



Universidad de  
**San Andrés**

UNIVERSIDAD DE SAN ANDRÉS  
ESCUELA DE ADMINISTRACIÓN Y NEGOCIOS  
MAESTRÍA EN FINANZAS

**ANÁLISIS DEL FPI GS-WATCH  
PARA ANTICIPAR VOLATILIDAD EN ACCIONES**

Autor: Reyes, Lorenzo  
DNI: 36.868.478  
Director: Grosz, Fernando

Victoria, 2023

## Tabla de Contenidos

Glosario.....	4
1.Resumen Ejecutivo.....	5
2. Introducción.....	6
3. Modelo. Fundamento e Implementación .....	14
4. Backtest. VaR, CVaR, EVaR y FPI.....	20
5. Conclusiones .....	24
Referencias. ....	25
Anexo .....	26



Universidad de  
**San Andrés**

*A mi familia por siempre estar, a Charles Severance de Michigan por enseñarme Python, a Ricardo David Ortiz y Hector Ariel Fernández por su amistad en El Cuartito.  
A Pergamino, mi ciudad*



Universidad de  
**SanAndrés**

## Glosario

**Conditional Value at Risk (CVaR)** es la pérdida promedio por debajo del VaR. Otro nombre con lo que se conoce a esta métrica es el ETL (pérdida esperada o *Expected Tail Loss* por sus siglas en inglés).

**Entropic Value at Risk (EVaR)** es el límite superior del VaR y CVaR basado en la desigualdad de Chernoff.

**Failure Ratio** es una estadística utilizada para saber con seguridad la certeza de modelos de riesgo. Se obtiene al dividir cantidad de eventos capturados por sobre el total de observaciones.

**FPI (Financial Pressure Indicator)** es un cuantil referencia, desarrollado por Goldman-Sachs en 1994 por la crisis Tequila, con el fin de monitorear la volatilidad de economías emergentes para anticiparse ante escenarios de alta volatilidad.

**Test de Bernoulli** es una métrica estadística para saber la proporción de fallas del VaR para medir los excesos de fallas. Otros nombres que puede tener son *Coverage Test* o *Kupiec Test*.

**Test de Christoffersen o de independencia**, es una prueba que estudia la frecuencia de eventos inusuales en exceso, se usa para determinar en caso de riesgo la presencia de *clusters* de volatilidad.

**Value at Risk (VaR)** es el  $\alpha$ -cuantil de la distribución de retornos, y representa la mayor pérdida posible dado un nivel de significancia  $\alpha$ , en un horizonte temporal determinado y bajo condiciones de mercado normales.

# 1. Resumen Ejecutivo

El presente trabajo tiene como objetivo analizar la viabilidad del GS-Watch (1998) como alarma temprana para volatilidad de acciones bursátiles. La utilidad del GS-Watch es monitorear riesgo cambiario al anticipar una crisis macro como alarma temprana, es decir vigilar si se dan condiciones que justifiquen anticipar un evento. La pregunta que se plantea este trabajo es ver si la lógica aplica a nivel micro de una acción bursátil individual. Con el fin de contar con un mecanismo que monitoree la volatilidad individual, con el solo uso de la serie de precios y volumen del instrumento, para observar si la propia información sirve para monitorear a la acción, pensado para inversores aversos al riesgo.

El trabajo está estructurado de la siguiente manera: la Sección 2 comienza con una descripción del GS-Watch, al desarrollar qué contexto motivó su creación y cómo se lo diseñó. En la Sección 3- indica la elección para el fin de este estudio y cómo se debe implementar el modelo actual al remarcar sus diferencias respecto al diseño original. En la Sección 4 se presentan los resultados y se verifica qué acierto posee la métrica a través de un *backtest* en comparación con otros indicadores de riesgo. La Sección 5 concluye.

## 2. Introducción

El presente trabajo analiza al FPI GS-Watch como monitor de volatilidad de acciones individuales, para vigilar su evolución y anticiparse ante sus aumentos de volatilidad para defender una inversión en escenarios que amenacen su valor. La necesidad del presente trabajo es dada por la falta de un sistema de alarmas financieras en relación a acciones individuales, que sirvan como un parámetro objetivo que establezca señales para liquidar una inversión para así defenderse ante un evento de alta volatilidad que implique pérdidas en el valor de la inversión. El modelo original FPI GS-Watch surge ante la necesidad de percibir escenarios de alta volatilidad en economías emergentes, a través de estudiar la evolución de la moneda doméstica junto a las reservas del banco central para anticipar una corrida cambiaria; más adelante indagaremos en su historia y los cambios que se hicieron para aplicarlo en el ámbito de este presente trabajo.

De igual modo, este trabajo es fruto del episodio del Covid-19, caracterizado como un evento de alta volatilidad e incertidumbre en que los inversores no podían reaccionar ante tales situaciones. Bajo tal contexto, resulta necesario contar con una herramienta para detectar instancias de altas volatilidad de forma objetiva y poder vender posiciones, para protegerse de pérdidas si la política de inversión lo establece.

En relación a nuestra temática, podemos recurrir a la Hipótesis de los Mercados Eficientes de Fama (1970), que se basa en la premisa que el valor actual refleja toda la información de un activo, y, por el lado de predecir el valor futuro contamos con la implementación de indicadores técnicos. A modo de ilustrar, los argumentos anteriores son para justificar que la mayoría de temas tratados en la bibliografía no giran en torno a vigilar la volatilidad de una inversión, por eso se basa el interés de desarrollar el presente trabajo.

Para llevar a cabo tal propósito, debemos observar con qué métricas contamos a nuestra disposición para tal fin. En principio, recurrimos a dos tipos de metodologías, análisis técnico y fundamental. Ambas buscan estudiar el precio de un activo; podemos obtener su precio actual por análisis fundamental o su precio futuro por uso de indicadores técnicos. Acorde a nuestro objetivo, que es prestar atención a la volatilidad, encontramos al RSI<sup>1</sup> (Índice de Fuerza Relativa, por sus siglas en inglés *Relative Strength Index*) y a la Parabólica SAR<sup>2</sup> (Parábola de Parar-Y-Revertir, por sus siglas en inglés de *Stop-And-Reverse*) por parte del análisis técnico (ambas desarrolladas por James Welles Jr. en 1978), que por propio diseño busca capturar el cambio de tendencia en un activo sin atender el riesgo del mismo, como pretendemos analizar en nuestro trabajo. En contraste, podemos recurrir al análisis fundamental que cuenta con dos métricas en relación con el riesgo, el VIX<sup>3</sup> y el VaR<sup>4</sup>. El primero es una medida para obtener la volatilidad mensual del mercado como referencia de volatilidad actual en el sistema bursátil; mientras que el VaR (*Value-at-Risk* o Valor-Puesto-en-Riesgo) busca reflejar la capacidad de pérdida de una inversión en situaciones normales. Tales fórmulas sirven para tener una noción de riesgo o la capacidad de pérdida que esperaríamos obtener; sin embargo, no sirven como alarmas que dicten deshacerse de la inversión para protegerse de un escenario de alta volatilidad acorde a nuestra necesidad de estudio.

Por los motivos explicados, se ha optado por la herramienta de Goldman Sachs FPI GS-Watch. El desarrollo del FPI fue impulsado a fin de monitorear la situación macroeconómica de los países de Latinoamérica para proteger inversiones en distintas monedas que estaban sujetas a riesgos cambiarios por el contexto internacional (una referencia a tal trabajo fue entender el “Efecto Tequila” de 1994 y su contagio). Con ese diseño en mente se hace hincapié a las fluctuaciones que

---

<sup>1</sup> Es un oscilador que se obtiene como la sumatoria de cambios positivos y negativos en el precio del activo, para generar un balance que servirá como indicador de si el activo estudiado en cuestión acumula periodos de mucha compra o venta, para determinar si hubiera una situación alcista o bajista.

<sup>2</sup> Es un indicador con el fin de determinar la dirección del precio de un activo en cuestión, como así posibles puntos de compra o venta para la toma de decisión que son considerados puntos de reversión de la tendencia. Busca capturar el precio con una referencia a su tendencia que será el precio móvil más un acelerador que incrementará el punto de referencia bajo un supuesto que la tendencia tiene una vida y se revertirá.

<sup>3</sup> El VIX es un instrumento creado por el CBOE (*Chicago Board of Trade*) ante la necesidad de tener un índice de volatilidad, que refleje la amalgama de futuros a expirar dentro de 30 días con su esperanza de ser ejecutados.

<sup>4</sup> El VaR es una métrica de riesgo que cuantifica cuanto sería la posible máxima pérdida que sufriría una inversión en un horizonte temporal dado, con un determinado nivel de confianza, y es usado para manejar el nivel de exposición de riesgo de una inversión.

tiene la moneda doméstica y las reservas propias del Banco Central, se observa el comportamiento de ambos factores y se determina la estabilidad de la economía como capacidad de responder a una corrida bancaria.

La lógica del modelo tiene como fin identificar momentos de "crisis financieras", entendidas como instancias de alta volatilidad en que el indicador diagnostica una volatilidad actual que supera un punto crítico y activa la alarma, al identificar tal evento como crisis<sup>5</sup>; en síntesis el indicador se activaría al identificar momentos de alta volatilidad en comparación a la historia del activo. En retrospectiva, con tal diseño en mente se construye un Índice de Presión Financiera (FPI, por sus siglas en inglés), que utiliza la serie de precios y la serie de volumen respecto a un activo, y analiza la evolución de ambos para estudiar su disparidad entre sí. A los datos se le realiza el siguiente proceso: primero se saca la serie de retornos respecto al factor precios y se convierte en términos absolutos. En segundo término, se hace el mismo proceso con la serie del factor volumen, pero esta serie debe ser normalizada con un ajuste de volatilidad a fin de poder comparar ambos factores; una vez aplicado el ajuste de volatilidad al factor volumen se transforma la serie a valores en negativos para así contrastarlos con la serie de precios. Como resultado, tenemos dos términos: precio en positivo y volumen en negativo. Como último paso se resta a la serie precios la serie volumen, para obtener la disparidad entre ambos que diagnosticará la volatilidad del activo.

Resulta necesario aclarar que el ajuste de volatilidad se hace considerando los últimos tres meses, más específicamente 60 días hábiles, al generar una media móvil de cada factor. Esto se debe ya que se busca un horizonte temporal de tres meses en que el valor sea válido, en expectativa que sirva a tres meses tener un punto crítico.

La fórmula es la siguiente:

$$FPI = |\delta P| - \left| \left( \frac{P_{SMA\sigma}}{V_{SMA\sigma}} \right) * \delta V \right|$$

---

<sup>5</sup>El indicador provee dos series, una el valor actual de la serie y la otra el punto crítico (obtenido como tres desvíos estándares de la serie del indicador más su media). Si el valor actual del indicador supera el punto crítico será causal para activar la alarma.



donde:

$|\delta P|$  = Es el Factor Precio, se usa el computo de los cambios porcentuales de la serie de precios del activo en valores absolutos.

$\left(\frac{P_{SMA\sigma}}{V_{SMA\sigma}}\right)$  = Ajuste de volatilidad. Se construye a partir de dividir a la volatilidad respecto a la media móvil de sesenta días de la serie precios, por la respectiva media móvil de sesenta días de la serie volumen.

$\delta V$  = Es la serie de cambios porcentuales respecto a la serie volumen.

$-\left|\left(\frac{P_{SMA\sigma}}{V_{SMA\sigma}}\right) * \delta V\right|$  = Es el Factor Volumen. Obtenido tras aplicar el ajuste de volatilidad a la serie de cambios porcentuales de la serie volumen, se pasa la serie a valores absolutos y, por último, a negativo para poder contrastarlo con el Factor Precio.

Así se aspira monitorear la fortaleza del país (al ser un indicador macroeconómico, estudia la viabilidad de una crisis en un país) ante distintas circunstancias que puedan representar un peligro para la estabilidad financiera. Se determina una circunstancia de crisis,  $A_t$ , que se define como

$$A_t = \begin{cases} 1 & \text{si } FPI_t > \overline{FPI} + 3\sigma_{FPI} \\ 0 & \text{sino} \end{cases}$$

El FPI tiene mayores consideraciones, como son:


- (1) la situación del mercado financiero.

- (2) la facilidad de crédito en el País.
- (3) la apreciación real de la moneda.
- (4) Nivel de exportaciones.
- (5) la necesidad de financiamiento externo.
- (6) reservas internacionales.
- (7) riesgo político.
- (8) liquidez global.
- (9) efecto contagio.

En suma, el índice suma factores domésticos, externos y globales para obtener una probabilidad de riesgo, que será interpretada como una alarma temprana de crisis.

Sin embargo, dado el diseño actual del trabajo que aspira poder contar con un método de alarmas para acciones, debemos adaptar el modelo con la información disponible. Para eso, nos detendremos a tres datos con los que contamos; la información respecto a la serie de tiempo del precio, del volumen y del total acciones del activo bajo análisis. La restricción resulta en un beneficio, ya que tenemos que ser capaces de contar con un monitor con poca información y que sea práctico de utilizar. Por lo tanto, contamos con un indicador simplificado con la esencia del modelo original. Para ilustrar, en un caso práctico aplicado al índice S&P 500 en los últimos 20 años, podemos observar el Gráfico 1.


Gráfico 1: Evolución del Índice S&P 500 (símbolo ^GSPC).



Nota: elaboración propia en base a datos del índice S&P 500 2003-2023. Ver anexo 1. En azul puede observarse el precio histórico del índice y sus señales producidas por el indicador, en color rojo son alarmas por factor precio y en verde por factor volumen.

Universidad de  
San Andrés

Gráfico 2: Serie FPI del S&P 500 2003-2023 con sus respectivas señales



Nota: Elaboración propia. En azul se observa la serie del FPI respecto al S&P 500 con sus respectivos puntos críticos del Factor Precio, en rojo, y Factor Volumen, en amarillo. Ver anexo 1.

El primer gráfico corresponde a la serie de precios histórica del índice S&P 500, símbolo bursátil  $\wedge GSPC$ , que muestra todos los episodios de alarmas. Es decir, se remarca todo momento en que la presión financiera del periodo actual superó al promedio del indicador más 3 desvíos estándares. Se pueden identificar los eventos relacionados como la crisis del 2008, COVID-19 y el efecto ocasionado por la invasión a Ucrania en 2022. Tales episodios están registrados ya que el FPI actual de la serie ha superado la variable crisis, registrado como alarmas. Cada marca en el primer gráfico se puede ver en el segundo gráfico, donde se muestra en detalle la serie del FPI diario y los puntos críticos por precio y volumen. Cada vez que el FPI actual supere el punto crítico de referencia será instancia para activar la alarma.

En suma, la finalidad de este trabajo será poner a prueba al indicador GS-Watch para predecir volatilidad en acciones. Se hará referencia a la Eficiencia de los Mercados como así a los indicadores técnicos, con la distinción de elaborar un sistema para observar su viabilidad como

alarma ante el comportamiento volátil en el mercado. En lo que respecta a la metodología, los procesos ilustrados se desarrollarán en el lenguaje de programación Python, y se hará un análisis de los resultados obtenidos para determinar su eficiencia y qué posibles lecturas pueden realizarse.



Universidad de  
**SanAndrés**

### 3. Modelo. Fundamento e Implementación

En esta sección, se tratará el modelo propuesto en aras de probar su viabilidad respecto a su objetivo. Debemos hacer mención al modelo original para así explicar los cambios pertinentes y poder justificarlos. Respecto al modelo actual, plantea la evolución del precio y volumen de un activo, y los contrarresta entre sí, a fin de observar la relación de disparidad entre ambos factores como posibles señales de crisis. Se toma como referencia la evolución de esta serie de disparidad como objeto de estudio para diagnosticar una situación de estrés financiero y se genera un punto crítico para delimitar instancias para activar la alarma, un cuantil dado por su media más tres desvíos estándares. Como resultado obtendremos la serie del FPI, o Indicador de Presión Financiera acorde a Goldman Sachs, que se expandirá y contraerá reflejando la serie de evolución de la disparidad, y serán motivo de alarma las instancias de gran disparidad que den lugar a una alarma. Recordemos la definición de FPI:


$$FPI = |\delta P| - \left| \left( \frac{P_{SMA\sigma}}{V_{SMA\sigma}} \right) * \delta V \right|$$

mientras que la variable de alarma,  $A_t$ , se define como

$$A_t = \begin{cases} 1 & \text{si } FPI_t > \overline{FPI} + 3\sigma_{FPI} \\ 0 & \text{sino} \end{cases}$$

A modo ilustrativo, se muestra la serie del FPI con su punto de quiebre para activar la alarma aplicado al Índice S&P 500 (^GSPC) respecto los últimos 20 años:


Gráfico 3: Serie FPI del S&P 500 2003-2023 y Punto Crítico del Factor Precio



Nota: Aplicación del FPI GS-WATCH Original al índice S&P 500 en los últimos 20 años. Se remarca la serie del indicador en azul y los puntos críticos en rojo. Elaboración propia. Ver anexo I.

Una primera observación a destacar es que el indicador dispone la serie del FPI y el punto crítico positivo, no así el lado negativo de la muestra que puede servir para capturar señales también. Bajo tal cambio, podemos obtener así el siguiente gráfico:

Gráfico 4: Serie FPI del S&P 500 2003-2023 con Factor Precio y Factor Volumen



Nota: Aplicación del FPI GS-WATCH al índice S&P 500 con la incorporación del punto crítico negativo en amarillo. Elaboración propia. Ver anexo 1.

Ante la apreciación actual se tiene en cuenta que la crisis puede detectarse por sus dos componentes, tanto por el Factor Precio, como se hacía en el modelo original, más el Factor Volumen. Tal cambio se justifica ya que la serie puede capturar señales al considerar que cada término de la fórmula es sujeto de producir señales, por lo que interesa capturar si tal factor supera ciertos niveles. Con esta nueva perspectiva podemos tener en cuenta los siguientes datos a analizar:


- (1) Alarma.** Es la esencia del indicador, se obtiene en cada instancia en que la serie diaria supera un punto crítico. Si nos remitimos al modelo original, el mismo hace hincapié a tal situación y establece, a partir de mayores variables macroeconómicas, hacer un modelo logístico para la probabilidad del evento; sin embargo, en el presente trabajo descartamos tal proceso por carecer de tales variables en el plano individual de una acción.



- (2) Valor FPI Actual y sus Puntos Críticos.** Dato dado por la serie misma y a partir de la misma puede calcularse su punto de quiebre (su media más tres desvíos).
- (3) Volatilidad Diaria y Punto Crítico.** Por medio de la serie del indicador tenemos la volatilidad de la serie misma y la correspondiente al punto crítico.
- (4) Posibles lecturas.** Quedará al libre criterio de cada profesional cómo utilizar la métrica; si uno espera que la serie iguale un punto de quiebre para activar la alarma o que supere un rango la volatilidad preestablecida como zona de tolerancia.

La suma de las observaciones puede ser ilustrada en el siguiente gráfico:

*Gráfico 5: Componentes del FPI en términos absolutos del Índice S&P 500*




*Nota: Se ilustran en azul el Factor Precio, en términos absolutos, y contrarresta en rojo el Factor Volumen. Debe aclararse que se ha distanciado ambos componentes de 0 para así visualizarlos con mayor claridad. Elaboración propia. Ver anexo 1.*

En base a tales datos podemos formar el indicador de presión financiera. Se puede apreciar la discordancia que existe entre ambos componentes, que se traduce en la relación de disparidad entre ambos. En consecuencia, podemos crear el indicador y sus respectivos puntos de referencia con

rezago, debido a que la idea que motivó el modelo era poder tener una referencia de volatilidad proyectada a tres meses. A modo ilustrativo, ajustamos el siguiente gráfico con su versión corregida.

Gráfico 6: Serie diaria del FPI más sus respectivas señales críticas con rezago temporal de 3 meses



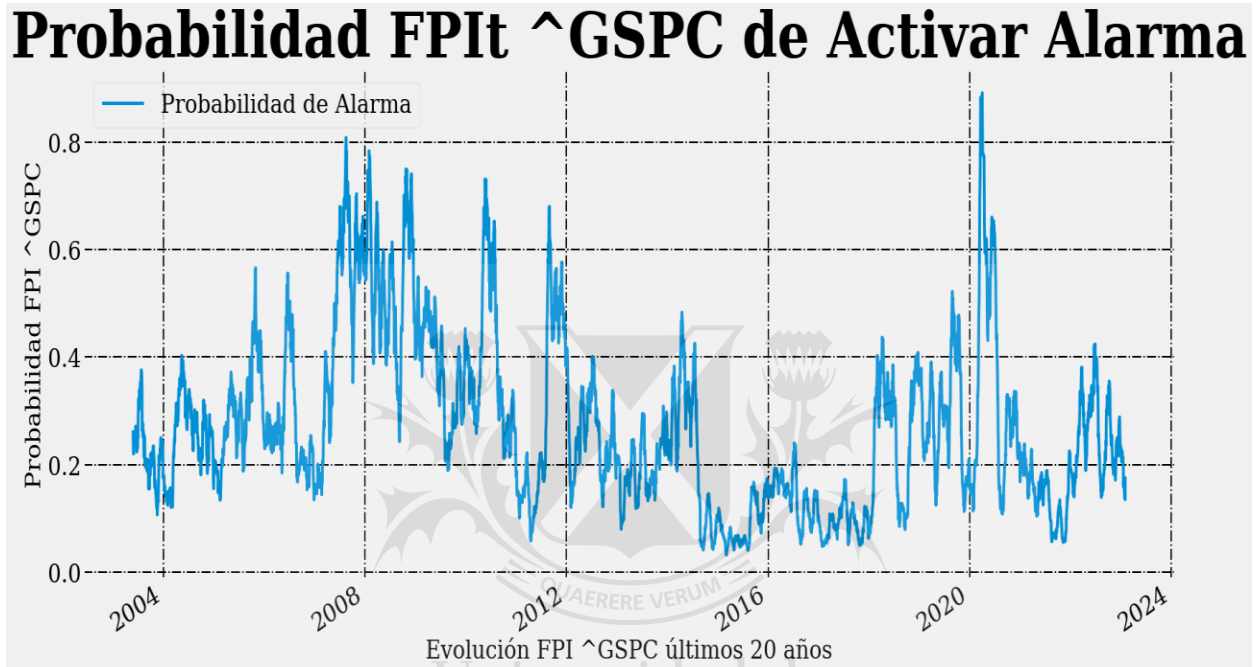
Nota: Se ilustra la serie de retornos del FPI más sus puntos críticos (la media más tres desvíos estándares) tanto para el Factor Precio, en rojo, como el Factor Volumen, en amarillo. Elaboración propia. Ver anexo 1.

En la ilustración, se puede corroborar la lógica de la métrica, con el indicador en valores diarios y el punto crítico con rezago temporal. En relación con esto se evidencia que el indicador que varía y se alteran sus puntos de referencia para las alarmas tempranas. A su vez, también se puede capturar el rol que tiene el volumen para la métrica, al apreciar las señales del lado negativo de la serie.

Otro aspecto a tener en cuenta, si tomamos los valores del indicador en términos absolutos y lo proporcionamos con el punto de referencia de crisis podemos obtener un porcentaje de cuanta

volatilidad presente corresponde a la necesaria para derivar en una crisis, que también puede interpretarse como la distancia de la volatilidad actual respecto de la necesaria para activar una alarma.

Gráfico 7: Serie diaria del FPI actual en proporción a su alarma



Nota: Tal relación se obtiene al dividir el valor absoluto de la serie respecto al punto de alarma. Se interpreta como cuanto del riesgo actual representa respecto al nivel necesario para activar la alarma. Elaboración propia. Ver anexo 1.

En otra perspectiva, podemos observar la propia fluctuación de la evolución del punto de crisis. Así la expansión-contracción de los niveles de riesgo por sí mismo diagnostican la volatilidad propia del activo. En sintonía con tal visión, estaría a la interpretación de cualquier inversor establecer niveles de riesgo como referencia de tolerancia, con la función de advertir el estado de volatilidad actual y delimitar asunciones en la toma de riesgo.

## 4. Backtest. VaR, CVaR, EVaR y FPI

En esta sección se aplicarán dos pruebas, el *test* de Kupiec o Bernoulli y el *test* de Christoffersen o de independencia, en aras de contrastar su desempeño en medidas como el VaR, CVaR y EVaR para evaluar el riesgo de un activo. Respecto a la metodología, se replicará en parcialidad una Jupyter Notebook del blog Financieroncias (Cajas del 6 de Febrero de 2021) para realizar el *backtest*, con la adaptación de integrar el FPI propuesto de este trabajo. Por último, se someterán estas métricas a una serie de índices globales como activos individuales, como son los siguientes:

- (1) 4 Índices: S&P 500 (^GSPC), Dow Jones (^DJI), NASDAQ (^IXIC) y Russell 2000 (^RUT).
- (2) 4 Acciones: Apple (AAPL – Sector Tecnológico), Ford (F – Sector Automotriz), Marriott (MAR – Sector Hotelero) y Walmart (WMT – Sector Consumo Defensivo).

El uso de las métricas a comparar se debe a que son referencias, cada una con sus debidas diferencias, para medir el riesgo. Es válido aclarar que utilizamos una muestra temporal de los activos mencionados bajo un periodo de 20 años con frecuencia diaria, 2003 a 2023. Una vez obtenida la data aplicamos las debidas fórmulas de la siguiente manera:

- VaR o *Value-at-Risk*: se define como un alpha-cuantil respecto a la distribución de retornos, busca representar la mayor pérdida posible dado el alpha-cuantil empleado en un horizonte temporal. La fórmula en código Python es:

$$VaR = (\mu - z * \sigma)$$

- CVaR o *Conditional-Value-at-Risk*: es la pérdida promedio por debajo del VaR. Obtenido por:

$$CVaR = (\mu - \sigma * stats.norm.pdf(z)/\alpha)$$

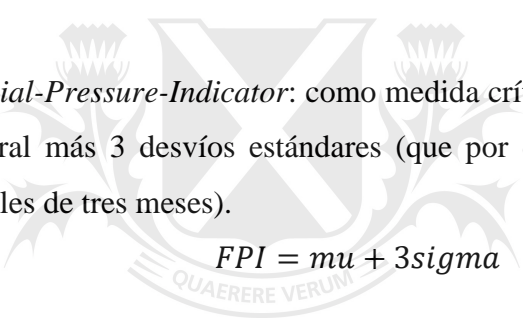
*stats.norm.pdf* es la función de probabilidad de densidad (*Probability Density Function*, por sus siglas en inglés). En este caso es la función de probabilidad de densidad con un  $z$  cuyo valor es del 95%.

Otro nombre con lo que se conoce a esta métrica es el ETL (pérdida esperada o *Expected Tail Loss* por sus siglas en inglés).

- EVaR o *Entropic-Value-at-Risk*: captura la volatilidad, la incertidumbre y patrones no lineales en los datos financieros, a través de análisis de información de entropía al castigar la incertidumbre

$$EVaR = \mu - \sigma * \sqrt{(-2 * \log(\alpha))}$$

- FPI o *Financial-Pressure-Indicator*: como medida crítica dada por el cuantil de la media muestral más 3 desvíos estándares (que por diseño son obtenidos como desvíos móviles de tres meses).

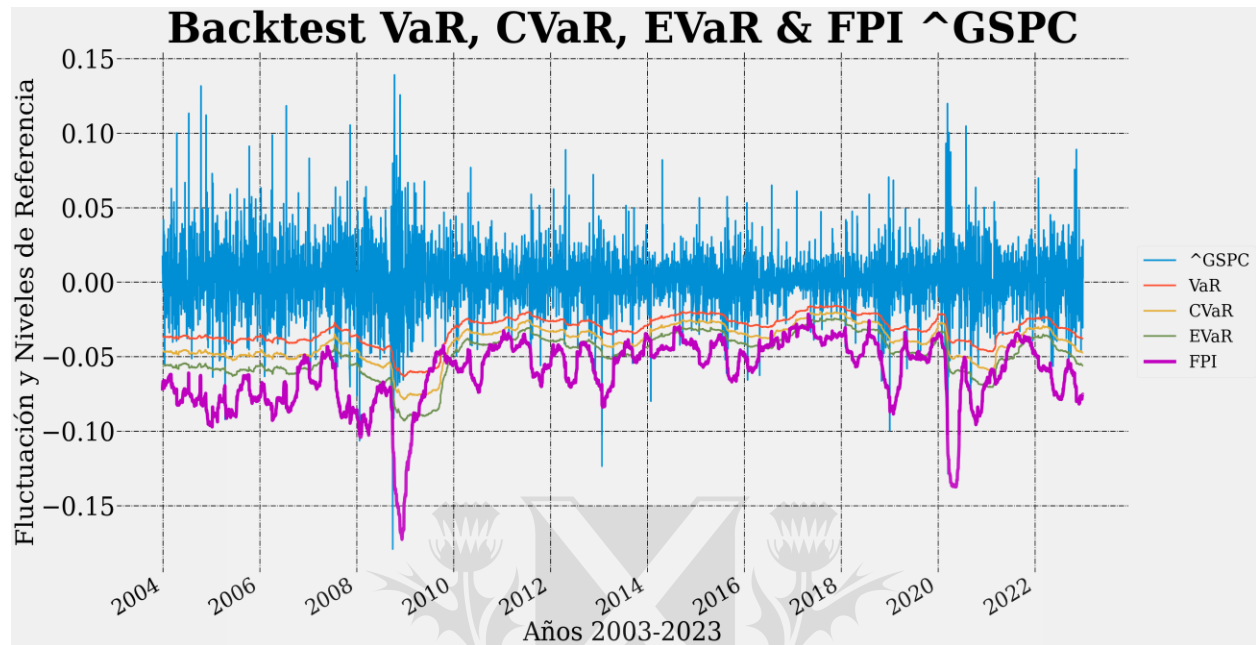

$$FPI = \mu + 3\sigma$$

Universidad de

San Andrés

Al aplicar dichas métricas a los activos, podemos obtener la siguiente ilustración:

Gráfico 8: Serie retornos S&P 500 para el periodo 2003-2023, con las métricas VaR, CVaR, EVaR y FPI



Nota: Serie Retornos S&P 500 en azul, VaR en rojo, CVaR en amarillo, EVaR en verde y FPI violeta. Elaboración propia. Ver anexo 2. Datos obtenidos a través de Yahoo Finance, para el periodo 01/01/2003 a 01/01/2023, con una frecuencia diaria. Los precios de las acciones están homogeneizados por el pago de dividendos.

Ahora bien, debemos realizar a las observaciones de la muestra los respectivos tests para corroborar qué tan efectivos son. Se emplean test de Bernoulli y test de Christoffersen<sup>6</sup> al ser métricas de riesgo<sup>7</sup>. La siguiente tabla es resumen de los 8 activos en estudio durante el periodo 2003-2023:

<sup>6</sup> Los estadísticos de Bernoulli y Christoffersen tienen una distribución chi cuadrado con un grado de libertad.

<sup>7</sup> El test de Bernoulli examina la cantidad de veces que se ha infringido el VaR para un periodo de tiempo, mientras que test de Christoffersen examina que tan frecuente son los excesos de tales eventos para así determinar si hay clusters de volatilidad o que la métrica tiene independencia y puede identificar el evento de forma aislada.

Tabla 1: Valores p de los tests de Bernoulli y Christoffersen

	^GSPC	^DJI	^IXIC	^RUT	F	AAPL	MAR	WMT
Failure Ratio VaR	0.069	0.060	0.067	0.057	0.070	0.068	0.065	0.065
Failure Ratio CVaR	0.044	0.04	0.039	0.036	0.045	0.045	0.041	0.04
Failure Ratio EVaR	0.031	0.024	0.025	0.022	0.03	0.028	0.029	0.03
Failure Ratio FPI	0.021	0.015	0.012	0.016	0.019	0.024	0.024	0.025
Bernoulli Test VaR p-value	<0.001	0.002	<0.001	0.029	<0.001	<0.001	<0.001	<0.001
Bernoulli Test CVaR p-value	0.066	<0.001	<0.001	<0.001	0.135	0.089	0.004	0.009
Bernoulli Test EVaR p-value	<0.001	<0.001	<0.001	<0.001	<0.001	<0.001	<0.001	<0.001
Bernoulli Test FPI p-value	<0.001	<0.001	<0.001	<0.001	<0.001	<0.001	<0.001	<0.001
Independent Test VaR p-value	0.0178	0.0108	0.0000	0.0012	0.0002	0.0862	0.2619	0.1686
Independent Test CVaR p-value	0.40	0.083	0.022	0.002	0.000	0.023	0.323	0.069
Independent Test EVaR p-value	0.486	0.451	0.001	0.002	0.000	0.007	0.022	0.112
Independent Test FPI p-value	0.091	0.130	0.042	0.040	0.002	0.081	0.188	0.011

Elaboración propia. Ver anexo. "F" es Ford, "AAPL" es Apple, "MAR" es Marriott y "WMT" es Walmart.

Se puede observar en suma, que el FPI tiene un *Failure Ratio* menor para índices accionarios y para Ford, pero no así en el resto de acciones; esto justificaría el uso del FPI al menos para índices bursátiles. La métrica *Failure Ratio* consta en medir los excesos de fallas en las observaciones (el cómputo es cantidad de eventos sobre la cantidad de observaciones) para así tener una referencia de fiabilidad de los resultados. Por otro lado, los estadísticos de Bernoulli y Christoffersen demuestran que se rechaza la hipótesis nula. Respecto a los *test* de Bernoulli rechazar la hipótesis nula implica una violación del VaR, mientras que el *test* de Christoffersen estudia si el evento es independiente, si no hay independencia como es el caso se concluye que hay *clusters* de volatilidad en estas estimaciones y no puede ser una métrica que obtenga un dato significativo para la toma de decisiones.

## 5. Conclusiones

En base al presente estudio podemos observar que la tabla nos diagnostica la presencia de *clusters*, que nos permite concluir que no hay independencia y habría que investigar más a fondo los *clusters de volatilidad*. Este hecho importa ya que el evento estudiado no puede ser identificado de forma aislada y así el presente planteo no sería de un estudio de gran utilidad.

A modo de reflexión para futuros trabajos, el presente escrito se dedicó de forma exclusiva a comprobar si la métrica servía como alarma de volatilidad. Como una posible investigación futura, se podría analizar si al momento de desactivarse la alarma sería oportuno retomar las posiciones en la inversión liquidada por la activación de la alarma, o verificar una circunstancia oportuna para hacerlo a partir de la información del indicador. Tal observación podría tratar sobre una estrategia de inversión ante clusters de volatilidad.

En suma, el indicador FPI propuesto puede servir para la gestión de inversión en aras de contar con referencias para determinar altos niveles de volatilidad y así reaccionar para proteger una inversión antes tales situaciones. Queda a criterio del lector implementar el indicador como se propone en el presente trabajo o introducir cambios en base a sus preferencias o necesidades.

Universidad de  
San Andrés



## Referencias

Ades, A., Masih, R., & Tenengauzer, D. (1998). *GS-Watch: A New Framework for Predicting Financial Crises in Emerging Markets*. New York: Emerging Markets Economic Research.

Cajas, D. (2021). Backtesting Value at Risk with Python. *Financioneruncios*. Consultado en: <https://financioneruncios.wordpress.com/2021/02/06/backtesting-var-cvar-evar-garch-and-ewma/>

Christoffersen, P. (1998). Evaluating interval forecasts. *International Economic Review*, 39(4), 841–862.

Fama, E. F. (1970). Efficient Capital Markets: A Review of Theory and Empirical Work. *The Journal of Finance*, 25(2), 383–417. <https://doi.org/10.2307/2325486>

Kupiec, P. (1995). Techniques for verifying the accuracy of risk measurement models. *Journal of Derivatives*, 2(2), 173–184.

Wilder, J. W. (1978). *New Concepts in Technical Trading Systems*. Hunter Publishing Company.



# ANEXO 1

A continuación se describe el código `fpi_gswatch.py`

---

```
import yfinance as yahoo
import pandas as pd
import datetime as dt
import numpy as np
import scipy.optimize as sco
from scipy import stats
import matplotlib.pyplot as plt
from pylab import mpl
mpl.rcParams['font.family'] = 'serif'
plt.style.use('fivethirtyeight')

stock = input('Ticket to test?\t\t\n\n')
data = yahoo.download(stock,period="max")
volume = (yahoo.Ticker(stock)).get_info()['volume']

price = data['Adj Close'].pct_change()
vol = data['Volume']
vol /= volume
vol = vol.pct_change()

price_mon, vol_mon = price.rolling(5,min_periods=1).mean(),
vol.rolling(5,min_periods=1).mean()

volatility = (price.rolling(60,min_periods=1).std() / vol.rolling(60,min_periods=1).std())
volatility = volatility.replace([np.inf, -np.inf], np.nan)
volatility = volatility.dropna()

fpi = abs(price_mon) - (volatility * abs(vol_mon))
fpi = fpi.dropna()
fpi_mean = fpi.replace([np.inf, -np.inf], np.nan).mean()
```

```

sigma3 = fpi.rolling(60,min_periods=1).std() * 3

watch = pd.DataFrame(index=fpi.index)
watch['serie'] = fpi.values#.rolling(20,min_periods=1).mean()
# generamos señales condicionales de 1, 2 y 3 std Indicio de crisis, Crisis y Megacrisis
watch['crisis'] = 0
watch['crisis'][:] = np.where(watch.serie > ((fpi.rolling(60,min_periods=1).mean()) + sigma3),
1.0, None)
crisis = watch[watch.crisis>=0].index.to_list()

fig = plt.figure(figsize=(25,12))
ax1 = fig.add_subplot(111)
plt.scatter(data.loc[crisis].index,data.loc[crisis]['Adj Close'],marker='X',c='crimson',s=1600)
plt.plot(data['Adj Close'],alpha=0.8)
ax1.set_title(f'FPI Signaling {stock}', fontsize=50, fontweight='bold')
ax1.grid(True,color='k',linestyle='-',linewidth=2)
ax1.legend(loc='center left', bbox_to_anchor=(1, 0.5),fontsize=30)
plt.xticks(size=30)
plt.yticks(size=30)

indicator = pd.DataFrame(fpi,columns=['FPI t'], index=fpi.index)
indicator['FPI + 3σ FPI'] = (fpi.rolling(60,min_periods=1).mean()) + sigma3

fig = plt.figure(figsize=(25,12))
ax1 = fig.add_subplot(111)
indicator.plot(ax=ax1,lw=8)
ax1.set_title(f'FPI t vs Crisis Signal', fontsize=50, fontweight="bold")
ax1.grid(True,color='k',linestyle='-',linewidth=2)
ax1.legend(loc='center left', bbox_to_anchor=(1, 0.5),fontsize=30)
plt.xticks(size=30)
plt.yticks(size=30)

```

## ANEXO 2

Backtest. Conjunto de todos los calculos aplicados para recrear el FPI

FPI\_backtest.ipynb (Jupyter Notebook)

### 2 Backtest de VaR, CvaR, EvaR & FPI

#### 2.1 Descarga de Datos y seteo variables primarias

```
import yfinance as yahoo
import pandas as pd
import datetime as dt
import numpy as np
import scipy.optimize as sco
import scipy.stats as stats
import matplotlib.pyplot as plt
from pylab import mpl
mpl.rcParams['font.family'] = 'serif'
plt.style.use('fivethirtyeight')
import warnings
```

```
warnings.filterwarnings("ignore")
```

```
# Rangos 01/01/2003 - 01/01/2023
start = '2003-01-01'
end = '2023-01-01'
```

```
# Lista de Activos
```

```
assets = ['^GSPC', '^DJI', '^IXIC', '^RUT', 'F', 'AAPL', 'MAR', 'WMT']
```

```
# Descargamos la data
```

```
data = yahoo.download(assets, start = start, end = end)
volume = data.loc[:, ('Volume', slice(None))]
close = data.loc[:, ('Adj Close', slice(None))]
close.columns, volume.columns = assets, assets
ret = close.pct_change().fillna(0)
vol = volume.pct_change().fillna(0)
```

```
ret, vol
```

```
[*****100%*****] 8 of 8 completed
(      ^GSPC  ^DJI  ^IXIC  ^RUT  F  AAPL \
      Date
2003-01-02  0.000000  0.000000  0.000000  0.000000  0.000000  0.000000
2003-01-03  0.006754 -0.026157  0.007346 -0.031007 -0.000677 -0.000484
2003-01-06  0.000000  0.040290 -0.009918  0.003800  0.019982  0.022474
2003-01-07 -0.003352  0.005958 -0.000295  0.005379 -0.003759 -0.006545
2003-01-08 -0.020205 -0.011846 -0.011199 -0.009314 -0.016621 -0.014086
```

2022-12-23	-0.002798	0.004421	0.009238	0.002021	0.005342	0.005868
2022-12-27	-0.013878	-0.014084	-0.001548	0.000278	0.001133	-0.004050
2022-12-28	-0.030685	-0.022321	-0.018537	-0.017523	-0.011006	-0.012021
2022-12-29	0.028324	0.053881	0.016277	0.006087	0.010497	0.017461
2022-12-30	0.002469	0.007799	0.006217	-0.002533	-0.002214	-0.002541

	MAR	WMT
Date		
2003-01-02	0.000000	0.000000
2003-01-03	0.001610	-0.005782
2003-01-06	0.024685	0.017140
2003-01-07	0.007212	-0.007683
2003-01-08	-0.021305	-0.012387

2022-12-23	0.002075	0.003900
2022-12-27	-0.013777	-0.006480
2022-12-28	-0.013517	-0.015719
2022-12-29	0.025927	0.025685
2022-12-30	-0.001108	-0.002831

[5035 rows x 8 columns],

	^GSPC	^DJI	^IXIC	^RUT	F	AAPL \
Date						
2003-01-02	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000
2003-01-03	-0.187265	-0.167850	-0.140870	0.111828	-0.040630	-0.080052
2003-01-06	1.648513	0.307326	0.841342	-0.113347	0.102735	0.269809
2003-01-07	-0.123390	-0.237718	-0.517901	-0.103436	0.034607	0.076120
2003-01-08	-0.329200	0.099882	1.384884	0.169126	-0.042402	-0.050220
2022-12-23	-0.180306	-0.491733	-0.418898	-0.270203	-0.351074	-0.287512
2022-12-27	0.081374	0.173732	0.264519	0.052066	0.112916	0.074849
2022-12-28	0.238098	0.101210	-0.021037	0.517860	0.025405	0.017563
2022-12-29	-0.113938	0.084554	0.083459	-0.398418	-0.036470	-0.025892
2022-12-30	0.016603	-0.268917	0.076821	0.254309	0.215749	-0.007927

	MAR	WMT
Date		
2003-01-02	0.000000	0.000000
2003-01-03	-0.107142	-0.080052
2003-01-06	0.363695	0.269809
2003-01-07	0.119966	0.076120
2003-01-08	-0.170154	-0.050220

2022-12-23	-0.308365	-0.287512
2022-12-27	0.079728	0.074849
2022-12-28	0.004097	0.017563

```
2022-12-29 0.080961 -0.025892
2022-12-30 -0.046958 -0.007927
```

```
[5035 rows x 8 columns])
# generamos los factores de precio y volumen paso a paso
rets = [pd.DataFrame(ret[i].values,columns=[i],index=ret[i].index) for i in assets]
vols = [pd.DataFrame(vol[i].values,columns=[i],index=vol[i].index) for i in assets]

alpha = 0.05
z = stats.norm.ppf(0.95)

fpis = []
# calculo de FPI paso a paso, tras geerar los factores a cada activo estudiado
for i in range(len(assets)):
    volatility =
rets[i].iloc[:,0].rolling(60,min_periods=60).std().divide(vols[i].iloc[:,0].rolling(60,min_periods=60).std())
    volatility = volatility.replace([np.inf, -np.inf], np.nan)
    volatility = volatility.dropna()
    vol_adj = volatility * vol.iloc[:,0]

    factors = pd.DataFrame(rets[0].iloc[:,0].values,columns=['Price_Change+'],index=rets[0].index)
    factors['Volume_Change-'] = -vol_adj

    fpi = rets[i].iloc[:,0] - vol_adj
    fpi = fpi.fillna(method='ffill')
    fpi_mean = fpi.rolling(250,min_periods=250).mean()

    sigma3 = fpi.rolling(60,min_periods=60).std() * 3

    fpi_serie = fpi.replace([np.inf, -np.inf], np.nan)
    metric = fpi_mean + sigma3
    monthly =
pd.DataFrame(metric.groupby([metric.index.year,metric.index.month]).mean().values,columns=['Factor
Precio'])
    dates = pd.date_range(start=metric.index[0],end=metric.index[-1],freq='3M')
    monthly = monthly.tail(len(dates))
    monthly.index = dates
    fpi = pd.DataFrame(fpi.values,columns=['FPI'],index=fpi.index)
    sample = pd.concat([fpi,monthly]).sort_index().fillna(method='ffill')
    sample['Factor Volumen'] = -sample['Factor Precio']
    sample = sample.dropna()
    fpis.append(sample)
```

*# corroboramos que los datos calculados tienen su tamaño correcto para hacer los exámenes*

```
for i in range(len(fpis)):
    print(len(fpis[i]))
```

```
fpis[0]
```

```
5055
5055
5055
5055
5055
5055
FPI Factor Precio Factor Volumen
2003-03-28 -0.001879 0.071383 -0.071383
2003-03-31 -0.059915 0.071383 -0.071383
2003-04-01 0.017105 0.071383 -0.071383
2003-04-02 0.026087 0.071383 -0.071383
2003-04-03 -0.002814 0.071383 -0.071383
...
2022-12-23 0.013383 0.093061 -0.093061
2022-12-27 -0.021117 0.093061 -0.093061
2022-12-28 -0.051759 0.093061 -0.093061
2022-12-29 0.038480 0.093061 -0.093061
2022-12-30 0.000986 0.093061 -0.093061
```

[5055 rows x 3 columns]

*# generamos las medidas para agregar los modelos VaR, CVaR, EVaR y FPI a las series de activos*

```
for j in range(len(assets)):
```

```
    mu = rets[j].rolling(250,min_periods=250).mean()
    sigma = rets[j].rolling(250,min_periods=250).std()
    sigmaq = rets[j].rolling(60,min_periods=60).std()
    rets[j]['VaR'] = (mu - z * sigma)#['VaR']
    rets[j]['CVaR'] = (mu - sigma * stats.norm.pdf(z) / alpha)#['CVaR']
    rets[j]['EVaR'] = (mu - sigma * np.sqrt(-2 * np.log(alpha)))#['EVaR']
    rets[j]['FPI'] = (-mu - (sigmaq * 3))#['FPI']
```

```
rets[0].dropna()
```

```
^GSPC VaR CVaR EVaR FPI
Date
2003-12-29 0.017808 -0.036739 -0.046504 -0.055502 -0.072757
2003-12-30 0.006146 -0.036717 -0.046482 -0.055481 -0.069604
2003-12-31 0.004229 -0.036724 -0.046489 -0.055487 -0.068735
2004-01-02 -0.004211 -0.036746 -0.046512 -0.055510 -0.066637
2004-01-05 0.041824 -0.036787 -0.046610 -0.055660 -0.068877
...
2022-12-23 -0.002798 -0.037742 -0.047087 -0.055697 -0.076291
2022-12-27 -0.013878 -0.037823 -0.047174 -0.055791 -0.075555
2022-12-28 -0.030685 -0.038045 -0.047427 -0.056073 -0.075310
2022-12-29 0.028324 -0.038043 -0.047458 -0.056133 -0.075591
2022-12-30 0.002469 -0.038035 -0.047425 -0.056078 -0.075504
```

[4786 rows x 5 columns]

#Calculamos el FPI a cada serie de activos y lo sumamos al resto de métricas

2.2 Graficamos VaR, CVaR, EVaR y FPI con un iterador de cada activo

for i in range(len(rets)):

```
    fig = plt.figure(figsize=(40,25))
```

```
    ax1 = fig.add_subplot(111)
```

```
    rets[i].iloc[:, :-1].dropna().plot(ax=ax1, lw=4.)
```

```
    rets[i]['FPI'].dropna().plot(ax=ax1, lw=8.,c='m')
```

```
    ax1.set_title('Backtest VaR, CVaR, EVaR & FPI ' + assets[i], fontsize=100, fontweight='bold')
```

```
    ax1.grid(True,color='k',linestyle='-',linewidth=2)
```

```
    ax1.legend(loc='center left', bbox_to_anchor=(1, 0.5),fontsize=40)
```


```
    plt.xlabel("Años 2003-2023",fontsize=60)
```

```
    plt.ylabel("Fluctuación y Niveles de Referencia",fontsize=60)
```



```
    plt.xticks(size=50)
```



```
    plt.yticks(size=60)
```



```
    plt.show()
```














```
ret = pd.DataFrame(fpis[0]['FPI'].values,columns=[f'{assets[0]}'],index=fpis[0].index)
```

```
# observamos los valores de cada caso
```

```
for i in range(1,len(assets)):
```

```
    ret[f'{assets[i]}'] = fpis[i]['FPI'].values
```

```
ret = ret.dropna()
```

```
ret
```

	^GSPC	^DJI	^IXIC	^RUT	F	AAPL \
2003-03-28	-0.001879	-0.034355	-0.011473	-0.023972	-0.026208	-0.029461
2003-03-31	-0.059915	-0.032048	-0.061858	-0.086471	-0.089351	-0.113114
2003-04-01	0.017105	0.018999	0.004395	0.040875	0.046360	0.062305
2003-04-02	0.026087	0.029378	0.039356	0.021977	0.016397	0.011572
2003-04-03	-0.002814	0.025885	0.007900	0.012474	0.008486	0.014393
...	...	...	...	...	...	...
2022-12-23	0.013383	0.015902	0.019815	0.008057	0.005474	0.017358
2022-12-27	-0.021117	-0.019249	-0.006305	-0.002404	0.001075	-0.009217
2022-12-28	-0.051759	-0.037429	-0.032567	-0.025300	-0.011173	-0.026964
2022-12-29	0.038480	0.060842	0.022692	0.009760	0.010574	0.024460
2022-12-30	0.000986	0.006791	0.005274	-0.003065	-0.002225	-0.003565

	MAR	WMT
2003-03-28	-0.036663	-0.021393
2003-03-31	-0.127302	-0.088333
2003-04-01	0.060721	0.051956
2003-04-02	0.019188	0.008864
2003-04-03	0.022584	0.012868
...	...	...
2022-12-23	0.019395	0.016615
2022-12-27	-0.021582	-0.012244

```
2022-12-28 -0.036197 -0.032464
2022-12-29 0.036695 0.033507
2022-12-30 -0.002688 -0.003974
```

[5055 rows x 8 columns]

```
Risk_norm = {}
for i in assets:
    Risk_norm[i] = {'VaR':[], 'CVaR': [], 'EVaR': [], 'FPI': []}

window = 250 * 1
alpha = 0.05

ret = ret.replace([np.inf, -np.inf], np.nan)
ret = ret.dropna()

n = ret.shape[0]
for j in assets:
    for i in range(window, n):
        X = ret[j].iloc[i-window:i]
        z = stats.norm.ppf(1 - alpha)
        mu, sigma = stats.norm.fit(X)
        Q = ret[j].iloc[i-round(window/4):i]
        muq, sigmaq = stats.norm.fit(Q)
        Risk_norm[j]['VaR'].append(mu - z * sigma)
        Risk_norm[j]['CVaR'].append(mu - sigma * stats.norm.pdf(z) / alpha)
        Risk_norm[j]['EVaR'].append(mu - sigma * np.sqrt(-2 * np.log(alpha)))
        Risk_norm[j]['FPI'].append((-mu - sigmaq * 3))

for i in assets:
    Risk_norm[i] = pd.DataFrame(Risk_norm[i], index=ret.index[window:])
```

2.3 Evaluamos los modelos para hacer los Tests formales al generar funciones con test de Bernoulli y Christoffersen

```
def bern_test(p,v):
    lv = len(v)
    sv = sum(v)
    al = np.log(p)*sv + np.log(1-p)*(lv-sv)
    bl = np.log(sv/lv)*sv + np.log(1-sv/lv)*(lv-sv)
    return (-2*(al-bl))
```

```
def ind_test(V):
    T = len(V)
    J = np.full([T,4], 0)
    for i in range(1,len(V)-1):
```

```

J[i,0] = (V[i-1] == 0) & (V[i] == 0)
J[i,1] = (V[i-1] == 0) & (V[i] == 1)
J[i,2] = (V[i-1] == 1) & (V[i] == 0)
J[i,3] = (V[i-1] == 1) & (V[i] == 1)
V_00 = sum(J[:,0])
V_01 = sum(J[:,1])
V_10 = sum(J[:,2])
V_11 = sum(J[:,3])
p_00=V_00/(V_00+V_01)
p_01=V_01/(V_00+V_01)
p_10=V_10/(V_10+V_11)
p_11=V_11/(V_10+V_11)
hat_p = (V_01+V_11)/(V_00+V_01+V_10+V_11)
al = np.log(1-hat_p)*(V_00+V_10) + np.log(hat_p)*(V_01+V_11)
bl = np.log(p_00)*V_00 + np.log(p_01)*V_01 + np.log(p_10)*V_10 + np.log(p_11)*V_11
return (-2*(al-bl))
keys = ['Failure Ratio VaR',
'Failure Ratio CVaR',
'Failure Ratio EVaR',
'Failure Ratio FPI',
'Bernoulli Test VaR stat',
'Bernoulli Test VaR p-value',
'Bernoulli Test CVaR stat',
'Bernoulli Test CVaR p-value',
'Bernoulli Test EVaR stat',
'Bernoulli Test EVaR p-value',
'Bernoulli Test FPI stat',
'Bernoulli Test FPI p-value',
'Independent Test VaR stat',
'Independent Test VaR p-value',
'Independent Test CVaR stat',
'Independent Test CVaR p-value',
'Independent Test EVaR stat',
'Independent Test EVaR p-value',
'Independent Test FPI stat',
'Independent Test FPI p-value']

```

```
Stats_norm = {}
```

```
for i in assets:
```

```
    Stats_norm[i] = {}
```

```
    for j in keys:
```

```
        Stats_norm[i][j] = []
```

```
for i in Stats_norm.keys():
```

```
    for j in Risk_norm[i].keys():
```

```

a = np.minimum(ret[i].iloc[window:] - Risk_norm[i][j],0)
H = np.count_nonzero(a)
T = len(Risk_norm[i])
q = a < 0
v = a * 0
v[q] = 1
ber = bern_test(0.05, v)
ind = ind_test(v)
Stats_norm[i]['Failure Ratio ' + j].append(H/T)
Stats_norm[i]['Bernoulli Test ' + j + ' stat'].append(round(ber, 5))
Stats_norm[i]['Bernoulli Test ' + j + ' p-value'].append(round(1 - stats.chi2.cdf(ber, 1),5))
Stats_norm[i]['Independent Test ' + j + ' stat'].append(round(ind, 5))
Stats_norm[i]['Independent Test ' + j + ' p-value'].append(round(1 - stats.chi2.cdf(ind, 1),5))

```

```

a = pd.DataFrame([])
for i in assets:
    Stats_norm[i] = pd.DataFrame(Stats_norm[i]).T
    Stats_norm[i].columns = [i]
    a = pd.concat([a, Stats_norm[i]], axis=1)

```


```

Stats_norm = a
display(Stats_norm)

```

	^GSPC	^DJI	^IXIC	^RUT \
Failure Ratio VaR	0.068887	0.059938	0.066805	0.057024
Failure Ratio CVaR	0.044329	0.036420	0.039126	0.035796
Failure Ratio EVaR	0.030593	0.023725	0.024974	0.021644
Failure Ratio FPI	0.021228	0.015193	0.012279	0.015817
Bernoulli Test VaR stat	32.446410	9.418770	25.963570	4.783690
Bernoulli Test VaR p-value	0.000000	0.002150	0.000000	0.028730
Bernoulli Test CVaR stat	3.377110	20.515370	12.886290	22.555560
Bernoulli Test CVaR p-value	0.066110	0.000010	0.000330	0.000000
Bernoulli Test EVaR stat	43.965340	85.990210	77.035120	102.370820
Bernoulli Test EVaR p-value	0.000000	0.000000	0.000000	0.000000
Bernoulli Test FPI stat	105.877180	166.636240	203.914560	159.396550
Bernoulli Test FPI p-value	0.000000	0.000000	0.000000	0.000000
Independent Test VaR stat	5.614560	6.491300	16.716720	10.558010
Independent Test VaR p-value	0.017810	0.010840	0.000040	0.001160
Independent Test CVaR stat	0.701430	3.010190	5.230580	9.997910
Independent Test CVaR p-value	0.402300	0.082740	0.022190	0.001570
Independent Test EVaR stat	0.485040	0.569350	10.954210	9.455570
Independent Test EVaR p-value	0.486150	0.450520	0.000930	0.002110
Independent Test FPI stat	2.861350	2.288240	4.153840	4.233340
Independent Test FPI p-value	0.090730	0.130360	0.041540	0.039640

	F	AAPL	MAR	WMT
Failure Ratio VaR	0.069719	0.067846	0.064724	0.064516
Failure Ratio CVaR	0.045369	0.044745	0.041207	0.042040
Failure Ratio EVaR	0.028720	0.028304	0.028512	0.027680
Failure Ratio FPI	0.019355	0.023933	0.023517	0.024558
Bernoulli Test VaR stat	35.222290	29.122720	20.148480	19.604450
Bernoulli Test VaR p-value	0.000000	0.000000	0.000010	0.000010
Bernoulli Test CVaR stat	2.235620	2.891350	8.298300	6.761030
Bernoulli Test CVaR p-value	0.134860	0.089060	0.003970	0.009320
Bernoulli Test EVaR stat	53.751800	56.088100	54.912440	59.706340
Bernoulli Test EVaR p-value	0.000000	0.000000	0.000000	0.000000
Bernoulli Test FPI stat	122.670750	84.453650	87.544750	79.950250
Bernoulli Test FPI p-value	0.000000	0.000000	0.000000	0.000000
Independent Test VaR stat	14.346920	2.944300	1.258650	1.895800
Independent Test VaR p-value	0.000150	0.086180	0.261910	0.168550
Independent Test CVaR stat	12.417320	5.140770	0.975740	3.300600
Independent Test CVaR p-value	0.000430	0.023370	0.323250	0.069250
Independent Test EVaR stat	14.067820	7.376950	5.232640	2.530790
Independent Test EVaR p-value	0.000180	0.006610	0.022170	0.111640
Independent Test FPI stat	9.219660	3.045610	1.734960	6.503780
Independent Test FPI p-value	0.002390	0.080960	0.187780	0.010760



Universidad de  
San Andrés





Universidad de  
**San Andrés**