



Universidad Nacional Mayor de San Marcos
Universidad del Perú. Decana de América
Facultad de Ingeniería de Sistemas e Informática
Escuela Profesional de Ingeniería de Sistemas

**Sistema de apoyo para la toma de decisión de inversión en la
Bolsa de Valores**

TESIS

Para optar el Título Profesional de Ingeniero de Sistemas

AUTOR

Alvaro Sebastian PAZOS MEDINA

ASESOR

Dr. David Santos MAURICIO SÁNCHEZ

Lima, Perú

2021



Reconocimiento - No Comercial - Compartir Igual - Sin restricciones adicionales

<https://creativecommons.org/licenses/by-nc-sa/4.0/>

Usted puede distribuir, remezclar, retocar, y crear a partir del documento original de modo no comercial, siempre y cuando se dé crédito al autor del documento y se licencien las nuevas creaciones bajo las mismas condiciones. No se permite aplicar términos legales o medidas tecnológicas que restrinjan legalmente a otros a hacer cualquier cosa que permita esta licencia.

Referencia bibliográfica

Pazos, A. (2021). *Sistema de apoyo para la toma de decisión de inversión en la Bolsa de Valores*. [Tesis, Universidad Nacional Mayor de San Marcos, Facultad de Ingeniería de Sistemas e Informática, Escuela Profesional de Ingeniería de Sistemas]. Repositorio institucional Cybertesis UNMSM.

Metadatos complementarios autor/ asesor

Datos de autor	
Nombres y apellidos	Alvaro Sebastian Pazos Medina
Tipo de documento de identidad	DNI
Número de documento de identidad	75913803
URL de ORCID	https://orcid.org/0000-0002-4032-411X
Datos de asesor	
Nombres y apellidos	David Santos Mauricio Sánchez
Tipo de documento de identidad	DNI
Número de documento de identidad	06445495
URL de ORCID	https://orcid.org/0000-0001-9262-626X
Datos del jurado	
Presidente del jurado	
Nombres y apellidos	Marcos Hernán Rivas Peña
Tipo de documento	DNI
Número de documento de identidad	09241816.
Miembro del jurado 1	
Nombres y apellidos	Ana María Huayna Dueñas
Tipo de documento	DNI
Número de documento de identidad	06017183
Datos de investigación	
Línea de investigación	No aplica.

Grupo de investigación	Investigación Artificial
Agencia de financiamiento	Sin financiamiento
Ubicación geográfica de la investigación	Perú, Lima, Lima, Lima Latitud: -12.0621065 Longitud: -77.0365256
Año o rango de años en que se realizó la investigación	2018 – 2021
URL de disciplinas OCDE	Ingeniería de sistemas y comunicaciones https://purl.org/pe-repo/ocde/ford#2.02.04



**UNIVERSIDAD NACIONAL MAYOR DE SAN MARCOS
FACULTAD DE INGENIERIA DE SISTEMAS E INFORMATICA
Escuela Profesional de Ingeniería de Sistemas**

Acta Virtual de Sustentación de Tesis

Siendo las 16:00 horas del día 18. de noviembre del año 2021, se reunieron virtualmente los docentes designados como miembros de Jurado de Tesis, presidido por el Mg. Marcos Hernán Rivas Peña, Ing. Ana María Huayna Dueñas(Miembro) y el Dr. David Santos Mauricio Sánchez(Miembro Asesor), usando la plataforma Meet (meet.google.com/dgr-wefe-sin), para la sustentación Virtual de la tesis Intitulada: **“Sistema de Apoyo para la Toma de Decisión de Inversión en la Bolsa de Valores”**, del Bachiller: **Alvaro Sebastian Pazos Medina**; para obtener el Título Profesional de Ingeniero de Sistemas.

Acto seguido de la exposición de la Tesis, el Presidente invitó al Bachiller a responder las preguntas formuladas por los Miembros del Jurado.

El Bachiller, en el curso de sus intervenciones demostró pleno dominio del tema, al responder con acierto y fluidez a las preguntas formuladas por los señores miembros del Jurado.

Finalmente habiéndose efectuado la calificación correspondiente por los miembros del Jurado, el bachiller obtuvo la nota de **dieciocho (18)**

A continuación el Presidente del Jurado Mg. Marcos Hernán Rivas Peña, declara al Bachiller **Ingeniero de Sistemas.**

Siendo las 17:00 horas, se levantó la sesión.



UNMSM

Firmado digitalmente por RIVAS
PENA Marcos Hernan FAU
20148092282 soft
Motivo: Soy el autor del documento
Fecha: 30.11.2021 19:46:54 -05:00

Mg. Marcos Hernán Rivas Peña
Presidente

Ing. Ana María Huayna Dueñas
Miembro

Dr. David Santos Mauricio Sánchez
Miembro Asesor

DEDICATORIA

A mi familia, en especial a mi madre Carmen, mi abuelita Leonilda, mi tía María Ysabel y mi padre Max, por haberme forjado como la persona que soy actualmente y por apoyarme en todo momento, les dedico este y todos mis logros.

AGRADECIMIENTOS

A Dios, por bendecir y guiar cada paso de mi camino.

A mi familia, por su apoyo en cada momento de mi vida y siempre desear lo mejor para mí.

A mi asesor, el Dr. David Mauricio, por su valiosa guía y dedicación en la elaboración del presente trabajo.

ÍNDICE

LISTA DE TABLAS	vi
LISTA DE FIGURAS	viii
RESUMEN.....	ix
CAPÍTULO I: INTRODUCCIÓN.....	1
1.1. ANTECEDENTES DEL PROBLEMA.....	1
1.2. PROBLEMA.....	2
1.3. IMPORTANCIA.....	2
1.4. MOTIVACIÓN.....	3
1.5. OBJETIVOS	4
1.5.1. Objetivo general	4
1.5.2. Objetivos específicos.....	4
1.6. PROPUESTA.....	5
1.7. ORGANIZACIÓN DE LA TESIS	5
CAPÍTULO II: MARCO TEÓRICO.....	6
2.1. MERCADO DE VALORES	6
2.1.1. Definición.....	6
2.1.2. Actores.....	6
2.1.3. Importancia para las empresas.....	7
2.1.4. Portafolio de inversión	7
2.2. SISTEMA DE APOYO A LA DECISIÓN (DSS).....	8
2.2.1. Definición.....	8
2.2.2. DSS para inversión en la bolsa de valores.....	8
CAPÍTULO III: REVISIÓN DE LITERATURA	10
3.1. METODOLOGÍA.....	10
3.1.1. Planificación.....	10
3.1.2. Desarrollo	11
3.1.3. Resultados.....	12
3.2. ANÁLISIS DE ESTUDIOS	12
3.2.1. ¿Qué métodos existen para selección de portafolio – Q1?.....	13
3.2.2. ¿Qué métodos existen para predicción de precio futuro de las acciones – Q2?.	13

3.2.3. ¿Qué DSSs existen que generen un portafolio de inversión de forma automática – Q3?	14
CAPÍTULO IV: MODELO AIM	16
3.1. FASE P1: PREDICTOR DE PRECIOS	18
3.2. FASE P2: SELECCIÓN DE PORTAFOLIO	19
3.3 FASE P3: PROCESO DE COMPRA-VENTA	25
CAPÍTULO V: AIS: SISTEMA DE INVERSIÓN AUTOMÁTICA	27
5.1. ARQUITECTURA	27
5.2. MODELO DE DATOS	30
5.3. DICCIONARIO DE DATOS	31
5.3.1. Tabla <i>profile</i>	31
5.3.2. Tabla <i>user</i>	32
5.3.3. Tabla <i>setting</i>	33
5.3.4. Tabla <i>company</i>	33
5.3.5. Tabla <i>forecasted_price</i>	34
5.3.6. Tabla <i>portfolio</i>	34
5.3.7. Tabla <i>order</i>	35
5.4. SELECCIÓN DE PORTAFOLIO Y PERFILES	36
CAPÍTULO VI: VALIDACIÓN DEL SISTEMA	38
6.1. DATASETS.....	38
6.2. EXPERIMENTO	44
6.3. RESULTADOS	44
6.3.1. Rentabilidad por variación del error del precio de cierre	44
6.3.2. Impacto de la variable de holgura (Δ) en el error (ϵ)	49
6.3.3. Rentabilidad por capital de inversión	53
CAPÍTULO VII: CONCLUSIONES Y TRABAJOS FUTUROS	57
7.1. CONCLUSIONES.....	57
7.2. TRABAJOS FUTUROS.....	58
REFERENCIAS BIBLIOGRÁFICAS	59

LISTA DE TABLAS

Tabla 1. Actores del mercado de valores.....	7
Tabla 2. Criterios de inclusión / exclusión	11
Tabla 3. Estudios sobre selección de portafolio de inversión.....	13
Tabla 4. Estudios de predicción de precio futuro de una acción	14
Tabla 5. Estudios de DSS para la generación automática de portafolio de inversión	15
Tabla 6. Actores en AIM	17
Tabla 7. Componentes de la arquitectura de SAI	28
Tabla 8. Metadatos de la tabla profile	32
Tabla 9. Metadatos de la tabla user	32
Tabla 10. Metadatos de la tabla <i>setting</i>	33
Tabla 11. Metadatos de la tabla company	33
Tabla 12. Metadatos de la tabla forecasted_price.....	34
Tabla 13. Metadatos de la tabla portfolio	34
Tabla 14. Metadatos de la tabla order.....	35
Tabla 15. Rentabilidad diaria promedio (%) de AIS para varios capitales de inversión y $\Delta=0$	53
Tabla 16. Rentabilidad diaria promedio (%) de AIS para varios capitales de inversión y $\Delta= \epsilon $	54
Tabla 17. Rentabilidad mensual promedio (%) de AIS para varios capitales de inversión y $\Delta= \epsilon $	54

LISTA DE FIGURAS

Figura 1. Volumen de transacciones de la Bolsa de Valores de Nueva York, en julio de 2021	3
Figura 2. Impacto del SARS-CoV-2 en las principales bolsas de valores	4
Figura 3. Proceso de selección de artículos	12
Figura 4. Un modelo para inversión automática en la bolsa de valores (AIM).....	16
Figura 5. Proceso para construir el predictor de precios	19
Figura 6. Escenarios sobre los precios de apertura, cierre y estimado de cierre	22
Figura 7. Proceso de compra-venta de acciones.....	26
Figura 8. Vista física de la arquitectura de AIS.....	27
Figura 9. Vista tecnológica de la arquitectura de AIS	30
Figura 10. Modelo de datos	31
Figura 11. Interfaces AIS para el administrador.....	36
Figura 12. Interfaces AIS para el inversionista	37
Figura 13. Comportamiento del precio de apertura y cierre para 5 empresas mineras peruanas (02/02/2020–12/31/2020).....	39
Figura 14. Precio de cierre de BGC con error ε (%)	41
Figura 15. Rentabilidad diaria de AIS: capital de inversión = 10K USD, $\Delta=0$, precio de cierre con error (%) ε	45
Figura 16. Rentabilidad diaria de AIS: capital de inversión = 10K USD, precio de cierre con error ε (%), y $\Delta= \varepsilon $	49
Figura 17. Comportamiento de la rentabilidad diaria y mensual de AIS respecto al Capital y el Error, $\Delta= \text{Error} $	55

RESUMEN

El problema de inversión en la bolsa de valores se puede resumir con la respuesta a la siguiente pregunta: ¿Dónde, cuánto y cuándo invertir de manera que se obtenga la máxima rentabilidad para un capital de inversión dado? Esta interrogante constituye un problema de selección de portafolio con incertidumbre, pues no se conoce a priori el comportamiento de los datos y es NP-hard por su naturaleza combinatoria, es decir, es un problema complejo y, en general, presenta alta probabilidad de pérdidas en las inversiones. En este trabajo se estudia los escenarios de inversión considerando el precio de apertura y el precio estimado de cierre de las acciones, y se identifica que cuando el precio de apertura de la acción es menor que el precio estimado de cierre, la mejor estrategia es *comprar acciones al inicio y venderlas todas al cierre*. Considerando esta estrategia, se propone un sistema de apoyo a la decisión para la inversión automática en la Bolsa de Valores (AIS) que está basada en un modelo predictivo de estimación de precios de cierre, un algoritmo greedy y un algoritmo GRASP para la construcción del portafolio, y un módulo que genera las órdenes de compra y venta de acciones integrado con el sistema del bróker. Las pruebas sobre datos del 2020, aplicadas a 5 empresas mineras peruanas que cotizan en NYSE, muestran que los algoritmos propuestos generan portafolio de inversión que son muy rentables, alcanzando una rentabilidad mensual promedio superior al 23 %, con un error de ± 3 % en la estimación del precio de cierre, además, no se altera si se varía el capital de inversión, pero decrece si se incrementa el error. Además, se propone una variable de holgura en el criterio de decisión de compra para amortiguar el impacto negativo del error sobre la rentabilidad, y se muestra que, cuando la variable de holgura asume el valor absoluto del error, el impacto negativo del 77.27 % para un error del ± 3 % se reduce a 28.03 %, haciendo que la rentabilidad diaria promedio de 0.30 % aumente y pase a 0.95 %.

Palabras clave: Inversión en mercado de valores, selección de portafolio, problema de la mochila entero, algoritmo voraz, GRASP

ABSTRACT

The investment problem in the stock market can be summarized by answering the question: Where, how much and when to invest in such a way as to receive the maximum profitability for a given investment capital? It is a portfolio selection problem with uncertainty, since the behavior of the data is prior unknown and it is NP-hard due to its combinatorial nature, that is, it is a complex problem and, in general, it presents a high probability of losses in investments. In this work, investment scenarios are studied considering the opening price and the estimated closing price of the shares, and it is identified that when the price of the share at the opening is lower than the estimated closing price, the best strategy is buy shares at the beginning and sell them all at the close. Considering this strategy, a decision support system for automatic investment in the Stock Market (AIS) is proposed that is based on a predictive model for estimating closing prices, a greedy algorithm and a GRASP algorithm for the construction of the portfolio, and a module that generates purchase and sale orders for shares integrated with the broker's system. Tests on 2020 data from 5 Peruvian mining companies listed on the NYSE show that the proposed algorithms generate investment portfolios that are very profitable, reaching average monthly profitability higher than 23%, even with an error of $\pm 3\%$ in the estimate. Moreover, the closing price does not change if the investment capital is changed, but it decreases if the error increases. In addition, a slack variable is proposed in the purchase decision criterion to cushion the negative impact of the error on profitability, and it is shown that, when the slack variable assumes the absolute value of the error, the negative impact of 77.27% for an error of $\pm 3\%$ is reduced to 28.03%, causing the average daily profitability of 0.30% to increase and go to 0.95%.

Keywords: Stock market investment, portfolio selection, integer knapsack problem, greedy algorithm, GRASP

CAPÍTULO I: INTRODUCCIÓN

1.1. ANTECEDENTES DEL PROBLEMA

Los estudios para resolver el problema de encontrar el portafolio óptimo de inversión (POI), es decir, encontrar la cantidad de acciones a comprar o vender de determinado conjunto de empresas, de manera que se obtenga la máxima rentabilidad, se orientan a precios, portafolio e híbridos (mezclan precios y portafolio). Los precios son importantes para la selección del portafolio óptimo, si este se conociera a priori, la incertidumbre desaparecería, entonces el problema se reduce a un problema de selección de portafolio sin incertidumbre, de ahí que se realicen esfuerzos para predecir los precios de las acciones, tales como los precios de apertura (Qiu, et. al., 2020), los precios de cierre (Adebiyi, et. al., 2014; Chiang, et. al., 2016), los precios mínimos y máximos dentro de un día (Laboissiere, et. al., 2015), o el movimiento del precio de cierre (Liu et al., 2020). Los estudios de portafolio se orientan al desarrollo de algoritmos que permitan construir un portafolio de inversión, asumiendo que se conoce a priori la rentabilidad estimada o el riesgo de inversión, entre ellos se encuentran (Bernard et al., 2018), (Chen et al., 2018), (Chen et al., 2017), (Guasoni & Mayerhofer, 2020), (Gupta et al., 2019), (Shinzato & Yasuda, 2015). El enfoque híbrido se refiere al hecho de resolver POI considerando la estimación de los datos como los precios, la rentabilidad o el riesgo, y, a la vez, la construcción del portafolio, algunas de estas aproximaciones son (Guo et al., 2020), (Vaezi et al., 2019), (Yang et al., 2019).

En el camino de apoyar a los inversionistas en la adecuada y oportuna toma de decisiones, también se han desarrollado sistemas de apoyo a la decisión (DSS) para el inversionista que se apoyan en Análisis e investigación de mercados (por ejemplo, Motley Fool Stock Advisor, Motley Fool Rule Breakers, Tim's alerts, Seeking Alpha, Tradespoon, Trade Ideas, Mindful Trader), Investigación e información acreditadas (por ejemplo, Morningstar Premium, Kiplinger Mutual Fund Rankings, Refinitiv; MAXfunds.com), Analizador de tarifa (por ejemplo, Personal Capital, TD Ameritrade, Bloom), Planificación financiera (por ejemplo, Personal Capital, Mint), Cuenta de corretaje (por ejemplo, SoFI invest, M1 Finance,

Robinhood), Evaluador de inversiones (por ejemplo, Stock Rover, Yahoo Finance's), y apps, como Betterment, Acorns, Robinhood, Webull, TD Ameritrade, Stash, E*Trade, Wealthfront, Ally Invest, Personal Capital, Charles Schwab, varias de ellas automatizan el proceso de inversión. También, en la literatura, se describen algunos DSS, entre ellos el trabajo de (Paiva, et. al., 2018), donde se usa el método de machine learning de support vector machine (SVM) para la predicción de precios y el método media-varianza (MV) para la selección del portafolio, además, es necesario mencionar el trabajo de (Naranjo & Santos, 2019) que usa lógica difusa y el algoritmo k-nearest neighbor para la predicción de los precios y la selección del portafolio.

1.2. PROBLEMA

POI es uno de los principales problemas de los inversionistas. Este problema es muy complejo, debido a la cantidad de variables que involucra las combinaciones exponenciales de los posibles portafolios de inversión y la incertidumbre de los datos. POI puede ser formulado como un integer knapsack problem con incertidumbre en la rentabilidad, pues no se conoce a priori la rentabilidad del portafolio, en el ámbito sin incertidumbre (menos difícil), este problema es categorizado algorítmicamente como NP-Hard (Garey & Johnson, 1990).

1.3. IMPORTANCIA

El mercado de valores es vital en la economía a nivel mundial, porque, a través de ella, las empresas consiguen capital para varios fines como escalar, consolidar y expandirse a otros mercados, además, para los inversionistas, es un medio para obtener rentabilidad de sus inversiones, por lo que mueve mucho dinero y registran inmensas cantidades de transacciones al día, un ejemplo claro es la Bolsa de Valores de Nueva York (NYSE), la más grande del mundo, que en promedio ha registrado, en el mes de julio de 2021, un volumen de transacciones valuado en más de 8 mil millones de USD diarios (ver figura 1).

Figura 1. Volumen de transacciones de la Bolsa de Valores de Nueva York, en julio de 2021

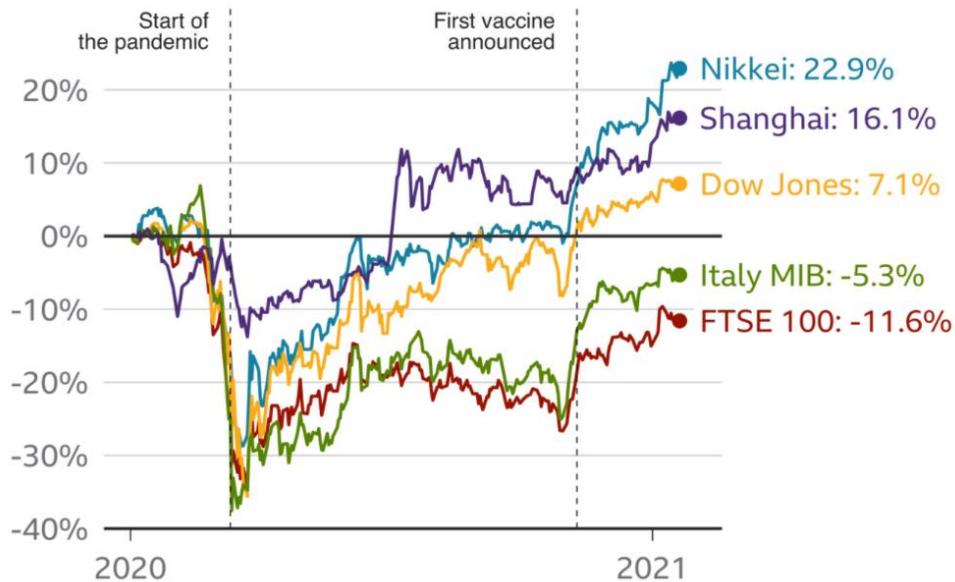
Today 5 Day Avg MTD						
Matched Volume	Tape A	Tape B	Tape C	Market*	Today	5 Day
⊕ NYSE (P,N,A,C,M)	935,053,873	275,277,136	368,346,920	1,578,677,929	19.22%	21.20%
⊕ NASDAQ (B,X,Q)	397,958,060	146,966,195	808,217,373	1,353,141,628	16.47%	18.84%
⊕ Cboe (Z,Y,K,J)	459,336,306	213,266,625	510,653,880	1,183,256,811	14.40%	12.48%
Members Exchange (U)	81,379,001	34,884,483	92,450,781	208,714,265	2.54%	2.20%
Investors Exchange (V)	88,600,079	16,704,325	71,888,532	177,192,936	2.16%	2.01%
MIAX Pearl (H)	9,420,014	9,050,898	8,347,445	26,818,357	0.33%	0.29%
LTSE (L)	202		915	1,117	0.00%	0.00%
Matched Total	1,971,747,535	696,149,662	1,859,905,846	4,527,803,043	55.11%	57.01%
FINRA & TRF Volume						
⊕ TRFs (DQ, DN, DB)	1,254,100,861	542,067,896	1,891,520,138	3,687,688,895	44.89%	42.99%
FINRA & TRF Total	1,254,100,861	542,067,896	1,891,520,138	3,687,688,895	44.89%	42.99%
Total Consolidated Volume						
Total	3,225,848,396	1,238,217,558	3,751,425,984	8,215,491,938	100%	100%

Fuente. CBOE (2021)

1.4. MOTIVACIÓN

La cantidad de información y herramientas es muy amplia y especializada, lo que hace compleja la toma de decisión adecuada en la inversión en la bolsa de valores, aún más en un periodo de pandemia ocasionada por el SARS-CoV-2, que agrega más incertidumbre en los mercados bursátiles, pues, en los inicios de la pandemia, generó pérdidas de hasta 35 % en los precios de las acciones en los mercados de Japón, USA y Europa (ver figura 2).

Figura 2. Impacto del SARS-CoV-2 en las principales bolsas de valores



Fuente. Bloomberg (2020)

1.5. OBJETIVOS

1.5.1. Objetivo general

Desarrollar un sistema de apoyo a la toma de decisiones que ofrezca al inversor un portafolio de inversión usando dos heurísticas que resuelven POI.

1.5.2. Objetivos específicos

- OS1: Revisar en la literatura algoritmos para selección del portafolio de inversión
- OS2: Identificar los algoritmos más adecuados para selección de portafolio
- OS3: Investigar el proceso de inversión online en la bolsa de valores
- OS4: Desarrollar el sistema implementando las heurísticas que resuelven POI

- OS5: Realizar experimentos para corroborar que, si el usuario realiza transacciones de acuerdo al portafolio brindado por el sistema, obtiene una rentabilidad promedio mayor que otros trabajos de la literatura

1.6. PROPUESTA

En este trabajo, se propone un DSS para la generación automática del portafolio de inversión considerando el precio de apertura y el precio estimado de cierre de las acciones antes de iniciar la jornada bursátil. A continuación, se precisa la contribución de este trabajo:

- Identifica y analiza cuatro escenarios de inversión.
- Modela el problema del portafolio con restricciones de oferta.
- Propone dos heurísticas para resolver POI que consideran un parámetro para mitigar el error en la estimación de precios.

1.7. ORGANIZACIÓN DE LA TESIS

Esta tesis está organizada en 6 secciones. En la sección 2, se presentan los conceptos más relevantes de la investigación. En la sección 3, se presentan estudios sobre construcción automática de portafolios. El modelo de DSS propuesto y su implementación se presentan en las secciones 4 y 5, respectivamente. Las pruebas numéricas sobre datos de 5 empresas mineras que cotizan en la bolsa de NYSE y sus resultados se muestran en la sección 6. Finalmente, las conclusiones siguen en la sección 7.

CAPÍTULO II: MARCO TEÓRICO

En este capítulo, se presentan conceptos que servirán para entender el contexto del presente trabajo, tales como Bolsa de Valores, Portafolio de inversión y DSS, revisando los componentes y características de cada uno de estos conceptos.

2.1. MERCADO DE VALORES

2.1.1. Definición

Según el Portal de Transparencia Económica del Ministerio de Economía y Finanzas de Perú (2021), el mercado de valores se define como un mecanismo en el que concurren los ciudadanos y empresas para invertir en valores que le produzcan eventualmente una ganancia o para captar recursos financieros de aquellos que lo tienen disponible. Asimismo, de acuerdo con el Glosario de términos económicos del Banco Central de Reserva del Perú (2021), el mercado de valores es un mercado organizado en el que se negocia públicamente la compra y venta de títulos de renta fija y variable (acciones, obligaciones, etc.), bienes, materias primas, entre otros.

2.1.2. Actores

En la Tabla 1, se presentan los actores que intervienen dentro del sistema bursátil.

Tabla 1. Actores del mercado de valores

Actor	Descripción
Inversor	Es aquella persona natural o jurídica que cuenta con el capital para invertir en acciones, buscando tener ganancias en un futuro.
Broker	Denominado también agente de bolsa, es quien se encarga de representar al inversor en el mercado de valores y negociar acciones en su nombre.
Empresa	Agente que cotiza en bolsa buscando obtener liquidez a través de la venta de acciones

Fuente. Autor

2.1.3. Importancia para las empresas

Para que una empresa pueda crecer, necesita un capital adicional, por lo que las empresas hacen una oferta pública, para conseguir nuevos socios que puedan invertir en la empresa. Para cotizar sus valores en bolsa, las empresas previamente deben hacer públicos sus estados financieros, ya que estos permiten determinar la situación financiera de las compañías. En el momento en que una empresa cotiza en bolsa, esta se vuelve pública; es decir, ya no solo los accionistas tienen acceso a la información de la empresa, sino que cualquier persona puede conocer la información sobre el desempeño de la misma.

2.1.4. Portafolio de inversión

Es una selección de documentos que se cotizan en el mercado bursátil, y en los que una persona o empresa decide colocar o invertir su dinero. El objetivo es repartir el riesgo al combinar diferentes instrumentos: acciones, depósitos a plazo, efectivo, monedas internacionales, bonos, bienes raíces. A esto se le conoce como diversificar la cartera de inversiones.

2.2. SISTEMA DE APOYO A LA DECISIÓN (DSS)

2.2.1. Definición

Según (Munoz, et. al., 2019), un DSS es una solución de tecnología de información que puede ser usado para apoyar la toma de decisiones complejas y la resolución de problemas. Por otro lado, de acuerdo con (Kashyap, 2019), DSS es el término utilizado para la ayuda basada en datos a propuestas programadas para impulsar decisiones y reforzar a un gerente. A diferencia de un sistema de información tradicional, que tiene como fin proporcionar información a un gerente, un gerente utiliza los DSS para predecir acciones basadas en un modelo formal, según (Ferguson & Hebels, 2003).

2.2.2. DSS para inversión en la bolsa de valores

Un DSS que genera de forma automática un portafolio de inversión para el mercado bursátil es una herramienta que apoya al inversionista ofreciéndole, de manera oportuna, un portafolio que proporcione una tasa de rentabilidad adecuada sobre la inversión, minimice el riesgo de pérdida, tenga alta disponibilidad y sea de rápida ejecución. La importancia de un DSS con estas características es que simplifica y automatiza el proceso especializado y complejo de análisis para la toma de decisión, de esta manera, el inversionista tendrá una herramienta que le indique oportunamente cuándo, cuánto y dónde comprar o vender acciones de la bolsa de valores para obtener mayor rentabilidad. Estos DSS consideran, en general, información bursátil actual e histórica de la bolsa (precios de apertura, cierre, mínima, máxima de las acciones por empresa, índices bursátiles, entre otros), costos de transacciones, rentabilidad y construcción de portafolios de inversión, algunos incluyen predicción de precios.

Los costos de las transacciones se refieren a las tarifas que se deben pagar a los brókeres por cada transacción (compra o venta de acciones), el cual es establecido por cada empresa de corretaje, además de ello, existen otros costos, tales como el impuesto sobre la renta y las ganancias (Paiva, et. al., 2018). La rentabilidad generada por las acciones puede ser positiva o negativa, y se reporta de forma periódica (diaria, mensual o anual).

CAPÍTULO III: REVISIÓN DE LITERATURA

En este capítulo, se desarrolla una revisión de literatura con el objetivo de responder a las preguntas Q1) ¿Qué métodos existen para selección de portafolio de inversión?, Q2) ¿Qué métodos existen para predicción de precio futuro de las acciones? y Q3) ¿Qué DSSs existen que generen un portafolio de inversión de forma automática? Además, se realiza el análisis de los resultados obtenidos, profundizando en los DSS que combinan técnicas para predicción de precios de acciones y selección de portafolio de inversión.

3.1. METODOLOGÍA

Para realizar la revisión de la literatura, se utilizó la metodología de 3 fases: Planificación, Desarrollo y Análisis, la cual adopta métodos explícitos y sistemáticos para la identificación, selección y evaluación crítica de la información.

3.1.1. Planificación

Se plantearon las siguientes interrogantes sobre técnicas de predicción de precios y selección de portafolio:

- Q1: ¿Qué métodos existen para selección de portafolio de inversión?
- Q2: ¿Qué métodos existen para predicción de precio futuro de las acciones?
- Q3: ¿Qué DSSs existen que generen un portafolio de inversión de forma automática?

Los bancos de Journal considerados para la búsqueda son ACM, IEEE, Science Direct y Scopus. Se tomaron en cuenta únicamente los trabajos publicados entre los años 2013 y 2021. Asimismo, las palabras clave utilizadas en la búsqueda son “stock market”, “predictive model” y “decision support system”.

3.1.2. Desarrollo

Se realizó un filtro sobre los artículos de investigación obtenidos según los criterios que se detallan en la Tabla 2.

Tabla 2. Criterios de inclusión / exclusión

Criterios de inclusión	Criterios de exclusión
1. Se incluyeron todos los documentos encontrados en las bases de datos en el intervalo de tiempo comprendido entre 2015 y 2021. 2. Se incluyeron solo los tipos de documentos que son artículos. 3. Se incluyeron solo artículos en inglés.	1. Se excluyeron todos los documentos que no estuvieran relacionados con la temática de la investigación. 2. Se excluyeron los documentos con fecha de publicación fuera del periodo establecido. 3. Se excluyeron los tipos de documentos como editorial, corrección, resumen, noticia. 4. Se excluyeron los artículos en idiomas diferentes al inglés.

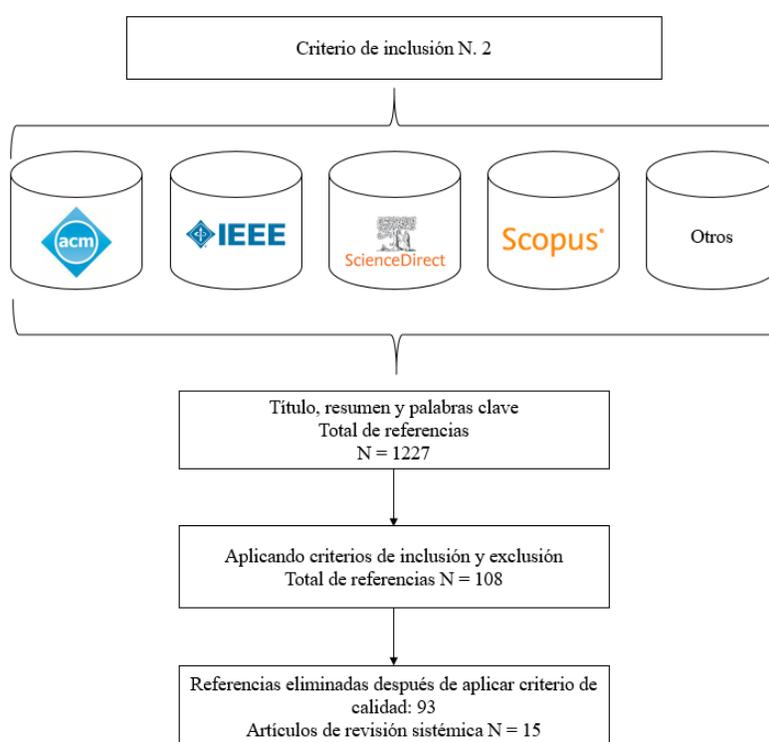
Fuente. Autor

En primer lugar, se realizó la búsqueda de artículos de investigación en los bancos de acuerdo al criterio de inclusión N.2, obteniendo un total de 1227 estudios en los que el título, resumen o palabras clave coincidían con las palabras clave utilizadas para la búsqueda mencionadas anteriormente. Posteriormente, se procedió a aplicar los criterios de inclusión y exclusión restantes, con lo cual se redujeron los estudios a 108. Finalmente, se refinó el filtro leyendo los abstracts, introducción y conclusiones de los artículos con el fin de determinar si guardan relación con nuestra investigación, obteniendo 15 estudios primarios (ver Figura 3).

3.1.3. Resultados

Como resultado del proceso de selección de artículos, se obtuvo 15 artículos de investigación, que servirán de sustento para dar respuesta a las preguntas planteadas en la fase de planificación.

Figura 3. Proceso de selección de artículos



Fuente. Autor

3.2. ANÁLISIS DE ESTUDIOS

En esta sección, se responderán las preguntas de investigación con base en los artículos seleccionados.

3.2.1. ¿Qué métodos existen para selección de portafolio – Q1?

En la Tabla 3, se presentan unos estudios acerca de selección de portafolio de inversión. La selección de portafolio se realiza mediante métodos que buscan apoyar a la decisión ofreciendo un portafolio que ofrezca un nivel aceptable de rentabilidad estimada, indicando dónde, cuánto, y, en algunos casos, cuándo invertir, por ejemplo, en qué acciones invertir, qué cantidad de cada una y en qué momento comprar o vender acciones. Entre los métodos usados, se encuentran lógica difusa (FL) (Naranjo & Santos, 2019), Recurrent Reinforcement Learning (RRL) (Almahdi & Yang, 2019), Multi-Objective Particle Swarm Optimization (MOPSO) (Chen & Zhou, 2018), Self-adaptative Particle Swarm Optimization (SAPSO) (Jin, et. al., 2018), Mean Maverick y Data Envelopment Analysis (MM-DEA) (Essid, et. al., 2018).

Tabla 3. Estudios sobre selección de portafolio de inversión

Fuente	Método	Mercado
Naranjo & Santos (2019)	FL	NASDAQ, IBEX 35
Almahdi & Yang (2019)	RRL	SPY, IWD, IWC, DEM, CLY
Chen & Zhou (2018)	MOPSO	China
Jin, et. al. (2018)	SAPSO	NASDAQ
Essid, et. al. (2018)	MM-DEA	Euronext Paris

Fuente. Autor

3.2.2. ¿Qué métodos existen para predicción de precio futuro de las acciones – Q2?

En la Tabla 4, se presenta un listado de estudios orientados a la predicción de precios de las acciones en la bolsa de valores. La predicción del precio futuro de una acción tiene por finalidad apoyar a la toma de decisiones en la compra o venta de acciones, por ende, en la

construcción del portafolio óptimo de inversión. En general, los métodos de predicción son de dos tipos: a) métodos estadísticos, como ARIMA (Khan & Alghulaiakh, 2020), o regresión lineal (Amrutphale, et. al., 2020); b) métodos basados en machine learning, como SVM (Chen & Hao, 2017; Paiva, et. al., 2018), RBF (Lai, et. al., 2018) o Deep Learning (Chong, et. al., 2017; Shen & Lian, 2018). Además, los DSS, en general, se orientan a un mercado bursátil.

Tabla 4. Estudios de predicción de precio futuro de una acción

Fuente	Método	Técnica
Khan & Alghulaiakh (2020)	Estadístico	ARIMA
Amrutphale, et. al. (2020)	Estadístico	Regresión lineal
Chen & Hao (2017)	Machine learning	SVM
Paiva, et. al. (2018)	Machine learning	SVM
Lai, et. al. (2018)	Machine learning	RBF
Chong, et. al. (2017)	Machine learning	Deep Learning
Shen & Lian (2018)	Machine learning	Deep Learning

Fuente. Autor

3.2.3. ¿Qué DSSs existen que generen un portafolio de inversión de forma automática – Q3?

En la Tabla 5, se presenta un inventario de 8 DSS que genera, de forma automática, un portafolio de inversión para la bolsa de valores. La mayoría (62.5 %) de ellas no consideran la predicción de precios, y todas muestran un método diferente para la construcción del portafolio. La rentabilidad mensual reportada en los estudios es heterogénea, incluso para un mismo mercado bursátil, como China, que, en promedio, para un estudio es de -3.11 % (Chen

& Zhou, 2018), y para otro de 13.2 % (Lai, et. al., 2018). Los mercados bursátiles considerados son de los más importante en el mundo, entre ellos destacan NYSE y NASDAQ, en USA; Euronext Paris, la bolsa más grande de Francia; Bolsa de Valores del Estado de Sao Paulo (Bovespa), en Brasil, y Bolsa de Madrid (IBEX 35), la más importante de España.

Tabla 5. Estudios de DSS para la generación automática de portafolio de inversión

Fuente	Predicción de precios	Selección de portafolio	Rentabilidad Mensual	Mercado
Cabrera & Paniagua (2015)	-	artificial emotions	-	NYSE
Chen & Zhou (2018)	-	MOPSO	(-8.34, 5.23)*	China
Jin, et. al. (2018)	-	SAPSO	6.34**	NASDAQ
Essid, et. al. (2018)	-	MM-DEA	(0.36, 0.83)*	Euronext Paris
Lai, et. al. (2018)	RBF	AICTR	(0.90, 25.50)*	China
Paiva, et. al. (2018)	SVM	MV	(-0.60, 3.35)*	Ibovespa
Almahdi & Yang (2019)	-	RRL	13.4	SPY, IWD, IWC, DEM, CLY
Naranjo & Santos (2019)	FL	FL	1.26 1.82	NASDAQ IBEX 35

- sin información

* intervalo (a,b): a valor mínimo, b valor máximo

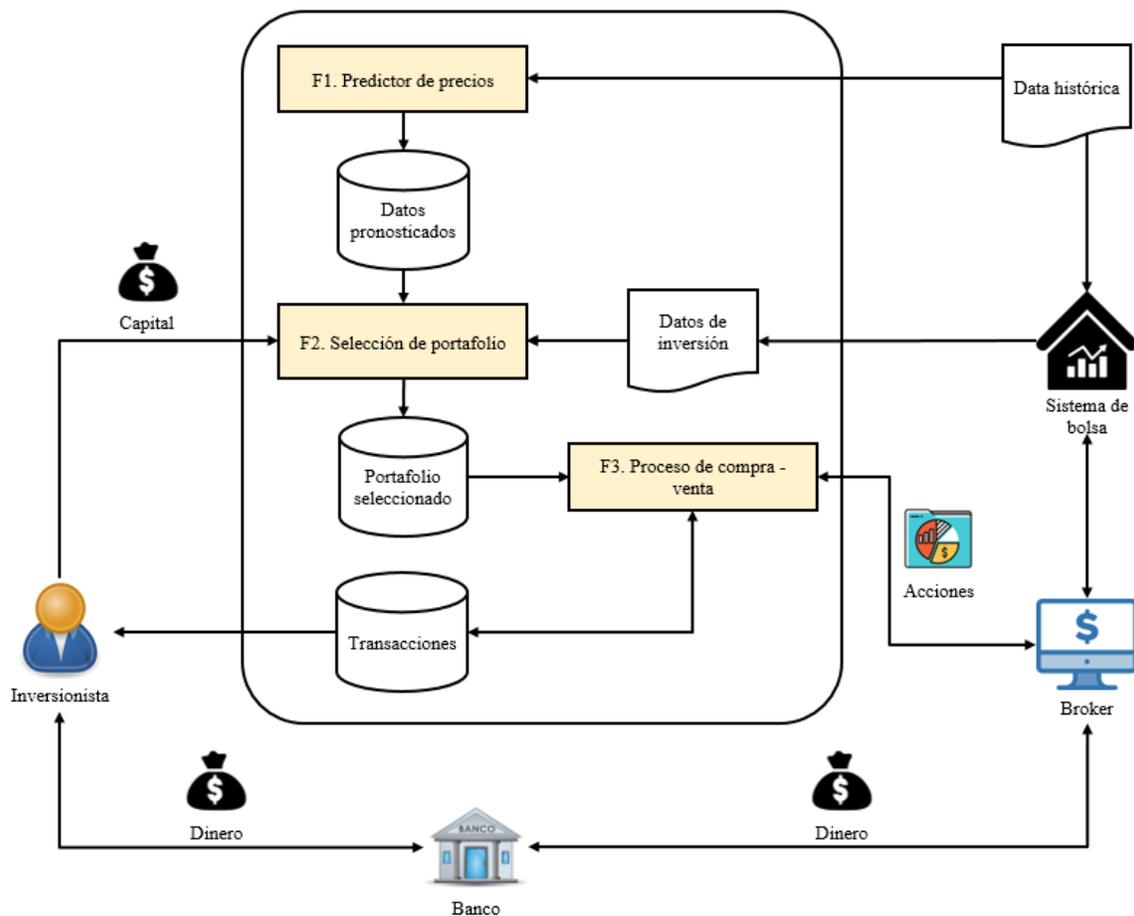
** no especifica periodo

Fuente. Autor

CAPÍTULO IV: MODELO AIM

Se propone un modelo de inversión automática (AIM) en el mercado de valores, con la finalidad de obtener de forma automática la mayor rentabilidad en la bolsa para un capital de inversión dado. AIM se compone de un modelo predictivo de precios basado en machine learning, un generador del portafolio de inversión que es basado en una heurística, y un módulo de compra y venta de acciones (ver Figura 4).

Figura 4. Un modelo para inversión automática en la bolsa de valores (AIM)



Fuente. Autor

El modelo funciona como sigue. Todos los días laborables en la bolsa, se extraen datos del sistema de la bolsa valores y se pronostica el precio de cierre de las empresas antes del inicio de la jornada bursátil, a través de un modelo predictivo basado en los datos históricos de las acciones (Fase 1). El inversionista, a través de una cuenta en el banco destinada a la inversión en la bolsa, designa un capital de inversión. El módulo de selección de portafolio (Fase 2) ejecuta la heurística, tomando como entrada el capital de inversión, los datos de inversión (costos de transacción, oferta mínima, oferta máxima y precios) del sistema de bolsa y los precios de cierre pronosticados, y genera un portafolio de inversión (compra de acciones) o un portafolio de venta de acciones, señalando cuánto comprar o vender, de manera que maximice la rentabilidad. Seguidamente, el módulo de compra y venta (Fase 3) interactúa con el bróker para efectuar las órdenes de compra (transferir dinero de la cuenta del banco al sistema de bolsa) generando acciones a nombre del inversionista, y órdenes de venta (transfiriendo las acciones al sistema de la bolsa), generando dinero a la cuenta del inversionista en el banco. El modelo le permite al inversionista ahorrar tiempo y esfuerzo en el análisis, la revisión de precios, la selección del portafolio, la comunicación con el bróker, entre otros trámites.

La descripción de los actores que intervienen en AIM se presenta en la Tabla 6.

Tabla 6. Actores en AIM

Actor	Descripción
Inversionista	Propietario de la cuenta del banco para invertir, destina el capital de inversión y es quien autoriza al Broker para que haga las transacciones de compra y venta de acciones en el Banco y en el Sistema de Bolsa, y recibe los réditos de las mismas
Banco	Actualiza la cuenta del inversionista, ejecuta las transacciones del Broker, que pueden ser transferencia de dinero al Sistema de Bolsa para comprar acciones o recibe dinero del Sistema de Bolsa por la venta de acciones

Broker	Representante legal-financiero del Inversionista ante el Sistema de Bolsa, realiza las órdenes de compra o venta a través del Sistema de Bolsa y el Banco, e informa al Inversionista de las transacciones realizadas
Sistema de Bolsa	Sistema informático oficial de la Bolsa de Valores, a través del cual se realiza la compra o venta de acciones, además, proporciona data histórica sobre las acciones que sirven al predictor de precios y datos de inversión para la selección del portafolio

Fuente. Autor

A continuación, se detalla cada fase del modelo.

3.1. FASE P1: PREDICTOR DE PRECIOS

Esta tiene por finalidad estimar los precios de las acciones de cierre antes del inicio de la jornada (precio futuro), para este fin, se recomienda usar modelos de machine learning, algunos usados en predicción de precios son Deep Neural Network (DNN) (Chong, et. al, 2017), SVM (Chen & Hao, 2017), Support Vector Regression (SVR) (Henrique, et. al, 2018); sin embargo, también existen modelos predictivos no aplicados a la bolsa que presentan buenos resultados para problemas de predicción, como Decisión Tree (DT), Bayesian Network (BN), Gradient Boosting (GB), Random Forest (RF), y los híbridos que se puedan obtener como combinación de ellos. Para la predicción, los modelos previamente deben entrenarse y validarse, todo ello con data histórica de precios, volúmenes de transacción, entre otras, que se obtienen del sistema de bolsa.

Figura 5. Proceso para construir el predictor de precios



Fuente. Autor

El proceso para obtener el modelo de machine learning, para predecir el precio de cierre antes del inicio de la jornada (ver Figura 5), inicia con la extracción de datos históricos sobre las acciones (precios de inicio, de cierre, mínimos, máximo, volúmenes de transacción, entre otros), luego se realiza un pre-procesamiento de los datos (eliminar registros de días no bursátil, completar datos faltantes, normalizar datos, entre otros). Seguidamente, se realiza un entrenamiento, validación y testing con diversos modelos de machine learning y parámetros (calibración) para obtener un modelo predictivo que se utilizará para realizar los pronósticos de los precios.

3.2. FASE P2: SELECCIÓN DE PORTAFOLIO

En esta fase, se resuelve el problema de selección de portafolio de inversión (PSP-compra), y el problema de selección de portafolio de venta (PSP-venta).

Definición 1. (PSP-compra) Dado un conjunto de n empresas E_1, E_2, \dots, E_n , que cotizan en el Sistema de Bolsa de Valores, con datos para cada empresa E_i ($i = 1, \dots, n$): \underline{Q}_i oferta mínima de sus acciones, \overline{Q}_i oferta máxima de sus acciones, p_i precio de la acción al inicio de la jornada bursátil, q_i precio de la acción al cierre de la jornada bursátil, p_i^f precio pronosticado de la acción al cierre de la jornada, c costo (tasa) de la transacción, PSP-Compra consiste en determinar cuántas acciones comprar de cada empresa al inicio de la jornada bursátil, de tal manera que se consiga la mayor rentabilidad, para un capital de inversión b .

Observe que PSP-compra es una simplificación del problema POI que contempla los precios de las acciones en cada instante de tiempo durante la jornada bursátil, pues solo se ha

considerado los precios de las acciones al inicio y al cierre de la jornada bursátil, este último solo se conoce al cierre de la jornada.

Sea x_i la cantidad de acciones a comprar de la empresa E_i ($i = 1, \dots, n$) en la apertura de la jornada bursátil, entonces PSP-compra se puede formular como sigue:

$$\text{Maximize} \quad \sum_{i=1}^n \left(\frac{p_i^f - p_i}{p_i} \right) x_i \quad (1)$$

$$\text{subject to} \quad \underline{O}_i \leq x_i \leq \bar{O}_i \quad i = 1, \dots, n \quad (2)$$

$$\sum_{i=1}^n p_i x_i (1 + c) \leq b, \quad i = 1, \dots, n \quad (3)$$

$$x_i \in \mathbb{N}_0 \quad (4)$$

Observe las ecuaciones del modelo arriba: (1) es la rentabilidad total estimada de las acciones adquiridas, (2) es la restricción de las cantidades de acciones a comprar para cada empresa, (3) es la restricción de capital de inversión, es decir, la inversión total no puede superar a b , (4) es la restricción de integridad de la variable de decisión. Observe también que PSP-Compra es una extensión del problema de Integer Knapsack Problem (ver Salkin & De Kluyver, 1975), al cual se le agregó un límite inferior y superior a la variable de decisión (2), y es un problema muy estudiado.

El problema PSP-venta corresponde a la pregunta ¿al final de la jornada bursátil, cuántas acciones de las que se dispone se debe vender de cada empresa de forma que se genere la máxima utilidad o rentabilidad posible?, este problema es similar a PSP-compra, por lo que no se ahondará su estudio.

Para cada empresa, se puede presentar uno de cuatro escenarios excluyentes para la compra y venta de acciones (ver Figura 6):

- I) El precio de apertura es mayor que el precio estimado de cierre, y, al final de la jornada, es menor que el precio de cierre.
- II) El precio de apertura es mayor que el precio estimado de cierre, y, al final de la jornada, es mayor que el precio de cierre.
- III) El precio de apertura es menor que el precio estimado de cierre, y, al final de la jornada, es menor que el precio de cierre.

IV) El precio de apertura es menor que el precio estimado de cierre, y, al final de la jornada, es mayor que el precio de cierre.

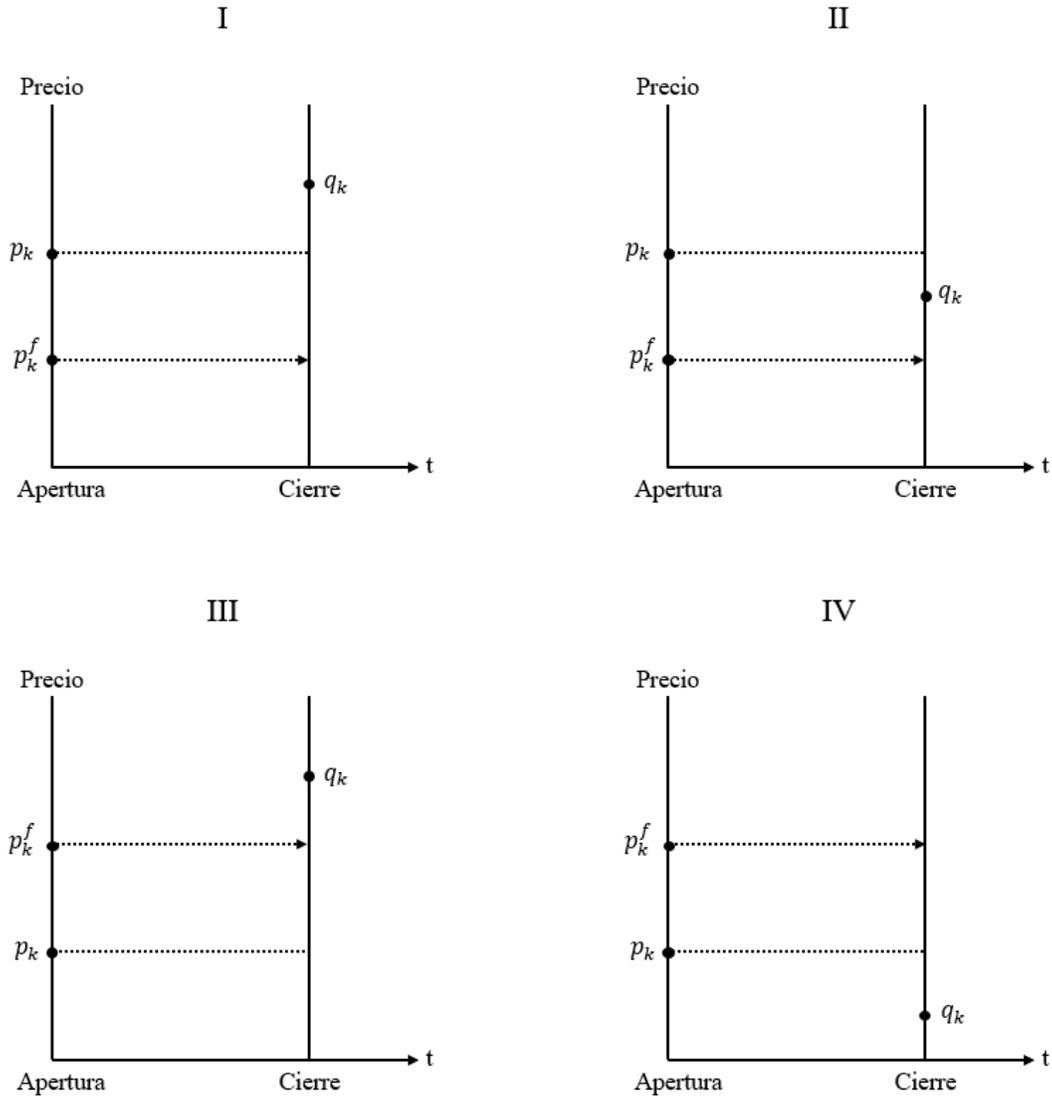
Si se asume que se desea tener ganancias diariamente y que se va a invertir todo el capital de inversión, es decir, si solo se tiene la alternativa comprar al inicio y vender al final, en esta condición, las mejores decisiones para los cuatro escenarios es como sigue:

- En los escenarios I y II (precio de apertura es mayor que el precio estimado de cierre), es adecuado no comprar acciones al inicio, pues se estima que, al cierre, el precio va a caer, una acción contraria podría generar pérdidas. En caso de que el precio de apertura sea menor que el precio de cierre (I), se hubiera dejado de ganar y esto se debe a la equivocada decisión de no comprar acciones al inicio, generada por el error en la estimación del precio cierre y que, en general, presenta baja probabilidad de ocurrencia debido a las bajas tasas de error; en caso contrario (II), conviene no comprar acciones al inicio, porque las acciones cayeron de precio al cierre, una compra solo generaría pérdidas. *En conclusión, en los escenarios I y II, es adecuado no comprar acciones y, por consiguiente, no habrá venta de acciones al cierre.*
- En los escenarios III y IV (precio de apertura es menor que el precio estimado de cierre), es adecuado comprar al inicio pensando en vender al cierre, lo que podría generar ganancias. En caso de que al cierre de la jornada el precio de apertura sea menor que el precio de cierre (III), conviene vender todas las acciones disponibles, pues se genera ganancia; en caso contrario (IV), la venta de acciones generará pérdida, y esto se debe a la equivocada decisión de comprar acciones al inicio, generada por el error en la estimación del precio cierre, lo cual presenta baja probabilidad de ocurrencia debido a las bajas tasas de error. *En conclusión, en los escenarios III y IV, es adecuado comprar acciones al inicio y venderlas todas al cierre.*

Obsérvese que la decisión sugerida para los escenarios I y II no genera ganancia ni pérdidas, y, en el peor de los casos, solo se dejaría de ganar (I) y con baja probabilidad de ocurrencia. Entretanto, la decisión sugerida para el escenario III genera ganancias, y para el escenario IV pérdidas, pero con baja probabilidad de ocurrencia. Los errores en la toma de decisiones y su

probabilidad de ocurrencia dependen de la estimación del precio de cierre, si este fuera estimado con error nulo, las decisiones sugeridas serían las óptimas.

Figura 6. Escenarios sobre los precios de apertura, cierre y estimado de cierre



Fuente. Autor

Los procesos de compra y venta de acciones se denominan, respectivamente, *ComprarAcciones* y *VenderAcciones*, se explican a seguir:

El proceso *VenderAcciones* para una empresa E_k , del cual se tiene s_k acciones, se realiza al cierre de la jornada bursátil, este consiste en vender todas las acciones posibles de dicha

empresa, es decir, s_k , y actualizar el capital del inversor por la venta realizada, pagando el impuesto respectivo, como se formula en las ecuaciones (5)-(6):

$$b := b + q_k(1 - c)s_k \quad (5)$$

$$s_k := 0 \quad (6)$$

El proceso *ComprarAcciones*, para una empresa E_k , se realiza al inicio de la jornada bursátil, consiste en comprar todas las acciones posibles de acuerdo al capital disponible y a la oferta mínima y máxima de acciones de dicha empresa, esto porque es la empresa más rentable (criterio greedy), y, seguidamente, en actualizar el stock de acciones y el capital por la compra, pagando el impuesto respectivo, como se formula en las ecuaciones (7)-(11):

$$x_k := \left\lfloor \frac{b}{p_k(1+c)} \right\rfloor \quad (7)$$

$$\text{If } (x_k > \bar{O}_k) \Rightarrow x_k := \bar{O}_k \quad (8)$$

$$\text{If } (x_k < \underline{O}_k) \Rightarrow x_k := 0 \quad (9)$$

$$b := b - p_k(1 + c)x_k \quad (10)$$

$$s_k := x_k \quad (11)$$

Se propone un algoritmo greedy y un algoritmo GRASP (greedy randomized adaptive search procedure) (Feo & Resende, 1995) para la inversión en la bolsa de valores, el primero por su simplicidad y eficiencia, y el segundo por su robustez. Las propuestas consideran los escenarios, las decisiones sugeridas y los procesos *ComprarAcciones* y *VenderAcciones* al inicio y cierre de la jornada, respectivamente. El primer algoritmo G2I (greedy to investment) usa el criterio greedy para la selección de la empresa a invertir (paso 2: empresa más rentable).

Algoritmo G2I

```
/* Inicio de jornada
1. Input( $n, c, b, \Delta, \underline{Q}_i, \overline{O}_i, p_i, p_i^f, (i := 1, \dots, n)$ );
2. Let  $I := \{1, 2, \dots, n\}$  such that  $\frac{p_i^f(1-\Delta)-p_i(1+c)}{p_i(1+c)} \geq \frac{p_{i+1}^f(1-\Delta)-p_{i+1}(1+c)}{p_{i+1}(1+c)} \quad \forall i \in I$ 
3. For  $k := 1, n$ 
4.   If  $(p_k(1+c) < (1-\Delta)p_k^f)$  Then ComprarAcciones;
5. end-for;

/* Cierre de jornada
6. Input( $n, b, q_i, s_i (i := 1, \dots, n)$ );
7. For  $k := 1, n$ 
8.   If  $(s_i > 0)$  Then VenderAcciones;
9. end-for;

10. Output( $b, x_i, y_i, s_i (i := 1, \dots, n)$ );
```

Observe que se ha considerado una holgura Δ sobre p_k^f en el escenario de comprar acciones (step 4) con el fin de evitar la posible pérdida ocasionada por el error en la estimación del precio de cierre, además, se ha considerado el costo de las transacciones en los precios. Observe también que G2I tiene complejidad computacional $O(n \log_2(n))$, característica adecuada para este problema, en donde la variación de precios y las transacciones ocurren de forma muy rápida. Una alternativa para no tener pérdidas al cierre de la jornada por la venta acciones cuando su precio de cierre es mayor que el precio adquirido (al inicio de la jornada) es no vender las acciones y tomar las decisiones al día siguiente, sin embargo, nada garantiza que esto sea favorable al día siguiente.

El segundo algoritmo que se propone, que se denota por R2I, relaja el criterio greedy de selección de empresas del algoritmo G2I por una lista de empresas candidatas considerando un parámetro de relajación $\alpha \in [0, 1]$ (step 6) del cual se extrae una aleatoriamente (steps 7). Obsérvese que los valores de α próximo a 0 hace que el criterio GRASP se aproxime al criterio greedy, y valores próximos a 1, que se aproxime a un criterio totalmente aleatorio; por ello, este parámetro deberá ser calibrado de forma que proporcione mejores resultados.

Algoritmo R2I

```
/* Inicio de jornada
1. Input( $n, c, b, \Delta, Q_i, \bar{O}_i, p_i, p_i^f, s_i$  ( $i := 1, \dots, n$ ));
2.  $I := \{1, 2, \dots, n\}$ ;
3. While ( $I \neq \emptyset$ )
4.      $\bar{r} := \text{Max}_{i \in I} \left\{ r_i = \frac{p_i^f(1-\Delta) - p_i(1+c)}{p_i(1+c)} \right\}$ ;
5.      $\underline{r} := \text{Min}_{i \in I} \left\{ r_i = \frac{p_i^f(1-\Delta) - p_i(1+c)}{p_i(1+c)} \right\}$ ;
6.      $RCL := \{i \in I : \bar{r} - \alpha(\bar{r} - \underline{r}) \leq r_i \leq \bar{r}\}$ ;
7.      $k = \text{Random}(RCL)$ ;
8.     If ( $p_k(1+c) < (1-\Delta)p_k^f$ ) Then ComprarAcciones;
9.      $I := I - \{k\}$ ;
10. end-while;

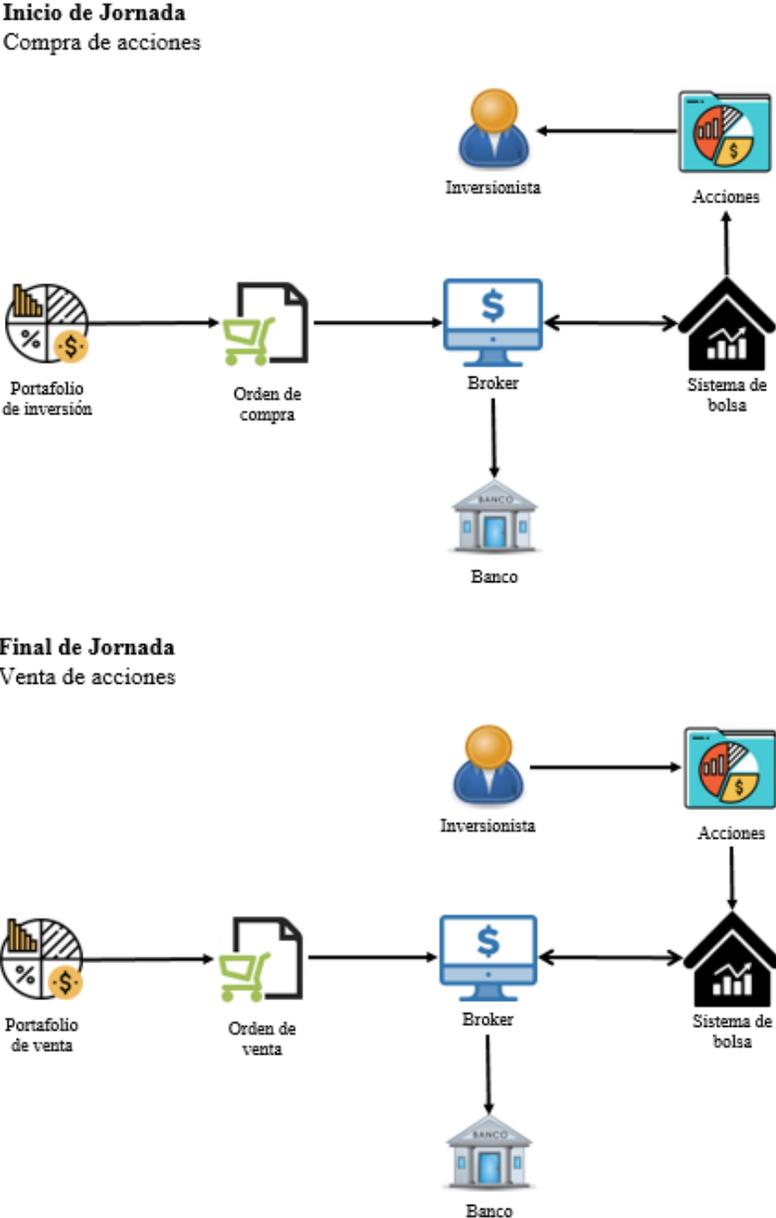
/* Cierre de jornada
11. Input( $n, b, q_i, s_i$  ( $i := 1, \dots, n$ ));
12. For ( $k := 1, n$ )
13.     If ( $s_i > 0$ ) Then VenderAcciones;
14. end-for;
15. Output( $b, x_i, y_i, s_i$ , ( $i := 1, \dots, n$ ));
```

3.3 FASE P3: PROCESO DE COMPRA-VENTA

Este proceso se realiza en dos momentos: al inicio y al final de la jornada bursátil. Al inicio, se recibe el portafolio de inversión (lista de empresas a invertir y la cantidad de acciones a comprar de cada una de ellas) resultante de la fase anterior (Fase 2: Selección de portafolio), seguidamente, se generan las órdenes de compra y estas se envían al bróker para que este ejecute dichas órdenes (previamente debe haber un contrato de servicio entre el inversor que usa el modelo y el bróker, además, una cuenta bancaria del inversionista con capital y con autorización para que el bróker pueda realizar transacciones). El bróker ejecuta las órdenes de compra haciendo uso del capital de la cuenta bancaria del inversor, con lo cual se realiza la transacción bancaria pagando las acciones adquiridas a nombre del inversor, que, a su vez, se registran en el sistema de bolsa. Al final de la jornada, se recibe el portafolio de venta (lista y cantidad de acciones a vender) generado por el algoritmo (Fase 2: Selección de portafolio), a continuación, se generan las órdenes de venta y estas se envían al bróker para que este ejecute dichas órdenes. El bróker ejecuta las órdenes de venta ante el sistema de bolsa

haciendo uso de las acciones y la cuenta bancaria del inversor, con lo cual se resta las acciones vendidas que, a su vez, se registra en el sistema de bolsa, y deposita en la cuenta del inversionista el dinero obtenido por la venta, previo pago de impuestos y servicios. Este proceso se puede visualizar en la Figura 7.

Figura 7. Proceso de compra-venta de acciones



Fuente. Autor

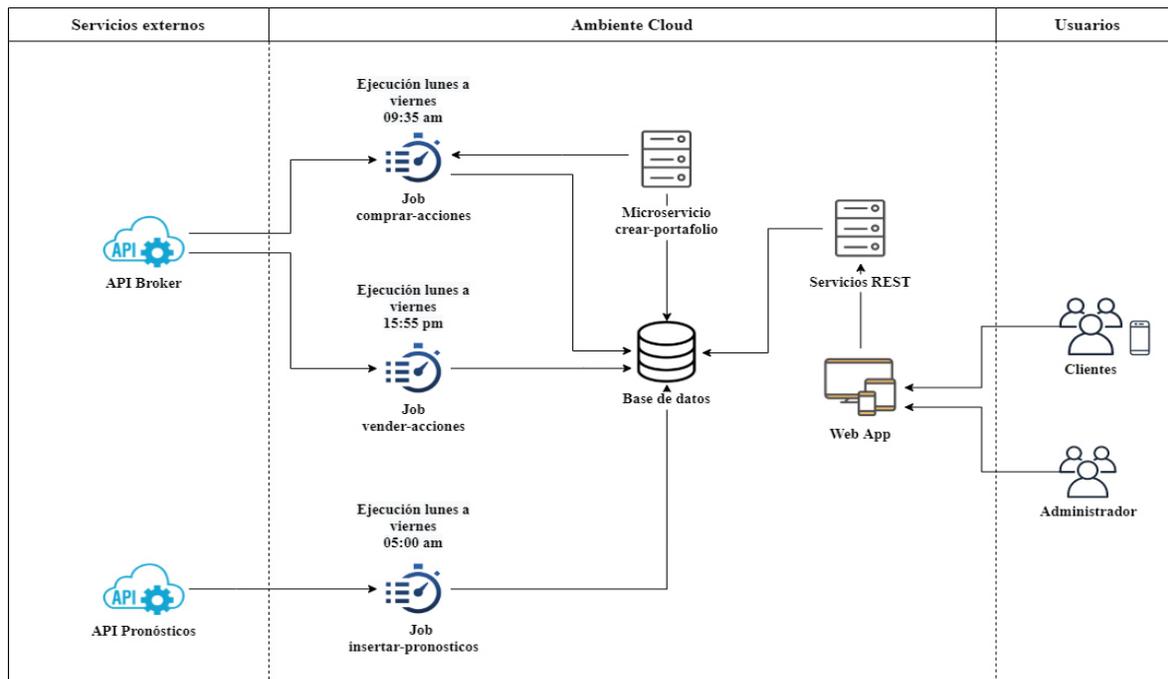
CAPÍTULO V: AIS: SISTEMA DE INVERSIÓN AUTOMÁTICA

En este capítulo, se presenta AIS, un sistema de inversión automática en la bolsa de valores que implementa el modelo propuesto AISM. Se detalla la arquitectura propuesta para integrar los precios pronosticados, resultado de un modelo predictivo, un servicio de selección de portafolio y la comunicación con una API de bróker, para llevar a cabo las transacciones de compra o venta.

5.1. ARQUITECTURA

En las figuras 8 y 9, se muestran las vistas física y tecnológica, respectivamente, de la arquitectura de AIS. En la vista física, se muestran los componentes en un alto nivel, mientras que en la vista tecnológica se muestran las herramientas y tecnologías utilizadas para cada componente, desplegados en un ambiente de Amazon Web Services.

Figura 8. Vista física de la arquitectura de AIS



Fuente. Autor

Los componentes necesarios para la implementación de SAI, con el fin de integrar la selección de portafolio con los precios pronosticados y, en última instancia, con un bróker de inversión para colocar órdenes de compra y venta, son los siguientes: una web app responsiva de acceso para los usuarios administradores e inversionistas, un conjunto de servicios para gestionar la información del sistema, una base de datos relacional que centralice toda la información que se genere a través de la utilización del sistema, un microservicio especialmente construido para generación de portafolios de inversión para cada usuario, un job que almacene en la base de datos del sistema los precios pronosticados obtenidos de una fuente externa, un job que coloque las órdenes de compra en el mercado de valores y uno que venda las acciones que se compraron al inicio de la jornada. En la Tabla 7, se profundiza en cada componente de la arquitectura, resaltando cuál es su aporte dentro del sistema y su nivel de interacción con otros componentes.

Tabla 7. Componentes de la arquitectura de SAI

Nombre	Descripción	Función
Web app	Página web responsiva para acceso a SAI	Permitir a los usuarios inversionistas y administradores acceder al sistema y mostrar opciones diferenciadas según el tipo de perfil
Base de datos	Base de datos relacional para almacenar la información generada por el sistema	Almacenar los registros de las operaciones realizadas en el sistema por los diversos usuarios
Servicios REST	Conjunto de APIs	Orquestar las acciones de creación, edición y eliminación de registros de la base de datos realizadas a partir de las opciones disponibles en la web
Microservicio crear-portafolio	Microservicio que tiene la función de generar un	Obtener los datos de los precios de las empresas desde la base de datos y, con base en ello, utilizar el algoritmo de

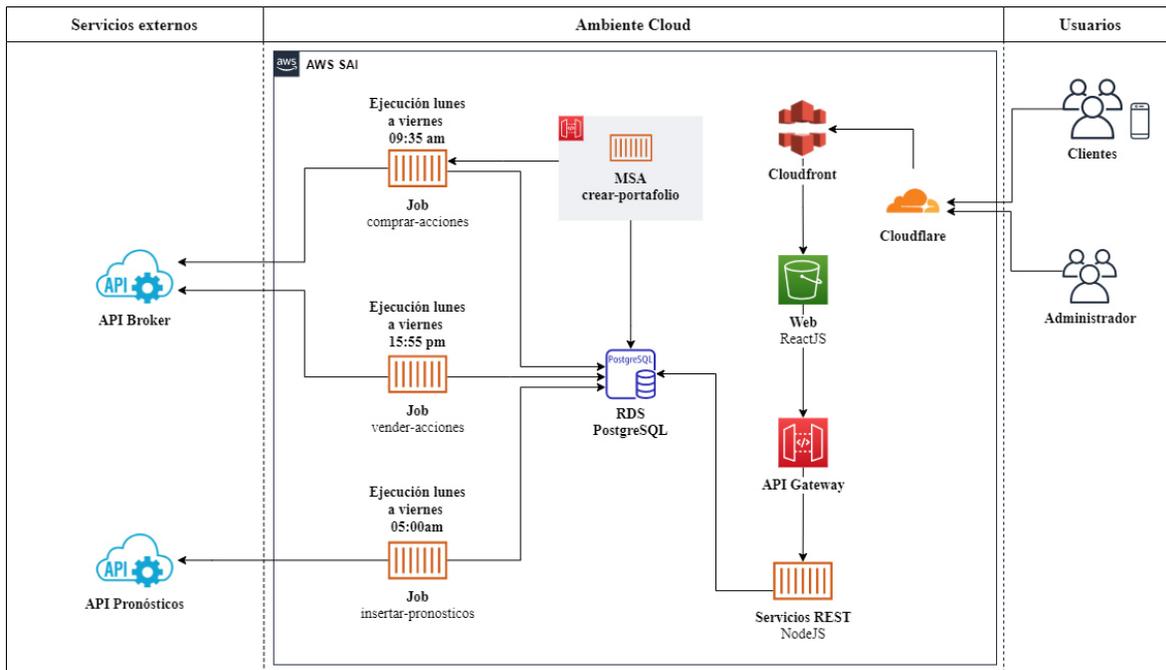
	portafolio de inversión para un usuario	selección de portafolio para generar uno para ese día
Job insertar-pronósticos	Job que se ejecuta de lunes a viernes a las 5:00 a. m. (horas antes de la apertura del mercado bursátil) para insertar los precios pronosticados en la base de datos	Obtener los precios pronosticados de cada empresa que se encuentre registrada, desde una API externa, e insertarlos en la base de datos
Job comprar-acciones	Job que se ejecuta de lunes a viernes a las 9:35 a. m. (minutos después de la apertura del mercado bursátil) para colocar las órdenes de compra en el mercado bursátil	Utilizar el microservicio crear-portafolio para obtener un portafolio de inversión y consumir una API de bróker externa para comprar la cantidad de acciones que indique el portafolio para cada empresa
Job vender-acciones	Job que se ejecuta de lunes a viernes a las 15:55 p. m. (minutos antes del cierre del mercado bursátil) para vender las acciones que tenga el usuario en ese momento	Consumir la API de bróker externa para realizar la venta de todas las acciones que posea el usuario en ese momento

Fuente. Autor

En cuanto a la implementación de los componentes en un ambiente cloud, la web app está construida usando la librería ReactJS y desplegada en un Bucket S3. El backend, los jobs *insertar-pronósticos*, *comprar-acciones* y *vender-acciones*, así como el microservicio *crear-portafolio*, están contruidos con NodeJS y desplegados en contenedores ECS, y las APIs de los servicios REST y MSA están publicadas en API Gateways de AWS. Como capa de acceso

a las aplicaciones web por parte de los usuarios, se implementa Cloudflare como reverse proxy y método de seguridad.

Figura 9. Vista tecnológica de la arquitectura de AIS

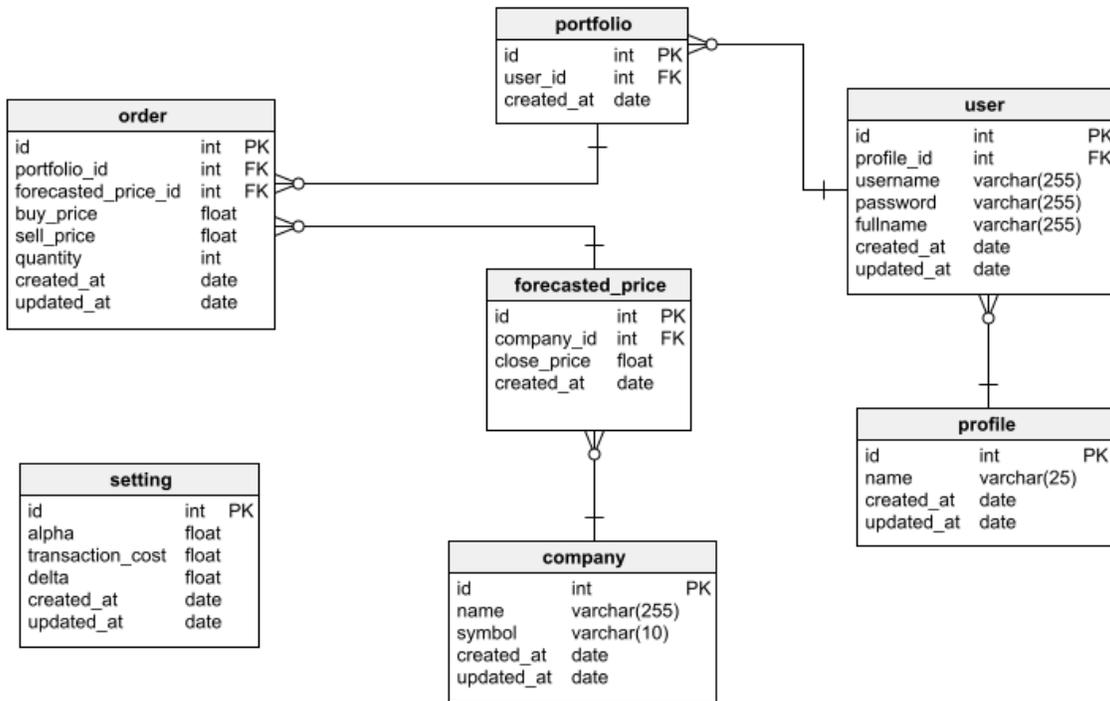


Fuente. Autor

5.2. MODELO DE DATOS

Se implementó una base de datos relacional que contempla tablas de portafolio, usuario y su perfil, empresas, precios, órdenes (de compra o venta) y parámetros de configuración, que son relevantes para la ejecución del algoritmo (ver Figura 10).

Figura 10. Modelo de datos



Fuente. Autor

5.3. DICCIONARIO DE DATOS

En esta sección, se presenta un listado organizado de los datos definiendo la información que almacenan, significado, tipo de contenido, uso y relación con otros datos, con el fin de brindar un mayor entendimiento de la base de datos.

5.3.1. Tabla *profile*

Almacena los diferentes perfiles que pueden existir en el sistema, teniendo cada registro un identificador único y un nombre de perfil, además de las fechas de creación y actualización de dicho registro (ver Tabla 8).

Tabla 8. Metadatos de la tabla *profile*

Campo	Tipo	Longitud	Descripción
id	int	-	Identificador de la tabla
name	varchar	25	Nombre del perfil
created_at	date	-	Fecha de creación del registro
updated_at	date	-	Fecha de actualización del registro

Fuente. Autor

5.3.2. Tabla *user*

Almacena la información de los usuarios registrados en el sistema, esto es, un identificador único, el nombre completo del usuario, el perfil al cual está asociado, email del usuario, una contraseña para validar su acceso en el sistema, y las fechas de creación y actualización de dicho registro (ver Tabla 9).

Tabla 9. Metadatos de la tabla *user*

Campo	Tipo	Longitud	Descripción
id	int	-	Identificador de la tabla
profile_id	int	-	Identificador del perfil
fullname	varchar	255	Nombre completo del usuario
email	varchar	255	Email del usuario
password	varchar	255	Contraseña para acceso al sistema
created_at	date	-	Fecha de creación del registro
updated_at	date	-	Fecha de actualización del registro

Fuente. Autor

5.3.3. Tabla *setting*

Almacena los valores de los parámetros relacionados a los algoritmos de selección de portafolio, esto es, el valor numérico de las variables alpha, costo de transacción y la variable de holgura delta, asimismo, la fecha en que se creó el registro y la fecha en que se actualiza alguno de los parámetros, de tal manera que el algoritmo lea estos valores al momento de su ejecución (ver Tabla 10).

Tabla 10. Metadatos de la tabla *setting*

Campo	Tipo	Longitud	Descripción
id	int	-	Identificador de la tabla
alpha	float	-	Identificador del perfil
transaction_cost	float	-	Nombre de usuario
delta	float	-	Parámetro de holgura
created_at	date	-	Fecha de creación del registro
updated_at	date	-	Fecha de actualización del registro

Fuente. Autor

5.3.4. Tabla *company*

Almacena la información de las empresas que cotizan en bolsa, con el fin de considerarlas en la selección de portafolio. Se registra el nombre y símbolo de la empresa, así como la fecha de creación y actualización del registro (ver Tabla 11).

Tabla 11. Metadatos de la tabla *company*

Campo	Tipo	Longitud	Descripción
id	int	-	Identificador de la tabla
name	varchar	255	Nombre comercial de la empresa

symbol	varchar	10	Símbolo de la empresa en la bolsa
created_at	date	-	Fecha de creación del registro
updated_at	date	-	Fecha de actualización del registro

Fuente. Autor

5.3.5. Tabla *forecasted_price*

Almacena los registros de precio de cierre pronosticado para cada empresa en un determinado día, cada registro tiene un identificador único, el identificador de la empresa, el precio de cierre pronosticado y la fecha de creación del registro (ver Tabla 12).

*Tabla 12. Metadatos de la tabla *forecasted_price**

Campo	Tipo	Longitud	Descripción
id	int	-	Identificador de la tabla
company_id	int	-	Identificador de la empresa
close_price	float	-	Precio de cierre pronosticado
created_at	date	-	Fecha de creación del registro

Fuente. Autor

5.3.6. Tabla *portfolio*

Almacena los portafolios de cada usuario, considerando que un usuario tiene diariamente un único portafolio de inversión. Cada registro tiene un identificador único de portafolio, el identificador del usuario al que pertenece y la fecha de creación (ver Tabla 13).

*Tabla 13. Metadatos de la tabla *portfolio**

Campo	Tipo	Longitud	Descripción
id	int	-	Identificador de la tabla

user_id	int	-	Identificador del usuario
created_at	date	-	Fecha de creación del registro

Fuente. Autor

5.3.7. Tabla *order*

Almacena las órdenes de compra y venta de un portafolio determinado, los campos que se registran por cada orden son los siguientes: un identificador único, el identificador del portafolio, el identificador que asocia a la tabla de precio pronosticado para una empresa, la cantidad de acciones por orden, precio de compra, precio de venta, fecha de creación y actualización del registro (ver Tabla 14).

*Tabla 14. Metadatos de la tabla *order**

Campo	Tipo	Longitud	Descripción
id	int	-	Identificador de la tabla
portfolio_id	int	-	Identificador del usuario
forecasted_price_id	int	-	Identificador del precio pronosticado para una empresa
buy_price	float	-	Precio de compra de la acción
sell_price	Float	-	Precio de venta de la acción
quantity	int	-	Cantidad de acciones compradas
created_at	date	-	Fecha de creación del registro
updated_at	date	-	Fecha de actualización del registro

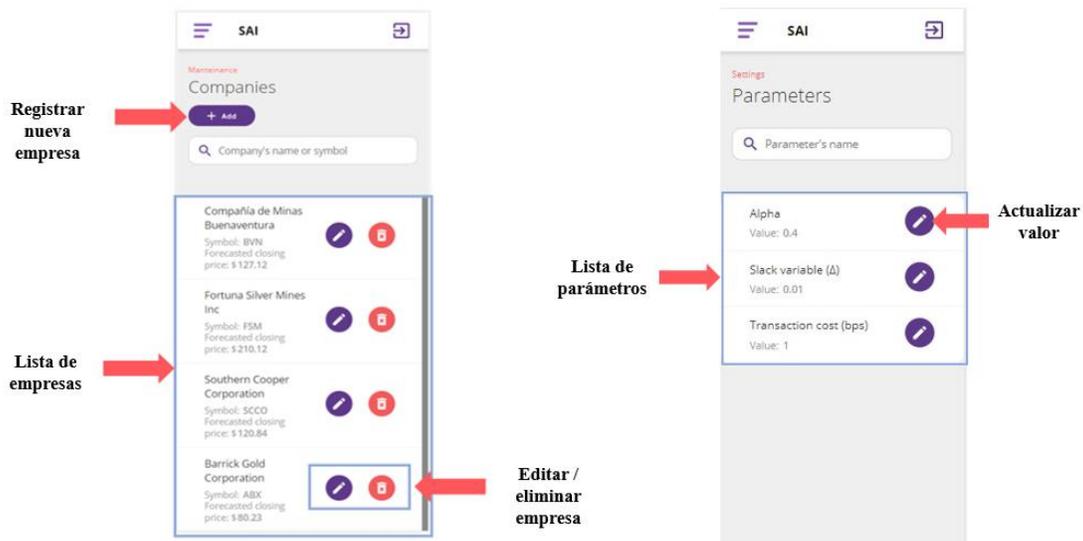
Fuente. Autor

5.4. SELECCIÓN DE PORTAFOLIO Y PERFILES

Se implementó los algoritmos G2I y R2I en lenguaje Javascript, luego de varias pruebas, se estableció por default el parámetro $\alpha=0.6$ para el algoritmo R2I.

AIS considera dos perfiles de usuario: administrador e inversionista. El administrador del sistema es responsable de seleccionar las empresas que participarán en la selección de portafolio (el inversionista podrá centrar su inversión a un sector empresarial o empresas de su interés), fijar el valor del parámetro de relajación (α), la variable de holgura (Δ) y el costo de transacción (c), esto a través de una interface fácil y simple, tal como se muestra en la Figura 11.

Figura 11. Interfaces AIS para el administrador

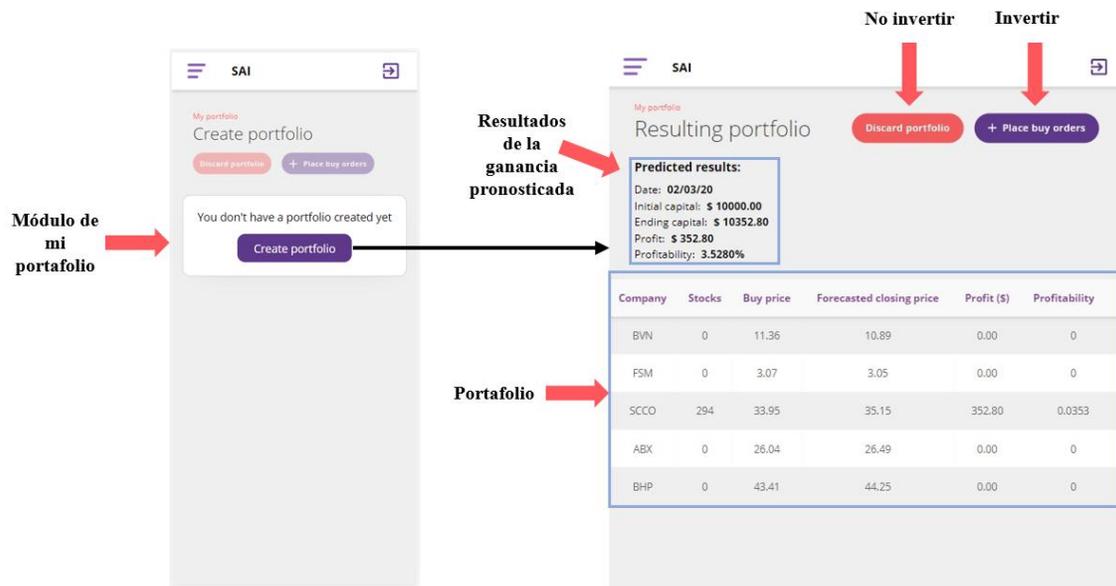


Fuente. Autor

El usuario inversionista cuenta con un módulo que le permite crear un portafolio de inversión para el día, para lo cual debe indicar cuánto dinero está dispuesto a invertir. AIS, para un capital de inversión, genera y muestra un portafolio de inversión en donde para cada empresa

se detalla lo siguiente: cantidad de acciones a comprar, precio de compra, precio de cierre pronosticado, ganancia y rentabilidad estimada para esa operación (ver Figura 12). Con toda esta información, el usuario podrá decidir si quiere invertir con ese portafolio y colocar las órdenes de compra, o no invertir. Además, al cierre de la jornada, podrá conocer la utilidad y rentabilidad obtenida.

Figura 12. Interfaces AIS para el inversionista



Fuente. Autor

CAPÍTULO VI: VALIDACIÓN DEL SISTEMA

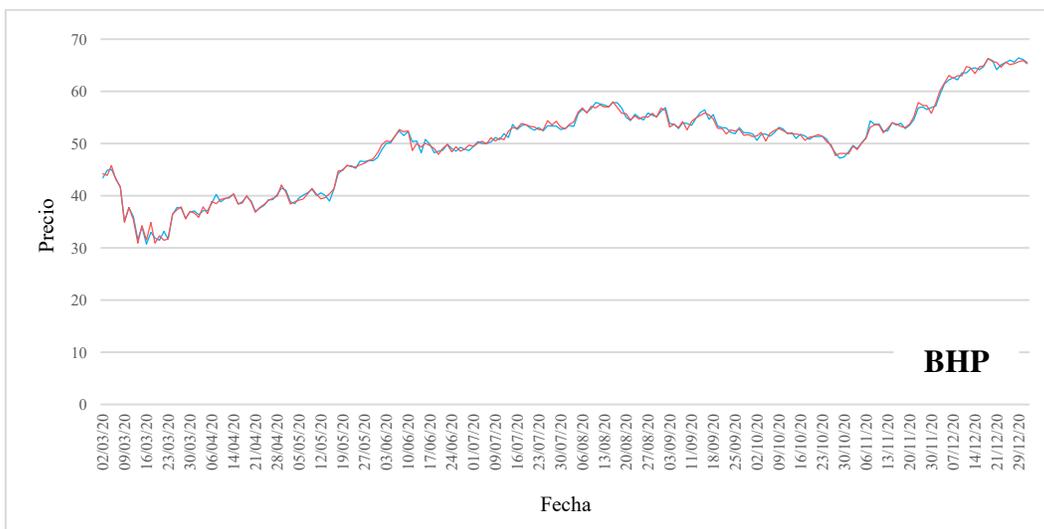
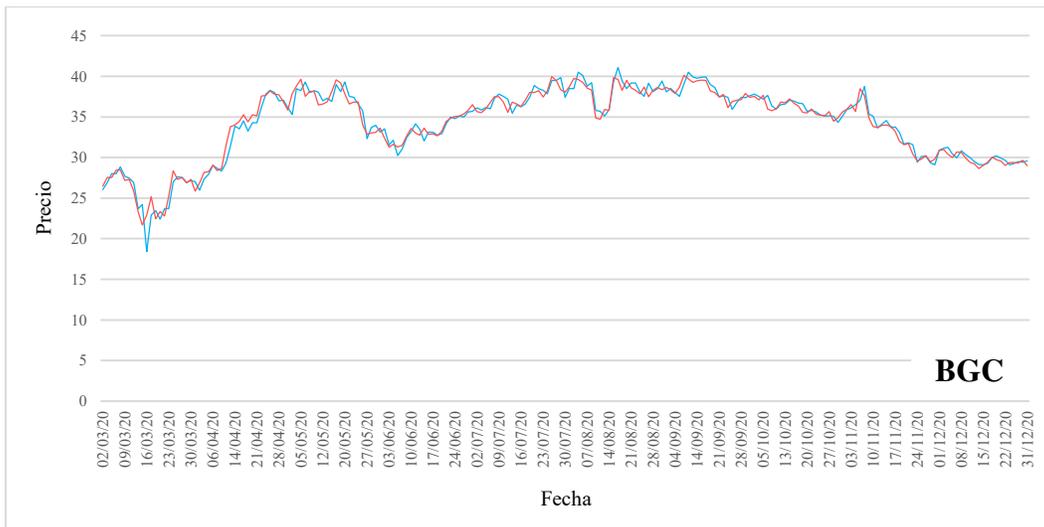
En este capítulo, se valida el sistema propuesto (SAI) con data histórica de cinco empresas mineras peruanas que cotizan en la bolsa de NYSE, analizando los resultados de los experimentos con diferentes variaciones de datasets y demostrando que, incluso en escenarios con estimaciones de precio de cierre que presentan alto nivel de error, se obtienen rentabilidades diarias y mensuales altas.

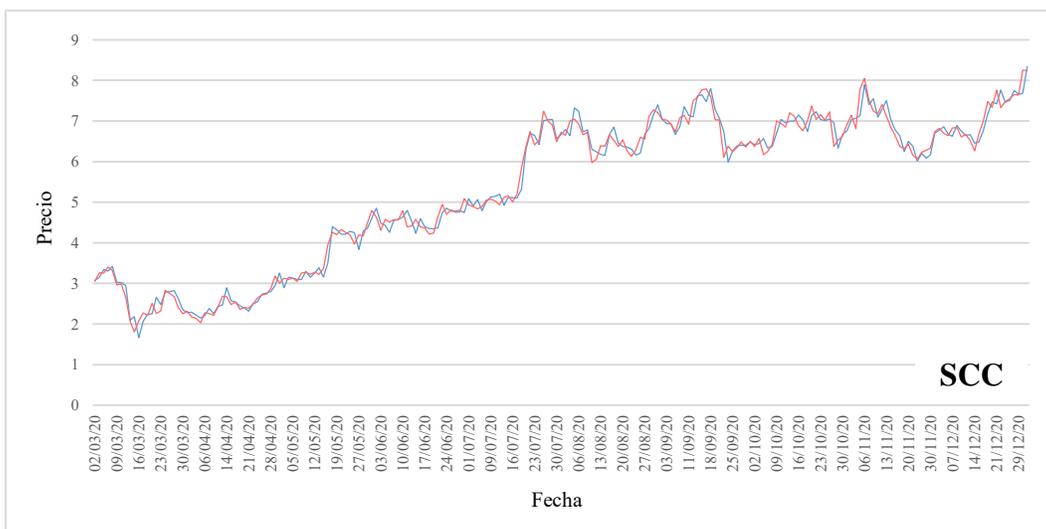
6.1. DATASETS

Para la validación de AIS, se utilizó los datos de la Bolsa de Nueva York (NYSE), que es la bolsa de valores más grande en el mundo en volumen monetario, alcanzando una capitalización de más de 25.6 trillones de dólares a febrero de 2021 (Statista.com, 2021). Se ha considerado el sector minero, y de ahí 5 grandes empresas peruanas: Barrick Gold Corporation (BGC), BHP Group (BHP), Compañía de Minas Buenaventura S.A.A. (BVN), Fortuna Silver Mines Inc. (FSM) y Southern Copper Corporation (SCC).

Los datos se extrajeron desde la plataforma Yahoo! Finance (Yahoo Finance, 2021), se exportaron los csv con la data histórica colocando los filtros de periodo entre el 02/03/2020 y el 31/12/2020, obteniendo 211 registros por empresa con los precios diarios de apertura y de cierre; además, se consideró, para cada registro, una oferta mínima de 1 acción y oferta máxima ilimitada. Seguidamente, se realizó el pre-procesamiento de los datos obteniéndose el dataset que se denota por DNYSE. El comportamiento de los precios de apertura y cierre de cada una de las empresas estudiadas son muy similares (ver Figura 13), la menor distancia entre los precios es 0 %, y la mayor es de 21.27 %, correspondiente a la empresa BVN.

Figura 13. Comportamiento del precio de apertura y cierre para 5 empresas mineras peruanas (02/02/2020–12/31/2020)





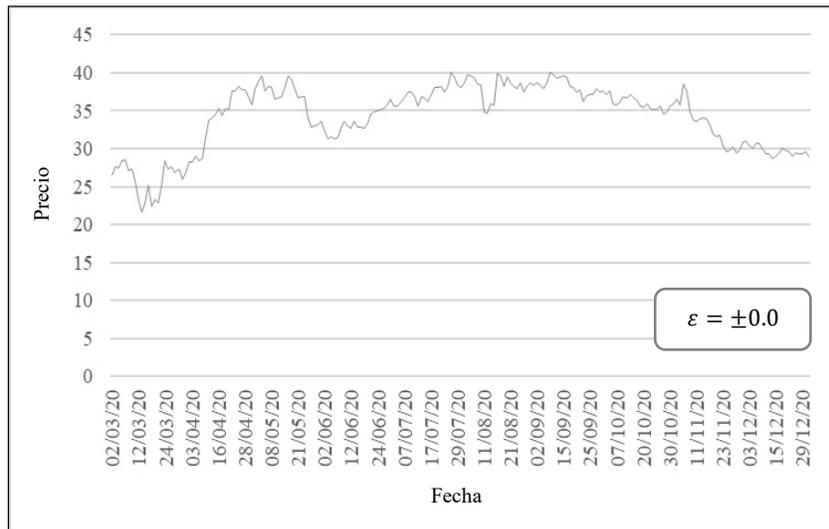
Leyenda

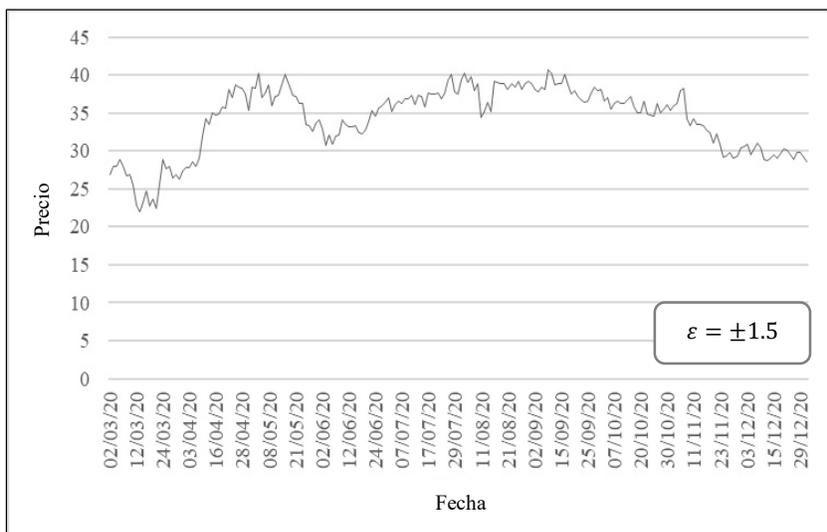
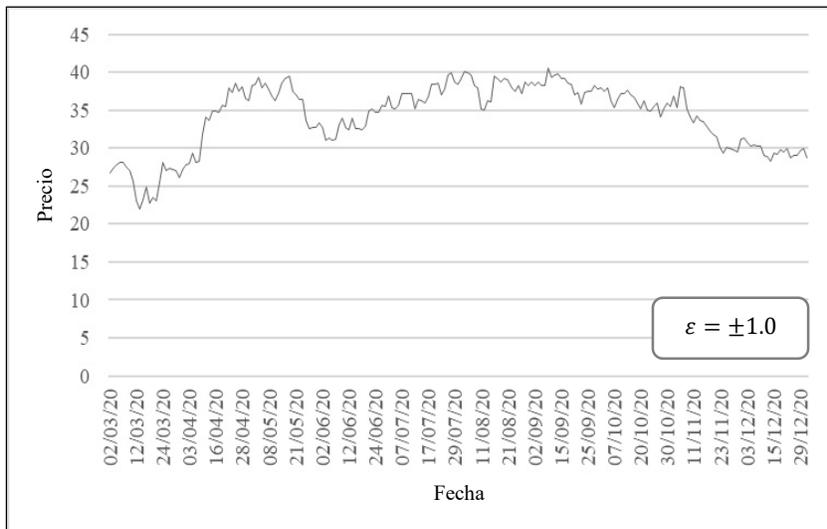
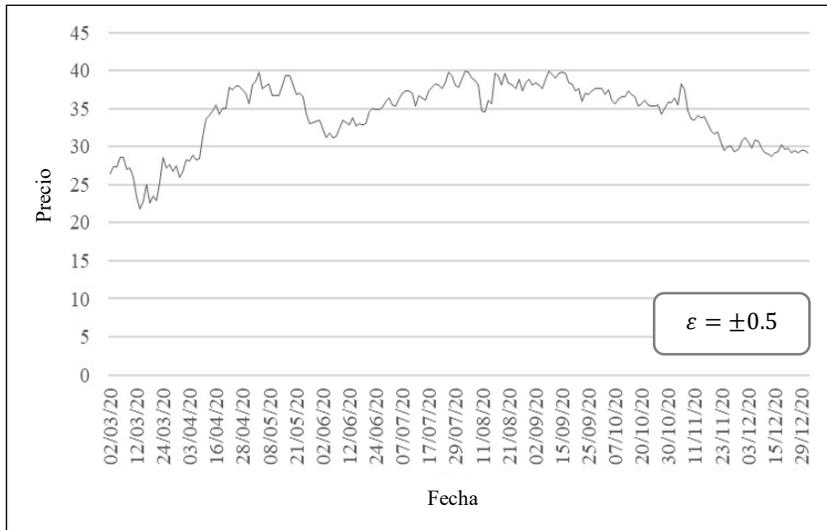
- Precio de inicio
- Precio de cierre

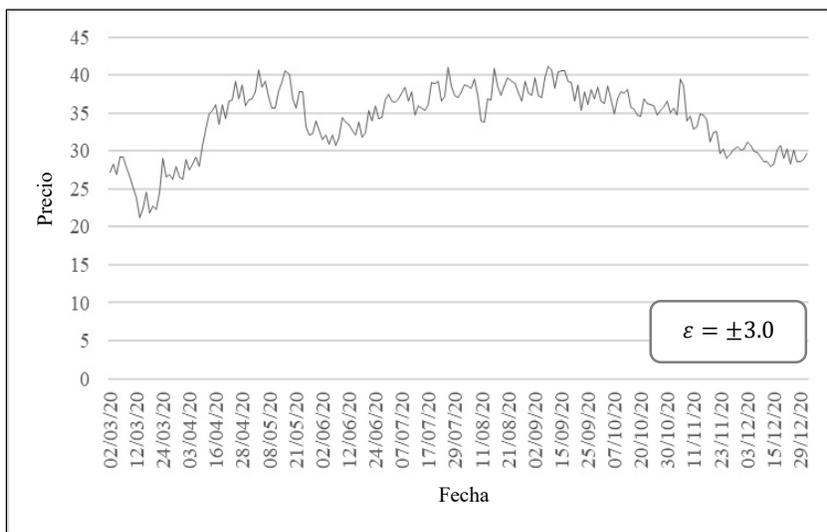
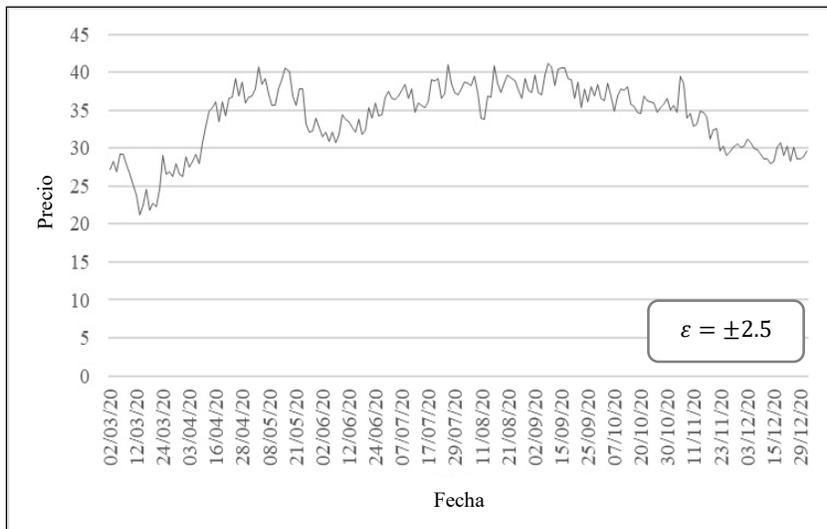
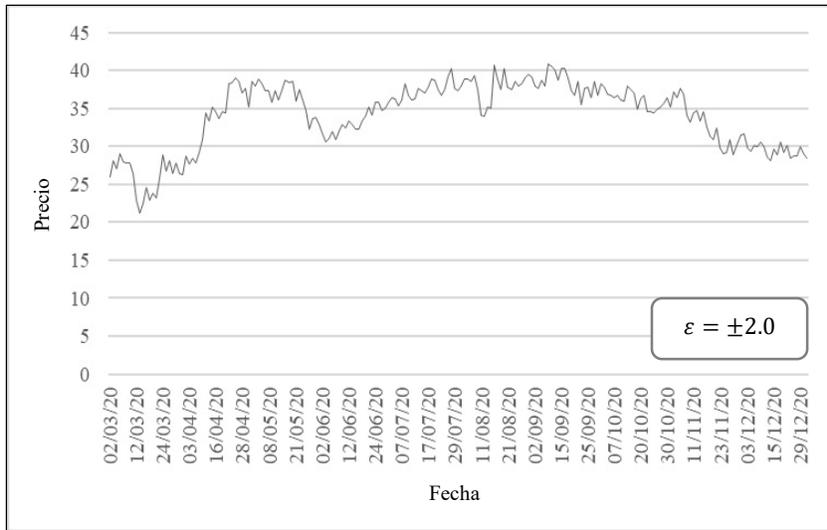
Fuente. Autor

Además, con el fin de conocer la eficiencia de los algoritmos propuestos respecto al error de la estimación del precio de cierre del día, se ha perturbado el precio real de cierre de cada una de las 5 empresas, agregándole un error sistemático (ϵ) del $\pm 0.5\%$, $\pm 1\%$, $\pm 1.5\%$, $\pm 2\%$, $\pm 2.5\%$ y $\pm 3\%$ de su precio real, generando, de esta manera, 5 datasets. La Figura 14 muestra los precios de cierre de la empresa BGC y sus precios perturbados.

Figura 14. Precio de cierre de BGC con error ϵ (%)







Fuente. Autor

6.2. EXPERIMENTO

Para conocer la eficiencia de los algoritmos G2I y R2I, esto es, la rentabilidad del sistema AIS, se realizaron los siguientes experimentos:

- i. Rentabilidad por variación del error del precio de cierre: su finalidad es conocer el comportamiento de la rentabilidad del sistema respecto al error en la estimación del precio de cierre.
- ii. Impacto de la variable de holgura (Δ): su finalidad es conocer su impacto sobre la rentabilidad cuando $\Delta = |\varepsilon|$.
- iii. Rentabilidad por capital de inversión: su finalidad es conocer la variación de la rentabilidad del sistema ante la variación del capital de inversión, para ello se ha considerado capital de 10K, 100K y 1000K USD.

Las pruebas del sistema se realizaron en una laptop con procesador core i7, RAM de 16 GB, y disco duro de 1 TB, además, se consideró el costo de transacción del 1 % de la transacción ($1\text{bps}=0.01$), y el parámetro de relajación $\alpha = 0.6$ para R2I, valor que fue obtenido mediante pruebas.

6.3. RESULTADOS

En esta sección, se detallan los resultados obtenidos para los experimentos definidos previamente, obteniendo resultados prometedores que sirven de apoyo para ajustar los parámetros de los algoritmos G2I y R2I con el fin de incrementar la rentabilidad esperada para diferentes niveles de error en la estimación.

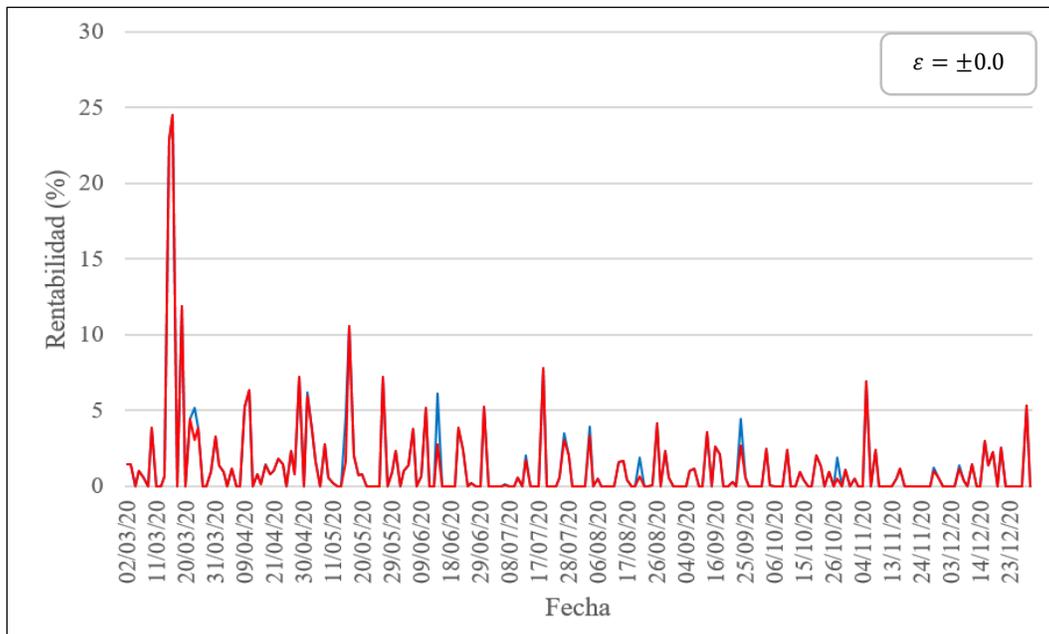
6.3.1. Rentabilidad por variación del error del precio de cierre

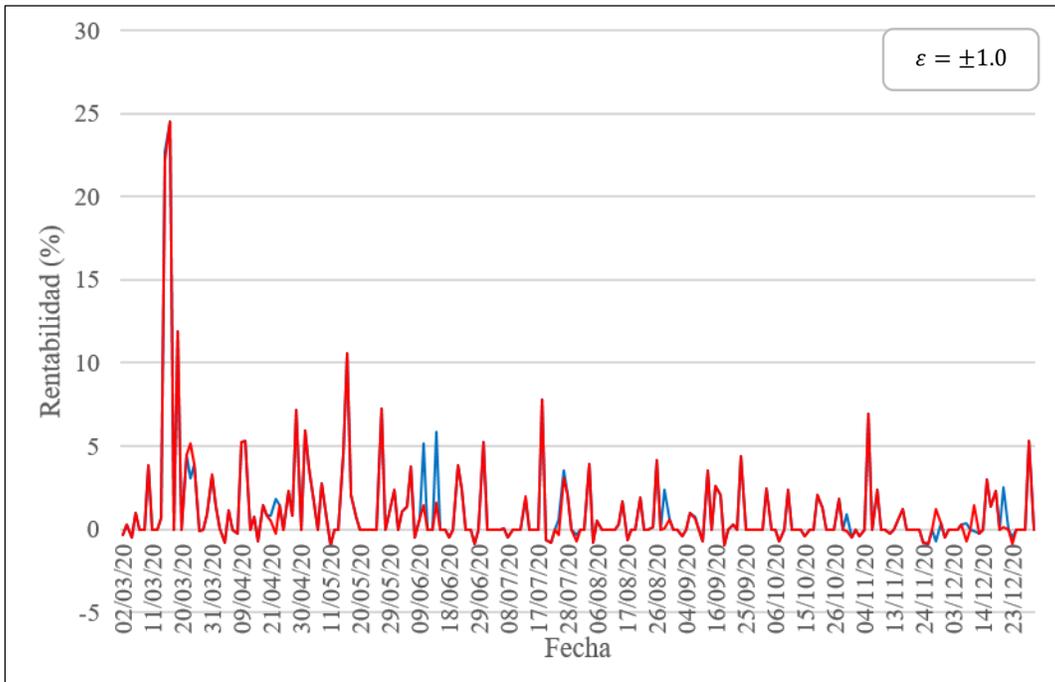
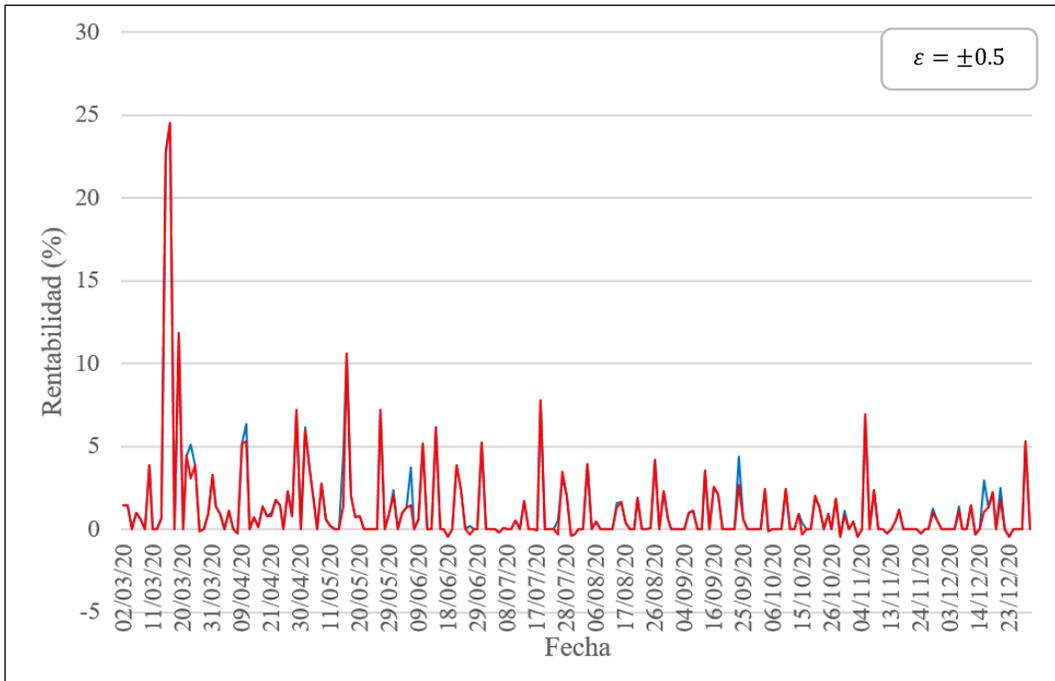
La Figura 15 muestra el comportamiento de la rentabilidad diaria obtenida por los algoritmos propuestos considerando el precio de cierre con un error sistemático de $\varepsilon =$

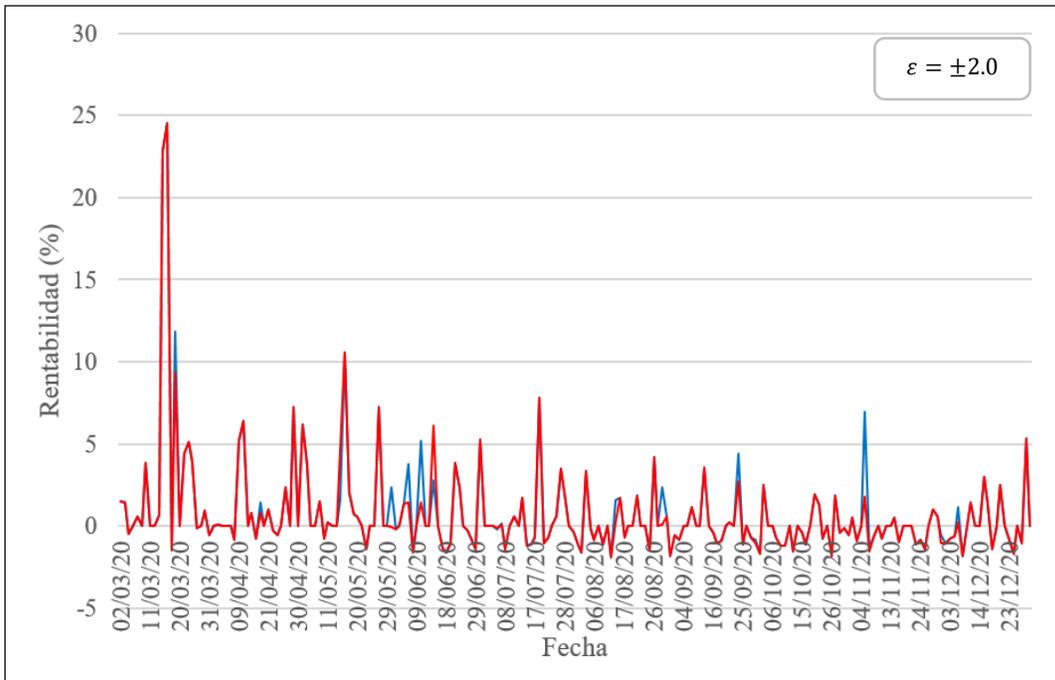
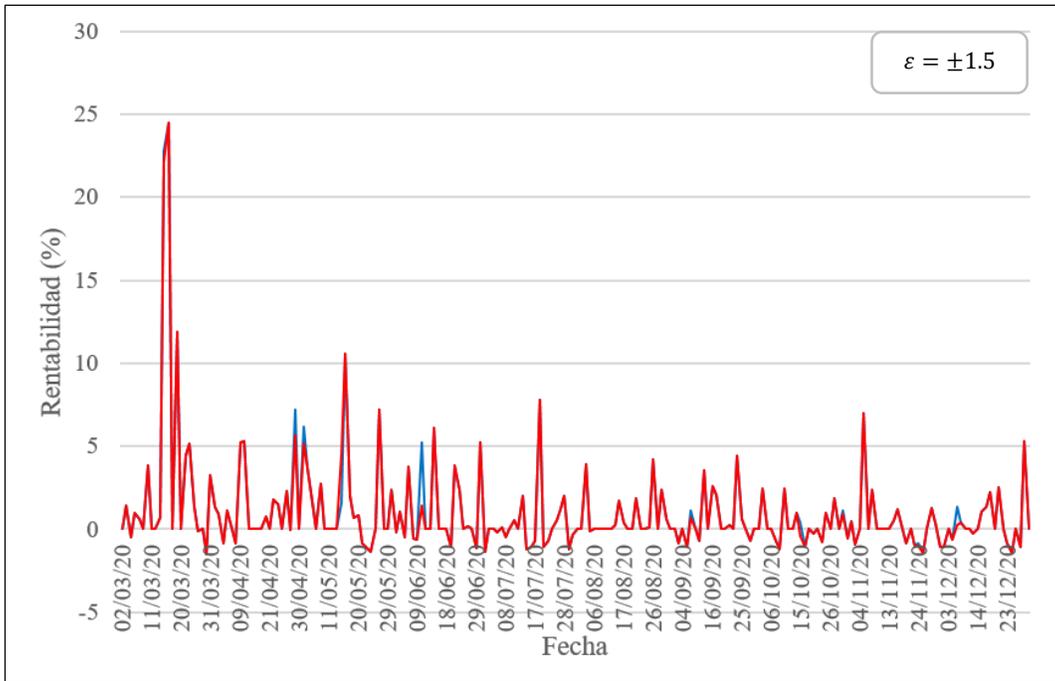
$0, \pm 0.5, \pm 1.0, \pm 1.5, \pm 2.0, \pm 2.5, \pm 3.0$ (%), $\Delta = 0$, y un capital de inversión de 10K USD, en donde se observa lo siguiente:

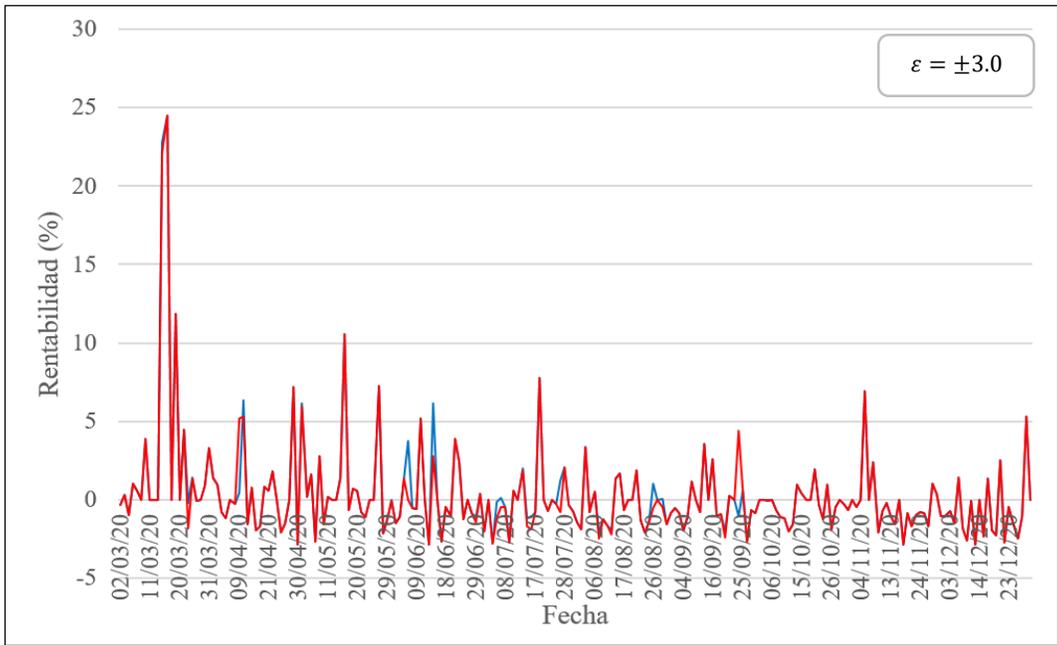
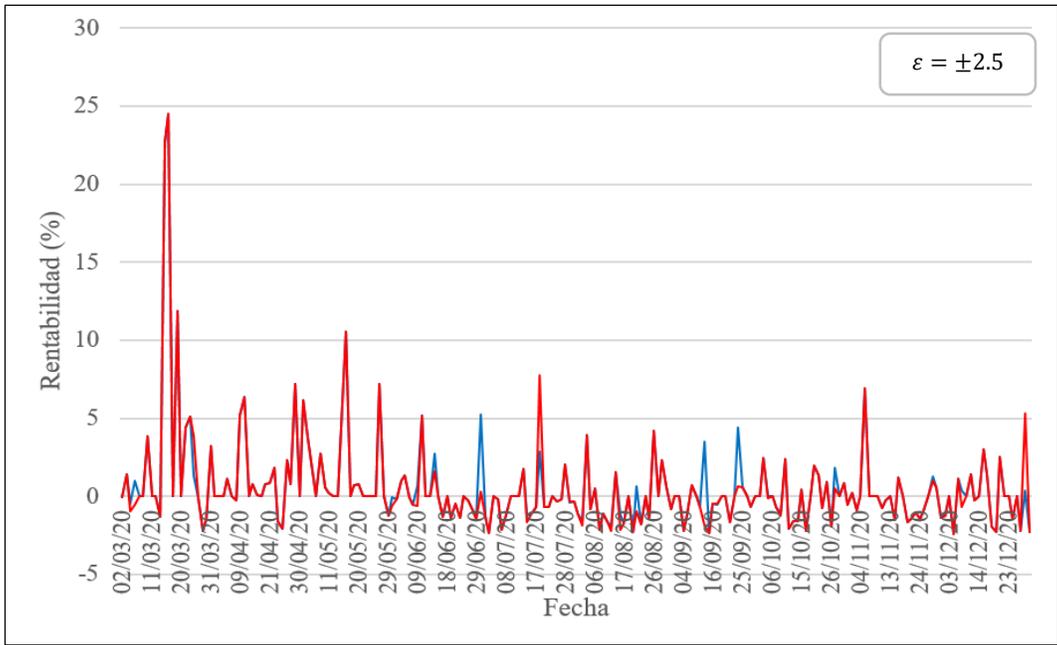
- i. La rentabilidad en los primeros días del mes de marzo del año 2020 es alta, alcanzando cerca del 25 % y, gradualmente, va cayendo para los últimos días del mes de diciembre del mismo año para cualquier cambio del error en los precios de cierre, esto se podría explicar debido a la desaceleración y contracción de la economía mundial ocasionada por la pandemia de la COVID-19.
- ii. El comportamiento de la rentabilidad es similar cuando se varía el error en la estimación del precio de cierre con más días de rentabilidad positiva que negativa, pero, a medida que aumenta el error, se incrementa las transacciones (los días) y el valor de la rentabilidad negativa.
- iii. Ambos algoritmos, G2I y R2I, presentan similares resultados de rentabilidad, pero, en general, G2I presenta mejor eficiencia que R2I, esto podría ser porque el criterio goloso de comprar y vender las acciones que generen mayor rentabilidad estimada en un día es mejor que comprar otras menos rentables, sin embargo, esto dependerá de los datos como los precios, el error, el capital de inversión, entre otros.

Figura 15. Rentabilidad diaria de AIS: capital de inversión = 10K USD, $\Delta=0$, precio de cierre con error (%) ε









Leyenda

- R2I
- G2I

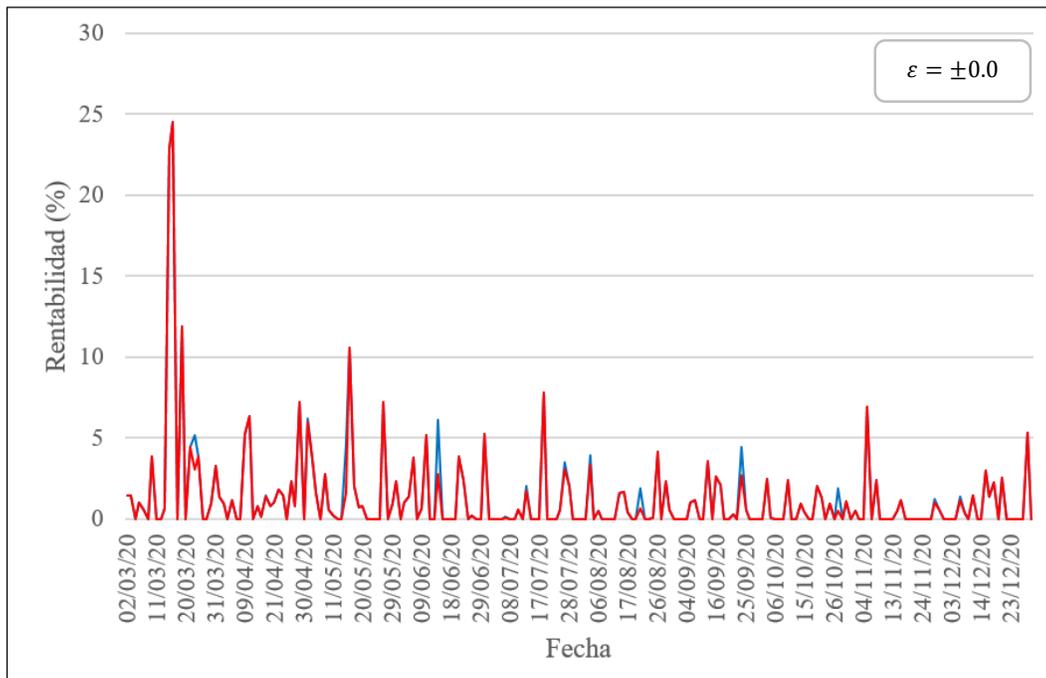
Fuente. Autor

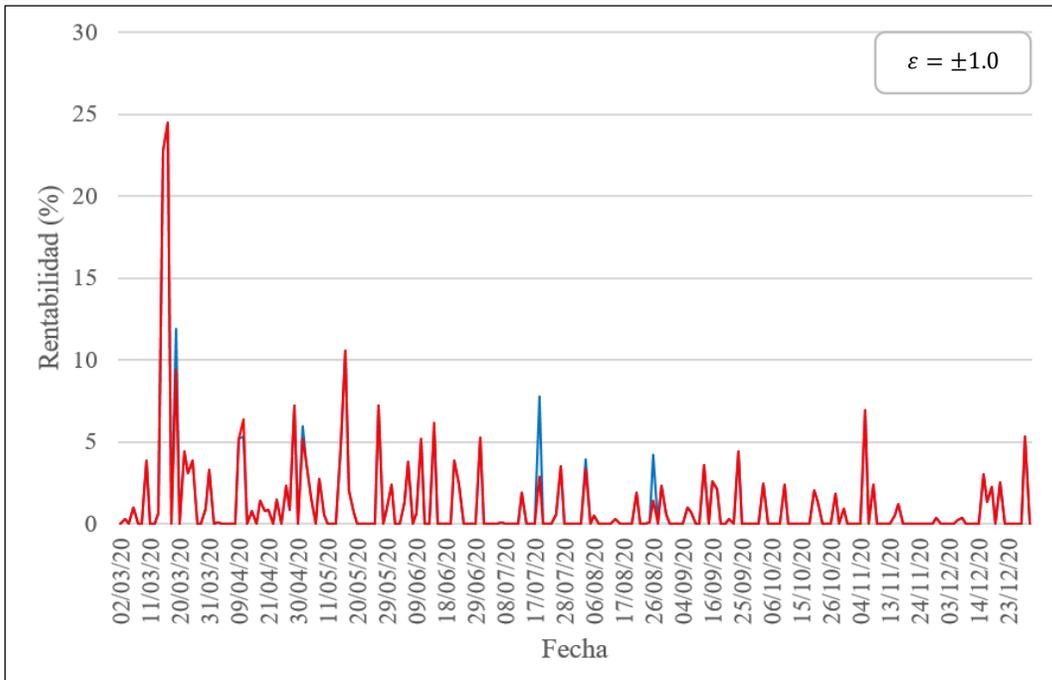
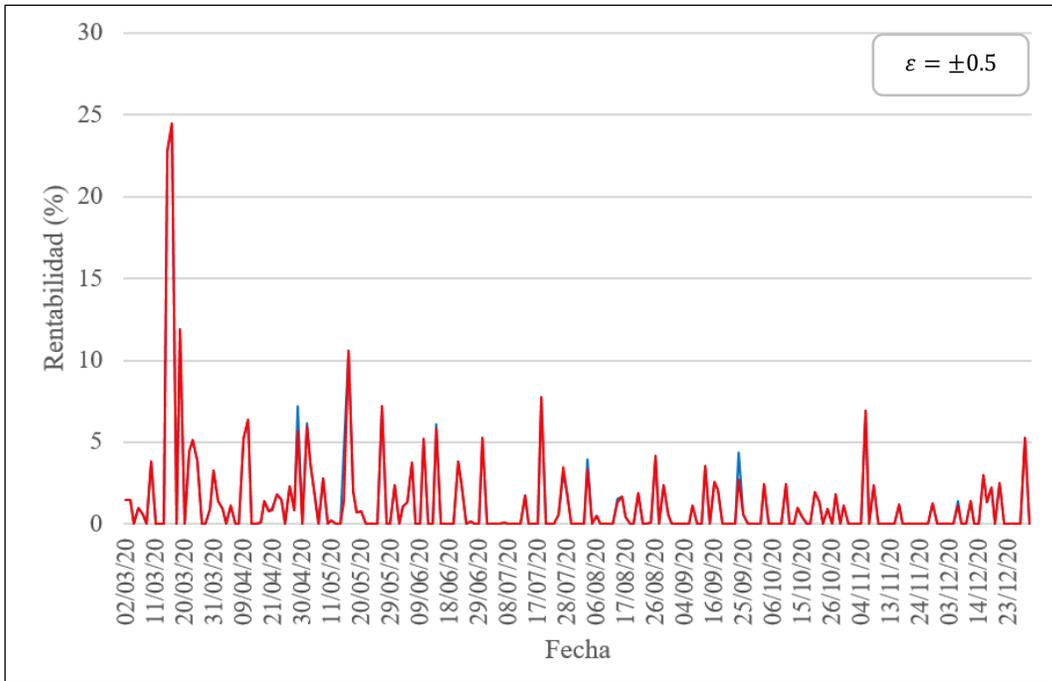
6.3.2. Impacto de la variable de holgura (Δ) en el error (ϵ)

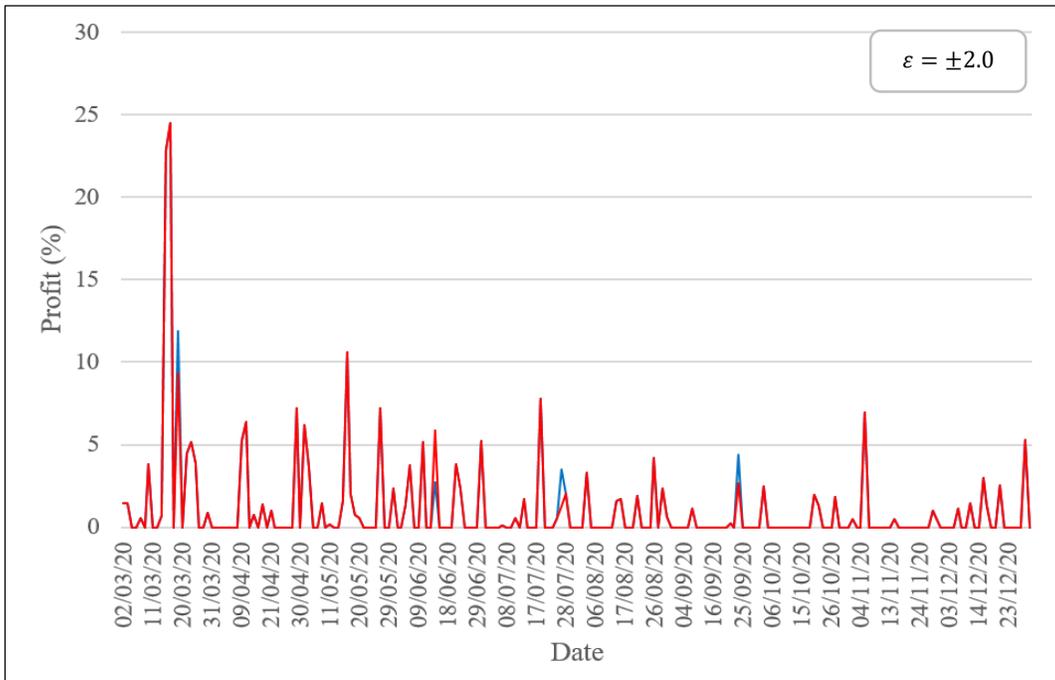
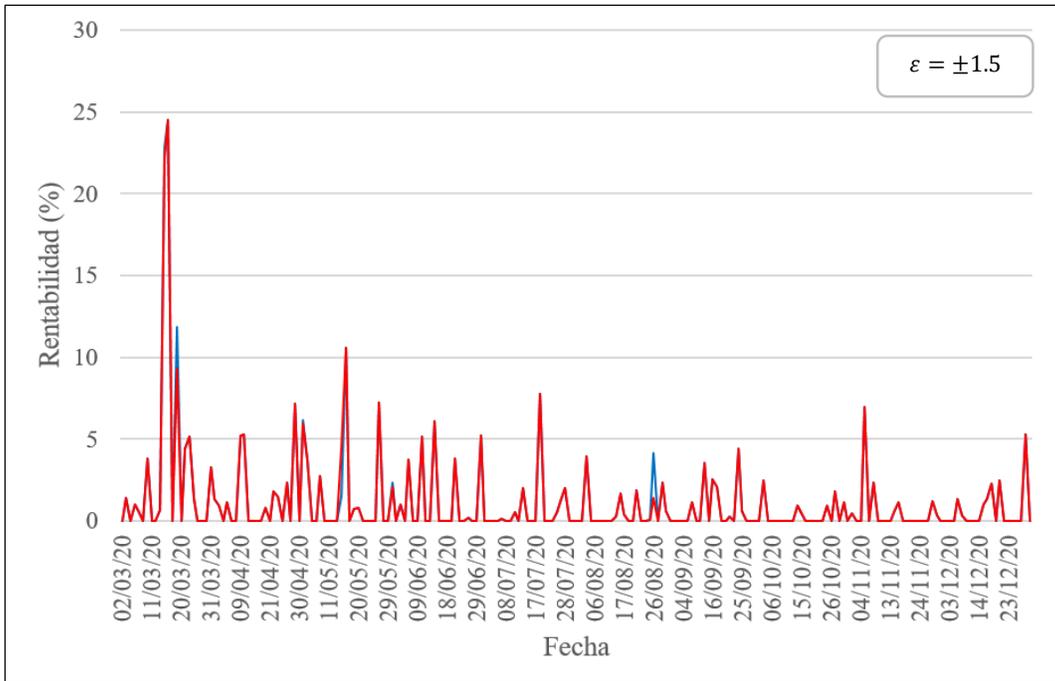
La Figura 16 muestra el comportamiento de la rentabilidad diaria obtenida por los algoritmos propuestos considerando un precio de cierre con un error sistemático de $\epsilon = 0, \pm 0.5, \pm 1.0, \pm 1.5, \pm 2.0, \pm 2.5, \pm 3.0$ (%), $\Delta = |\epsilon|$, y un capital de inversión de 10K USD, en donde se puede observar lo siguiente:

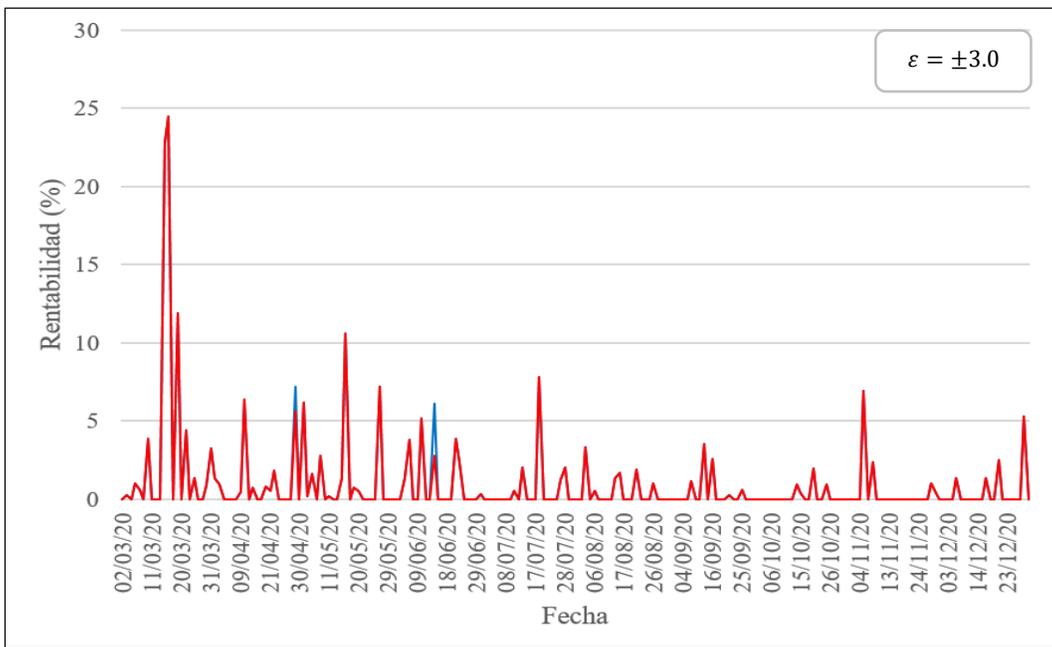
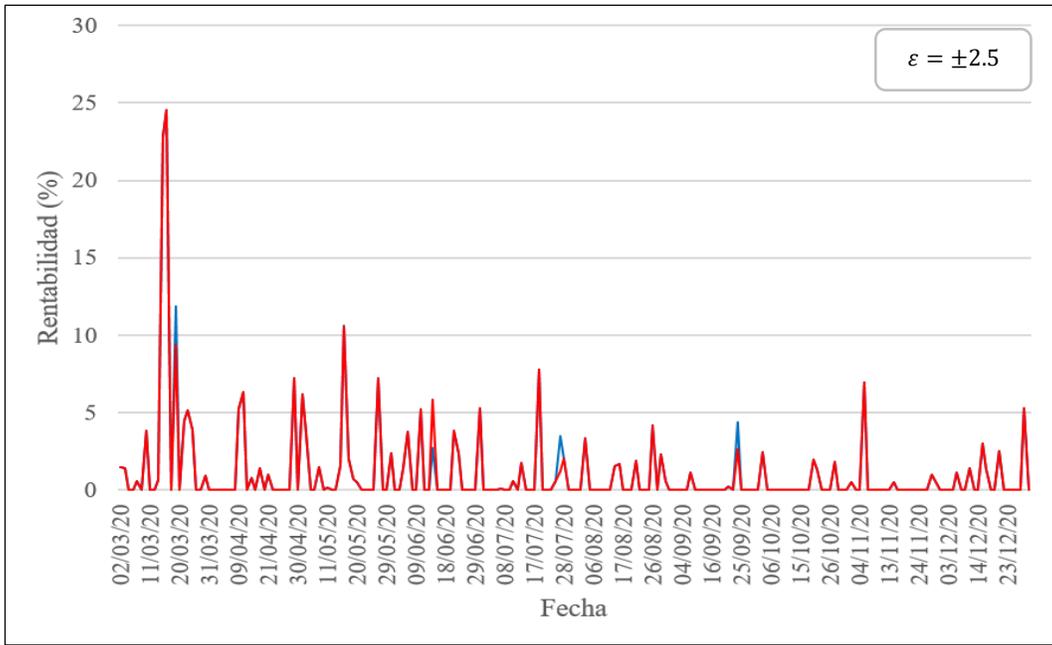
- i. La rentabilidad siempre es positiva, esto se explica porque la holgura absorbe el error en la estimación del precio y, por consiguiente, anula la decisión equivocada.
- ii. El incremento del error reduce la rentabilidad, esto se explica porque, a medida que aumenta el error y, por consiguiente, la holgura, la condición de compra de acciones se hace menos frecuente de verificarse y, por lo tanto, se obtiene menos rentabilidad.
- iii. El comportamiento de los resultados de los algoritmos G2I y R2I es muy similar entre sí, pero, en general, G2I posee mejores resultados que R2I.

Figura 16. Rentabilidad diaria de AIS: capital de inversión = 10K USD, precio de cierre con error ϵ (%), y $\Delta = |\epsilon|$









Leyenda

- R2I
- G2I

Fuente. Autor

6.3.3. Rentabilidad por capital de inversión

Las tablas 15 y 16 muestran la rentabilidad diaria promedio de AIS para capitales de inversión de 10K, 100K y 1000K USD, precio de cierre con un error sistemático de $\varepsilon = 0, \pm 0.5, \pm 1.0, \pm 1.5, \pm 2.0, \pm 2.5, \pm 3.0$ (%), y holgura $\Delta = 0$ y $\Delta = |\varepsilon|$, respectivamente, de donde se observa lo siguiente:

- i. Las rentabilidades son muy similares entre sí, cuando se varía el capital de inversión, es decir, no son influenciadas por el volumen del capital de inversión.
- ii. La rentabilidad de ambos algoritmos decrece gradualmente a medida que aumenta el error en el precio de cierre, así, cuando el error aumenta de 0 a ± 3 % para una holgura de 0, esta se reduce en 77 % para G2I, y en 82 % para R2I. Sin embargo, cuando la holgura es igual al valor absoluto del error ($\Delta = |\varepsilon|$), la rentabilidad decrece menos, reduciéndose en 27 % para G2I, y 26 % para R2I.

Tabla 15. Rentabilidad diaria promedio (%) de AIS para varios capitales de inversión y $\Delta=0$

ε (%)	Capital = 10K USD		Capital = 100K USD		Capital = 1000K USD	
	G2I	R2I	G2I	R2I	G2I	R2I
0.0	1.3260	1.2575	1.3262	1.2603	1.3262	1.2920
± 0.5	1.3008	1.2254	1.3010	1.2542	1.3010	1.2485
± 1.0	1.1518	1.0870	1.1520	1.1350	1.1520	1.0828
± 1.5	1.0137	0.9815	1.0139	0.9668	1.0139	0.9600
± 2.0	0.7922	0.7110	0.7923	0.7524	0.7923	0.7221
± 2.5	0.5828	0.5205	0.5828	0.3959	0.5828	0.4894
± 3.0	0.3026	0.2597	0.3024	0.1519	0.3024	0.2449

Fuente. Autor

Tabla 16. Rentabilidad diaria promedio (%) de AIS para varios capitales de inversión y $\Delta=|\varepsilon|$

ε (%)	Capital = 10K USD		Capital = 100K USD		Capital = 1000K USD	
	G2I	R2I	G2I	R2I	G2I	R2I
0.0	1.3260	1.2575	1.3262	1.2603	1.3262	1.2920
± 0.5	1.2882	1.2518	1.2884	1.2444	1.2884	1.2268
± 1.0	1.1916	1.1439	1.1917	1.1609	1.1918	1.1642
± 1.5	1.1538	1.1376	1.1539	1.1427	1.1539	1.1286
± 2.0	1.0837	1.0679	1.0838	1.1120	1.0839	1.0893
± 2.5	0.9405	0.9138	0.9407	0.9206	0.9407	0.9390
± 3.0	0.9560	0.9328	0.9562	0.9293	0.9562	0.9386

Fuente. Autor

La Tabla 17 confirma que la rentabilidad de los algoritmos propuestos no es influenciada por el capital de inversión, pues todas son muy similares si se cambia el capital, además, su tasa es muy alta, llegando en promedio a 24.11 % mensual para G2I, y 23.55 % para R2I, para $\varepsilon = \pm 3 \%$ y $\Delta = |\varepsilon|$.

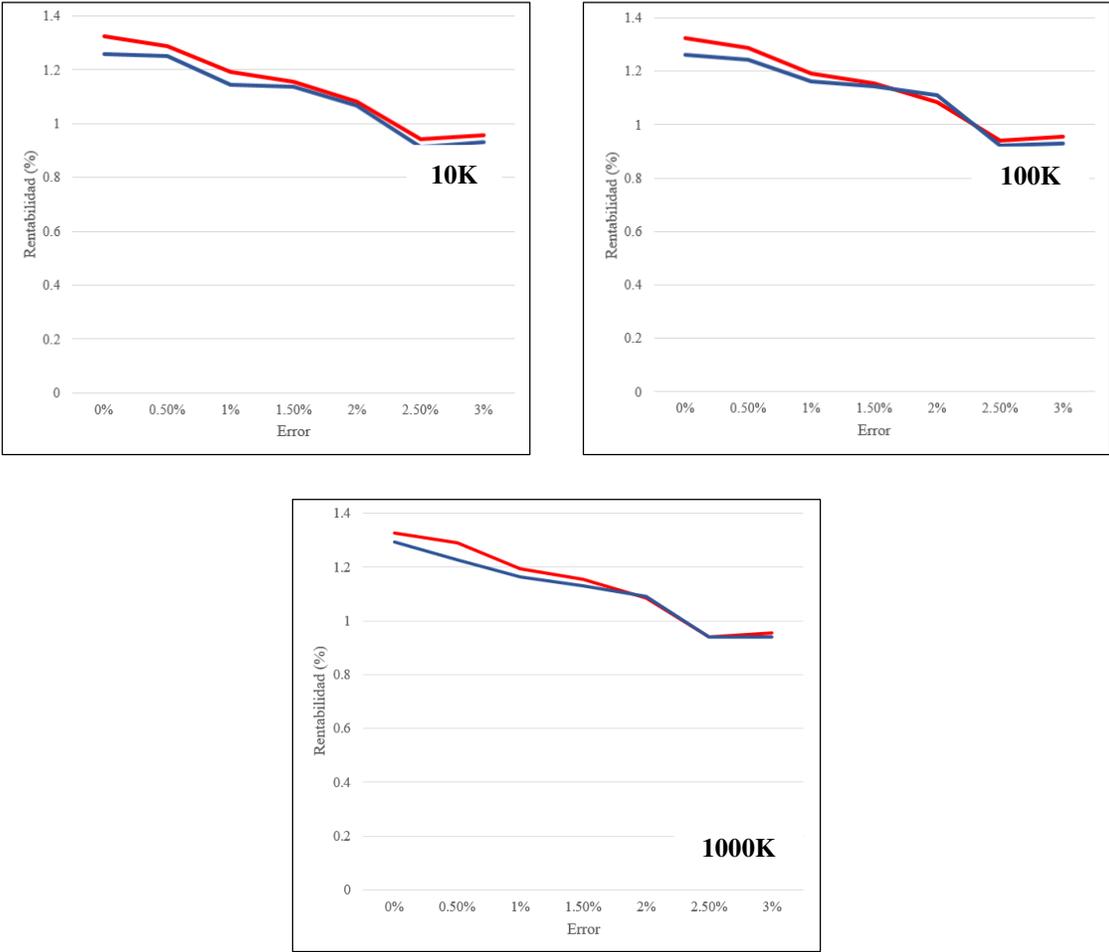
Tabla 17. Rentabilidad mensual promedio (%) de AIS para varios capitales de inversión y $\Delta=|\varepsilon|$

ε (%)	Capital = 10K USD		Capital = 100K USD		Capital = 1000K USD	
	G2I	R2I	G2I	R2I	G2I	R2I
0.0	34.71	32.68	34.72	32.95	34.72	33.77
± 0.5	33.62	32.60	33.63	32.38	33.63	31.73
± 1.0	30.68	29.36	30.69	29.93	30.69	29.78
± 1.5	29.59	29.03	29.59	29.20	29.59	28.79
± 2.0	27.92	27.40	27.92	28.72	27.92	28.14
± 2.5	23.86	23.18	23.87	23.37	23.87	23.83
± 3.0	24.11	23.52	24.11	23.45	24.11	23.69

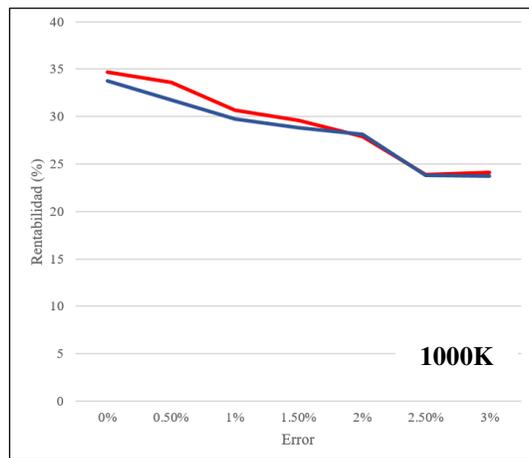
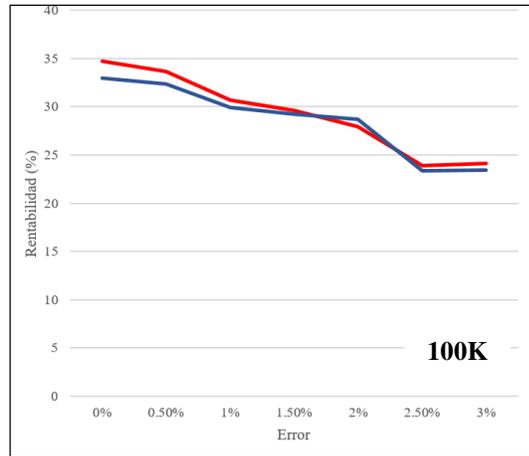
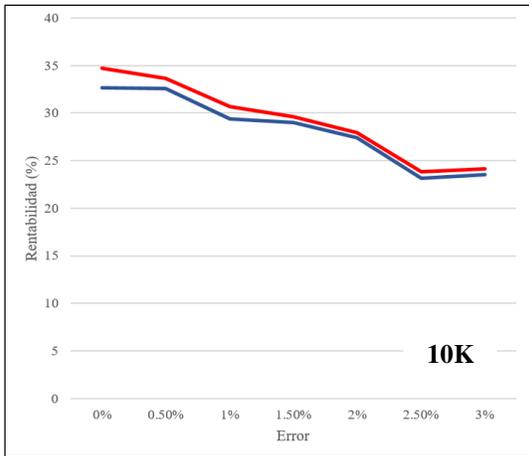
Fuente. Autor

La Figura 17 ilustra el comportamiento de la rentabilidad promedio diaria y mensual obtenida por los algoritmos propuestos para un capital de inversión de 10K, 100K y 1000K USD, y precio de cierre con error sistemático de $\varepsilon = 0, \pm 0.5, \pm 1.0, \pm 1.5, \pm 2.0, \pm 2.5, \pm 3.0$ (%), y holgura $\Delta = |\varepsilon|$. Es necesario observar que la rentabilidad de ambos algoritmos es muy similar y decrece a medida que aumenta el error en la estimación del precio de cierre, por lo que su comportamiento es independiente del volumen del capital de inversión, además, hay una tendencia de convergencia cuando incrementa el error.

Figura 17. Comportamiento de la rentabilidad diaria y mensual de AIS respecto al Capital y el Error, $\Delta = |\text{Error}|$



Rentabilidad Diaria



Rentabilidad Mensual

Leyenda

— R2I

— G2I

Fuente. Autor

CAPÍTULO VII: CONCLUSIONES Y TRABAJOS FUTUROS

7.1. CONCLUSIONES

Se ha propuesto un modelo de inversión automática en la Bolsa de Valores (AISM) para la compra de acciones en la apertura de la jornada bursátil y la venta de todo lo adquirido al cierre, que está basado en un modelo predictivo de estimación de precios de cierre, un algoritmo para la construcción del portafolio, y un módulo que genera las órdenes de compra y venta de acciones que se integra con el sistema del bróker. Además, se estudia cuatro posibles escenarios de compra y venta de acciones, así, se identifica que cuando el precio de la acción en la apertura es menor que el precio estimado de cierre, la mejor estrategia es comprar acciones al inicio y venderlas todas al cierre. Considerando esta estrategia, se define y se modela el problema del portafolio de inversión para responder a la pregunta ¿dónde, cuándo y cuánto se debe invertir para obtener la mayor rentabilidad posible con un capital de inversión dado?, este problema es catalogado como NP-hard, para el cual se propone los algoritmos greedy y GRASP.

AISM se ha implementado en un sistema de apoyo a la decisión denominado AIS. Las pruebas sobre datos del 1 de marzo al 31 de diciembre de 2020 de 5 empresas mineras peruanas que cotizan bolsa de valores NYSE muestran que los algoritmos propuestos generan portafolio de inversión que son muy rentables, los cuales, con un error de $\pm 3\%$ en la estimación en el precio de cierre, alcanzan rentabilidad mensual promedio de 24 % y 23 % para G2I y R2I, respectivamente. Los resultados también muestran que la rentabilidad obtenida por ambos algoritmos no se altera si se varía el capital de inversión, pero decrece si se incrementa el error en la estimación del precio de cierre. Además, los resultados muestran que la variable de holgura dada en las condiciones para la decisión de compra reduce el impacto negativo del error de la estimación del precio de cierre sobre la rentabilidad de la inversión, así, cuando la variable de holgura es nula y el error aumenta de 0 % a 3 %, la rentabilidad diaria cae para G2I del 1.32 % a 0.30 %, pero si la variable de holgura asume el valor absoluto del error, cae del 1.32 % a 0.95 %, es decir, recupera el 64 % de rentabilidad.

7.2. TRABAJOS FUTUROS

Los resultados de este estudio están limitados a los precios de las empresas contempladas, el sector de inversión y el periodo de los datos, por lo que, en un trabajo futuro, se realizará más pruebas con empresas de diversos sectores para conocer el comportamiento de la rentabilidad generada por el DSS propuesto, además, se integrará a un sistema de predicción del precio de cierre.

REFERENCIAS BIBLIOGRÁFICAS

- Adebiyi, A., Adewumi, A. O., & Ayo, C. K. (2014). Comparison of arima and artificial neural networks models for stock price prediction. *Journal of Applied Mathematics*.
- Almahdi, S., & Yang, S. (2017). An adaptative portfolio trading system: A risk-return portfolio optimization using recurrent reinforcement learning with expected maximum drawdown. *Expert Systems with Applications*, 267-279.
- Bernard, C., De Staelen, R., & Vanduffel, S. (2018). Optimal portfolio choice with benchmarks, *Journal of the Operational Research Society*, 1600-1621. DOI: 10.1080/01605682.2018.1470066
- Bloomberg (2020). The impact of coronavirus on stock markets. <https://www.bloomberg.com/graphics/2020-stock-market-recover-dow-industrial-decline/> (March 19, 2020).
- Cboe (2021). U.S. Equities Market Volume Summary. Cboe Global Marteks. https://markets.cboe.com/us/equities/market_share (June 29, 2021).
- Chen, C., Chen, C., & Yusuke, N. (2017). An efficient and effective approach for mining a group stock portfolio using mapreduce. *Intelligent Data Analysis*. 21 S217–S232 S217. <https://doi.org/10.3233/IDA-170879>
- Chen, C., & Zhou, Y. (2018). Robust Multiobjective Portfolio with Higher Moments. *Expert Systems with Applications*, 165-181.
- Chen, W., Wang, Y., Gupta, P., & Mehlawat, M. (2018). A novel hybrid heuristic algorithm for a new uncertain mean-variance-skewness portfolio selection model with real constraints. *Applied Intelligence*, 48, 2996-3018. <https://doi.org/10.1007/s10489-017-1124-8>
- Chen, Y., & Hao, Y. (2017). A feature weighted support vector machine and K-nearest neighbor algorithm for stock market prediction. *Expert Systems with Applications*, 340-355.
- Chiang, W., Enke, D., Wu, T., & Wang, R. (2016). An adaptive stock index trading decision support system. *Expert System with Applications*, 195-207.

- Chong, E., Han, C., & Park, F. (2017). Deep learning networks for stock market analysis and prediction: Methodology, data representation, and case studies. *Expert Systems with Applications*, 187-205.
- Essid, H., Ganouati, J., & Vigeant, S. (2018). A Mean-Maverick Game Cross-Efficiency Approach to Portfolio Selection: An Application to Paris Stock Exchange, 161-185.
- Feo, T., & Resende, M. (1995). Greedy Randomized Adaptive Search Procedures. *Journal of Global Optimization*, 6 (2), 109-133.
- Ferguson, S., & Hebels, R. (2003). Library management systems. *Computers for Librarians*, 3, 111-142.
- Garey, M., & Johnson, D. (1990). *Computers and Intractability; A Guide to the Theory of NP-Completeness*. W. H. Freeman & Co., New York, NY, USA.
- Guasoni, P., & Mayerhofer, E. (2020). Technical Note—Options Portfolio Selection. *Operations Research*. Published online in *Articles in Advance* 22 Apr 2020, 68 (3).
- Guo, G., Rao, Y., Zhu, F., Xu, F. (2020). Innovative deep matching algorithm for stock portfolio selection using deep stock profiles. *PLoS ONE* 15(11): e0241573. <https://doi.org/10.1371/journal.pone.0241573>.
- Gupta, P., Mehlawat, M., Yadav, S., & Kumar, A. (2019). A polynomial goal programming approach for intuitionistic fuzzy portfolio optimization using entropy and higher moments. *Applied Soft Computing Journal*, 85 (2019). <https://doi.org/10.1016/j.asoc.2019.105781>
- Henrique, B., Sobreiro, V., & Kimura, H. (2018). Stock Price prediction using support vector regression on daily and up to the minute prices. *The Journal of Finance and Data Science* 4 (2018), 183-201.
- Jin, X., Chen, N., & Yuan, Y. (2018). Multi-period and tri-objective uncertain portfolio selection model: A behavioral approach. *North American Journal of Economics and Finance*, 492-504.
- Kashyap, R. (2019). Miracle of Deep Learning Using IoT. *Deep Learning and Parallel Computing Environment for Bioengineering Systems*, 165-178.

- Khan, S., & Alghulaiakh, H. (2020). ARIMA model for accurate time series forecasting. *International Journal of Advanced Computer Science and Applications*, 524-528.
- Laboissiere, L., Fernandes, R., & Lage, G. (2015). Maximum and minimum stock price forecasting of Brazilian power distribution companies based on artificial neural networks. *Applied Soft Computing*, 66-74.
- Lai, Z., Qing, D., Ren, C., & Huang, K. (2018). Radial Basis Functions with Adaptive Input and Composite Trend Representation for Portfolio Selection. *IEEE Transactions on Neural Networks and Learning Systems*, 6214-6226.
- Liu, S., Zhang, X., Wang, Y., & Feng, G. (2020). Recurrent convolutional neural kernel model for stock price movement prediction. *PLoS ONE* 15(6): e0234206. <https://doi.org/10.1371/journal.pone.0234206>
- Munoz, E., Capon-Garcia, E., & Puigjaner, L. (2019). Advanced Model Design Based on Intelligent System Characterization and Problem Definition. *Computer Aided Chemical Engineering*, 46, 1045-1050.
- Naranjo, R., & Santos, R. (2019). A fuzzy decision system for money investment in stock markets based on fuzzy candlesticks pattern recognition. *Expert Systems With Applications* 133 (2019) 34–48.
- Paiva, F., Nogueira, R., Peixoto, G., & Moreira, W. (2018). Decision-Making for Financial Trading: A Fusion Approach of Machine Learning and Portfolio Selection. *Expert Systems with Applications*, 635-655.
- Qiu, J., Wang, B., & Zhou, C. (2020). Forecasting stock prices with long-short term memory neural network based on attention mechanism. *PLoS ONE*.
- Salkin, H. M., & De Kluyver, C. A. (1975). The knapsack problem: A survey. *Naval Research Logistics Quarterly*, 22(1), 127–144. doi:10.1002/nav.3800220110
- Shen, H., & Liang, X. (2018). A Quantitative Analysis Decision System Based on Deep Learning and NSGA-II for FX Portfolio Prediction. *Recent Trends and Future Technology in Applied Intelligence*, 572-579.

Shinzato, T., & Yasuda, M. (2015) Belief Propagation Algorithm for Portfolio Optimization Problems. PLoS ONE 10(8): e0134968. doi:10.1371/journal.pone.0134968

Statista.com (2021), Largest stock exchange operators in 2021, listed by market cap of listed companies, <https://www.statista.com/statistics/270126/largest-stock-exchange-operators-by-market-capitalization-of-listed-companies/> (last access on June 15, 2021).

Vaezi, F., Sadjadi, S., & Makui, A. (2019). A portfolio selection model based on the knapsack problem under uncertainty. PLoS ONE 14(5): e0213652. <https://doi.org/10.1371/journal>.

Yahoo Finance (2021), <https://finance.yahoo.com/> (last access on March 15, 2021).

Yang, F., Chen, Z., Li, J., & Tang, L. (2019). A novel hybrid stock selection method with stock prediction. Applied Soft Computing Journal 80 (2019) 820–831. <https://doi.org/10.1016/j.asoc.2019.03.028>.