística con un optimizador LBFGS a una tasa de aprendizaje de 0.01 para establecer los patrones financieros, operacionales, comerciales o de gobierno corporativo que puedan explicar y/o predecir el comportamiento del mismo en el mercado. La investigación concluye que la capacidad de generación de caja y la velocidad con la que se rotan los activos, así como la velocidad con la que se desembolsa el Capex constituyen los principales factores que influyen en la determinación de las mejores combinaciones de rendimiento y riesgo para el grupo de activos financieros considerados como materia de estudio, independiente del sector de mercado en el cual se opera. La investigación encontró una red neuronal capaz de aproximar la predicción de rendimiento y riesgo con un 76.93% de eficacia para el conjunto de activos seleccionados en el periodo de estudio. La investigación aporta un reconocimiento de patrones diferenciados en aspectos financieros, operacionales, comerciales y de gobierno corporativo con un especial énfasis en la capacidad gerencial que los genera cuya influencia se refleja en el desempeño del conjunto de activos estudiados por medio de la técnica de redes neuronales generando una herramienta predictiva para estimar su comportamiento bursátil.

Palabras clave: Activo financiero, Fondo cotizado, redes neuronales, rendimiento bursátil, riesgo bursátil.

ABSTRACT

The purpose of this research is to identify an artificial intelligence tool based on neural networks to predict the behavior of performance and risk of the set of financial assets based on actions that more accurately reflect the stock market movement of the Peruvian stock market. The research initially identified the most appropriate financial asset to estimate the performance and risk values of the 50% most liquid share portfolio in the Peruvian market in the 2010-2016 period. From the selected asset, the technique of artificial neural networks with

***Autor Correspondiente: Max Schwarz. Universidad de Lima. Peru**

Email: mschwarz@ulima.edu.pe

Fecha de recepción: 13/11/2018; Fecha de aceptación: 28/02/2019

a multilayer perceptron with regression configured with 3 layers (21,85,2) was used, using a logistic activation function with an LBFGS optimizer at a learning rate of 0.01 to establish the financial, operational, commercial or corporate governance patterns that can explain and / or predict the behavior of the same in the market. The research concludes that the cash generation capacity and the speed with which the assets are rotated, as well as the speed with which the Capex is disbursed, constitute the main factors that influence the determination of the best combinations of performance and risk for the group of financial assets considered as a subject of study, independent of the market sector in which it operates. The research found a neural network able to approximate the prediction of performance and risk with a 76.93% efficiency for the set of assets selected in the study period. The research provides a recognition of differentiated patterns in financial, operational, commercial and corporate governance aspects with a special emphasis on the managerial capacity that generates them whose influence is reflected in the performance of the set of assets studied through the technique of neural networks generating a predictive tool to estimate its stock market behavior.

Keywords: Financial assets, exchange traded fund, neural networks, stock performance, stock market risk.

INTRODUCCIÓN

La búsqueda de instrumentos capaces de predecir el comportamiento financiero de los activos listados en las bolsas de valores es un problema en permanente discusión en la literatura científica y empresarial cuya solución ha intentado ser aproximada con el uso de sofisticadas herramientas matemáticas a lo largo del tiempo, procurando identificar los patrones que configuran las causas de los mejores desempeños bursátiles a partir de la experiencia de la data obtenida por estos activos. Una solución a este problema por más aproximada que sea permitiría a los inversionistas y al mercado tener un mejor control del riesgo de las inversiones y conocer la ruta de las actividades clave que puedan ser gestionadas para agregar o mantener el valor de los activos listados en una clara protección a los inversionistas proporcionando al mercado mayor equidad y transparencia informada. La inversión bursátil constituye una alternativa para los excedentes de capital de todo inversionista independiente de su perfil de inversión y representan una alternativa democrática de acceso al mercado para los ciudadanos comunes lo cual ha sido especificado en la literatura en el análisis de los denominados "mercados eficientes". En ese contexto entendemos por mercado eficiente a aquel ambiente en el cual cada actor cuenta con equidad de información en calidad, oportunidad de acceso y veracidad para tomar decisiones informadas en la manera como desarrolla sus transacciones para operar el dicho contexto.

Desde un punto de vista analítico el problema es complejo porque tradicionalmente ha sido abordado a partir de la regresión matemática con parámetros estructurados más o menos lineales en el supuesto que los hechos del pasado se repetirán en el futuro, sin embargo, las investigaciones demuestran que el comportamiento bursátil es claramente no lineal y es en simultáneo fuertemente sensible a la influencia de parámetros considerados aún como no estructurados que son a su vez altamente dependientes de la naturaleza del inversionista y su entorno. Existe abundante literatura que respalda el comportamiento no lineal de las actividades humanas, aunque el alcance psicológico de este accionar escapa claramente al alcance de la

presente investigación. Sin embargo, es importante rescatar la diferencia entre información estructurada y no estructurada que abunda en relación al mercado de valores.

Para ello es necesario entender que existe un conjunto de variables que pueden ser cuantificadas y directamente extraídas de las memorias y reportes de las empresas que sustentan los activos como la rentabilidad sobre el capital (ROE), la rentabilidad sobre los activos (ROA), la capacidad de generar efectivo (EBITDA), el ratio precio-beneficio, la inversión en bienes de capital (CAPEX), el coeficiente de riesgo (BETA) y similares que surgen del análisis de la información contable, operacional, comercial y financiera con la que operan siendo esta información de carácter cuantificable, medible y reportable que configura una condición para ser considerada como variable estructurada en contraste con información más bien cualitativa, de características y atributos influenciados por el carácter y las emociones de los actores empresas y personas que se vinculan al contexto y son consideradas variables no estructuradas como el perfil del inversionista, el contexto político, la experiencia de los directivos, el grado de concentración familiar, la vulnerabilidad reputacional y similares que normalmente son excluidas del análisis tradicional.

Para lograr desarrollar mercados eficientes existe la necesidad de encontrar herramientas predictivas para identificar las mejores combinaciones rentabilidad-riesgo como las que pueden ofrecer actualmente las técnicas de Inteligencia Artificial basadas en algoritmos sobre BigData que permitirían a los inversionistas alinear con mayor precisión y seguridad sus portafolios a las diferentes alternativas de inversión en función al perfil del inversionista, con lo cual, el mercado sería más objetivo reduciendo los niveles de especulación y dejando un mayor espacio relativo para la entrada de inversionistas sofisticados con claros horizontes de inversión en este mercado.

En el caso del Perú, contamos con una bolsa de valores centrada en activos negociables excluyendo las bolsas de productos cuya existencia en el Perú no ha prosperado. La bolsa de valores peruana opera formalmente desde 1860 y fue formada sobre la base de la antigua Cámara de Comercio de Lima fundada a finales del siglo XIX (Giesecke & Contreras, 2007) evolucionando desde sus primeras necesidades para las transacciones de operaciones guaneras con las principales plazas europeas hasta nuestros días con la transacción de sofisticados activos financieros con operadores globales e inversionistas naturales e institucionales. El mercado de Valores peruano es un mercado \$116 K MM y actualmente pertenece al MILA que globalmente se configura como el primer mercado bursátil más importante de América Latina. (Bloomberg, 2017; World Economic Forum, 2017).



Grafico 1: Mapa mundial según la capitalización de las bolsas, publicado en World Economic Forum.

Los activos tranzados en la Bolsa de Valores de Lima están constituidos principalmente de acciones, bonos y fondos cotizados.

La Tabla 1 muestra los activos financieros de mayor liquidez en el mercado de valores peruano en el período 2010-2016 registrados en la Bolsa de Valores de Lima por la Superintendencia de Mercado de Valores (SMV, 2017) representados por la cartera de activos 50% más líquida que operan en el mercado bursátil donde el criterio de liquidez utilizado en la segmentación está referido a la frecuencia de días de negociación del activo financiero en el mercado bursátil respecto a los días totales de operación de la rueda bolsa sobre la base de un mes de operaciones negociadas entre lunes y viernes de manera convencional.

METODOLOGÍA

La investigación plantea como hipótesis que solo algunos factores de la industria son determinantes en la conformación de las mejores combinaciones rentabilidad-riesgo, estableciendo como objetivo la búsqueda e identificación de estos factores a partir del uso de técnicas de inteligencia artificial aplicadas a la data del comportamiento de los activos bursátiles entre el 2010 y el 2016.

Para el análisis, utilizando el criterio de liquidez como criterio de segmentación, se ha segmentado la cartera de acciones 50% más líquida del mercado peruano correspondiente al período 2010-2016 a partir de datos de la Superintendencia del Mercado de Valores (SMV, 2017), incluyendo activos financieros cuya composición está basada en combinaciones de acciones de manera que pueda reflejar con mayor precisión el comportamiento del mercado peruano para identificar su correspondiente rendimiento y riesgo de mercado. A partir de esta selección se identifica un perceptrón multicapa con la configuración de 3 capas (21,85,2) con una función de activación logística optimizada con el algoritmo LBFSGS (Shanno, 1970) con una tasa de aprendizaje de 0.01 que permita establecer los patrones financieros, operacionales, comerciales o de gobierno corporativo que puedan explicar y predecir el comportamiento del mismo en el mercado.

El algoritmo LBFGS (Limited-BFGS) es un método de optimización de funciones complejas propuesto por Broyden, Fletcher, Goldfarb y Shanno a mediados de los años 70s (Shanno, 1970) que funciona como un método de activación logística que permite trabajar eficientemente con un alto número de variables haciendo un uso limitado de memoria que procesa entradas y las reconfigura en salidas predeterminadas (función logística) entrenándose a una tasa de aprendizaje determinada para obtener los mínimos de una función utilizando únicamente su estructura y el gradiente generando la optimización de manera más rápida y efectiva a un costo computacional razonable que se ajusta perfectamente a la naturaleza del problema planteado en la investigación presentada.

Para el entrenamiento de la red neuronal artificial se utilizó un 80% de casos aleatorios y para las pruebas el 20% restante, ajustándose los parámetros sobre la base de los mejores resultados obtenidos con un promedio de ajuste usando el algoritmo de Garson (Garson, 1991) para determinar la importancia de las características de entrada.

Las variables tradicionales utilizadas para la caracterización de cada activo financiero que se han seleccionado para el desarrollo de la presente investigación son el precio del activo, el EBITDA generado, las utilidades por acción, la rentabilidad (ROE y ROA), el CAPEX por acción, el grado de liquidez, el coeficiente beta de riesgo, la rotación del patrimonio, la rotación del activo, el ciclo de caja, el ratio precio/beneficio (PER), el ratio precio/valor contable, la capitalización bursátil, la rentabilidad del dividendo y el grado de endeudamiento. En el caso de la rentabilidad porcentual se ha considerado una rentabilidad real ajustada por la inflación acumulada entre el periodo 2010-2016 correspondiente al corte del 25.5944%. Las variables seleccionadas han sido extraídas de las bases de datos de Economática, Bloomberg, la Superintendencia del Mercado de Valores peruana (SMV) y la Bolsa de Valores de Lima (BVL).

Las variables no tradicionales utilizadas para la caracterización de cada activo financiero que se han seleccionado para el desarrollo de la presente investigación son la experiencia del Chief Executive Officer (CEO), el número de directores independientes, el porcentaje de concentración de la familia en el directorio, el grado de vulnerabilidad política, el grado de vulnerabilidad ambiental y el grado de vulnerabilidad reputacional. Estas variables han sido normalizadas para su integración en la metadata de la investigación.

Las especificaciones de la red neuronal utilizada son las siguientes:

- Capas: 3 capas, una de entrada con 21 nodos, una oculta con 85 nodos (el mejor de la prueba utilizando de 1 a 100 nodos) y 2 en la capa de salida (rentabilidad y riesgo).
- Tasa de aprendizaje: 0.01 constante (valor estándar).
- Optimizador: LBFGS, minimiza el error cuadrático (para obtener una regresión) entre el valor real y el predicho.
- Función de activación en la capa oculta: Logística, regresa $f(x)=1/(1+\exp(-x))$.

Tabla 1: Cartera de activos negociables 50% más líquida del mercado bursátil peruano

Nombre	Clase	Pais Sede	Bolsa / Fuente	Tipo de Activo	Activo / Cancelado	Codigo	Presencia 09Nov17 1 meses
1 Andino Investment Hold...	C	PER	BVL	Accion	activo	AHIC1	50,00
2 Alicorp S.A.	C1	PER	BVL	Accion	activo	ALICORC1	100,00
3 Atacocha	BC1	PER	BVL	Accion	activo	ATACOCB1	100,00
4 UCP Backus Johnst	I1	PER	BVL	Accion	activo	BACKUSI1	81,818
5 Credicorp	C1	PER	BVL	Accion	activo	BAP	100,00
6 El Brocal	C1	PER	BVL	Accion	activo	BROCALC1	77,273
7 Casa Grande S.A.	C1	PER	BVL	Accion	activo	CASAGRC1	100,00
8 Banco Continental	C1	PER	BVL	Accion	activo	CONTINC1	100,00
9 Corp Aceros Arequip	I1	PER	BVL	Accion	activo	CORAREC1	63,636
10 Cementos Pacasmay	C1	PER	BVL	Accion	activo	CPACASC1	100,00
12 Banco de Credito	C1	PER	BVL	Accion	activo	CREDITC1	95,455
13 Soc.Min.Cerro Verde	C1	PER	BVL	Accion	activo	CVERDEC1	100,00
14 Candente Copper Corp.	C	CAN	BVL	ADR,etc (e...	activo	DNT	100,00
15 Enel Distribucion Peru...	C1	PER	BVL	Accion	activo	ENDISPC1	88,182
16 Enel Generación Perú...	C1	PER	BVL	Accion	activo	ENGEPEC1	81,818
17 Engie Energía Peru S.A...	C1	PER	BVL	Accion	activo	ENGIEC1	95,455
18 Ferreycorp S.A.A.	C1	PER	BVL	Accion	activo	FERREYC1	100,00
19 Fossal SAA	C1	PER	BVL	Accion	activo	FOSSALC1	54,545
20 Grana Y Montero S.A	C1	PER	BVL	Accion	activo	GRAMONC1	100,00
21 Hudbay Minerals Inc.	Com	CAN	BVL	ADR,etc (e...	activo	HBM	59,091
22 Hidrandina	C1	PER	BVL	Accion	activo	HIDRA2C1	68,182
23 Intercorp Financial Servi...	C1	PER	BVL	Accion	activo	IFS	95,455
24 Inretail Peru Corp.	C1	PER	BVL	Accion	activo	INRETC1	100,00
25 Santa Luisa	I1	PER	BVL	Accion	activo	LUISAI1	50,00
26 Luz del Sur S.A	C1	PER	BVL	Accion	activo	LUSURC1	100,00
27 Milpo	C1	PER	BVL	Accion	activo	MILPOC1	95,455
28 Soc.Minera Corona	I1	PER	BVL	Accion	activo	MINCORI1	95,455
29 Minsur	I1	PER	BVL	Accion	activo	MINSURI1	95,455
30 Minera IRL Limited	C	PER	BVL	Accion	activo	MIRL	63,636
31 San Ignacio de Morococ...	I1	PER	BVL	Accion	activo	MOROCOI1	100,00
32 Panoro Minerals Ltd	C	CAN	BVL	ADR,etc (e...	activo	PML	95,455
33 Pomalca S.A.	C1	PER	BVL	Accion	activo	POMALCC1	54,545
34 Peruvian Precious Meta...	N.A.	CAN	BVL	ADR,etc (e...	activo	PPX	81,818
35 Red Eagle Mining	C	CAN	BVL	ADR,etc (e...	activo	R	100,00
36 Refiner.la Pampilla	C1	PER	BVL	Accion	activo	RELAPAC1	100,00
37 Southern Copper Corp	Com	USA	BVL	ADR,etc (e...	activo	SCCO	86,364
38 Scotiabank Peru S.A	C1	PER	BVL	Accion	activo	SCOTIAC1	72,727
39 Siderperu	C1	PER	BVL	Accion	activo	SIDEREC1	95,455
40 Telefonica SA	Com	ESP	BVL	ADR,etc (e...	activo	TEF	68,182
41 Telefonica del Peru	BC1	PER	BVL	Accion	activo	TELEFBC1	95,455
42 Trevali Mining Corporati...	C	CAN	BVL	ADR,etc (e...	activo	TV	100,00
43 Unión Andina de Ceme...	C1	PER	BVL	Accion	activo	UNACEMC1	100,00
44 Volcan	BC1	PER	BVL	Accion	activo	VOLCABC1	100,00

Fuente: Economatica 2017

La combinación rentabilidad-riesgo de los activos de mayor liquidez durante el período 2010 al 2016 se presenta en la Tabla 2.

Tabla 2: Rentabilidad y Riesgo de la cartera seleccionada 2010-2016

Nombre	Clase	Pais Sede	Bolsa / Fuente	Tipo de Activo	Activo / Cancelado	Codigo	Rentabilidad Real ajustada con inflación	Beta Dic16 Ene10 en moneda orig
1 Andino Investment Hold.	C	PER	BVL	Accion	activo	AIHC1	-	-
2 Alicorp S.A.	C1	PER	BVL	Accion	activo	ALICORC1	177,5	0,61
3 Alacocha	BC1	PER	BVL	Accion	activo	ATACOCB1	-100,7	1,30
4 UCP Backus Johnst	I1	PER	BVL	Accion	activo	BACKJUS1	499,6	0,23
5 Credicorp	C1	PER	BVL	Accion	activo	BAP	107,6	0,65
6 El Brocal	C1	PER	BVL	Accion	activo	BROCALC1	-102,6	1,08
7 Casa Grande S.A.	C1	PER	BVL	Accion	activo	CASAGR1	7,0	1,42
8 Banco Continental	C1	PER	BVL	Accion	activo	CONTINC1	60,2	0,83
9 Corp.Aceros Arequip	I1	PER	BVL	Accion	activo	CORAREC1	-70,5	0,95
10 Corp.Aceros Arequip	I1	PER	BVL	Accion	activo	CORAREI1	-74,4	1,31
11 Cementos Pacasmay	C1	PER	BVL	Accion	activo	CPACASC1	177,6	0,85
12 Banco de Credito	C1	PER	BVL	Accion	activo	CREDITC1	144,8	0,62
13 Soc.Min.Cerro Verde	C1	PER	BVL	Accion	activo	CVERDEC1	-36,3	1,25
14 Candente Copper Corp.	C	CAN	BVL	ADR, etc (e...	activo	DNT	-110,2	2,27
15 Enel Distribucion Peru...	C1	PER	BVL	Accion	activo	ENDISPC1	229,2	0,62
16 Enel Generación Peru...	C1	PER	BVL	Accion	activo	ENGEPEC1	251,9	0,63
17 Engie Energia Peru S.A.	C1	PER	BVL	Accion	activo	ENGIEC1	117,2	0,42
18 Ferreycorp S.A.A.	C1	PER	BVL	Accion	activo	FERREYC1	45,0	0,96
19 Fossal SAA	C1	PER	BVL	Accion	activo	FOSSALC1	-	-
20 Grana Y Montero SA	C1	PER	BVL	Accion	activo	GRAMONC1	89,1	1,25
21 Hudbay Minerals Inc.	Com	CAN	BVL	ADR, etc (e...	activo	HBM	-	-
22 Hidrandina	C1	PER	BVL	Accion	activo	HIDRA2C1	363,4	0,68
23 Intercorp Financial Servi.	C1	PER	BVL	Accion	activo	IFS	95,7	0,81
24 Inretail Peru Corp.	C1	PER	BVL	Accion	activo	INRETC1	-	-
25 Santa Luisa	I1	PER	BVL	Accion	activo	LUISA1	82,9	0,63
26 Luz del Sur S.A.	C1	PER	BVL	Accion	activo	LUSURC1	357,4	0,54
27 Milpo	C1	PER	BVL	Accion	activo	MILPOC1	-50,9	1,08
28 Soc.Minera Corona	I1	PER	BVL	Accion	activo	MINCOR1	16,4	0,48
29 Minsur	I1	PER	BVL	Accion	activo	MINSUR1	-59,6	1,56
30 Minera IRL Limited	C	PER	BVL	Accion	activo	MIRL	-	-
31 San Ignacio de Morococ.	I1	PER	BVL	Accion	activo	MOROOC1	76,9	-
32 Panoro Minerals Ltd	C	CAN	BVL	ADR, etc (e...	activo	PML	-56,6	1,62
33 Pomalca S.A.	C1	PER	BVL	Accion	activo	POMALCC1	-	0,57
34 Peruvian Precious Meta...	N.A	CAN	BVL	ADR, etc (e...	activo	PPX	-	-
35 Red Eagle Mining	C	CAN	BVL	ADR, etc (e...	activo	R	-	-
36 Refineria Pampilla	C1	PER	BVL	Accion	activo	RELAPAC1	-82,4	1,08
37 Southern Copper Corp	Com	USA	BVL	ADR, etc (e...	activo	SCCO	3,8	0,69
38 Scotiabank Peru S.A	C1	PER	BVL	Accion	activo	SCOTIAC1	104,3	0,75
39 Siderperu	C1	PER	BVL	Accion	activo	SIDERC1	-98,8	1,47
40 Telefonica SA	Com	ESP	BVL	ADR, etc (e...	activo	TEF	-80,0	0,28
41 Telefonica del Peru	BC1	PER	BVL	Accion	activo	TELEFBC1	-60,6	0,58
42 Trevali Mining Corporati...	C	CAN	BVL	ADR, etc (e...	activo	TV	-	-
43 Unión Andina de Ceme...	C1	PER	BVL	Accion	activo	UNACEMC1	16,3	0,97
44 Volcan	BC1	PER	BVL	Accion	activo	VOLCABC1	-80,1	1,46

Fuente: Ecomatrica, 2017-Bloomberg, 2017

Revisión de Literatura

La predicción del comportamiento de activos financieros del mercado bursátil es un tema en permanente investigación por los especialistas. El análisis de portafolios de acciones cotizadas en bolsa de valores y del comportamiento de los fondos cotizados (ETFs) y fondos de inversión listados en bolsa han sido tratados en los trabajos de Karceski (2002), Rompotis (2011) y Arugaslan & Samant (2014) mediante el análisis de riesgo diferenciado a partir del coeficiente BETA y su impacto en el valor de los activos financieros. De igual forma las investigaciones de Sánchez & Wei (2010), Ivanov (2011) y Borkovec & Serbin (2013) proponen estrategias específicas de segmentación por liquidez aplicables a la cartera de fondos cotizados mientras que la investigación de DiLellio & Jakob (2011) y Meric et al. (2011) se enfocan en las estrategias de gestión para obtener la mayor rentabilidad de los fondos cotizados y activos financieros listados en el mercado de valores. El volumen de activos y su influencia como tamaño de cartera en los resultados de inversión ha sido tratado por Riepe & Iachini (2011); Bello (2012) y Li, Klein & Zhao (2012)

mientras que en relación comparada a instrumentos similares se encuentra el trabajo de Sharifzadeh & Hojat (2012) quienes comparan la inversión y su riesgo en relación adicional a la exposición a nuevos mercados y nuevos instrumentos como los fondos mutuos. De igual forma el tratamiento de los fondos cotizados (ETFs), su naturaleza de gestión y el impacto de la inversión de los mismos ha sido tratado por Yamori (2011) quien explica esta realidad para el caso de la bolsa japonesa al permitir exponer a los inversionistas a nuevos mercados mundiales como oportunidad particular para acceder hacia el mercado americano y europeo.

La naturaleza de los fondos cotizados (ETFs) ha sido tratadas en las investigaciones de Madhavan, 2014; Schizas, 2014, Williams, 2014; Chang et al., 2015 y Jacobsen (2015) como una nueva oportunidad de acceso a mercados a los cuales el inversionista podría eventualmente no tener acceso haciendo énfasis en la naturaleza global de acceso a la inversión para el capitalista. La investigación de Lu, Wang & Zhang (2012) se concentra en el comportamiento de largo plazo de los instrumentos de inversión en la bolsa de valores en particular de los fondos cotizados que permiten acceder a múltiples mercados especializados con mayores oportunidades para los inversionistas. De igual forma, los trabajos de Papadelis, Flamos & Androulaki (2012), Dunham & Simpson (2015) y Kanuri (2016) se concentran en las estrategias de configuración de modelos de negocio vinculados a la conformación de carteras en los fondos de inversión mientras que la investigación de Chung & Hrazdil (2013) aborda el problema desde el punto de vista de la eficiencia de los mercados y en línea con ese análisis la investigación de Narend & Thenmozhi (2016) desarrolla la identificación de factores clave que activan la rentabilidad de los activos y en particular de los fondos cotizados listados en la bolsa de valores.

De igual forma los trabajos Koti (2013), Lin (2013) y Dunham, Jorgensen & Washer (2016) desarrollan análisis particulares del comportamiento de los activos financieros desde el punto de vista del volumen de transacciones y su correlación con la conformación de cartera y su estrategia de gestión, mientras que la investigación de Milonas & Rompotis (2013) establece una evaluación particular del comportamiento de los fondos cotizados en el mercado alemán frente a períodos de crisis, mercado analizado también en la investigación de Osterhoff & Kaserer (2016). Este aspecto de riesgo también ha sido tratado en la investigación de Shum & Kang (2013) para establecer patrones de gestión que permiten un mejor desarrollo del mercado frente a condiciones adversas. De igual forma el efecto estacional los fondos cotizados ha sido teorizado Chen, Shin & Sun (2015) como estrategia de gestión diferenciada para la obtención de mejores combinaciones de rentabilidad y riesgo para carteras específicas.

Las investigaciones de Scozzari et al. (2013) y Huang et al. (2015) desarrollan enfoques heurísticos para la internalización de restricciones en la segmentación de carteras para la evaluación de fondos cotizados. De igual forma las investigaciones de Tseng & Lee (2016) y Jung-Chu (2017) abordan el análisis de los fondos de inversión, fondos cotizados y activos financieros listados por medio de distintas técnicas estadísticas incluyendo el análisis de variables tradicionales y no tradicionales que afectan el rendimiento y el riesgo de los activos financieros.

La combinación esperada del desempeño de indicadores de rendimiento y riesgo de los activos financieros está condicionada al comportamiento de un conjunto complejo de variables sobre las cuales es necesario reflexionar para

abordar del problema de estudio. De acuerdo con Hansen (2002) y Shiller (2003) el precio de los activos financieros que cotizan en la bolsa es equivalente a la cantidad monetaria que refleja la oferta y demanda de los mismos en un contexto de negociación bursátil determinado, sin embargo, el precio solo no refleja el verdadero valor de dichos activos. Para estimar el valor de los activos, los analistas suelen usar diferentes métodos de evaluación normalmente basados en información financiera y bursátil que es reportada regularmente al mercado. En ese contexto aparecen indicadores como la capacidad de generar efectivo (EBITDA) que claramente reflejan la capacidad de la gerencia para generar flujos de efectivo, en las cuales se mide su capacidad sobre la base de variables que están bajo su control de gestión. El EBITDA se forma por las utilidades antes de intereses e impuestos a las cuales se le agrega la depreciación y/o amortización que son costos contables que no representan salidas de caja, con lo cual se representa en forma agregada la capacidad de gerencia de generar efectivo como aporte al valor del activo. Esto constituye una razón poderosa para incluir al EBITDA como uno de los componentes para ser evaluados en el modelo. De igual forma, las utilidades por acción (UPA) se convierten en una variable de extrema importancia dado que en el largo plazo dicha utilidades constituyen el sustento de valor del activo en el mercado siendo además claro que la generación de UPA's positivas genera incentivos interesantes a los inversionistas para agregar rentabilidades ya obtenidas por el diferencial de precios lo cual claramente se refleja en las políticas de inversión que profundizan en carteras vinculadas a acciones que pagan dividendos.

La rentabilidad es una variable compleja y su naturaleza es multidimensional excediendo al campo puramente económico donde existen contextos de rentabilidad social, ética, ambiental y similares que participan directamente en casi todos los procesos vinculados a la toma de decisiones gerenciales y empresariales, sin embargo, tradicionalmente para la mayoría de los analistas de inversión el análisis se reduce a una particularidad en el estudio del ROE y el ROA (ROI) como indicadores para medir la capacidad del negocio y de sus activos para generar renta para los inversionistas. Esta limitación no restringe la necesidad de al ser variables estructuradas, medidas y reportadas obligatoriamente de manera pública en el mercado materia de estudio se vuelvan relevantes para su inclusión en el análisis de la presente investigación. En esa línea de análisis se ha considerado también el concepto de CAPEX en clara diferenciación del OPEX tradicional y del Cash Cost como conceptos de distinta interpretación conceptual. El CAPEX involucra todo el conjunto de inversiones que permiten construir el activo para ponerlo a operar a partir de lo cual el activo subsiste por los desembolsos de OPEX que sustentan su operación en el día a día. Un análisis particular requiere el Cash Cost como subconjunto del OPEX que excluye el costo del corporativo que para los inversionistas será una de las primeras variables a ser racionalizadas o cambiadas en la gerencia una vez adquirido el activo.

En esa misma línea de análisis, la liquidez constituye un factor central de alta sensibilidad para la decisión de entrada o salida de actores en el mercado reflejando una cantidad inherente de riesgo asignable al mercado siendo más atractivos los mercados con mayor liquidez que aquellos en los cuales la liquidez es escasa y el riesgo de no conversión monetaria realizable es alto desde el perfil del inversionista. Esta es una variable que el inversionista no controla pues se configura por la estructura propia del mercado que se forma en la transacción de los valores que actúan en el sistema. Esta complejidad y el

hecho de ser variables medibles y calculables a partir de los reportes ha hecho que sean incluidas como variables centrales en la investigación. De igual forma el coeficiente Beta de riesgo es una medida de sensibilidad que es parte de la ecuación de inversión de todo inversionista sofisticado pues refleja la comparación entre el riesgo del activo y el riesgo de mercado. De igual forma la rotación del activo y el ciclo de caja actúan como un referente del reflejo de velocidad con la cual el activo puede generar caja mostrando la capacidad gerencial para lograr este efecto en el valor de los activos que operan en el mercado que es subyacente al valor de la compañía o del titular del activo. A esto se suman aspectos que también deben ser analizados como las ratios precio/valor contable, la capitalización bursátil, la rentabilidad del dividendo y el grado de endeudamiento, experiencia del CEO, el número de directores independientes, el porcentaje de concentración de la familia en el directorio, el grado de vulnerabilidad política, el grado de vulnerabilidad ambiental y el grado de vulnerabilidad reputacional.

Los métodos de búsqueda basados en técnicas de inteligencia artificial aplicados al análisis de activos financieros en distintos períodos de tiempo han sido revisados por diversos autores en las investigaciones de Abdou & Nasereddin (2011), Chien-Feng et al. (2015); Hegazy, Soliman & Salam (2015) y Ebadati & Mortazavi (2018) en particular con el uso herramientas de inteligencia artificial basadas en máquinas de soporte de vectores (SVM) como refieren los trabajos de Vaishy & Lavanya (2016) y Myšková, Hájek & Olej (2018) o bien por medio de la técnica de redes neuronales artificiales (RNA) como se aprecia en los trabajos de Vejendla & Enke (2013); Akhter (2014); Charumathi & Suraj (2014); Hamid & Habib (2014); Sharma & Rababaah (2014); Qiu & Song (2016) y Rajihy, Nermend & Alsakaa (2017) encontrándose mayor precisión en la predicción del comportamiento financiero en comparación con los métodos tradicionales.

Las redes neuronales son una técnica de la inteligencia artificial que permite establecer regresiones complejas sobre grandes volúmenes de datos sobre la base de identificar entradas y salidas deseadas para adaptar una configuración final de red que permita un aprendizaje supervisado a partir del cual se pueda lograr una gran precisión en la predicción de datos. Para ello es necesario recurrir al uso de algoritmos complementarios de optimización que operen sobre la red neuronal y permitan reducir el error en la predicción de la función objetivo como los planteados por Broyden (1970); Goldfarb (1970); Shanno (1970); Shanno & Kettler (1970); Fletcher (1987); Bonnans et al. (2006); Nocedal & Wright (2006) y Luenberger & Ye (2008) quienes configuran experiencia en la utilización del algoritmo LBFGS para lograr mejores resultados en el análisis predictivo. Los algoritmos LBFGS son comúnmente utilizados para minimizar el error en la predicción y su uso se inicializa con una distribución aleatoria de pesos de entrada que son sucesivamente actualizados con una tasa de aprendizaje predefinida hasta lograr configurar diferencias mínimas entre los valores obtenidos y los reales alcanzados en la data de prueba.


En general la literatura de las técnicas de análisis se concentra en la predicción del comportamiento de las variables casi exclusivamente en las características de la herramienta o su uso principal siempre a partir de patrones tradicionales y datos estructurados como los indicadores económicos y los resultados de los reportes financieros de las empresas que sustentan los activos cotizados dejando de lado el análisis de variables no estructuradas y complejas de contexto que pueden ser encontradas en las memorias de las compañías y

en las notas informativas de la información que divulgan al mercado y a las partes interesadas así como en los factores de contexto que configuran el entorno social, político y ambiental de las empresas que cotizan en el mercado.

DISCUSIÓN DE RESULTADOS

Los resultados muestran que la combinación rentabilidad-riesgo puede ser estimada a partir de las variables de entrada con un 76.93% de precisión evidenciando una fuerte dependencia sensitiva de la capacidad de generación de caja, la velocidad con que rotan los activos y la velocidad con la que se invierte el Capex como los principales generadores de las mejores combinaciones rentabilidad-riesgo sobre la base del aprendizaje en los datos de estudio. Los resultados muestran que las ganancias logradas y el tamaño de la inversión tienen una contribución menor relativa frente a las variables antes mencionadas, dejando claro que el resto de variables no presenta una contribución significativa en la determinación de las mejores combinaciones rentabilidad-riesgo.


El Gráfico 2 permite apreciar para la variable rentabilidad (expresada como porcentaje) el ajuste logrado mediante redes neuronales para la curva de los resultados rentabilidad-riesgo para los casos de entrenamiento en comparación con los estimados en la predicción de red.



Fuente: Elaboración propia con datos procesados a partir de SMV, 2017

Gráfico 2: Curva de Rentabilidad


De igual forma el Gráfico 3 permite apreciar para la variable riesgo (expresado en porcentaje) el ajuste logrado mediante redes neuronales para la curva de los resultados rentabilidad-riesgo para los casos de entrenamiento en comparación con los estimados en la predicción de red.



Fuente: Elaboración propia con datos procesados a partir de SMV, 2017

Grafico 3: Curva de Riesgo

El Gráfico 4 permite mostrar el análisis de sensibilidad combinado para ambas variables de salida (Rentabilidad y Riesgo) ambas expresadas porcentualmente respecto a las variables de entrada de conjunto de datos de prueba donde el 100% de los datos de entrada corresponden a la extracción de datos públicos de Economática 2017 y Bloomberg, 2017 sobre la base de datos de la Superintendencia de Mercado de Valores (SMV, 2017) que han sido procesados por medio de la simulación y análisis de sensibilidad del trabajo de la red neuronal.



Fuente: Elaboración propia con datos procesados a partir de SMV, 2017

Grafico 4: Sensibilidad de variables.

CONCLUSIONES

La investigación demuestra que las redes neuronales pueden representar una herramienta que permita hacer una estimación aceptable para predecir las mejores combinaciones rentabilidad-riesgo para los principales activos del mercado sobre la base de los parámetros tradicionales que los activos reportan al mercado y sobre los parámetros no tradicionales que se especifican en los reportes de las memorias institucionales de las compañías titulares de dichos activos. La investigación demuestra que puede alcanzarse precisiones en la predicción de hasta el 76.93% en promedio para el estudio del periodo 2010-2016 en la información reportada en el mercado de valores peruanos (Bolsa de Valores de Lima).

Lo resultados alcanzados en el análisis muestran que las mejores combinaciones rentabilidad-riesgo dependen en gran medida de la capacidad de generación de caja, la velocidad de rotación de activos y la velocidad con la que desembolsa el Capex como las principales variables de influencia dejando de lado el resto de variables estudiadas, lo cual representa un hallazgo significativo para la data materia de estudio puesto que demuestra el reflejo de un reconocimiento real a la capacidad de gestión expresada en la velocidad con la que la gerencia puede rotar el activo y generar caja como las principales palancas de valor en el logro de mayores rentabilidades con riesgos bajo control siendo su importancia significativamente mayor en comparación a la estructura del activo e independiente del mercado en el cual opera.

La investigación demuestra que existe cierta invariancia en relación al tipo de mercado en el que opera el activo así como una débil dependencia en relación a la naturaleza misma del activo, privilegiando la capacidad de gestión que permite generar caja y movilizar la inversión como el principal atributo de valor que impacta en las mejores combinaciones rentabilidad-riesgo que pueden lograrse en el mercado peruano que pueden explicar con mayor precisión el comportamiento bursátil si se definen a partir de las variables clave que resultan como hallazgo para la data de estudio en el mercado peruano entre el 2010 y el 2016.

Los hallazgos presentados reflejan una interesante complejidad en el estudio de la manera como se gestiona la gerencia de los activos representados en la muestra puesto que las principales variables de sensibilidad están fuertemente influenciadas por la capacidad de la gerencia para imprimir velocidad en dichos activos. El papel de la gerencia en sí mismo, constituye un aspecto que escapa al análisis realizado y que requiere ser materia de futuras investigaciones.

REFERENCIAS BIBLIOGRAFICAS

- Abdou, K., & Nasereddin, M. (2011). The persistence of hedge fund strategies in different economic periods: A support vector machine approach. *Journal of Derivatives & Hedge Funds*, 17(1), 2-15. doi:<http://dx.doi.org/10.1057/jdhf.2011.1>.
- Akhter, M. R. (2014). A hybrid intelligent method of predicting stock returns. *Advances in Artificial Neural Systems*, doi:<http://dx.doi.org/10.1155/2014/246487>.
- Arugaslan, O., & Samant, A. (2014). Evaluating S&P 500 sector ETFs using risk-adjusted performance measures. *Journal of Finance, Accounting and Management*, 5(1), 48-62.
- Bello, Z. (2012). The investment performance and tracking errors of small-cap ETFs. *Global Journal of Finance and Banking Issues*, 6(6), 12-20.
- Bello, Z. Y. (2012). The relative performance of equity index ETFs and equity index mutual funds. *European Journal of Finance and Banking Research*, 5(5), 35-46.
- Bonnans, J.; Gilbert, J.; Lemaréchal, C.; Sagastizábal, C. (2006), Numerical optimization: Theoretical and practical aspects, Universitext (Second revised ed. of

- translation of 1997 French ed.), Berlin: Springer-Verlag, pp. xiv+490, doi:10.1007/978-3-540-35447-5, ISBN 3-540-35445-X, MR 2265882 French Original: Optimisation numérique: Aspects théoriques et pratiques ISBN 3-540-63183-6.
- Borkovec, M., & Serbin, V. (2013). Create or buy: A comparative analysis of liquidity and transaction costs for selected U.S. ETFs. *Journal of Portfolio Management*, 39(4), 118-131,12.
- Broyden, C.(1970), "The convergence of a class of double-rank minimization algorithms", Journal of the Institute of Mathematics and Its Applications, 6: 76–90, doi:10.1093/imamat/6.1.76
- Chang, C. E., Krueger, T. M., & Witte, H. D. (2015). Do ETFs outperform CEFs in fixed income investing? *American Journal of Business*, 30(4), 231-246.
- Charumathi, B., & Suraj, E. S. (2014). Refining ohlson model for valuing bank stocks- an artificial neural network approach. *Independent Business Review*, 7(2), 32-48.
- Chien-Feng, H., Chi-Jen Hsu, Chi-Chung, C., Bao, R. C., & Chen-An, L. (2015). An intelligent model for pairs trading using genetic algorithms. *Computational Intelligence and Neuroscience: CIN*, doi: <http://dx.doi.org/10.1155/2015/939606>
- Chen, H., Shin, S. H., & Sun, X. (2015). Return-enhancing strategies with international ETFs: Exploiting the turn-of-the-month effect. *Financial Services Review*, 24(3), 271-288.
- Chung, D. Y., & Hrazdil, K. (2013). Speed of convergence to market efficiency in the ETFs market. *Managerial Finance*, 39(5), 457-475. doi: <http://dx.doi.org/10.1108/03074351311313852>
- DiLellio, J. A., & Jakob, K. (2011). ETF trading strategies to enhance client wealth maximization. *Financial Services Review*, 20(2), 145-163.
- DiLellio, J. A., Hesse, R., & Stanley, D. J. (2014). Portfolio performance with inverse and leveraged ETFs. *Financial Services Review*, 23(2), 123-149.
- Dunham, L. M., Jorgensen, R., & Washer, K. (2016). Securities lending activities in mutual funds and ETFs: Ethical considerations. *Journal of Business Ethics*, 139(1), 21-28. doi:<http://dx.doi.org/10.1007/s10551-015-2609-1>
- Dunham, L. M., & Simpson, T. H. (2015). An analysis of the impact of securities lending on the performance of ETFs. *The Journal of Wealth Management*, 17(4), 75-84,6.
- Ebadati, O. M. E., & Mortazavi, M. T. (2018). An efficient hybrid machine learning method for time series stock market forecasting. *Neural Network World*, 28(1), 41-55. doi:<http://dx.doi.org/10.14311/NNW.2018.28.003>
- Fama, E. 1970. "Efficient Capital Markets: A Review of Theory and Empirical Work", *The Journal of Finance*, v. 25, 383-417.
- Fletcher, R. (1987), *Practical methods of optimization* (2nd ed.), New York: John Wiley & Sons, ISBN 978-0-471-91547-8
- Garson, D.(1991) Interpreting neural-network connection weights. *AI Expert*, 6(4):46–51, 1991.
- Giesecke M. & Contreras C. (2007). *Bolsa de Valores de Lima 150 años de Historia*. BVL 1ra. Edición dic 2007, Peru
- Goldfarb, D. (1970), "A Family of Variable Metric Updates Derived by Variational Means", *Mathematics of Computation*, 24 (109): 23–26, doi:10.1090/S0025-5718-1970-0258249-6
- Hansen, L. (2002). "Method of Moments". In Smelser, N. J.; Bates, P. B. *International Encyclopedia of the Social and Behavior Sciences*. Oxford: Pergamon.
- Hamid, S. A., & Habib, A. (2014). Financial forecasting with neural networks. *Academy of Accounting and Financial Studies Journal*, 18(4), 37-55.
- Hegazy, O., Soliman, O. S., & Salam, M. A. (2015). Comparative study between FPA, BA, MCS, ABC, and PSO algorithms in training and optimizing of LS-SVM for stock market prediction. *International Journal of Advanced Computer Research*, 5(18), 35-45.
- Henderson, B. J., & Buetow, G. W. (2014). Are flows costly to ETF investors? *Journal of Portfolio Management*, 40(3), 100-112,10.

- Huang, C., Chiou, C., Wu, T., & Yang, S. (2015). An integrated DEA-MODM methodology for portfolio optimization. *Operational Research*, 15(1), 115-136. doi:<http://dx.doi.org/10.1007/s12351-014-0164-7>
- Ivanov, S. I. (2011). ETF volatility around the New York stock exchange close. *Journal of Accounting and Finance*, 11(4), 37-46.
- Ivanov, S. I. (2013). High-frequency analysis of exchange traded funds' pricing deviation. *Managerial Finance*, 39(5), 509-524. doi: <http://dx.doi.org/10.1108/03074351311313834>
- Ivanov, S. I. (2015). Intraday analysis of currency ETFs. *International Journal of Managerial Finance*, 11(4), 438-450.
- Ivanov, S. I. (2016). Analysis of the factors impacting ETFs net fund flow changes. *Studies in Economics and Finance*, 33(2), 244-261.
- Jacobsen, B. (2015). The big ETF charade. *Journal of Portfolio Management*, 41(2), 3-4.
- Jung-Chu, L. (2017). Does pricing deviation of exchange-traded funds predict ETF returns? *Asian Economic and Financial Review*, 7(8), 748-759. doi:<http://dx.doi.org/10.18488/journal.aefr.2017.78.748.759>.
- Karceski, J. (2002). Returns-chasing behavior, mutual funds, and beta's death. *Journal of Financial and Quantitative Analysis*, 37(4), 559-594.
- Kanuri, S. (2016). Hedged ETFs: Do they add value? *Financial Services Review*, 25(2), 181-198.
- Koti, R. T. (2013). Analysis of exchange traded funds & mutual funds. *I-Manager's Journal on Management*, 7(3), 12-25.
- Li, M., Klein, D., & Zhao, X. (2012). Empirical analysis of ETF intraday trading. *Financial Services Review*, 21(2), 149-176.
- Lin, J. (2013). Volume-return relationship in ETF markets: A reexamination of the costly short-sale hypothesis. *Journal of Applied Finance and Banking*, 3(6), 201-224.
- Lu, L., Wang, J., & Zhang, G. (2012). Long term performance of leveraged ETFs. *Financial Services Review*, 21(1), 63-80.
- Luenberger, D.; Ye, Y.(2008), Linear and nonlinear programming, International Series in Operations Research & Management Science, 116 (Third ed.), New York: Springer, pp. xiv+546, ISBN 978-0-387-74502-2, MR 2423726
- Madhavan, V. (2014). Investigating the nature of nonlinearity in indian exchange traded funds (ETFs). *Managerial Finance*, 40(4), 395-415. doi:<http://dx.doi.org/10.1108/MF-07-2013-0170>
- Milonas, N. T., & Rompotis, G. G. (2013). Does intervalling effect affect ETFs? *Managerial Finance*, 39(9), 863-882. doi:<http://dx.doi.org/10.1108/MF-01-2010-0004>
- Milonas, N. T., & Rompotis, G. G. (2015). The performance of German fixed-income ETFs: In the presence of the debt crisis. *Aestimatio*, (11), 46-77. doi: <http://dx.doi.org/10.5605/IEB.11.2>
- Meric, I., Gishlick, H. E., Taga, L. S., & Meric, G. (2011). Risks, returns, and portfolio diversification benefits of country index funds in bear and bull markets. *Business and Economics Research Journal*, 2(1), 1-14.
- Myšková, R., Hájek, P., & Olej, V. (2018). Predicting abnormal stock return volatility using textual analysis of news - a meta-learning approach. *Amfiteatru Economic*, 20(47), 185-201.
- Narend, S., & Thenmozhi, M. (2016). What drives fund flows to index ETFs and mutual funds? A panel analysis of funds in India. *Decision*, 43(1), 17-30. doi:<http://dx.doi.org/10.1007/s40622-016-0124-6>
- Nocedal, J.; Wright, S.(2006), Numerical Optimization (2nd ed.), Berlin, New York: Springer-Verlag, ISBN 978-0-387-30303-1
- Osterhoff, F., & Kaserer, C. (2016). Determinants of tracking error in German ETFs - the role of market liquidity. *Managerial Finance*, 42(5), 417-437.
- Papadelis, S., Flamos, A., & Androulaki, S. (2012). Setting the framework for a business strategy assessment model. *International Journal of Energy Sector Management*, 6(4), 488-517. doi: <http://dx.doi.org/10.1108/17506221211281993>
- Qiu, M., & Song, Y. (2016). Predicting the direction of stock market index movement using an optimized artificial neural network model. *PLoS One*, 11(5). doi: <http://dx.doi.org/10.1371/journal.pone.0155133>

- Rajihy, Y., Nermend, K., & Alsakaa, A. (2017). Back-propagation artificial neural networks in stock market forecasting. an application to the Warsaw stock exchange WIG20. *Aestimatio*, (15), 88-99. doi:http://dx.doi.org/10.5605/IEB.15.5
- Riepe, M. W., C.F.A., & Iachini, Michael, C.F.A., C.F.P. (2011). Volume and assets as determinants of ETF bid-ask spreads. *Journal of Financial Planning*, 24(5), 32-33,40.
- Rompotis, G. G. (2011). Predictable patterns in ETFs' return and tracking error. *Studies in Economics and Finance*, 28(1), 14-35.
doi: http://dx.doi.org/10.1108/108673711111110534
- Sanchez, B., & Wei, P. (2010). The liquidity of exchange traded funds. *International Review of Applied Financial Issues and Economics*, 2(4), 621-646.
- Sánchez, F. J. Z., Ovalle, R. I. A., Ramos, D. S., Alba, J. A. V., & García, F.,R.T. (2012). Una estrategia para portafolios con fondos cotizados */A strategy for exchange traded funds (ETFs) portfolios. *Revista Española De Financiación y Contabilidad*, 41(155), 417-444.
- Scozzari, A., Tardella, F., Paterlini, S., & Krink, T. (2013). Exact and heuristic approaches for the index tracking problem with UCITS constraints. *Annals of Operations Research*, 205(1), 235-250. doi:http://dx.doi.org/10.1007/s10479-012-1207-1
- Shanno, D. (1970), "Conditioning of quasi-Newton methods for function minimization", *Mathematics of Computation*, 24 (111): 647-656, doi:10.1090/S0025-5718-1970-0274029-X, MR 0274029
- Shanno, D.; Kettler, P.(1970), "Optimal conditioning of quasi-Newton methods", *Mathematics of Computation*, 24 (111): 657-664, doi:10.1090/S0025-5718-1970-0274030-6, MR 0274030
- Sharifzadeh, M., & Hojat, S. (2012). An analytical performance comparison of exchange-traded funds with index funds: 2002-2010. *Journal of Asset Management*, 13(3), 196-209. doi:http://dx.doi.org/10.1057/jam.2012.3
- Sharma, D. K., & Rababaah, A. R. (2014). Stock market predictive model based on integration of signal processing and artificial neural network. *Academy of Information and Management Sciences Journal*, 17(1), 51-70.
- Shiller, R. (2003). "From Efficient Markets Theory to Behavioral Finance." *Journal of Economic Perspectives*, 17 (1): 83-104.
- Schizas, P. (2014). Active ETFs and their performance vis-à-vis passive ETFs, mutual funds, and hedge funds. *The Journal of Wealth Management*, 17(3), 84-98,6-7.
- Shum, P. M., & Kang, J. (2013). Leveraged and inverse ETF performance during the financial crisis. *Managerial Finance*, 39(5), 476-508. doi: http://dx.doi.org/10.1108/03074351311313825
- Thaler, R. H. (2015). *Misbehaving: The making of behavioral economics*. New York: W.W. Norton & Company, [2015]
- Tseng, Y., & Lee, W. (2016). Investor sentiment and ETF liquidity - evidence from Asia markets. *Advances in Management and Applied Economics*, 6(1), 89-111.
- Vaishy, N., & Lavanya, K. (2016). Stock market prediction by non-linear combination based on support vector machine regression model. *International Journal of Advanced Research in Computer Science*, 7(7)
- Vejendla, A., & Enke, D. (2013). Performance evaluation of neural networks and garch models for forecasting volatility and option strike prices in a bull call spread strategy. *Journal of Economic Policy and Research*, 8(2), 1-19.
- Williams, S. O. (2014). Country ETFs, currencies and international diversification. *Journal of Asset Management*, 15(6), 392-414.
doi:http://dx.doi.org/10.1057/jam.2014.28
- Yamori, N. (2011). Commodity ETFs in the Japanese Stock Exchanges. *Journal of Advanced Studies in Finance*, 2(1), 11-12.