

INSTITUTO TECNOLÓGICO Y DE ESTUDIOS SUPERIORES DE OCCIDENTE

Departamento de Matemáticas y Física

Sustentabilidad y Tecnología

**Programa de Modelación Matemática para el Desarrollo de Planes y Proyectos de
Negocio**



**ITESO, Universidad
Jesuita de Guadalajara**

PROYECTO DE APLICACIÓN PROFESIONAL PAP

4J05 Optimización de Programas de Inversión en Intermediarios Financieros

Automatización de Selección de Activos con el uso de Machine Learning

PRESENTAN

|

Ingeniería Financiera, Cesar Eduardo Gerardo Escobar

Ingeniería Financiera, Jesús Israel Reyes Valdez

Ingeniería en Sistemas Computacionales, Ana Paola Aguilar Rodríguez

Ingeniería Financiera, Rodolfo García Palma

Profesor PAP: Sean Nicolás González Vázquez

Tlaquepaque, Jalisco, Noviembre 2023

ÍNDICE

Contenido

REPORTE PAP	2
Presentación Institucional de los Proyectos de Aplicación Profesional.....	2
Resumen	1
1. Ciclo participativo del Proyecto de Aplicación Profesional	2
1.2 Caracterización de la organización	4
1.3 Identificación de la(s) problemática(s).....	4
1.4. Planeación de alternativa(s)	6
1.5. Desarrollo de la propuesta de mejora.....	7
Correlación de Variables según Categoría de Evaluación.....	14
Gráfica Distribución de la Decisión.....	20
Construcción de Modelos.....	22
Aplicación de imblearn en modelo XGBoost	25
Ingeniería de características en modelo XGBoost	26
Selección de variables para cada modelo.....	27
1.6. Valoración de productos, resultados e impactos	29
1.7. Bibliografía y otros recursos	31
1.8. Anexos generales.....	32
2. Productos.....	34
3. Reflexión crítica y ética de la experiencia	35
3.1 Sensibilización ante las realidades	35
3.2 Aprendizajes logrados	36

REPORTE PAP

Presentación Institucional de los Proyectos de Aplicación Profesional

Los Proyectos de Aplicación Profesional (PAP) son experiencias socio-profesionales de los alumnos que desde el currículo de su formación universitaria- enfrentan retos, resuelven problemas o innovan una necesidad sociotécnica del entorno, en vinculación (colaboración) (co-participación) con grupos, instituciones, organizaciones o comunidades, en escenarios reales donde comparten saberes.

El PAP, como espacio curricular de formación vinculada, ha logrado integrar el Servicio Social (acorde con las Orientaciones Fundamentales del ITESO), los requisitos de dar cuenta de los saberes y del saber aplicar los mismos al culminar la formación profesional (Opción Terminal), mediante la realización de proyectos profesionales de cara a las necesidades y retos del entorno (Aplicación Profesional).

El PAP es un proceso acotado en el tiempo en que los estudiantes, los beneficiarios externos y los profesores se asocian colaborativamente y en red, en un proyecto, e incursionan en un mundo social, como actores que enfrentan verdaderos problemas y desafíos traducibles en demandas pertinentes y socialmente relevantes. Frente a éstas transfieren experiencia de sus saberes profesionales y demuestran que saben hacer, innovar, co-crear o transformar en distintos campos sociales.

El PAP trata de sembrar en los estudiantes una disposición permanente de encargarse de la realidad con una actitud comprometida y ética frente a las disimetrías sociales. En otras palabras, se trata del reto de “saber y aprender a transformar”.

El Reporte PAP consta de tres componentes:

El primer componente refiere al ciclo participativo del PAP, en donde se documentan las diferentes fases del proyecto y las actividades que tuvieron lugar durante el desarrollo de este y la valoración de las incidencias en el entorno.

El segundo componente presenta los productos elaborados de acuerdo con su tipología.

El tercer componente es la reflexión crítica y ética de la experiencia, el reconocimiento de las competencias y los aprendizajes profesionales que el estudiante desarrolló en el transcurso de su labor.

Resumen

El proyecto PAP, automatización de selección de activos con el uso de machine learning, consta de crear un modelo predictivo para decidir si invertir en acciones de la bolsa de valores estadounidense, el modelo usa datos llamados fundamentales, los cuales a partir del estado de resultados, balance general y flujo de caja podemos usar para determinar la salud financiera de la empresa a partir de ratios o valores de medición y por ultimo usamos el rendimiento efectivo de las empresas para determinar si invertir o no, si es positivo se invierte, si es negativo no se invierte.

El objetivo principal del proyecto es entrenar un modelo en base a análisis fundamental y los rendimientos, el cual pueda detectar patrones en los datos y posteriormente poder ingresar solo información de los fundamentales y que el modelo entrenado haga la predicción de invertir o no invertir. Como alcance buscamos facilitar al sector inversionista a tomar mejores decisiones en sus inversiones y poder dar una herramienta que atraiga más personas a concientizarse sobre la importancia de hacer crecer su dinero, ya que actualmente, según Forbes aproximadamente solo un 2% de los mexicanos invierten en bolsa a comparación del 50% en EUA.

Como resultados de nuestro proyecto nos enfocaremos en los aprendizajes aprendidos y destacar la importancia de la comprensión de las limitaciones en el ámbito de la predicción financiera dando como resultado una base sólida para reflexión y una mejora continua en futuras investigaciones y aplicaciones prácticas.

1. Ciclo participativo del Proyecto de Aplicación Profesional

El PAP es una experiencia de aprendizaje y de contribución social integrada por estudiantes, profesores, actores sociales y responsables de las organizaciones, que de manera colaborativa construyen sus conocimientos para dar respuestas a problemáticas de un contexto específico y en un tiempo delimitado. Por tanto, la experiencia PAP supone un proceso en lógica de proyecto, así como de un estilo de trabajo participativo y recíproco entre los involucrados.

Entrega 1:

Definición del proyecto: Se evaluará el alcance y se explicarán las generalidades del proyecto con conceptos básicos, como las métricas de análisis fundamental y los modelos propuestos para la realización del análisis de las acciones contenidas dentro del Dow Jones.

Entrega 2:

Obtención de Datos: Ya seleccionados los fundamentales que usaremos para el proyecto, procederemos a la parte de extracción de datos, tomando como datos de entrada los fundamentales y como datos de salida el rendimiento efectivo de cada acción. Con la ayuda de la API de Alpha Vantage, descargaremos el balance general y estado de resultados de al menos 200 empresas/acciones para poder calcular los fundamentales requeridos.

Entrega 3:

Construcción de Modelos: Se planea primero hacer el código de regresión logística, el cual nos permitirá evaluar el peso de cada fundamental y poder elegir los más significativos o los que tengan mayor relevancia para el modelo. Posteriormente, haremos la comparación con modelos como Random Forest y SVM para evaluar el desempeño de cada uno y elegir el que sirva de una mejor manera.

Entrega 4:

Selección de Modelo Óptimo: Para esta etapa del proyecto debemos elegir el modelo que tenga más precisión o el que sea más certero para la predicción de invertir o no invertir. Este modelo ya debe ser el definitivo, por lo cual se hará una última prueba o backtesting para corroborar que el funcionamiento con nuevos datos de entrada sea el óptimo.

Entrega 5:

Correcciones: Tiempo para hacer correcciones en el proyecto y empezar a redactar y documentar los hallazgos encontrados.

1.1 Entendimiento del ámbito y del contexto

A lo largo de la historia financiera, se han presenciado innumerables fenómenos en Wall Street, algunos representando éxito y otros, notorios fracasos. La selección de activos se destaca como una tarea compleja que exige razonamiento sólido. Este contexto resalta la relevancia de entender la diferencia crucial entre la gestión de activos por parte de fondos de inversión y las decisiones individuales de los inversionistas, especialmente en relación con la influencia psicológica en las finanzas descrita por Gustave Le Bon.

En nuestro proyecto, exploramos cómo modelos cuantitativos pueden mitigar la influencia de emociones en las decisiones de inversión, evitando sesgos cognitivos. La actualidad revela que la participación en el mercado bursátil en México es baja, planteando la visión de una herramienta accesible para decisiones financieras inteligentes.

Además, nos preocupa la posible vulnerabilidad económica de la generación actual de la tercera edad en México debido a la falta de educación financiera y prácticas deficientes en la gestión del fondo de retiro. En respuesta, desarrollamos un sistema que empodera a las personas en la toma de decisiones de inversión mediante tecnología y datos financieros.

La metodología se basa en análisis fundamental, examinando indicadores como Projected Earnings Growth, EBITDA, Dividend Payout Ratio, y Earnings Per Share. En situaciones pertinentes, incorporamos análisis técnico para evaluar patrones históricos y tendencias del mercado. El alcance de nuestra metodología refleja la selección de indicadores clave, el uso de fuentes confiables para datos en tiempo real y la implementación de modelos matemáticos para decisiones automáticas basadas en análisis previo.

El objetivo general es generar herramientas y conocimientos para la toma de decisiones informada en la adquisición de activos financieros. La combinación de análisis fundamental y la comprensión de la psicología financiera busca ayudar a los inversionistas a evitar trampas emocionales y tomar decisiones respaldadas por datos y análisis sólidos.

1.2 Caracterización de la organización

Participantes	Rol	Responsabilidad
Cesar Gerardo	Investigador	Parte Teórica del Proyecto
Jesús Reyes	Programador	Código de descarga de datos
Ana Aguilar	Investigador	Investigación de modelos
Rodolfo García	Programador e Investigador	Código de los modelos y búsqueda de nuevas herramientas

1.3 Identificación de la(s) problemática(s)

Desarrollo de la Codificación para la Descarga de Datos:

Desafío: Nos encontramos con desafíos significativos durante el proceso de desarrollo de la codificación destinada a la descarga de datos mediante el API de Alpha Vantage, dado que la API tenía un límite de solicitudes por minuto, las cuales generaban una mayor dificultad a la hora de realizar la descarga de los fundamentales.

Estrategias de Resolución: Para superar estas dificultades, nuestro equipo optó por una estrategia integral basada en la colaboración grupal, pruebas exhaustivas y desarrollo iterativo. La colaboración grupal permitió un intercambio activo de ideas y la identificación de enfoques innovadores para abordar problemas específicos. Realizamos pruebas meticulosas para validar la eficacia de la codificación en diversos escenarios y condiciones. Además, buscamos orientación y retroalimentación del profesor, aprovechando su experiencia para mejorar la calidad y eficiencia del código. Este enfoque colaborativo y riguroso no solo resolvió los desafíos técnicos, sino que también fortaleció la cohesión y el conocimiento del equipo en el proceso.

Modelos de Clasificación y Adaptación de KPIs:

Desafío: Al implementar modelos de clasificación, nos enfrentamos a la dificultad de adaptar los KPIs fundamentales a patrones coherentes para la clasificación precisa.

Estrategias de Resolución: Para abordar esta complejidad, implementamos ajustes significativos en los cálculos de los KPIs, buscando mejorar su capacidad discriminativa. Además, adoptamos una estrategia proactiva de expansión, captando más empresas de diversos índices financieros y sectores. Esta estrategia no solo enriqueció nuestro conjunto de datos, sino que también nos permitió explorar nuevas dimensiones y características relevantes para la clasificación. La diversificación de las fuentes de datos mejoró la robustez de nuestros modelos y proporcionó una base más sólida para la toma de decisiones informadas en el ámbito de la inversión.

Dificultades en la Diferenciación Precisa entre Escenarios Propicios e Imprudentes para la Inversión:

Descripción del Problema: La homogeneidad en las probabilidades asociadas a las predicciones complicó la identificación de patrones claros, generando incertidumbre en el proceso de toma de decisiones.

Estrategias de Resolución: Ante este desafío, reconocimos la necesidad de una revisión exhaustiva de nuestros enfoques. Nos comprometimos a realizar análisis más profundos de las características del conjunto de datos y a explorar técnicas avanzadas de modelado. También consideramos la posibilidad de incorporar fuentes de información adicionales que pudieran proporcionar insights valiosos. Esta estrategia de mejora continua no solo aborda las limitaciones identificadas, sino que también sienta las bases para futuras investigaciones y refinamientos en la aplicación práctica de nuestros modelos en el ámbito de la inversión.

1.4. Planeación de alternativa(s)

Definición de KPIs Fundamentales y Selección de Empresas:

En la fase inicial, se procederá a la identificación y definición de los indicadores clave de rendimiento (KPIs) fundamentales que desempeñarán un papel crucial en el análisis financiero. Este proceso implica la cuidadosa selección de métricas que proporcionarán información significativa sobre el desempeño económico. Simultáneamente, se llevará a cabo la elección de empresas representativas de diversos sectores, con el objetivo de construir un conjunto de datos integral que refleje la diversidad del mercado.

Desarrollo de la Codificación en Python para Obtener Cálculos de KPIs:

En esta etapa, se avanzará en la creación de un script en Python dedicado a la descarga de datos a través del API de Alpha Vantage. Este script se diseñará con el propósito de optimizar la eficiencia, superando posibles restricciones de descarga de datos. La programación será ejecutada con precisión para asegurar la obtención de cálculos precisos de los KPIs identificados previamente.

Realización de Análisis Exploratorio de Datos (EDA):

Se llevará a cabo un análisis exploratorio de datos exhaustivo con el objetivo de comprender la estructura y las características de la base de datos obtenida. Este proceso implica la identificación de patrones y tendencias significativas, así como la evaluación de posibles desafíos que puedan requerir atención adicional. El EDA será un paso crucial para informar las decisiones subsiguientes en el proceso de análisis.

Estrategias de Preprocesamiento de Datos:

En la fase de preprocesamiento, se implementarán estrategias sólidas para garantizar la calidad y coherencia de la base de datos. Esto incluirá la gestión de valores atípicos, la imputación de datos faltantes y la normalización de variables. Estas estrategias son esenciales para asegurar la robustez de los datos antes de proceder a etapas más avanzadas del análisis.

Codificación de Modelos y Comparación de Métricas:

En esta etapa, se desarrollarán scripts para la implementación de modelos predefinidos. Se llevará a cabo una comparación sistemática de métricas entre diferentes modelos para identificar el modelo óptimo que mejor se ajuste al conjunto de datos específico. Este proceso respaldará la toma de decisiones informada en la selección del modelo más adecuado para los objetivos de análisis establecidos.

1.5. Desarrollo de la propuesta de mejora

Se evaluó el alcance y se explicaron las generalidades del proyecto con conceptos básicos, como las métricas de análisis fundamental y los modelos propuestos para la realización del análisis de las acciones del Dow Jones. Ya seleccionados los fundamentales, procedimos a la parte de extracción de datos, tomando como datos de entrada los fundamentales y como datos de salida el rendimiento efectivo de cada acción. Con la ayuda de la API de Alpha Vantage, descargamos el balance general, estado de resultados y el estado de flujo de efectivo de al menos 200 empresas/acciones para poder calcular los fundamentales requeridos. Extraemos los datos financieros por cuartos de 5 años atrás que nos servirán para el cálculo de los fundamentales y por medio de la librería de Yahoo Finance obtendremos la información de los rendimientos de cada cuarto.

Con los fundamentales ya calculados y el rendimiento de cada fecha pudimos construir nuestra base de datos, la cual nos ayudara a entrenar los modelos propuestos que nos ayudaran a predecir si invertir o no invertir en acciones.

Seguido a esto realizamos un análisis exploratorio de datos (EDA) para comprender mejor la distribución y las tendencias de los fundamentales y los rendimientos en nuestro conjunto de datos. Esto nos ayuda a identificar posibles patrones o relaciones entre las métricas financieras y el rendimiento de las acciones.

Nuestra tarea en este proyecto es obtener datos fundamentales relacionados con acciones. Estos datos se utilizarán como entrada para un modelo que determinará si es recomendable invertir en dichas acciones o no. El propósito es proporcionar estos datos en la próxima entrega al modelo, permitiendo que este genere recomendaciones sobre si debiéramos considerar la inversión en las acciones que estamos analizando.

Data Quality Report (DQR):

El conjunto de datos consta de 9,749 observaciones.

1. "dates" y "synced_dates":

Tipo: 'object', fechas.

"synced_dates" tiene un rango desde el 29 de junio de 2018 hasta el 30 de junio de 2023.

2. Variable Categórica:

"ticket":

Tipo: 'object', categórica con 518 valores únicos.

Representa el nombre de las acciones.

3. Variables Numéricas:

Las siguientes variables representan los fundamentales y el rendimiento:

"ROA", "ROE", "NER", "DER", "CER", "GMR", "SOL", "QR", "BVPS", "EPS", "PE", "EVS", "EVEBI", "ICR", "PBR", "OM", "ADJ", "Rend_Futuro".

4. Variable Binaria:

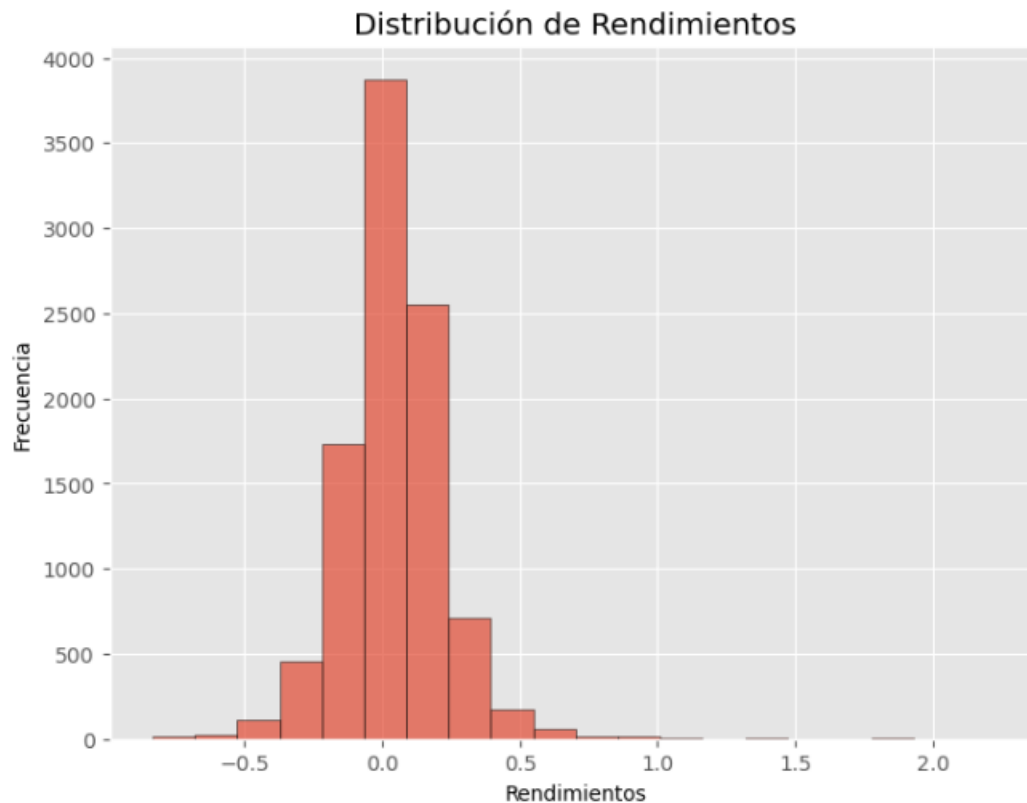
"decisión":

Binaria con valores 0 y 1.

Esta variable representa la toma de decisión, si es 1 se invierte, si es 0 no se invierte, recordando que depende de si el rendimiento es positivo o negativo.

Gracias a las observaciones de este análisis: podemos realizar visualizaciones para comprender mejor la distribución de las variables numéricas y la relación entre las variables. Esto ayudaría a obtener una comprensión más profunda de los datos.

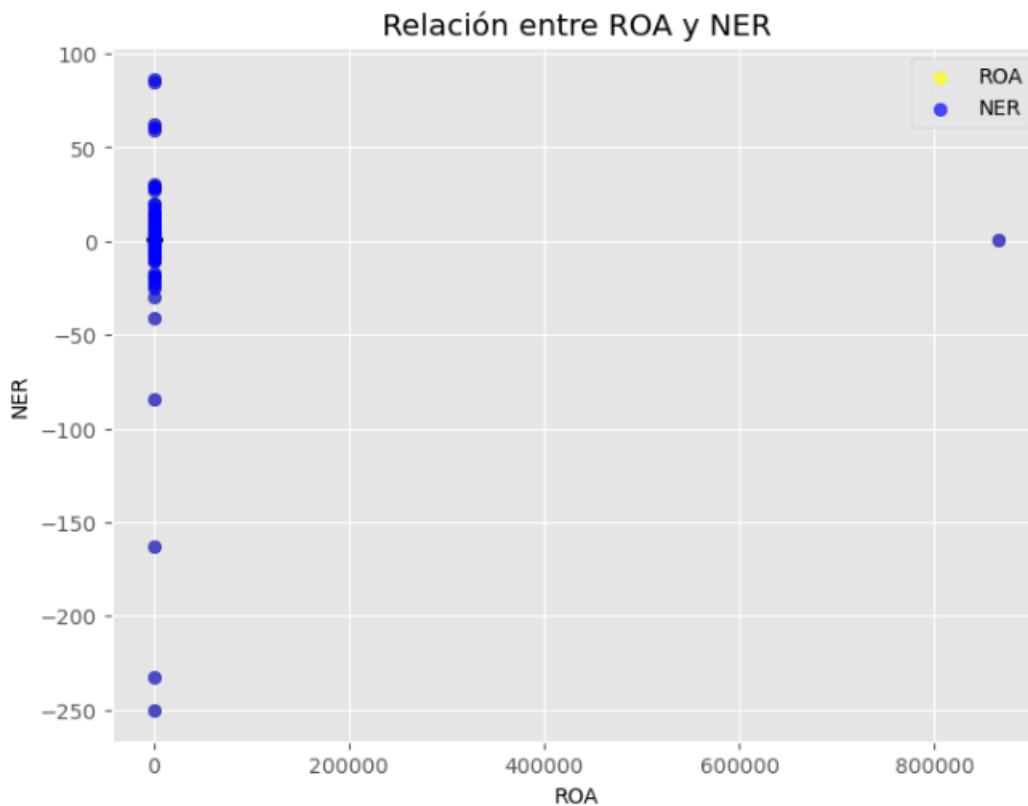
Análisis de los rendimientos:



Al analizar la distribución de los rendimientos desde una perspectiva de "aproximadamente una distribución normal", se observa una concentración notable de rendimientos alrededor del 0%. Esta tendencia puede atribuirse a la eficiencia del mercado, donde la rápida incorporación de información en los precios de los activos dificulta que los inversores obtengan rendimientos excepcionales en el corto plazo. Como resultado, con el tiempo, los rendimientos tienden a converger hacia valores cercanos a cero, reflejando la búsqueda de un equilibrio en los mercados financieros.

La mayoría de las acciones experimentan fluctuaciones dentro de un rango limitado, generalmente oscilando entre -25% y 25% de rendimiento. Este rango limitado indica que, en términos generales, las variaciones de precio de las acciones se mantienen dentro de límites razonables y predecibles, lo que puede ser una característica de estabilidad en los mercados financieros.

Análisis de características:



La gráfica en cuestión proporciona una visualización evidente de la distribución de datos de dos indicadores financieros clave: el ROA (Return on Assets o Retorno sobre Activos) y el NER (Net Earnings Ratio o Ratio de Ganancias Netas). Estos indicadores financieros, esenciales para evaluar el desempeño de una empresa, presentan una distribución de datos notablemente similar en la gráfica.

La similitud en la distribución de estos indicadores sugiere la existencia de una correlación potencial entre ROA y NER. En otras palabras, los valores de ROA y NER podrían estar relacionados entre sí de alguna manera. Esta correlación podría indicar que empresas con un alto ROA tienden a mostrar un NER específico y viceversa, lo que podría tener implicaciones significativas para la toma de decisiones financieras y estratégicas.

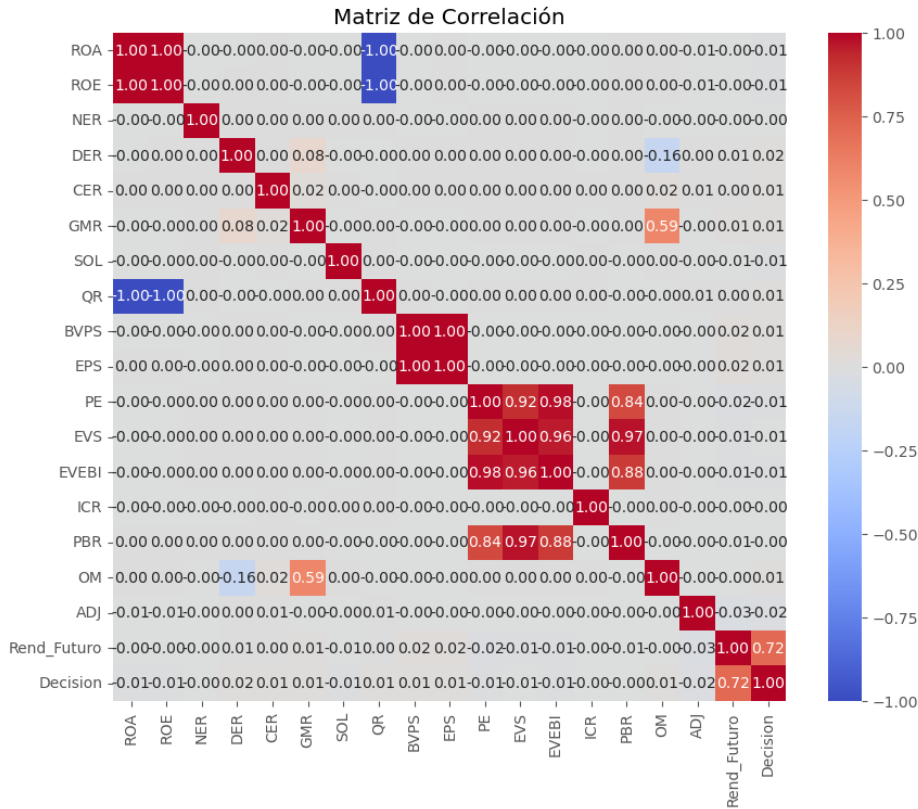
La identificación de esta correlación entre ROA y NER podría ser fundamental para entender cómo los activos de una empresa impactan directamente en sus ganancias netas. Además, puede proporcionar información valiosa para la evaluación de la rentabilidad y la gestión de recursos en el contexto empresarial.

Correlación de Pearson:

La correlación de Pearson es una medida estadística que evalúa la relación lineal entre dos variables continuas. Proporciona un valor entre -1 y 1, donde:

- 1 indica una correlación positiva perfecta (ambas variables aumentan juntas).
- -1 indica una correlación negativa perfecta (una variable aumenta mientras la otra disminuye).
- 0 indica ausencia de correlación lineal.

En otras palabras la correlación de Pearson ayuda a entender la dirección y la fuerza de la relación lineal entre dos variables numéricas




Al calcular la matriz de correlación entre las variables en nuestra base de datos, podemos identificar las relaciones existentes entre ellas. Esto nos permite entender cómo las variables se modifican en respuesta a cambios en otras. En particular, en este análisis, nos centramos en las variables QR y CUR, que representan el escenario mencionado anteriormente.

En este contexto, utilizamos la correlación de Pearson para evaluar las relaciones entre las variables continuas. Esto nos ayuda a comprender cómo los indicadores fundamentales y los rendimientos se relacionan cuando una variable continua experimenta cambios.

Correlación de Spearman:

La correlación de Spearman es útil cuando queremos entender la relación entre dos conjuntos de datos, especialmente cuando esos datos son dicotómicos o cuando no siguen una distribución normal. Ayuda a descubrir si existe una conexión que va en una dirección constante, ya sea hacia arriba o hacia abajo, sin importar el tipo específico de relación.



Resultados Correlación Spearman

- En este caso la correlación de Spearman nos sirve para ver la correlación de nuestra variable booleana (Decisión) respecto a las otras variables.}
- Aquí encontramos que la correlación de nuestras variables predictivas con nuestra variable de decisión en todos los casos era muy cercana a 0.


Correlación de Variables según Categoría de Evaluación

Las variables se han agrupado según su propósito particular, ya sea para evaluar la rentabilidad, analizar la estructura de capital, valorar las acciones o medir el rendimiento operativo. Esta clasificación se ha aplicado con el fin de evitar comparaciones inadecuadas entre las variables.

- Objetivo:

Identificar posibles sustituciones o eliminaciones de variables en función de su área de evaluación correspondiente.

Matriz de Correlación en Métricas de Rentabilidad




Resultados de Correlación en Métricas de rentabilidad

En el caso de las Métricas de rentabilidad, consideramos necesario eliminar alguna de estas dos variables:

- ROE
- ROA

porque mantienen una correlación perfecta y positiva entre estas dos variables. Esto significa que tienen una relación lineal idéntica.

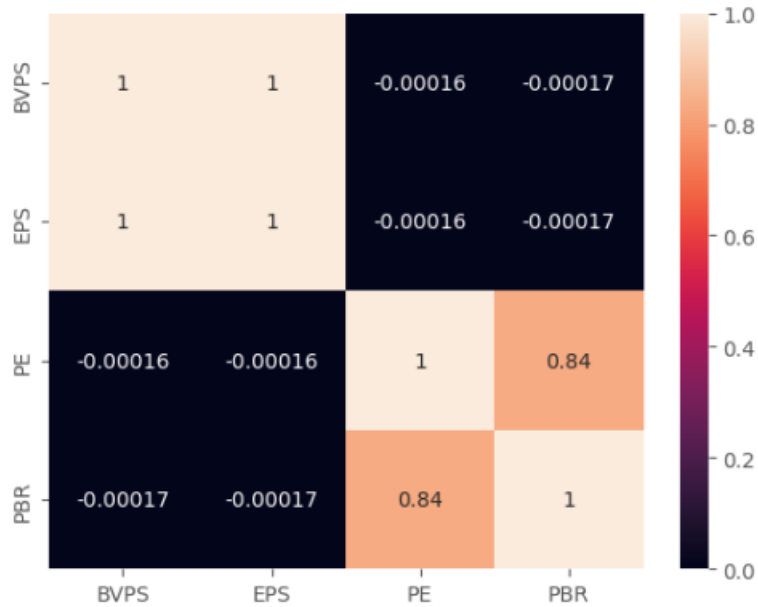
Matriz de Correlación en Métricas de Estructura de Capital



Resultados de Correlación en Métricas de Estructura de Capital

- Para estas métricas de estructura de capital no es necesario eliminar o reemplazar variables, prácticamente son nulas sus correlaciones.

Matriz de correlación en métricas de Valuación de Activos



Resultados de Correlación en Métricas de Valuación de Activos

En el caso de las Métricas de Valuación de activos, consideramos necesario eliminar alguna de estas dos variables:

- EPS
- BVPS

porque mantienen una correlación perfecta y positiva entre estas dos variables. Esto significa que tienen una relación lineal idéntica. Es decir, ambas se mueven en la misma magnitud con la misma dirección.

Matriz de Correlación en Métricas de Retorno Operativo



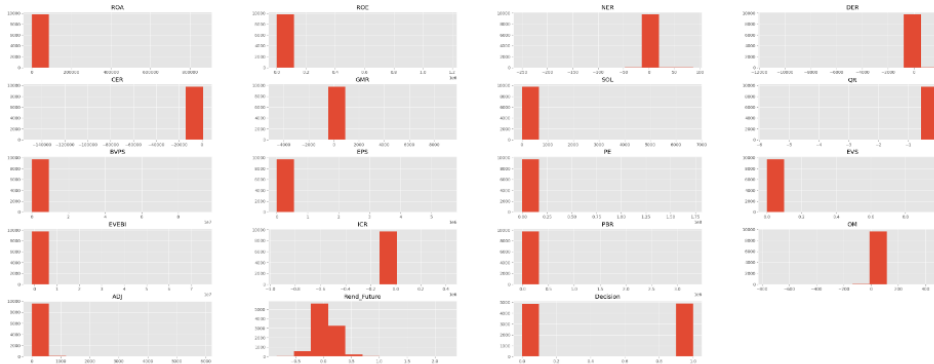
Resultados de Correlación en Métricas de Retorno Operativo

En el caso de las Métricas de Retorno Operativo, consideramos necesario eliminar alguna de estas dos variables:

- EVS
- EVEBI

porque mantienen una correlación perfecta y positiva entre estas dos variables. Esto significa que tienen una relación lineal con un 96% de relación.

Dispersión de datos



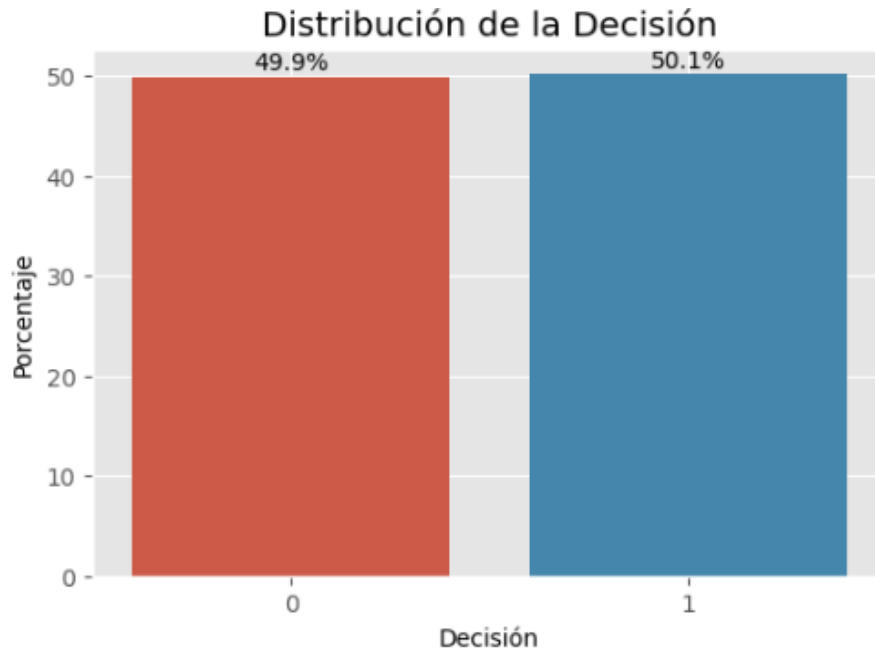
Observación en la Dispersión de Datos

Prácticamente los datos son cercanos a 0 en la mayoría de nuestras variables a excepción de:

- Rend_Futuro

Por lo que pudiera ser una variable demasiado significativa en comparación con el resto de las variables.

Gráfica Distribución de la Decisión




Observaciones en la Distribución de la Decisión

El gráfico proporcionado representa la distribución de una variable categórica crucial denominada 'Decisión', que indica si se llevará a cabo una inversión en el activo o no, basándose en su rendimiento. Una observación destacada de este gráfico es que sugiere la prevalencia de activos con un rendimiento positivo.

La mayor concentración de decisiones de inversión en la categoría de rendimiento positivo indica una tendencia hacia decisiones de inversión más favorables en el conjunto de datos. Esto implica que, en general, existe una inclinación a invertir en activos que han demostrado un rendimiento positivo, lo que podría reflejar una estrategia común en la toma de decisiones de inversión.

Box Plot de los Indicadores Fundamentales y Rendimientos



La mayoría de las variables se concentran alrededor del valor 0. Esto indica que estas variables tienen una distribución centralizada alrededor del valor medio o mediana.

Sin embargo, algunas variables, como PBR, EVEBI, EVS, PE, EPS y QR, se alejan significativamente de 0 en el boxplot. Esto indica que estas variables tienen valores que se extienden más allá de la región central y presentan una mayor variabilidad en comparación con las otras variables.

La presencia de valores atípicos es evidente en estas variables que se alejan de 0 en el boxplot. Los valores atípicos son puntos que se encuentran a una distancia considerable de la región intercuartílica (IQR), lo que sugiere la existencia de observaciones extremas o inusuales en estas variables. La distribución de estas variables puede ser asimétrica, lo que significa que no siguen una distribución normal y pueden sesgarse hacia valores altos o bajos, dependiendo de la dirección en la que se alejan de 0.

Construcción de Modelos

La construcción de modelos de clasificación es un aspecto esencial en el campo del aprendizaje automático y la ciencia de datos. Consiste en desarrollar algoritmos o modelos que pueden asignar automáticamente etiquetas o categorías a datos no etiquetados en función de patrones identificados en datos previamente etiquetados. En esencia, se trata de enseñar a una máquina a tomar decisiones de clasificación basadas en datos de entrenamiento.

Regresión logística

Con los resultados de la Regresión Logística a partir del Excel con todos los fundamentales, corrimos un back análisis iterativo de los p-values descartando el valor máximo para posteriormente volver a hacer un modelo matemático de Regresión Logística recursivamente hasta que todos los valores fueran menores de 0.05, lo que significa que podemos rechazar la hipótesis nula y que el predictor es significativo en el modelo.

Iniciamos con un archivo con los siguientes fundamentales:

Fundamentales	ROA	ROE	NER	DER	CER	GMR	SOL	QR	BVPS	EPS	PE	EVS	EVEBI	ICR	PBR	OM
---------------	-----	-----	-----	-----	-----	-----	-----	----	------	-----	----	-----	-------	-----	-----	----

Al final del análisis resultaron significativos los siguientes fundamentales:

Fundamental Significativo
EVEBI

Lo que significa que estos fundamentales son los más relevantes para predecir el rendimiento de acciones.

Modelos de Clasificación: Regresión Logística, Decision Tree, Random Forest, SVM, Naive Bayes, KNN, XGBoost, y Gradient Boosting

Resultados en los modelos de clasificación

	Modelo	Precision Global	Precision Clase 0	Precision Clase 1	Recall Clase 0	Recall Clase 1	F1-score Clase 0	F1-score Clase 1
0	Regresión Logística	50.26%	50%	53%	83%	19%	62%	28%
1	Decision Tree	49.49%	49%	50%	52%	47%	51%	48%
2	Random Forest	51.18%	50%	52%	54%	49%	52%	50%
3	SVM	49.18%	49%	46%	99%	1%	66%	2%
4	Naive Bayes	51.03%	61%	51%	2%	99%	3%	67%
5	KNN	51.18%	50%	52%	52%	51%	51%	51%
6	XGBoost	51.23%	50%	52%	53%	50%	52%	51%
7	Gradient Boosting	52.10%	51%	53%	54%	51%	52%	52%

Se observa que el Gradient Boosting sobresale con la precisión global más alta, alcanzando un 52.10%. Este modelo demuestra un equilibrio sólido entre precisión y recall para ambas clases, con F1-scores notables. En particular, destaca por su capacidad para discriminar efectivamente entre situaciones propicias e imprudentes para la inversión. Si bien otros modelos muestran rendimientos variados, el Gradient Boosting emerge como la elección más prometedora para abordar este desafío específico de predicción financiera.

XGBOOST con Hiperparámetros

	Modelo	Precision Global	Precision Clase 0	Precision Clase 1	Recall Clase 0	Recall Clase 1	F1-score Clase 0	F1-score Clase 1
0	XGBoost Sin Hiperparámetros	51.23%	51%	53%	53%	51%	52%	52%
1	XGBoost con Hiperparámetros	52.0%	51%	53%	53%	51%	52%	52%

En la comparación entre dos configuraciones de XGBoost, se destaca que ambos modelos muestran un rendimiento similar en términos de Precision Global, Precision Clase 0 y Clase 1, Recall Clase 0 y Clase 1, así como F1-score Clase 0 y Clase 1. Ambas configuraciones de XGBoost alcanzan niveles notables de precisión y equilibrio entre precisión y recall, situándose alrededor del 52%, lo cual sugiere que la modificación de hiperparámetros no genera una mejora significativa en la capacidad de predicción en este contexto específico de decisiones de inversión.

Modelo KMeans

Cluster 0

	Cluster 0	Precision Clase 0	Precision Clase 1	Recall Clase 0	Recall Clase 1	F1-score Global	F1-score Clase 0	F1-score Clase 1
0	Regresión Logística	50%	52%	56%	46%	48%	53%	49%
1	Random Forest	51%	52%	53%	49%	50%	52%	51%
2	XGBoost	50%	51%	50%	51%	50%	50%	51%

En la evaluación de diferentes modelos en el contexto de clústeres, se observa un rendimiento cercano entre Regresión Logística, Random Forest y XGBoost. Estos modelos presentan precisiones y recalls equilibrados para ambas clases en el Cluster 0, con puntuaciones F1 que oscilan alrededor del 50%.

En particular, el Random Forest destaca ligeramente con un rendimiento general del 50%, mostrando una consistencia en precisiones y recalls tanto para la Clase 0 como la Clase 1 en comparación con los otros modelos.

Cluster 48

	Cluster 48	Precision Clase 0	Precision Clase 1	Recall Clase 0	Recall Clase 1	F1-score Global	F1-score Clase 0	F1-score Clase 1
0	Regresión Logística	80%	43%	50%	75%	54%	62%	55%
1	Random Forest	100%	50%	50%	100%	66%	67%	67%
2	XGBoost	100%	50%	50%	100%	66%	67%	67%

Al igual que en la Tabla 8, el modelo Random Forest destaca ligeramente con un rendimiento general del 50%, mostrando una consistencia en precisiones y recalls tanto para la Clase 0 como la Clase 1 en comparación con los otros modelos.

Cluster 42

	Cluster 42	Precision Clase 0	Precision Clase 1	Recall Clase 0	Recall Clase 1	F1-score Global	F1-score Clase 0	F1-score Clase 1
0	Regresión Logística	100%	33%	33%	100%	50%	50%	50%
1	Random Forest	100%	33%	33%	100%	50%	50%	50%
2	XGBoost	100%	50%	67%	100%	66%	80%	67%

En la evaluación de clúster 42, se destaca un rendimiento perfecto en Precision Clase 0 para Regresión Logística y Random Forest, alcanzando el 100%. Sin embargo, en Precision Clase 1, ambos modelos muestran un rendimiento inferior, limitándose al 33%.

XGBoost, por otro lado, presenta un rendimiento perfecto en Precision Clase 0 y una mejora sustancial en Precision Clase 1, alcanzando el 50%. Esto sugiere que XGBoost tiene una capacidad mejorada para identificar instancias de la Clase 1 en comparación con los otros modelos en el mismo clúster.

Aplicación de imblearn en modelo XGBoost

	Modelo	Precision Global	Precision Clase 0	Precision Clase 1	Recall Clase 0	Recall Clase 1	F1-score Clase 0	F1-score Clase 1
0	XGBoost Sin Hiperparámetros	51.23%	51%	53%	53%	51%	52%	52%
1	XGBoost con Hiperparámetros	52.0%	51%	53%	53%	51%	52%	52%
2	XGBoost con Hiperparámetros + Imblearn	53.0%	52%	54%	56%	50%	54%	52%

A partir de la siguiente comparación, podemos sugerir que tanto la optimización de hiperparámetros como el manejo del desequilibrio de clases tienen impactos positivos en el rendimiento del modelo XGBoost.

La inclusión de técnicas específicas para abordar el desbalance de clases, como las proporcionadas por Imblearn, ha llevado a una mejora adicional en la capacidad del modelo para clasificar ambas clases de manera más equitativa.

Significancia de los datos

Esto para abordar aquellos datos que sean muy significantes, o no sean significantes para 3 modelos

- Random Forest
- Gradient Boosting
- XGBoost
- SVM

Partiendo del análisis de importancia de características con XGBoost identifica las variables más influyentes. Con ello podemos realizar ingeniería de características, ejemplificada con 'ROA_NER_ratio' y 'PBR_BVPS_product', consiste en crear nuevas variables para mejorar la capacidad predictiva del modelo. Estas adiciones buscan optimizar la representación de las características y, por ende, la efectividad del modelo en la toma de decisiones.

Ingeniería de características en modelo XGBoost

	Modelo	Precision Global	Precision Clase 0	Precision Clase 1	Recall Clase 0	Recall Clase 1	F1-score Clase 0	F1-score Clase 1
0	XGBoost Sin Hiperparámetros	51.23%	51%	53%	53%	51%	52%	52%
1	XGBoost con Hiperparámetros	52.0%	51%	53%	53%	51%	52%	52%
2	XGBoost con Hiperparámetros + Imblearn	53.0%	52%	54%	56%	50%	54%	52%
3	XGBoost con Hiperparámetros e Ing. Características	53.0%	52.0%	54.0%	54%	52%	53%	53%

Podemos observar que el modelo XGBoost con Hiperparámetros e Ing. Características, muestra la mejoría más significativa en términos de Precision Global y métricas específicas de las clases. La introducción de técnicas como Imblearn y la ingeniería de características

contribuyen a un rendimiento más equilibrado y mejorado del modelo XGBoost en la tarea de clasificación.

Selección de variables para cada modelo

Partiendo de la significancia de los datos, tomamos la decisión de realizar cambios en las características de la variable X en distintos modelos con el objetivo de mejorar su rendimiento. La significancia de las características en un modelo refleja la contribución relativa de cada variable en la predicción de la variable objetivo.

	Modelo	Precision Global	Precision Clase 0	Precision Clase 1	Recall Clase 0	Recall Clase 1	F1-score Clase 0	F1-score Clase 1
0	Random Forest	51.18%	50%	52%	54%	49%	52%	50%
1	Random Forest diff X	53%	52%	54%	54%	52%	53%	53%
2	SVM	49.18%	49%	46%	99%	1%	66%	2%
3	SVM diff X	49%	49%	30%	99%	0%	66%	1%
4	XGBoost	51.23%	50%	52%	2%	99%	52%	51%
5	XGBoost diff X	53%	52%	54%	57%	48%	54%	51%
6	Gradient Boosting	52.10%	66%	53%	54%	51%	52%	52%
7	Gradient Boosting diff X	51%	50%	53%	76%	27%	60%	36%

Random Forest diff X parece ser el modelo más prometedor hasta el momento, ya que muestra un rendimiento sólido en términos de Precision, Recall y F1-Score para ambas clases. Sin embargo, es crucial considerar otros factores y realizar validación cruzada u otras técnicas de evaluación del modelo para confirmar la robustez y generalización de estos resultados.

Modelo Sectorial con Variables Categóricas en X

	0	1	2	3	4	5	6	7
Modelo Sectorial	Regresión Logística	Decision Tree	Random Forest	SVM	Naive Bayes	KNN	XGBoost	Gradient Boosting
Precision Global	51%	51%	49%	51%	52%	50%	51%	51%
Precision Clase 0	52%	51%	50%	51%	53%	50%	51%	51%
Precision Clase 1	52%	51%	50%	51%	54%	50%	51%	51%
Recall Clase 0	49%	54%	49%	51%	59%	49%	49%	53%
Recall Clase 1	55%	47%	51%	52%	47%	51%	53%	49%
F1-score Clase 0	50%	52%	49%	51%	56%	50%	50%	52%
F1-score Clase 1	53%	49%	51%	51%	50%	50%	52%	50%

En la evaluación de modelos sectoriales, se observa un rendimiento similar en términos de Precision Global entre los diferentes modelos, oscilando alrededor del 51%. No obstante, existen variaciones en las métricas específicas de las clases.

- Regresión Logística, Decision Tree, SVM, XGBoost y Gradient Boosting: Estos modelos muestran un rendimiento equilibrado en precisiones y recalls para ambas clases, con F1-scores en la misma línea.
- Random Forest y KNN: Aunque muestran precisiones y recalls razonables, destacan menos en comparación con otros modelos.
- Naive Bayes: Se destaca por una alta precisión en la Clase 1, pero con un recall más bajo.

1.6. Valoración de productos, resultados e impactos

Durante la experiencia del Programa de Aprendizaje Práctico (PAP), nos sumergimos en un análisis exhaustivo de las problemáticas identificadas en nuestro proyecto, centradas en el desarrollo de modelos de clasificación para la toma de decisiones en inversiones. A continuación, compartimos una valoración detallada de nuestra experiencia PAP, resaltando los resultados obtenidos y los impactos generados:

Desafíos Reconocidos:

Identificamos dificultades sustanciales en la capacidad de nuestros modelos para diferenciar de manera consistente entre escenarios propicios e imprudentes para la inversión. El análisis de las probabilidades asociadas a cada predicción reveló una homogeneidad entre clases, complicando la identificación de patrones claros para la toma de decisiones.

Reconocimiento de la Complejidad Intrínseca:

Concluimos que la complejidad intrínseca de prever con precisión cuándo es adecuado invertir es un desafío significativo. La falta de diferenciación en las probabilidades subraya la necesidad de abordar las variaciones sutiles que caracterizan las decisiones de inversión efectivas.

Importancia de la Identificación de Homogeneidad en las Probabilidades:

La identificación de la homogeneidad en las probabilidades se convirtió en un elemento clave de nuestra investigación. Este hallazgo, lejos de restar valor a nuestro trabajo, destaca la importancia crítica de comprender las limitaciones en el ámbito de la predicción financiera.


Perspectivas para la Reflexión y Mejora Continua:

Al percatarnos de las probabilidades homogéneas, obtenemos una perspectiva valiosa sobre la complejidad inherente a la tarea de diferenciar entre situaciones propicias e imprudentes para la inversión. Este descubrimiento proporciona una base sólida para la reflexión y mejora continua en futuras investigaciones y aplicaciones prácticas.

Aspectos Pendientes y Consideraciones para la Siguiente Etapa del PAP:

Se reconoce la necesidad de explorar en profundidad estrategias avanzadas de modelización y análisis de datos para mejorar la capacidad de discernimiento de nuestros modelos. Se sugiere la incorporación de expertos en finanzas en futuras etapas del PAP para enriquecer nuestra comprensión de las dinámicas del mercado. Estas consideraciones apuntan hacia una evolución estratégica que fortalezca la calidad y la aplicabilidad de nuestro enfoque en el análisis de decisiones de inversión.

Probabilidades de la Variable de Decisión



	0	1
count	7799.000000	7799.000000
mean	0.500196	0.499804
std	0.018392	0.018392
min	0.000276	0.000287
25%	0.500260	0.499242
50%	0.500576	0.499424
75%	0.500758	0.499740
max	0.999713	0.999724

1.7. Bibliografía y otros recursos

API Documentación | Alpha Vantage. <https://www.alphavantage.co/documentation/>

Meza, M. G. S. (2021, 16 diciembre). *Solo 2% de los mexicanos invierte en la bolsa; en EU, el 50%.* Forbes México. <https://www.forbes.com.mx/solo-2-de-adultos-en-mexico-invierten-en-eeuu-50/>

SMOTE — version 0.11.0. https://imbalanced-learn.org/stable/references/generated/imblearn.over_sampling.SMOTE.html

XGBoost Documentación — XgBoost 2.0.2 documentación.
<https://xgboost.readthedocs.io/en/stable/>

1.8. Anexos generales

Link del repositorio de Git Hub con los archivos usados en el proyecto:

- [Repositorio en Github](#)

Resultados Regresión Logística a partir de fundamentales etiquetados:

OLS Regression Results						
Dep. Variable:	Decision	R-squared:	0.002			
Model:	OLS	Adj. R-squared:	0.000			
Method:	Least Squares	F-statistic:	1.174			
Date:	Sun, 19 Nov 2023	Prob (F-statistic):	0.281			
Time:	13:02:20	Log-Likelihood:	-5632.0			
No. Observations:	7773	AIC:	1.130e+04			
Df Residuals:	7756	BIC:	1.142e+04			
Df Model:	16					
Covariance Type:	nonrobust					
	coef	std err	t	P> t	[0.025	0.975]
const	0.4897	0.023	21.295	0.000	0.445	0.535
ROA	-0.0070	0.009	-0.818	0.414	-0.024	0.010
ROE	0.0068	0.008	0.821	0.412	-0.009	0.023
NER	-0.0038	0.007	-0.542	0.588	-0.018	0.010
DER	0.0011	0.007	0.159	0.874	-0.013	0.015
CER	0.0139	0.007	1.887	0.059	-0.001	0.028
GMR	0.0029	0.007	0.398	0.691	-0.011	0.017
SOL	0.0021	0.007	0.283	0.777	-0.013	0.017
QR	-0.0117	0.007	-1.628	0.104	-0.026	0.002
BVPS	0.0086	0.007	1.195	0.232	-0.006	0.023
EPS	-0.0018	0.007	-0.243	0.808	-0.016	0.013
PE	0.0031	0.008	0.395	0.693	-0.012	0.019
EVS	0.0055	0.008	0.692	0.489	-0.010	0.021
EVEBI	0.0141	0.008	1.690	0.091	-0.002	0.030
ICR	0.0015	0.008	0.196	0.844	-0.014	0.017
PBR	-0.0058	0.008	-0.741	0.459	-0.021	0.010
OM	-0.0153	0.007	-2.059	0.040	-0.030	-0.001
Omnibus:	26967.658	Durbin-Watson:	2.015			
Prob(Omnibus):	0.000	Jarque-Bera (JB):	1283.023			
Skew:	-0.015	Prob(JB):	2.48e-279			
Kurtosis:	1.010	Cond. No.	17.6			

Notes:

[1] Standard Errors assume that the covariance matrix of the errors is correctly specified.

Resultados Regresión Logística a partir de fundamentales etiquetados después del Método Backward:

OLS Regression Results

Dep. Variable:	Decision	R-squared:	0.001
Model:	OLS	Adj. R-squared:	0.000
Method:	Least Squares	F-statistic:	4.671
Date:	Sun, 19 Nov 2023	Prob (F-statistic):	0.0307
Time:	13:02:22	Log-Likelihood:	-5639.0
No. Observations:	7773	AIC:	1.128e+04
Df Residuals:	7771	BIC:	1.130e+04
Df Model:	1		
Covariance Type:	nonrobust		
	coef	std err	t P> t [0.025 0.975]
const	0.5037	0.006	88.829 0.000 0.493 0.515
x1	0.0123	0.006	2.161 0.031 0.001 0.023
Omnibus:	26856.873	Durbin-Watson:	2.016
Prob(Omnibus):	0.000	Jarque-Bera (JB):	1292.388
Skew:	-0.015	Prob(JB):	2.30e-281
Kurtosis:	1.003	Cond. No.	1.00

Notes:

[1] Standard Errors assume that the covariance matrix of the errors is correctly specified.

2. Productos

Tras extensivas pruebas con diversos modelos de clasificación y la exploración de distintas combinaciones de fundamentales, así como ajustes de umbrales para la variable de decisión, concluimos que nuestros modelos enfrentan dificultades para distinguir consistentemente entre escenarios propicios e imprudentes para la inversión.

Esta conclusión se basa en el análisis de las probabilidades asociadas a cada predicción, revelando una homogeneidad entre clases que complica la identificación de patrones claros para la toma de decisiones. Este fenómeno resalta la complejidad intrínseca de prever con precisión cuándo es adecuado invertir. La falta de diferenciación en las probabilidades sugiere que nuestros modelos carecen de la capacidad necesaria para discernir las variaciones sutiles que caracterizan decisiones de inversión efectivas.

La identificación de la homogeneidad en las probabilidades se convierte en un elemento clave de nuestra investigación. En lugar de restar valor a nuestro trabajo, este hallazgo destaca la importancia de la comprensión de las limitaciones en el ámbito de la predicción financiera. Al percatarnos de las probabilidades homogéneas, obtenemos una perspectiva valiosa sobre la complejidad inherente a la tarea de diferenciar entre situaciones propicias e imprudentes para la inversión. Este descubrimiento proporciona una base sólida para la reflexión y mejora continua en futuras investigaciones y aplicaciones prácticas.

Archivo .py: Un archivo que contiene toda la parte automática de la descarga de datos de los fundamentales y sus rendimientos, este archivo se conecta a la API de Alpha Vantage para descargar el estado de resultados, balance general y flujo de caja, después hace el cálculo de cada fundamental junto con los rendimientos de cada empresa, por último, se hace la descarga de todos los datos a un archivo de Excel.

Jupyter notebook de descarga de datos: Este notebook se conecta al archivo .py donde solo tienes que especificar los tickers deseados y comenzar con la descarga hasta obtener el archivo de Excel.

Explicación del proyecto: En este notebook viene toda la explicación de que hizo durante el PAP, contiene análisis del proyecto y los aprendizajes obtenidos a partir de los resultados

obtenidos. El análisis incluye desde los fundamentales hasta los modelos clasificatorios que se usaron, todo con información detallada para que un futuro nuestro trabajo pueda servir de base.

3. Reflexión crítica y ética de la experiencia

El RPAP tiene también como propósito documentar la reflexión sobre los aprendizajes en sus múltiples dimensiones, las implicaciones éticas y los aportes sociales del proyecto para compartir una comprensión crítica y amplia de las problemáticas en las que se intervino.

3.1 Sensibilización ante las realidades

Nuestro proyecto tiene como enfoque ayudar al sector inversionista y contrarrestar la problemática que vivimos actualmente en nuestro país, ya que según Forbes, solo el 2% de población invierte en bolsa, no esperamos que con esto las personas tomen la decisión de invertir por cuenta propia, ya que las herramientas que estamos usando son complejas y requieren cierto nivel de comprensión, a lo que aspiramos es poder ayudar a las personas que ya tienen ese conocimiento y puedan usar lo aprendido en este PAP para tomar decisiones más conscientes sobre las inversiones, teniendo como efecto que un futuro se lleve a cabo una implementación de nuevas tecnologías dirigida a personas que decidan llevar su dinero a instituciones financieras y a su vez dar visibilidad que las decisiones que se tomen están fundamentadas.

3.2 Aprendizajes logrados

En si todo el PAP fue un reto, estuvo lleno de momentos donde requirieron una amplia investigación y análisis sobre los procesos que íbamos haciendo, logrando que en el proceso todos esos conocimientos que ya habíamos adquirido anteriormente en otras materias se consolidaran. Siendo un poco más específicos logramos como equipo agregar más conocimiento sobre modelos, la interpretación de estos y la exploración de métodos para optimizar dichos modelos enriqueciendo nuestro conocimiento.

A la hora de afrontar estos retos alrededor de nuestro tiempo ejecutando los procesos de nuestro proyecto tuve una propuesta reactiva, apoyándome fuertemente en el análisis para poder resolver los problemas.

Como aprendizajes en general del proyecto, enfocándonos en el ámbito profesional, creo que es bastante valioso todo lo que obtuvimos en la ejecución de nuestro proyecto, ya que lidiamos con un problema real, usando datos reales y afrontando problemas comunes que se tienen a la hora de lidiar con este tipo de información, asemejando un poco a lo que se ve en el día a día en sectores donde se analizan este tipo de casos. En cuanto a lo social creo que es valioso apreciar un aporte social que tienen las finanzas a la comunidad, el hecho de poder ayudar a la gente a iniciarse en la cultura financiera es muy enriquecedor a la hora de ver las conclusiones del proyecto.

- César Gerardo

A través del PAP, he experimentado un desarrollo en competencias disciplinares, sociales y universitarias. Al adentrarme en el trabajo con modelos de clasificación y la exploración enfocada en combinaciones de indicadores fundamentales, he fortalecido mi capacidad para enfrentar desafíos en los ámbitos profesional y académico.

En momentos desafiantes, especialmente al abordar las dificultades de nuestros modelos para diferenciar consistentemente entre escenarios óptimos e imprudentes para la inversión, me comprometí a buscar soluciones alternativas y ajustar estratégicamente nuestras metodologías. El proyecto ha proporcionado aprendizajes valiosos en el ámbito profesional, profundizando mi comprensión de las complejidades en la predicción financiera, y fortaleciendo mis habilidades sociales al colaborar con un equipo diverso. A nivel personal, el proceso ha fomentado mi capacidad de reflexión crítica y mejora continua.

La identificación de la homogeneidad en las probabilidades se convirtió en un punto crucial, resaltando las limitaciones de nuestros modelos y requiriendo un enfoque específico en la investigación y el análisis.

En conclusión, mi participación en el PAP ha sido una experiencia enriquecedora que ha contribuido significativamente al desarrollo de competencias esenciales. A pesar de los desafíos, la capacidad para abordarlos con determinación ha reforzado mi confianza en la resolución de problemas complejos, estableciendo las bases para un crecimiento continuo en mi carrera académica y profesional.

- Jesús Reyes

Este PAP me sirvió para aprender no solo conceptos financieros, si no la aplicación de estos conocimientos en la selección y evaluación de activos para la búsqueda de un rendimiento positivo. El proceso de trabajo en este proyecto de análisis financiero ha sido una experiencia llena de retos, obstáculos y desafíos que han definido determinación y perseverancia.

Inicialmente, la aplicación de fundamentales financieros, la limpieza y estandarización de datos, y la experimentación con diversos modelos de Machine Learning se presentaron como procesos cruciales para el éxito del proyecto. Cada parte del proyecto fue una pieza esencial donde intentamos perfeccionar y optimizar los resultados con diferentes técnicas.

En el ámbito del análisis financiero, donde las variables y los modelos están en constante evolución, la importancia de la adaptabilidad y la tolerancia al fracaso no pueden ser subestimadas. Este proyecto ha sido un recordatorio constante de que el verdadero aprendizaje a menudo ocurre en medio del fracaso. Cada modelo que no funcionó como se esperaba, cada análisis que no proporcionó las respuestas buscadas, fueron una lección en sí misma. Estos momentos de fracaso no solo me enseñaron qué no hacer, sino que también nos impulsaron a buscar nuevas formas, a veces más creativas y eficientes, de abordar el problema.

En conclusión, este proyecto no solo ha sido enfocado hacia la creación de una herramienta financiera más eficaz, sino que es un parteaguas para el futuro que sirve como base para desarrollar una solución sin partir desde cero. Considero que aprender de los errores es la verdadera clave para el éxito.

- Ana Aguilar

Los aprendizajes adquiridos durante todo el proceso, en lo personal fueron bastantes, el reto que implicó crear el proyecto desde cero y darnos cuenta de que no era algo fácil me impulsó a seguir, investigar y tratar de obtener los mejores resultados posibles, el querer generalizar el mercado es un trabajo muy complicado, de ahí los resultados que obtuvimos, pero al final de cuentas lo que descubrimos es un aporte muy valioso a la investigación y a futuros trabajos que puedan partir de lo aprendido en este.

En cuanto a la parte social, proyectos como este pueden generar un gran cambio ya que muchas veces nos da más confianza el pensar que gracias a tecnología estamos obteniendo resultados, no importa si las personas no entienden la lógica que hay detrás y por otro lado darle una herramienta de este tipo a personas que se dediquen a tomar decisiones financieras o de inversión puede facilitar el análisis entorno al mundo financiero que les ayuden a ser más productivos en su área.

- Rodolfo García