



# Estrategias de trading con Time Series Momentum

**Esstefanía Acero Ríos**

Trabajo de grado presentada como requisito para optar al título de:  
**Maestría en Finanzas Cuantitativas**

Director(a): Hugo Ramírez  
Ph.D, Financial Mathematics

Universidad del Rosario  
Facultad de Economía, Departamento de Matemáticas  
Bogotá, Colombia  
2019

## Dedicatoria

A mis amados padres por ser el pilar fundamental en todo lo que soy, en mi educación, tanto académica como personal. Por servirme de inspiración y brindarme su amor y apoyo incondicional.

Todo este trabajo ha sido posible gracias a ellos.

A Felipe por el apoyo brindado.

# Abstract

Constructing a time-series momentum strategy involves the volatility-adjusted aggregation of univariate strategies and therefore relies heavily on the efficiency of the volatility estimator and on the quality of the momentum trading signal. Using a dataset with intra-day quotes of 18 assets from May 2017 to May 2019, we investigate these dependencies and their relation to time-series momentum profitability. Momentum trading signals generated by fitting a linear trend on the asset price path maximise the out-of-sample performance in small holding periods while minimising the portfolio turnover, hence dominating the ordinary momentum trading signal in literature, the sign of past returns. Regarding the volatility adjusted aggregation of univariate strategies, the Realized Volatility estimator did not present the best results as it was expected, however the Yang-Zhang range estimator and Garman and Klass Modified estimator constitute a good choice for volatility estimation in terms of maximising efficiency (Theoretically) and minimising the ex-post portfolio turnover, although the bias is not minimum.

**Keywords:** Trend-following; Time Series Momentum; Volatility Estimation; Trading Signals; Portfolio Turnover.

# Índice general

<b>1. Introducción</b>	<b>2</b>
1.1. Antecedentes	2
<b>2. Metodología</b>	<b>4</b>
2.1. Retorno del portafolio	4
2.2. Estimación Volatilidad	5
2.3. Validación del estimador de Volatilidad	9
2.3.1. Sesgo del Estimador	9
2.3.2. Rotación del Portafolio por el estimador de Volatilidad	10
2.4. Señales de Time-Series Momentum	11
2.4.1. Velocidad de cambio de la señal	13
<b>3. Descripción de la Data</b>	<b>14</b>
<b>4. Resultados</b>	<b>16</b>
4.1. Análisis Descriptivo del la data	16
4.2. Elección del estimador de volatilidad	19
4.2.1. Análisis de las señales	22
4.2.2. Retorno del portafolio	24
4.2.3. Conclusiones	27
<b>A. Anexos</b>	<b>28</b>
A.1. Volatilidades históricas	29
A.2. Código implementación	30
<b>Bibliografía</b>	<b>42</b>

# Capítulo 1

## Introducción

Con el presente trabajo se intenta construir un portafolio haciendo uso de la estrategia de *time series momentum*, comparando diferentes metodologías que involucran su construcción, en busca de optimizar la estrategia.

La estrategia de time series Momentum involucra dos aspectos, el primero, la señal de compra/venta de cada activo y el segundo, el tamaño de dicha posición, visto como la cantidad de participaciones que se tienen invertidas en un activo. Una manera de seleccionar dicha posición es mediante el inverso de la volatilidad de cada activo, este ajuste por riesgo (en otras palabras el uso de retornos estandarizados) a través de los instrumentos, es muy común en la literatura (Ver Pirrong [2005] y J.Moskowitz et al. [2012]), y es útil por dos razones, primero porque hace mucho más sencillo agregar estrategias de instrumentos con volatilidades muy disimiles y segundo por que ayuda a evitar que la estrategia global sea dominada por unos pocos periodos de volatilidad.

En la literatura clásica existen dos clases de estrategias de momentum tradicionales, la primera clase son las *cross sectional* que consisten en tomar posición en un activo basándose en su desempeño relativo a otros activos de su misma clase, por medio de rankings y/o índices que contemplen el comportamiento del activo en comparación con sus peers. La segunda clase *time series*, a diferencia *Cross-sectional* se apoya en el comportamiento longitudinal del activo independientemente del desempeño que hayan mostrado sus pares, son estrategias que buscan encontrar la tendencia por lo que únicamente se basan en su comportamiento histórico.

### 1.1. Antecedentes

Existe una creciente literatura que evidencia la predictibilidad del retorno de las acciones basados en una variedad de variables específicas de la empresa. Entre estas anomalías el efecto del momentum sobre el retorno es probablemente la más difícil de explicar dentro del contexto del paradigma tradicional de valorar activos basado en el riesgo. Por ejemplo Jegadeesh and Titman (1993) muestran que las acciones que se desempeñan mejor (peor) en un período de tres a 12 meses tienden a continuar teniendo un buen desempeño (mal)

durante los siguientes tres a 12 meses.

Los profesionales de la industria son conscientes del efecto del momentum y parece que, al menos, seleccionan las acciones según el momentum de los precios. Por ejemplo, Grinblatt, Titman y Wermers (1995) y Chan, Jegadeesh y Wermers (2000) encuentran que los fondos de inversión tienden a comprar ganadores pasados y vender perdedores pasados. Además, Womack (1996) advierte que los analistas generalmente recomiendan las acciones de alto momentum más favorablemente que las acciones de bajo momentum.

Jegadeesh y Titman (2001a) muestran que las estrategias de momentum también fueron rentables en los años noventa, que es un período posterior al período de muestra en Jegadeesh y Titman (1993).

Las estrategias de momentum también son rentables fuera de los Estados Unidos. Rouwenhorst (1998) describe como dichas estrategias examinadas por Jegadeesh y Titman (1993) para el mercado estadounidense, también son rentables en los mercados europeos. De hecho, Japón es el único mercado bursátil desarrollado que no exhibe momentum (ver Chui, Titman y Wei (2000)). Las estrategias de momentum implementadas en muestras que consisten en acciones de una serie de mercados de valores menos desarrollados también exhiben momentum (ver Rouwenhorst (1999) y Chui, Titman y Wei (2000)), aunque en la muestra estas estrategias dentro países individuales a menudo no son rentables.<sup>1</sup>

---

<sup>1</sup>[https://www.uts.edu.au/sites/default/files/FDG\\_Seminar\\_150408.pdf](https://www.uts.edu.au/sites/default/files/FDG_Seminar_150408.pdf)

# Capítulo 2

## Metodología

Como se mencionó en el capítulo 1, parte de la estrategia de *time series* consiste en generar las participaciones de cada activo por medio del inverso de su volatilidad, razón por la cuál uno de los objetivos de esta tesis es comparar diferentes metodologías para estimar dicha volatilidad, también lo es, encontrar cuál es la señal óptima que genera el mayor retorno sobre una variedad de señales propuestas.

Estas elecciones del estimador de volatilidad y de la señal de trading tienen un gran impacto tanto en la rotación de los activos que componen el portafolio como en el retorno global del mismo. Al aumentar la eficiencia de la estimación de la volatilidad utilizando estimadores con propiedades teóricas deseables, los costos transaccionales mejoran, sin embargo el efecto en el indicador de rotación del portafolio es menor en comparación con el efecto que produce usar diferentes técnicas para generar las señales de compra y venta.

A continuación se presenta la estructura de la metodología a seguir: (i) Revisar la definición de la estrategia agregada en términos del retorno del portafolio, (ii) presentar los diferentes métodos para la estimación de la volatilidad y, (iii) exponer la familia de metodologías que se emplearán para generar la señal de compra/venta.

### 2.1. Retorno del portafolio

Dado un punto de observación  $t$ , se define  $J$  como el periodo de observación (Medido en meses antes de  $t$ ) con el cuál se va a medir el desempeño pasado de los activos, y  $K$  el periodo de tenencia de dichos activos (En Meses a partir de  $t$ ), siguiendo la metodología descrita en [J.Moskowitz et al. \[2012\]](#), el retorno del portafolio queda determinado como:

$$R_{TS}(t, t + K) = \frac{1}{M} \sum_{i=1}^M X_i(t - J, t) \cdot \frac{40\%}{\sigma_i(t - D; t)} \cdot R_i(t, t + K) \quad (2-1)$$

Donde:

- $M$  es el número de activos

- $\sigma_i(t - D; t)$  denota el estimador de la volatilidad en el tiempo  $t$  del  $i$ -ésimo activo usando una ventana de  $D^1$  días desde  $t - D$  hasta  $t$ .
- $X_i(t - J, t)$  es una función que tiene como resultado la señal para el  $i$ -ésimo activo. Se calcula a partir de los datos del periodo de observación  $(t - J, t)$  y en general toma valores en el conjunto  $\{-1, 0, +1\}$ , que se traducen en {Venta, Inactividad, Compra}.
- El factor de del 40 % lo sugieren [Balta and Kosowski \[2012\]](#) para alcanzar una volatilidad ex-ante igual al 40 %.
- $R_i(t, t + K)$  denota el retorno del activo  $i$  en el periodo de desempeño de  $(t, t + K)$ .

## 2.2. Estimación Volatilidad

En la literatura de momentum los estimadores de volatilidad se han caracterizado por ser simples y de fácil implementación, la razón es que normalmente los conjuntos de datos consisten en series con una frecuencia diaria como máximo, y por tanto no existe mayor eficiencia al usar estimadores con mayor información. Sin embargo en este trabajo se busca usar estimadores con información de más alta frecuencia para maximizar el retorno del portafolio con una mínima rotación en las estrategias para evitar altos costos de transacción.

Para este trabajo se considerará un estimador de la literatura clásica muy usado por su simplicidad y fácil construcción, además de los estimadores de rango, que surgen por la disponibilidad de datos intradía que permiten emplear técnicas que usan mayor información para obtener estimadores teóricamente más eficientes.

A continuación se presenta el conjunto de estimadores:

### 1. Desviación estándar de los retornos diarios(STDEV)

El log-retorno diario en el tiempo  $t$  esta definido como  $R(t) = C(t) - C(t - 1)$ , con  $C(\cdot)$  el logaritmo del precio de cierre del activo en el tiempo  $(\cdot)$ . Así la varianza de los retornos anualizada con  $D$  días de negociación al año esta dada por:

$$\sigma_{STDEV}^2(t; D) = \frac{261}{D} \sum_{i=0}^{D-1} [R(t - i) - \bar{R}(t)]^2 \quad (2-2)$$

Donde el retorno medio  $\bar{R}(t) = \frac{1}{D} \sum_{i=0}^{D-1} R(t - i)$  y 261 es el número de días de negociación por año.

---

<sup>1</sup>Los autores sugieren usar ventanas de 30 y 60 días, por lo que  $D$  no tiene porque ser igual a  $J$  dado que el primero busca la estimación de la volatilidad(Que debería ser sobre periodos más cortos) y el otro puede incluso llegar a periodos de 24 meses si se buscan estrategias que capturen tendencias de largo plazo.



Antes de hablar estimadores de rango es necesario realizar las siguientes definiciones:

$$\text{Precio de apertura: } O(t) = \log S_1(t) \quad (2-3)$$

$$\text{Precio de Cierre: } C(t) = \log S_{N_{day}}(t) \quad (2-4)$$

$$\text{Precio Mayor: } H(t) = \log \left( \max_{j=1, \dots, N_{day}} S_j(t) \right) \quad (2-5)$$

$$\text{Precio Menor: } L(t) = \log \left( \min_{j=1, \dots, N_{day}} S_j(t) \right) \quad (2-6)$$

$$\text{Precio de cierre normalizado: } c(t) = C(t) - O(t) = \log (S_{N_{day}}(t)/S_1(t)) \quad (2-7)$$

$$\text{Precio mayor normalizado: } h(t) = H(t) - O(t) = \log \left( \max_{j=1, \dots, N_{day}} S_j(t)/S_1(t) \right) \quad (2-8)$$

$$\text{Precio menor normalizado: } l(t) = L(t) - O(t) = \log \left( \min_{j=1, \dots, N_{day}} S_j(t)/S_1(t) \right) \quad (2-9)$$

$$\text{Precio de apertura normalizado: } o(t) = O(t) - C(t-1) = \log (S_1(t)/S_{N_{day}}(t-1)) \quad (2-10)$$

Donde  $N_{day}$  indica el número de cotizaciones activas durante el día  $t$ , así las cotizaciones intradía se definen como  $S_1(t), S_2(t), \dots, S_{N_{day}}(t)$ .

## 2. Volatilidad Realizada (RV)

[Andersen and Bollerslev \[1998\]](#) y [Barndorff-Nielsen and Shephard \[2002\]](#) usan la teoría de la variación cuadrática, introducen el concepto de varianza integrada y muestran que la suma de los cuadrados de los log-retornos intradía de alta frecuencia es un estimador eficiente de la varianza diaria en ausencia de saltos de precios y correlación serial en los retornos.

[Hansen and Lunde \[2006\]](#) muestran que los efectos de micro-estructura de mercado (Falta de negociación continua, margen de oferta / demanda, discretización de precios)

empiezan a afectar significativamente la precisión de la estimación cuando el intervalo de tiempo es menor que 5 minutos. Por otro lado intervalos entre 5 y 30 minutos tienden a dar estimadores de volatilidad satisfactorios, aún cuando la varianza de la estimación incrementa para frecuencias menores, por lo que para este trabajo se tomaran datos cada 30 minutos.

El estimador RV se define como:

$$\sigma_{RV}^2(t) = \sum_{j=2}^{N_{Day}} [\log S_j(t) - \log S_{j-1}(t)]^2 \quad (2-11)$$

### 3. Estimador de Parkinson (PK)

[Parkinson \[1980\]](#) es el primero en proponer el uso de estimadores con datos intraday, asume que el precio del activo sigue un proceso de difusión sin tendencia, que en forma diferencial sería ( $dS_t = \sigma dW_t$ ) y muestra que el estimador generado puede llegar a ser alrededor de 5 veces más eficiente en comparación con el STDEV.

Para su cálculo se utiliza el precio más alto y el más bajo (normalizados). Se calcula como:

$$\sigma_{PK}^2(t) = \frac{1}{4 \log(2)} [h(t) - l(t)]^2 \quad (2-12)$$

### 4. Estimador de Garman y Klass (GK)

Es una versión extendida del estimador de Parkinson que incluye los precios de cierre y apertura para mejorar la eficiencia, sin embargo tal y como el estimador PK, asume un proceso de difusión sin drift y no tiene en cuenta el salto en la apertura.

Los autores buscaron obtener un estimador insesgado, de mínima varianza, con la restricción de “escala-invariante” y mediante un proceso de minimización obtuvieron un estimador 7.4 veces más eficiente (teóricamente) dado por la siguiente expresión :

$$\sigma_{GK}^2(t) = 0,511[h(t) - l(t)]^2 - 0,019\{c(t)[h(t) + l(t)] - 2h(t)l(t)\} - 0,383c^2(t) \quad (2-13)$$

[Garman and Klass \[1980\]](#) ofrecen una manera alternativa para calcular el estimador eliminando los productos cruzados y haciendo el cálculo computacional más sencillo e igualmente eficiente.

$$\sigma_{GK}^2(t) = 0,5[h(t) - l(t)]^2 - (2 \log 2 - 1)c^2(t) \quad (2-14)$$

### 5. Estimador de Garman y Klass modificado por Yang y Zhang (GKYZ)

[Yang and Zhang \[2000\]](#) modificaron el estimador GK e incorporaron la diferencia entre el log-precio de apertura actual y el log-precio de cierre el día anterior, con lo que el estimador se vuelve más robusto ante el salto de apertura aunque sigue asumiendo un proceso sin tendencia. Su fórmula es:

$$\sigma_{GKYZ}^2(t) = \sigma_{GK}^2 + [O(t) - C(t-1)]^2 \quad (2-15)$$

## 6. Estimador de Rogers y Satchell (RS)

Son los primeros en introducir un estimador insesgado que permite una pendiente diferente a 0 en el proceso de precios, sin embargo este estimador no tiene en cuenta el salto de apertura de los precios, el estimador está determinado por:

$$\sigma_{RS}^2(t) = h(t)[h(t) - c(t)] + l(t)[l(t) - c(t)] \quad (2-16)$$

Los estimadores anteriormente mencionados son de carácter diario (Con datos intradía), por lo que es necesario realizar una transformación para volverlos anuales:

$$\sigma_{Est}^2(t; D) = \frac{261}{D} \sum_{i=0}^{D-1} \sigma_{Est}^2(t-1), \quad \text{Donde } Est = \{RV, PK, GK, GKYZ, RS\} \quad (2-17)$$

## 7. Estimador de Yang y Zhang (YZ)

Finalmente el último estimador analizado en este documento es el propuesto por [Yang and Zhang \[2000\]](#) que introduce un estimador insesgado, independiente de los saltos de apertura y que asume que los precios siguen un proceso con tendencia. Este estimador es una combinación lineal del estimador STDEV, el RS y una modificación sobre la naturaleza del STDEV usando el log-retorno del precio de apertura normalizado en vez del log-retorno del precio de cierre. Esta dado por:

$$\sigma_{YZ}^2(t; D) = \sigma_{OPEN}^2(t; D) + k\sigma_{STDEV}^2(t; D) + (1 + k)\sigma_{RS}^2(t; D) \quad (2-18)$$

Dónde

$$\sigma_{OPEN}^2(t; D) = \frac{261}{D} \sum_{t=0}^{D-1} [o(t-1) - \bar{o}(t)]^2$$

y mediante la solución a un problema de minimización de una ecuación cuadrática generada por la varianza del estimador 2-18 se escoge  $k$  de manera que el estimador sea eficiente. En la práctica esto se alcanza en  $k = \frac{\alpha}{\alpha + (D+1)/(D-1)}$ . Los autores sugieren usar  $\alpha = 1,34$ , ya que esperan un drift pequeño para datos históricos diarios, y el estimador debería ser optimizado bajo esta premisa.

En la siguiente tabla <sup>2</sup> se resumen los estimadores mencionados anteriormente, y sus ventajas en eficiencia y uso de información de los precios:

En términos generales, el único estimador que utiliza datos intraday de alta frecuencia es el RV, mientras que los estimadores restantes (PK, GK, GKYZ, RS, YZ), conocidos como “estimadores de rango”, solo necesitan el precio de apertura, de cierre, el máximo y

<sup>2</sup>[http://www.todaysgroep.nl/media/236846/measuring\\_historic\\_volatility.pdf](http://www.todaysgroep.nl/media/236846/measuring_historic_volatility.pdf)

Estimate	Precios tomados	Drift	Saltos	Eficiencia teórica
STDEV	C	No	No	1
Parkinson	HL	No	No	5.2
Garman-Klass	OHLC	No	No	7.4
Rogers-Satchell	OHLC	Si	No	8
GK Yang Zhang	OHLC	No	Si	8
Yang Zhang	OHLC	Si	Si	14

Cuadro 2-1: Comparativa estimadores Volatilidad

el mínimo sobre la información diaria. Sin embargo, cuanto más frecuente sea el conjunto de datos, más precisa será la discretización del verdadero proceso de precios y más precisa será la estimación de los precios máximos y mínimos. En todo caso, la discretización de un proceso de precio continuo casi siempre conducirá a una estimación del máximo (mínimo) que se encuentra debajo (arriba) del máximo (mínimo) verdadero de la trayectoria continua del precio. En consecuencia, el rango aproximado  $h(t) - l(t)$  siempre subestimaré el rango verdadero y, por lo tanto, se subestimaré la volatilidad estimada. Ver [Rogers and Satchell \[1991\]](#) para una discusión sobre este tema.

Por otro parte, la ventaja de los estimadores de rango es que pueden capturar con precisión la alta volatilidad de una trayectoria de precios con movimiento errático durante un día que simplemente muestra precios de apertura y cierre similares y, por lo tanto, muestra un rendimiento diario bajo (esto se aplica para el estimador STDEV pero no para el estimador RV, debido a su naturaleza de alta frecuencia).

## 2.3. Validación del estimador de Volatilidad

Para poder medir en términos de precisión y rotación las diferentes metodologías propuestas para la estimación de la volatilidad se plantean algunas tecnicas en busca de determinar cual debe ser el estimador escogido para la construcción del portafolio visto en la ecuación 2-1.

Las metodologías anteriores se aplican a los activos del portafolio, utilizando una ventana móvil de  $D = 60$  días hábiles como sugiere [J.Moskowitz et al. \[2012\]](#). El resultado se gráfica a manera de una inspección visual del movimiento conjunto y la variación de la sección transversal de los diversos estimadores. También se presenta la matriz de correlación promedio de los estimadores de volatilidad en todos los activos.

### 2.3.1. Sesgo del Estimador

Con el fin de evaluar cuantitativamente la precisión de los diferentes estimadores, se calcula el sesgo de los estimadores asumiendo que el verdadero proceso de volatilidad, dado

que no lo observamos, coincide con el estimador RV. [W Brandt and Kinlay \[2005\]](#) presentan estudios de comparación similares para varios estimadores de volatilidad, suponen que el estimador de RV proporciona un buen indicador del proceso de volatilidad. El sesgo (Bias en inglés) de volatilidad anualizado que se calcula como:

$$Bias = \frac{1}{N_s - D} \sum_{t=D}^{N_s} [\sigma_{RV}(t; D) - \sigma_{Met}(t; D)] \quad (2-19)$$

Donde  $N_s$  Corresponde al número de días de la muestra, y  $\sigma_{Met}$  corresponde a cada una de las volatilidades calculadas por los diferentes métodos descritos.

Finalmente para calcular el sesgo por estimador del total del portafolio se propone ordenar el valor absoluto de los sesgos para cada activo y asignar un rango de 1 a 6 a cada estimador para posteriormente, tomar el promedio de los rangos sobre todos los activos.

### 2.3.2. Rotación del Portafolio por el estimador de Volatilidad

Desde una perspectiva de negociación, siempre es importante limitar el volumen de rotación de un portafolio. Una menor rotación significa que una parte más pequeña de la composición de la cartera cambia en cada fecha de rebalanceo, lo que, a su vez, reduce los costos de transacción incurridos durante el rebalanceo. Siendo esto posiblemente deseable para el inversor. De la ecuación 2-1, queda claro que un factor determinante en la rotación de la cartera es la volatilidad de los activos. De hecho, el cambio intertemporal de la razón  $1/\sigma$  y la señal de momentum determinan conjuntamente la rotación del portafolio. Claramente, cuanto más persistente sea el proceso de volatilidad, menor será la rotación resultante de la estrategia.

Dado que el verdadero proceso de la volatilidad es desconocido y se estima utilizando varias metodologías, la persistencia de la trayectoria estimada depende únicamente del ruido que se introduce mediante el procedimiento de estimación, o de manera equivalente de la eficiencia del estimador. Cuanto más persistente es la trayectoria de volatilidad estimada menor es la rotación. Por lo tanto, se espera ver que el estimador más eficiente sea el estimador de RV, el cual utiliza datos de alta frecuencia, seguido de los estimadores de rango que utilizan la información intradía para precios altos y bajos. Los estimadores de peor desempeño serían los que solo usan información diaria sobre precios de cierre, es decir, el estimadores STDEV. Para evaluar empíricamente la persistencia de las estimaciones de volatilidad, se calcula para cada estimador la siguiente expresión:

$$VTO = \frac{1}{N_s - (D + 1)} \sum_{t=D+1}^{N_s} \left| \frac{1}{\sigma(t; D)} - \frac{1}{\sigma(t-1; D)} \right| \quad (2-20)$$

Donde  $N_s$  es el número de días de la muestra. Al igual que con el sesgo, se busca un único indicador que permita, a través de todos los activos, determinar cuál es el estimador de menor

rotación, por lo cuál, para cada activo se ordenan los estimadores por *VTO*, se ranquean de 1 a 6 y posteriormente para cada estimación de volatilidad se obtiene el promedio de estos valores.

## 2.4. Señales de Time-Series Momentum

- **Signo del retorno (SIGN)**

La medida estándar del desempeño en la literatura de momentum es el signo del  $J$ -ésimo retorno pasado. Un retorno positivo (Negativo) en el pasado indica una posición Larga (Corta).

$$SIGN(t - J, t) = \begin{cases} +1 & \text{si } R(t - J, t) > 0 \\ -1 & \text{Caso contrario} \end{cases} \quad (2-21)$$

- **Promedio Móvil (MA)**

Conocido también como media Móvil, es usado extensivamente como una manera de extraer la tendencia de los precios. Una posición larga(Corta) es determinada cuando el promedio móvil de los precios rezagados  $J$  periodos se encuentra por debajo(encima) del precio actual. Sea  $S(t)$  el precio de un activo en el tiempo  $t$ , sea además  $N_j(t)$  el número de días de negociación en el periodo  $[t - J, t]$  y sea  $A_J(t)$  el promedio del precio durante ese mismo periodo, así:

$$A_J(t) = \frac{1}{N_J(t)} \sum_{i=1}^{N_J(t)} S(t - N_J(t) + i) \quad (2-22)$$

La señal esta determinada por:

$$MA(t - J, t) = \begin{cases} +1 & \text{si } A_J(t) < A_1(t) \\ -1 & \text{Caso contrario.} \end{cases} \quad (2-23)$$

- **Estadística de Tendencia de tiempo (TREND)**

Otra manera de capturar la tendencia de una serie de precios resulta de ajustar una regresión lineal sobre  $J$  periodos pasados usando mínimos cuadrados. El momentum puede ser determinado basado en la significancia del coeficiente de la pendiente del modelo.

$$\frac{S(i)}{S(t - N_j(t))} = \alpha + \beta \cdot i + \epsilon(i), \quad i = 1, 2, \dots, N_J(t) \quad (2-24)$$

Estimar este modelo para un activo usando todos los  $N$  días de negociación de un periodo de observación produce una estimación de la tendencia dada por el coeficiente

de  $\beta$ , la significancia de esta tendencia está determinada por el estadístico  $t$  de  $\beta$ , denotado como  $t(\beta)$ . Un punto de corte para la posición Larga/ Corta de la señal es escogido con  $+2/ -2$  (Valores de la distribución  $t$  para rechazar  $H_0 : \beta = 0$ ) respectivamente.

$$TREND(t - J, t) = \begin{cases} +1 & \text{si } t(\beta) > +2 \\ -1 & \text{si } t(\beta) < -2 \\ 0 & \text{Caso contrario.} \end{cases} \quad (2-25)$$

Para incluir lo que podría ser una potencial auto-correlación y/o heterocedasticidad en el proceso del precio, Newey y West proponen usar el estadístico  $t$ . Es importante resaltar que la normalización de la ecuación (2-24) es hecha porque permite hacer una comparación “cross-sectional” del coeficiente de la pendiente, sin embargo este cambio de escala no afecta el estadístico  $t$  de  $\beta$ .

- **Tendencia estadísticamente significativa (SMT)**

Bryhn and Dimberg [2011] estudiaron la significancia estadística de una regresión lineal y concluyeron que si el número de puntos es grande entonces la tendencia puede ser estadísticamente significativa, aún cuando los puntos están extremadamente dispersos alrededor de la línea de la regresión. Por este motivo introdujeron el término “*statistical meaningfulness*” para describir una tendencia que no solo es significativa sino que además describe el comportamiento de los datos. Los autores muestran que una tendencia es informativa y fuerte si el  $R^2$  de la regresión excede el 65 % y el  $p$  valor es menor al ya acostumbrado 0,05. Adicionalmente para que la estimación sea más robusta sugieren dividir el conjunto de datos en un número de sub-intervalos (Usualmente de 3 a 30) y reestimar (2-24), usando como nuevos puntos los promedios de los regresores y de la variable regresada (precio del activo y regresión estimada) sobre cada sub-intervalo. Este método esencialmente suaviza la serie antes de extraer la tendencia.

Así siguiendo la metodología anteriormente expuesta, se divide el periodo de observación en intervalos y se decide tomar una posición Larga/Corta si por lo menos una de las regresiones de cada sub-intervalo satisface el siguiente criterio:

$$SMT(t - J, t) = \begin{cases} +1 & \text{si } t_k(\beta) > +2 \text{ y } R_k^2 \geq 65 \% \text{ para algún } k \\ -1 & \text{si } t_k(\beta) < -2 \text{ y } R_k^2 \geq 65 \% \text{ para algún } k \\ 0, & \text{Caso contrario} \end{cases} \quad (2-26)$$

Donde  $k$  denota la  $k$ -ésima regresión.

Notése que SMT y TREND son las únicas estrategias que contienen señales de inactividad. Aunque SMT es más estricta que TREND lo que podría conllevar a mayores periodos de inactividad.

### 2.4.1. Velocidad de cambio de la señal

Nótese que por construcción las señales SIGN y MA siempre van a tomar una posición (+1) o (-1), sin embargo en el caso de TREND y SMT no siempre se genera actividad lo que da una ventaja práctica a las señales relacionadas con la tendencia, ya que la falta de actividad reduciría la rotación de la cartera, y por lo tanto los costos de transacción.

Sin embargo, la escasa actividad podría potencialmente limitar el rendimiento de la cartera. Por esa razón, se propone estimar para cada contrato y para cada señal una relación de actividad y rotación, denominada “velocidad de la señal” que se calcula como la raíz cuadrada de la relación entre el promedio de la serie de tiempo del valor de la señal al cuadrado. y el promedio de la serie de tiempo de la diferencia de primer orden al cuadrado en el valor de la señal:

$$SPEED_X = \sqrt{\frac{\mathbf{E}[X^2]}{\mathbf{E}[(\Delta X)^2]}} = \sqrt{\frac{\frac{1}{T-J} \sum_{t=1}^T X^2(t-J, t)}{\frac{1}{T-J-1} \sum_{t=1}^T [X(t-J, t) - X(t-J-1, t-1)]^2}} \quad (2-27)$$

Claramente, cuanto mayor sea la actividad de la señal y menor la diferencia promedio entre valores de señal consecutivos (en otras palabras, mientras más suave sea la transición entre las posiciones largas y cortas), mayor será la velocidad de la señal. Se debe tener en cuenta que para las señales SIGN y MA, el nominador siempre es igual a 1, porque saltan constantemente entre posiciones largas (+1) a cortas (-1).



# Capítulo 3

## Descripción de la Data

Para la construcción del portafolio se seleccionaron diferentes clase de activos tanto colombianos como de otro mercados. Estas clases van desde acciones, renta fija, moneda local y precio del petróleo como materia prima más importante en el desempeño de los activos locales. Para cada una de estas clases se tomaron referentes en diferentes mercados emergentes y mercados desarrollados con el fin de recoger momentos de apetito o inclinación por activos de mercados emergentes a nivel global, y momentos de “fly to quality” (búsqueda de activos refugio y baja exposición de activos colombianos).

- Se propone utilizar las monedas de mercados emergentes que más se relacionan con el tipo de cambio local (Real Brasileiro, Lira Turca, Peso Mexicano y Peso Argentino). De igual manera busca relacionar momentos de fortaleza o debilidad del dólar frente a otras monedas fuertes como el euro.
- Del lado de la renta fija se toma de punto de referencia la curva de bonos del gobierno TES con vencimiento en 2024 el cual tiene una relación directa con el desempeño de las curvas del tesoros, por lo que se toma el bono referencia con vencimiento a 10 años.
- Para el caso de renta variable del mercado Colombiano, se usaron las acciones más representativas de los tres sectores más importantes de la economía, a saber Financiero: Bancolombia, y Aval ; Consumo masivo: Nutresa; e infraestructura y construcción: Isa.
- Dado que Colombia tiene una alta dependencia económica por el intercambio de materias primas y más específicamente de petróleo, se toma el precio del ETF (Exchange Traded Fund) europeo que replica el precio de referencia del petróleo que más a afecta a Colombia (Referencia Brent), el dólar canadiense dada su alta correlación con el precio del petróleo y la acción de Ecopetrol.

Esta segmentación por clase de activo en mercados emergentes, mercados desarrollados y finalmente, el mercado colombiano intenta capturar señales producto de movimientos en globales(Como crisis mundiales, o cambios fuertes de políticas monetarias) y además de los administradores de portafolio que manejan sus posiciones sobre activos colombianos dentro de una canasta de otros mercados emergentes.

En la tabla 3-1 se presentan los activos tomados para la construcción de portafolio categorizados por tipo. Se presentan además la abreviatura/ticker de cada activo.

Clase de Activos	Colombia	Desarrollados	Emergentes
Monedas	Peso Colombiano (COFX)	Euro (EUR) Dólar Canadiense (CAD)	Real Brasileiro (BRL) Peso Mexicano (MXN) Peso Argentino (ARG) Lira Turca (TRY)
Renta Variable	Bancolombia (PFBCOLO) Aval (AVAL) Isa (ISA) Nutresa (NUTRESA) COLCAP (COLCAP)	Índice S&P (SPX)	
Materias Primas	Ecopetrol (ECOPTL)	EuroBrent-ETF (EUCBRDT) Oro (XAU)	
Renta fija	ColTES 2014 (COLTES)	US Tesoro 10yr <sup>1</sup> (USGG10)	

Cuadro 3-1: Activos para la construcción del portafolio

<sup>1</sup>Para US Tesoro 10yr fue necesario realizar una transformación en función de obtener una serie de valores sobre la serie original que viene dada por los *yield* de bono y no por precio, con el fin de poder calcular el retorno con el código de implementación genérico. La transformación se baso en calcular el retorno como la diferencia nominal entre las tasas y luego despejar el “precio” hacia adelante a partir del primer punto de observación que se definió como \$100.

# Capítulo 4

## Resultados

En esta sección se analiza inicialmente el comportamiento de las series, algunos estadísticos descriptivos y pruebas de normalidad y autocorrelación. Posteriormente se encuentran las pruebas sobre los estimadores de volatilidad tanto para el sesgo (tomando como proxy del proceso de volatilidad real el estimador de la volatilidad RV) como para el indicador de rotación, esto para poder definir cual(es) estimadores se van a usar para construir el portafolio según la ecuación 2-1. Posteriormente se realiza un análisis de sobre las señales que entrega una estrategia a corto plazo para validar contra los fundamentales del mercado si estas tienen sentido estructural. Finalmente a través de una grilla de parámetros ( $J, K$ ) se busco la combinación de mayor retorno, sobre el conjunto de los estimadores de volatilidad presentados con las diferentes señales propuestas en el capítulo anterior.

### 4.1. Análisis Descriptivo del la data

Se realizó un análisis descriptivo de las series de los activos que se consideraron para construcción del portafolio. A continuación se presenta el comportamiento de dichos activos en la figura 4-1:

Tal y como era de esperarse se observan relaciones entre algunos pares de activos, por ejemplo el ETF de petróleo EURBrent con la acción de Ecopetrol que se mueven de manera similar, se observa además como el tipo de cambio COFX afecta tanto el índice accionario local COLCAP como a los Bonos soberanos Colombianos COLTES, esto se puede ver como un cambio de preferencias en los inversionistas sobre moneda extranjera generando liquidación en las posiciones locales, donde la reacción se ve primero en el mercado de renta variable y luego se transmite al de renta fija.

Cabe resaltar además el co-movimiento de las monedas de mercados emergentes donde en la ventana examinada parece haber una tendencia alcista. Todo esto se puede corroborar también a través de los coeficientes de correlación que se pueden ver en el corrplot de la figura 4-2. Se calcularon además para cada uno de los activos del portafolio, los retornos anualizados, así como las volatilidades, la prueba de normalidad de Jaque-Bera y el test de autocorrelación sobre la serie de retornos mensuales de la ventana examinada para revisar si para cada uno de los activos existe una interdependencia en el tiempo, en la tabla 4-1 se observan dichos resultados, donde en general se ven unos retornos positivos para todos

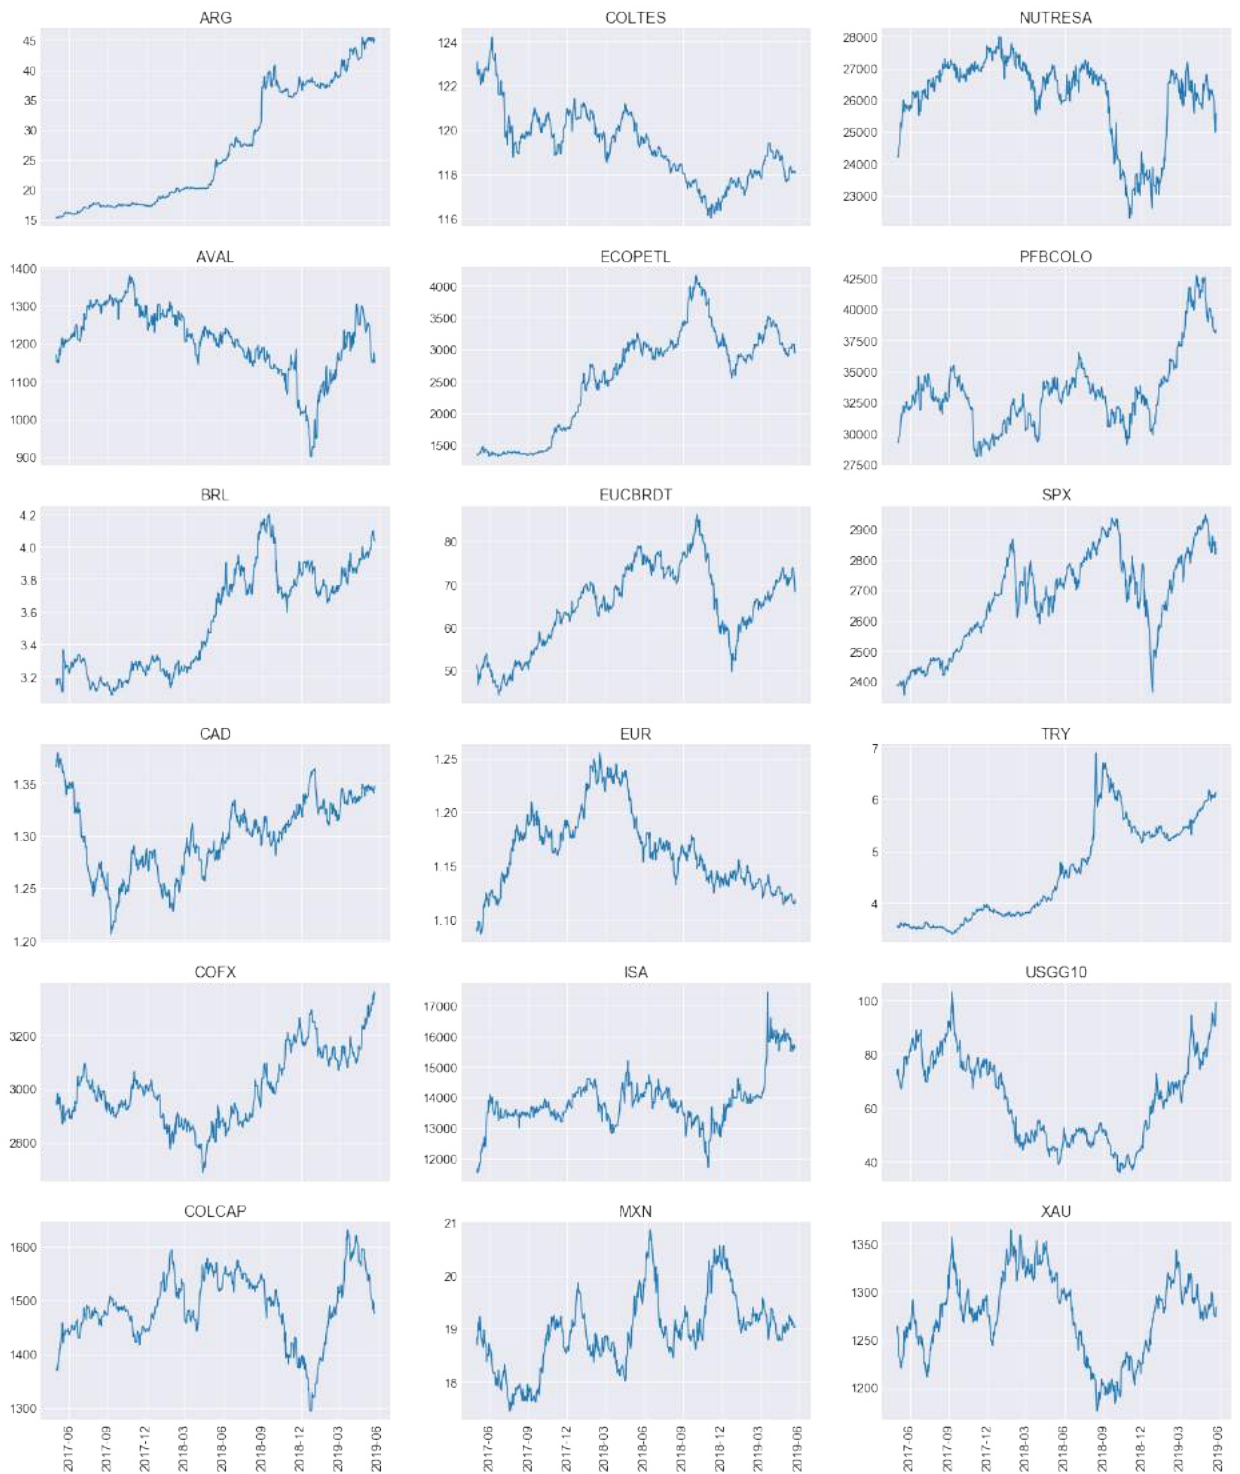


Figura 4-1: Comportamiento de los precios de los activos 2017-2019

los activos, así como una serie de volatilidades bastante diferente por lo cual cobra mucha importancia el normalizar la estrategia en la ecuación 2-1.

Respecto a las pruebas de normalidad y de autocorrelación los resultados parecen ser mixtos, donde se observa que en la mayoría de activos no se rechaza el test de normalidad, sin embargo para la prueba de Ljung-Box el resultado es más diverso, con 10 activos en los cuales no se rechaza la hipótesis de dependencia de primer orden, esto puede ser una buena señal a la hora de construir el portafolio en función de las metodologías que buscan capturar dicha tendencia.

	<b>Retorno Anual</b>	<b>Vol Anual</b>	<b>Skew</b>	<b>Kurtosis</b>	<b>p_LJBox</b>	<b>p_JBera</b>
<i>ARG</i>	74.8%	183.0%	1.96	16.03	0.00	0.00
<i>AVAL</i>	4.2%	90.8%	0.24	4.69	0.00	0.39
<i>BRL</i>	11.5%	62.7%	1.18	14.14	0.01	0.99
<i>CAD</i>	0.3%	28.6%	-0.32	0.57	0.85	0.77
<i>COFX</i>	5.7%	40.7%	0.19	1.16	0.52	0.38
<i>COLCAP</i>	6.0%	61.4%	-0.06	0.80	0.05	0.52
<i>COLTES</i>	-2.2%	8.9%	-0.39	1.52	0.00	0.59
<i>ECOPETL</i>	64.4%	261.6%	-0.04	1.80	0.50	0.87
<i>EUCBRDT</i>	24.1%	156.1%	-0.32	2.70	0.82	0.03
<i>EUR</i>	0.3%	22.7%	-0.11	1.23	0.44	0.82
<i>ISA</i>	10.3%	96.6%	0.40	3.78	0.00	0.38
<i>MXN</i>	1.7%	53.4%	0.19	0.62	0.47	0.60
<i>NUTRESA</i>	3.2%	70.1%	0.56	3.86	0.00	0.08
<i>PFBCOLO</i>	16.8%	119.0%	0.20	2.62	0.24	0.90
<i>SPX</i>	11.8%	53.2%	-0.82	4.79	0.52	0.09
<i>TRY</i>	36.3%	176.3%	2.31	30.27	0.00	0.00
<i>USGG10</i>	0.0%	18.5%	-1.94	30.51	0.06	0.13
<i>XAU</i>	1.2%	28.7%	0.20	0.49	0.73	0.67

Cuadro 4-1: Estadísticos de los datos. Retorno y volatilidad anualizada, coeficiente de asimetría, Curtosis,  $p$  value del test de normalidad Jaque Beta,  $P$  value del test de autocorrelación de primer orden de Ljung Box




Figura 4-2: Corrplot de las series de datos

## 4.2. Elección del estimador de volatilidad

Un primer análisis a realizar sobre los diferentes estimadores tiene ver con la tabla 4-2 que muestra la matriz de correlación entre los diferentes metodologías de estimación, en esta se observa que si bien están altamente correlacionados entre todos, los que mayores diferencias presentan respecto a sus pares, son el estimador *STDEV* y el *RS*, lo que podría indicar que estos estimadores pueden ser los menos viables para estructurar el portafolio.

Tal y como se mencionó en el capítulo 2, para la elección del estimador de volatilidad es de suprema importancia tener una volatilidad con unas propiedades deseables como son la eficiencia, el menor sesgo, y la menor rotación, y dado que los resultados no son concluyentes se decide seleccionar un grupo de 3 estimadores a probar con las diferentes metodologías para obtener la señal y poder conformar el portafolio. Ver figura 4-3.

El estimador *GKYZ* como se observa en la tabla 4-3 es el que mejores indicadores obtiene, seguidamente por el Estimador *YZ*. Cabe señalar que se esperaba que el estimador *RV* fuera el de mejor desempeño según [Balta and Kosowski \[2012\]](#), sin embargo este estimador en términos de turnover (dado que por sesgo no se puede comparar al tomarse como variable proxy tal y como lo sugiere [Pirrong \[2005\]](#)) no ocupa el primer lugar, esto puede deberse a que los activos en Colombia no tienen una variación diaria altamente significativamente, por lo que no le agrega mayor valor a la estimación del proceso real de volatilidad.

Los resultados se obtuvieron bajo una ventana de  $D = 60$  días, sin embargo tal y como lo recomienda el autor se probaron bajo varios escenarios obteniendo resultados muy similares que llegaban a las mismas conclusiones.

	<b>RV</b>	<b>PK</b>	<b>GK</b>	<b>GKYZ</b>	<b>RS</b>	<b>STDEV</b>	<b>YZ</b>
<b>RV</b>	1.00						
<b>PK</b>	0.92	1.00					
<b>GK</b>	0.90	0.97	1.00				
<b>GKYZ</b>	0.90	0.93	0.92	1.00			
<b>RS</b>	0.87	0.93	0.90	0.80	1.00		
<b>STDEV</b>	0.90	0.88	0.86	0.93	0.74	1.00	
<b>YZ</b>	0.91	0.92	0.90	0.99	0.82	0.94	1.00

Cuadro 4-2: Matriz de correlación promedio entre estimadores de volatilidad

	<b>RV</b>	<b>PK</b>	<b>GK</b>	<b>GKYZ</b>	<b>RS</b>	<b>STDEV</b>	<b>YZ</b>
<i>ARG</i>	0.12	0.18	0.21	0.09	0.25	0.13	0.08
<i>AVAL</i>	0.04	0.11	0.12	0.04	0.21	0.08	0.05
<i>BRL</i>	0.07	0.10	0.11	0.07	0.13	0.13	0.07
<i>CAD</i>	0.09	0.15	0.17	0.10	0.16	0.19	0.10
<i>COFX</i>	0.09	0.16	0.19	0.08	0.26	0.14	0.08
<i>COLCAP</i>	0.08	0.15	0.15	0.08	0.20	0.15	0.09
<i>COLTES</i>	0.64	0.65	0.71	0.30	0.99	0.58	0.31
<i>ECOPETL</i>	0.03	0.08	0.08	0.04	0.10	0.06	0.04
<i>EUCBRDT</i>	0.03	0.05	0.05	0.03	0.05	0.06	0.03
<i>EUR</i>	0.09	0.15	0.16	0.09	0.15	0.19	0.09
<i>ISA</i>	0.03	0.07	0.07	0.04	0.10	0.08	0.04
<i>MXN</i>	0.05	0.09	0.10	0.07	0.10	0.13	0.06
<i>NUTRESA</i>	0.06	0.12	0.13	0.06	0.19	0.10	0.07
<i>PFBCOLO</i>	0.04	0.07	0.08	0.04	0.10	0.07	0.04
<i>SPX</i>	0.13	0.26	0.25	0.13	0.30	0.18	0.13
<i>TRY</i>	0.07	0.10	0.11	0.06	0.11	0.11	0.06
<i>USGG10</i>	0.01	0.02	0.02	0.01	0.02	0.03	0.01
<i>XAU</i>	0.06	0.11	0.12	0.07	0.12	0.15	0.07
<b>Avg Rank</b>	2.06	4.56	5.72	1.89	6.22	5.44	2.11

Cuadro 4-3: Indicador de rotación para cada estimador de volatilidad

	<b>RV</b>	<b>PK</b>	<b>GK</b>	<b>GKYZ</b>	<b>RS</b>	<b>STDEV</b>	<b>YZ</b>
<i>ARG</i>	0.00	0.07	0.07	-0.13	0.10	0.00	-0.12
<i>AVAL</i>	0.00	0.22	0.21	0.02	0.26	0.15	0.05
<i>BRL</i>	0.00	0.05	0.05	-0.07	0.06	0.01	-0.06
<i>CAD</i>	0.00	0.01	0.01	-0.05	0.02	0.00	-0.04
<i>COFX</i>	0.00	0.05	0.05	-0.05	0.06	0.00	-0.05
<i>COLCAP</i>	0.00	0.04	0.04	-0.08	0.05	0.00	-0.07
<i>COLTES</i>	0.00	0.00	0.00	-0.03	0.01	-0.01	-0.03
<i>ECOPETL</i>	0.00	0.17	0.17	-0.13	0.21	0.02	-0.12
<i>EUCBRDT</i>	0.00	0.04	0.04	-0.17	0.06	0.01	-0.16
<i>EUR</i>	0.00	0.01	0.01	-0.04	0.02	0.00	-0.04
<i>ISA</i>	0.00	0.16	0.16	-0.03	0.18	0.11	-0.02
<i>MXN</i>	0.00	0.02	0.02	-0.06	0.03	0.01	-0.06
<i>NUTRESA</i>	0.00	0.11	0.12	0.01	0.13	0.07	0.01
<i>PFBCOLO</i>	0.00	0.10	0.10	-0.12	0.13	0.01	-0.12
<i>SPX</i>	0.00	0.05	0.05	-0.07	0.06	0.01	-0.06
<i>TRY</i>	0.00	0.04	0.04	-0.11	0.05	0.02	-0.11
<i>USGG10</i>	0.00	0.10	0.10	-0.33	0.14	0.03	-0.31
<i>XAU</i>	0.00	0.01	0.01	-0.06	0.02	0.00	-0.06
<b>Avg Rank</b>	-	2.78	3.00	4.94	4.72	1.44	4.11

Cuadro 4-4: Sesgo de los estimadores de volatilidad




Figura 4-3: Índice de Rotación de Sesgo por Estimador






Figura 4-4: Velocidad de Cambio de Señales

#### 4.2.1. Análisis de las señales

Tal y como se mencionó en el capítulo anterior un criterio importante a la hora de generar la señales es la cantidad de cambios de posición que se tienen que hacer en cada rebalanceo del portafolio, en la figura 4-4 se observa para diferentes periodos de observación y para un periodo de desempeño de 1 año, la velocidad de cambio vista en la formula 2-27. El indicador es promedio sobre los 18 activos.

En la tabla 4-5 se tiene el porcentaje de coincidencia entre las 4 estrategias y sus respectivas correlaciones, donde se puede observar una alta correlación y grado de coincidencia entre las estrategias TREND y SMT, siendo la segunda más restrictiva dado que la metodología sobre la cual esta construida exige mayor evidencia de tendencia.

Se observa además en la tabla 4-6 los porcentajes de posiciones de largos y cortos para la diferentes señales calculadas. para un horizonte de inversión de 3 Meses(61 días hábiles) y un periodo de observación de 2 meses(42 días hábiles)<sup>1</sup>.

<sup>1</sup>Se validó la misma información para un periodo de desempeño (K) más amplio sin embargo al ser tiempos más extensos, los resultados fueron muy diversos. Por otro lado en el corto plazo si se ven tendencias claras de activos en los que NO(SI) se debería invertir

Signal	Coincidencia de Posiciones				Correlación			
	SIGN	MA	TREND	SMT	SIGN	MA	TREND	SMT
SIGN	100 %	84 %	70 %	55 %	1.00	0.68	0.78	0.68
MA	84 %	100 %	67 %	54 %	0.68	1.00	0.70	0.65
TREND	70 %	67 %	100 %	81 %	0.78	0.70	1.00	0.87
SMT	55 %	54 %	81 %	100 %	0.68	0.65	0.87	1.00

Cuadro 4-5: Matrices de coincidencia de posiciones y de correlación por tipo de señal con una Ventana  $(J, K) = (2, 3)$  meses

Un análisis sobre la estrategia SMT de posiciones presentada en la tabla 4-6 particularmente deja entrever la relación que tienen las señales del modelo planteado con los fundamentales de mercado: A continuación se relacionan dichos hallazgos:

- Mercados Desarrollados: El modelo muestra un ambiente de fortaleza dólar<sup>2</sup> frente a otras monedas fuertes como el EUR, lo que indica que hay una preferencia por movilidad de flujos de Europa al mercado de acciones de EEUU donde la señal es de compra. No obstante esta preferencia por movilidad de flujos hacia EEUU no se da más para el mercado de tesoros americanos (renta fija buscando refugio) esto lo confirma también la señal de indiferencia (No predomina ni compra ni venta) sobre el oro que es otro activo refugio. Es decir que el modelo indica que si bien los últimos días han sido caracterizados por un movimiento de *fly to quality*, debido a la presión por la guerra comercial con china, este parece estar llegando a su fin activando la preferencia por acciones y materias primas y activos de mercados emergentes.
- Mercados Emergentes: Materias primas: En este escenario donde se da una señal de compra de acciones en Estados Unidos es evidente que materias primas como el petróleo tienen una oportunidad de seguir subiendo, lo que el modelo corrobora en la señal de oportunidad de compra en Ecopetrol y en la señal de compra del dólar canadiense (CAD). Esta moneda generalmente es predictor del movimiento del petróleo debido a que su bolsa de valores es especializada en compañías del sector de hidrocarburos. Lo anterior debería motivar un comportamiento favorable de acciones locales. El modelo así lo captura pues da señales de compra en COLCAP, AVAL y Bancolombia. Acciones que son el termómetro de la economía. Para otras acciones como Nutresa e ISA que son más estables y cuyos ingresos no son tan elásticos al ciclo económico, las señales del modelo son de indiferencia.  
Respecto a la renta fija local: la señal sobre los TES es de compra, no tan marcada como en el mercado de acciones pero si indicando que las desvalorizaciones sufridas en las últimas semanas deben corregir.

<sup>2</sup>Tal y como se vio en el análisis descriptivo la mayoría de las monedas de mercados emergentes se encuentran debilitándose frente al dólar.

Finalmente para las monedas el contexto de la señal a nivel del peso dólar es consecuente pues pese a que la moneda ha venido con un movimiento fuertemente al alza en los últimos días, el modelo genera una señal de venta, es decir que lo que se espera es una corrección de la tendencia. Lo anterior coincide con el apetito por acciones financieras locales, la señal del petróleo y el CADUSD. No pasa lo mismo con la señal a nivel de otras monedas emergentes como el peso argentino (ARS), la Lira Turca (TRY), el Real Brasileiro (BRL), las cuales muestran que la debilidad frente al dólar va a continuar. Esto tiene sentido si se observa que el peso colombiano ha sido una de las monedas que más se ha devaluado a nivel mundial. Para el caso del peso MXN la señal es de indiferencia ya que su contexto político y de incertidumbre a nivel comercial no permiten que tenga una situación clara en el corto plazo.

Ticker	Corto				Largo			
	Signo	MA	TREND	SMT	Signo	MA	TREND	SMT
ARG	1.6 %	0.0 %	0.0 %	0.0 %	98.4 %	100.0 %	100.0 %	<b>96.8 %</b>
AVAL	12.7 %	14.3 %	0.0 %	0.0 %	87.3 %	85.7 %	90.5 %	<b>88.9 %</b>
BRL	11.1 %	1.6 %	4.8 %	0.0 %	88.9 %	98.4 %	87.3 %	73.0 %
CAD	17.5 %	9.5 %	11.1 %	12.7 %	82.5 %	90.5 %	71.4 %	49.2 %
COFX	38.1 %	33.3 %	22.2 %	23.8 %	61.9 %	66.7 %	46.0 %	25.4 %
COLCAP	14.3 %	28.6 %	15.9 %	17.5 %	85.7 %	71.4 %	77.8 %	69.8 %
COLTES	27.0 %	34.9 %	22.2 %	17.5 %	73.0 %	65.1 %	71.4 %	61.9 %
ECOPETL	33.3 %	44.4 %	28.6 %	20.6 %	66.7 %	55.6 %	63.5 %	63.5 %
EUCBRDT	1.6 %	0.0 %	0.0 %	0.0 %	98.4 %	100.0 %	100.0 %	<b>98.4 %</b>
EUR	88.9 %	90.5 %	100.0 %	66.7 %	11.1 %	9.5 %	0.0 %	<b>0.0 %</b>
ISA	20.6 %	23.8 %	25.4 %	17.5 %	79.4 %	76.2 %	63.5 %	36.5 %
MXN	65.1 %	58.7 %	39.7 %	22.2 %	34.9 %	41.3 %	19.0 %	27.0 %
NUTRESA	47.6 %	46.0 %	30.2 %	6.3 %	52.4 %	54.0 %	31.7 %	19.0 %
PFBCOLO	12.7 %	23.8 %	9.5 %	0.0 %	87.3 %	76.2 %	82.5 %	<b>85.7 %</b>
SPX	3.2 %	15.9 %	0.0 %	0.0 %	96.8 %	84.1 %	95.2 %	<b>95.2 %</b>
TRY	11.1 %	7.9 %	12.7 %	6.3 %	88.9 %	92.1 %	81.0 %	74.6 %
USGG10	73.0 %	55.6 %	54.0 %	46.0 %	27.0 %	44.4 %	27.0 %	<b>15.9 %</b>
XAU	65.1 %	79.4 %	61.9 %	31.7 %	34.9 %	20.6 %	19.0 %	20.6 %

Cuadro 4-6: Posiciones de largo y corto por estrategia con una Ventana  $(J, K) = (2, 3)$  meses

#### 4.2.2. Retorno del portafolio

Después de seleccionar los mejores métodos de estimación de volatilidad los cuales son GKYZ, YZ y RV, el paso siguiente es probar las diferentes estrategias definidas en el capítulo 2 para diferentes periodos de observación y de desempeño, dado que se tienen 2 años de data, se decidió probar con una grilla de  $(J, K)$  sobre 1,3,6, y 12 meses respectivamente, los resultados se pueden ver en la tabla 4-3 donde se observan retornos mixtos dependiendo de la estrategia de señales usada. Si un inversionista busca estrategias de corto y mediano plazo se sugiere el uso de SMT y TREND con ventanas de observación de 21 y 42 días (1 y 2 meses

respectivamente), sin embargo para inversiones con un horizonte de inversión más largo se prefieren MA y Signo.

SMT																		
	J	1	2	3	6	12	1	2	3	6	12	1	2	3	6	12		
K	Vol GKYZ						Vol RV						Vol YZ					
1	-2.0%	2.0%	-16.6%	-36.9%	17.1%	-1.6%	8.6%	-25.4%	-48.2%	25.1%	-1.8%	2.4%	-16.3%	-37.3%	17.8%			
2	3.4%	6.9%	1.4%	-25.4%	7.7%	3.8%	10.9%	-1.6%	-35.3%	11.6%	3.5%	7.5%	-25.8%	8.2%				
3	10.0%	16.1%	5.4%	-13.2%	6.9%	16.1%	28.0%	7.7%	-19.2%	7.9%	10.3%	16.7%	5.7%	-13.5%	7.2%			
6	6.8%	5.2%	0.1%	-21.7%	-13.6%	9.6%	9.8%	0.5%	-29.4%	-20.9%	7.1%	5.3%	0.1%	-22.0%	-13.7%			
12	7.9%	9.6%	4.7%	-8.3%	-4.7%	12.0%	16.5%	8.3%	-10.2%	-6.9%	8.2%	9.9%	5.0%	-8.1%	-4.4%			
TREND																		
	J	1	2	3	6	12	1	2	3	6	12	1	2	3	6	12		
K	Vol GKYZ						Vol RV						Vol YZ					
1	4.1%	-5.4%	-19.0%	-30.7%	25.2%	12.2%	-6.4%	-28.9%	-41.2%	43.6%	4.9%	-5.2%	-18.7%	-31.0%	26.6%			
2	4.7%	10.3%	-1.9%	-16.9%	15.3%	9.2%	13.3%	-7.3%	-25.6%	27.5%	4.9%	10.9%	-1.4%	-17.0%	16.1%			
3	10.4%	16.2%	7.3%	-5.1%	18.8%	20.2%	26.1%	10.2%	-7.8%	28.9%	10.8%	16.8%	7.8%	-5.1%	19.4%			
6	11.1%	7.0%	-1.7%	-18.9%	-19.6%	19.2%	11.0%	-3.6%	-27.3%	-26.8%	11.2%	7.1%	-1.6%	-19.1%	-19.5%			
12	13.1%	10.7%	7.0%	-5.0%	-6.2%	20.6%	17.7%	11.2%	-6.3%	-8.1%	13.4%	11.0%	7.5%	-4.7%	-5.8%			
MA																		
	J	1	2	3	6	12	1	2	3	6	12	1	2	3	6	12		
K	Vol GKYZ						Vol RV						Vol YZ					
1	4.1%	12.1%	-17.5%	-27.0%	-34.0%	8.3%	23.3%	-17.8%	-39.9%	-47.2%	5.1%	13.1%	-16.7%	-26.7%	-33.7%			
2	-16.9%	8.2%	-12.8%	-13.4%	-16.8%	-23.0%	11.2%	-15.7%	-24.1%	-27.3%	-17.3%	8.8%	-12.4%	-13.3%	-16.2%			
3	-6.8%	12.5%	-4.0%	-6.5%	2.0%	-5.8%	21.2%	-1.2%	-10.8%	1.5%	-7.0%	13.1%	-3.6%	-6.4%	2.9%			
6	1.1%	13.5%	-1.1%	-14.3%	-21.0%	4.8%	23.0%	1.6%	-20.9%	-30.3%	0.9%	13.9%	-1.1%	-14.7%	-20.8%			
12	7.0%	13.5%	6.9%	-3.3%	-8.5%	13.0%	23.3%	14.3%	-3.3%	-11.2%	7.1%	13.9%	7.1%	-3.3%	-8.1%			
SIGN																		
	J	1	2	3	6	12	1	2	3	6	12	1	2	3	6	12		
K	Vol GKYZ						Vol RV						Vol YZ					
1	-11.9%	-35.5%	-27.3%	-37.5%	-14.4%	-9.7%	-46.1%	-39.2%	-47.7%	-14.9%	-11.5%	-35.6%	-27.5%	-37.8%	-14.3%			
2	6.9%	-7.8%	5.9%	-26.9%	4.3%	14.0%	-12.2%	3.3%	-37.1%	10.8%	7.6%	-7.4%	6.5%	-27.1%	5.0%			
3	26.5%	-1.8%	10.1%	-15.0%	12.5%	44.6%	-1.7%	12.8%	-19.8%	22.4%	27.4%	-1.5%	10.6%	-14.9%	13.3%			
6	15.0%	-5.3%	-6.2%	-25.8%	-13.7%	25.9%	-5.0%	-9.2%	-35.2%	-17.9%	15.3%	-5.5%	-6.4%	-26.0%	-13.6%			
12	15.1%	4.8%	3.9%	-9.9%	-0.6%	24.7%	10.3%	6.8%	-11.8%	0.8%	15.4%	5.0%	4.2%	-9.5%	-0.3%			

Cuadro 4-7: Retornos anualizados del portafolio para diferentes periodos se desempeño y observación

### 4.2.3. Conclusiones

A diferencia del paper de [Balta and Kosowski \[2012\]](#), que utiliza futuros para construir el portafolio, en nuestro caso el estimador más óptimo de volatilidad no fue el de Yang Zhang, aún cuando según cálculos teóricos es el más eficiente de todos (Sin incluir RV), por lo que para este tipo de estrategias de *tim series momentum* es importante validar como se debe reponderar los retornos, dado que el cambio de mercados e incluso del tipo de activos puede generar diferencias considerables.

En [Balta and Kosowski \[2012\]](#) se refieren también a que lo ideal sería tener usar el estimador RV, sin embargo por provenir de datos intraday que a veces son complejos de obtener y no generar mayores beneficios versus un estimador de rango, RV no se suele usar, en [J.Moskowitz et al. \[2012\]](#) incluso obtienen excelentes resultados con un estimador EWMA.

Para nuestros datos se observo una particularidad y es que dado que en su mayoría son activos colombianos y/o de mercados emergentes, no parecen tener tanto movimiento como los contratos futuros de USA, esto se ve reflejado en gran medida, cuando se calculan los sesgos promedio en la tabla [4-4](#) y en las volatilidades históricas de la figura [A-1](#) donde el estimador STDEV es nominalmente el que mejor resultado tiene en comparación con RV, esto considerando que es un estimador que toma los precios de cierre únicamente, podría significar que no existe una alta variabilidad del precio a nivel intraday, por lo que la mejor opción en este caso es un estimador de rango, que si bien está más sesgado que STDEV (si se considera RV como el proceso de volatilidad real, que podría ser incorrecto considerando el poco movimiento diario de los activos tomados), tiene mejores propiedades de eficiencia, generando un portafolio más estable a través del tiempo.

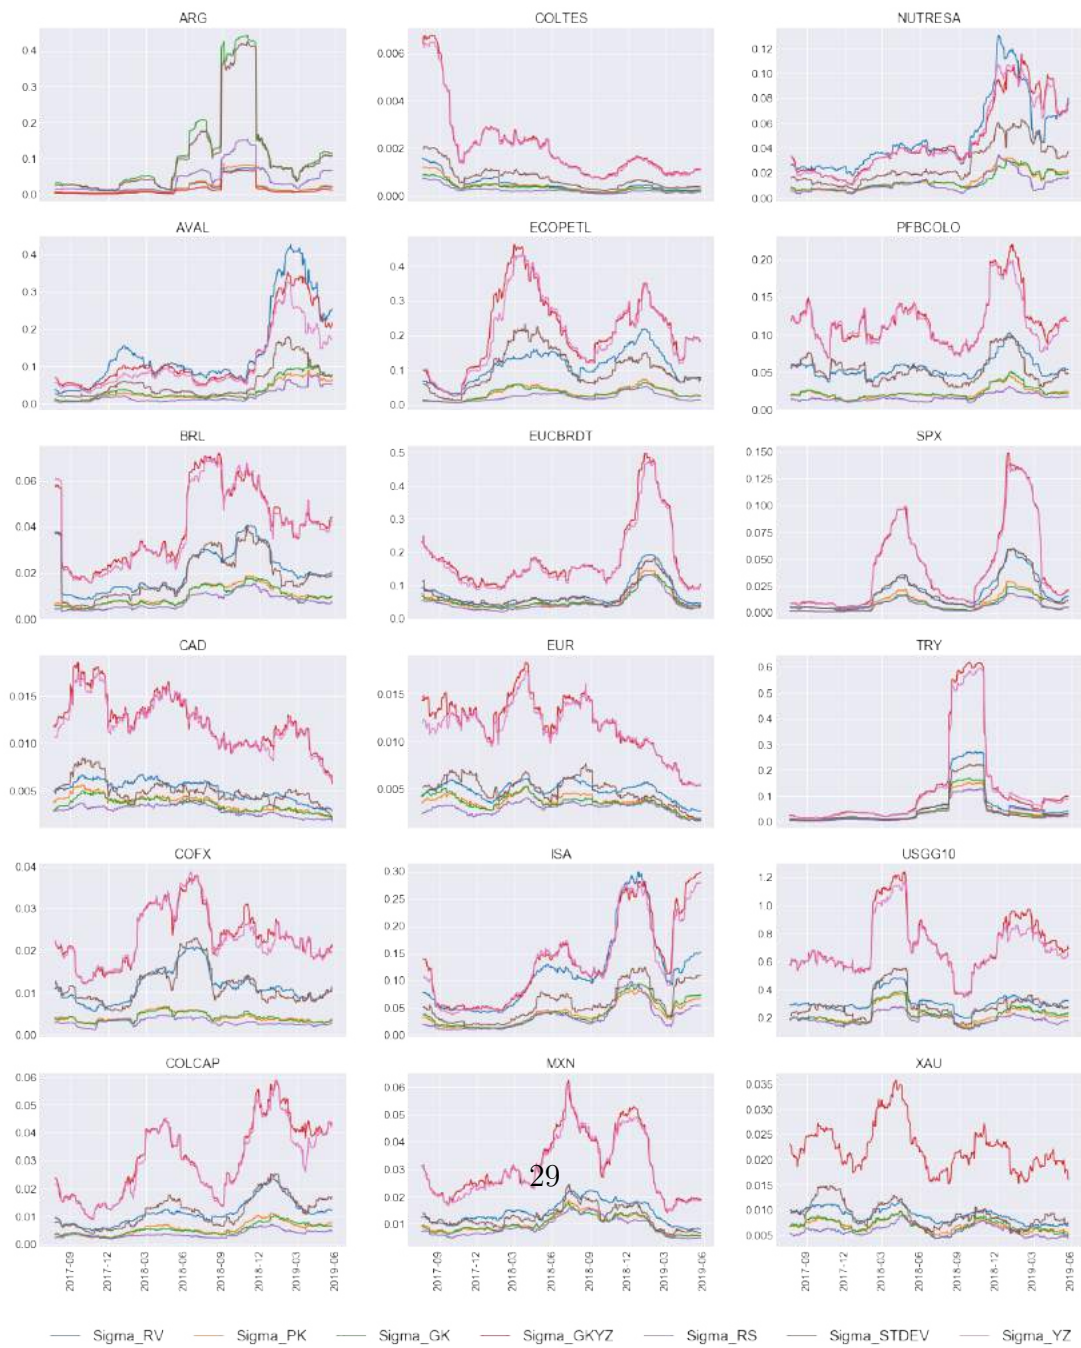
Es importante además conocer las preferencias del inversor, debido a que si bien en este trabajo la propuesta fue buscar el mejor retorno anual optimizando el periodo de horizonte de inversión y de observación, una posible sugerencia podría ser en función de un horizonte de inversión buscar los activos mejor comportados y construir el portafolio únicamente con estos. Es importante señalar que además del análisis cuantitativo que se puede extraer al observar los retornos y propiedades, vale la pena realizar un análisis macro para revisar que el modelo tenga lógica con los fundamentales, tal y como se vio anteriormente.



# Apéndice A

## Anexos

### A.1. Volatilidades históricas





## A.2. Código implementación

```
1 import datetime
2 import numpy as np
3 import pandas as pd
4 import matplotlib.pyplot as plt
5 import time
6 import urllib.parse
7 import glob
8 import os
9 from pyfinance.ols import PandasRollingOLS
10 from pandas.tseries.offsets import *
11 from matplotlib.dates import MonthLocator, YearLocator, WeekdayLocator
12 import matplotlib.dates as mdates
13 import seaborn as sns
14 import statsmodels.api as sm
15 from scipy import stats
16 from scipy.stats import kurtosis
17 from scipy.stats import skew
18 from statsmodels import *
19 from scipy import mean
20 pd.options.display.float_format = '{:.6f}'.format
21 plt.style.use('seaborn-darkgrid')
22
23 ### Funcion para calcular la volatilidad por diferentes metodos:
24 ##### Recibe 2 parametros:
25 #1. Ruta: Ruta con nombre del archivo de los datos, debe ser csv (;)
26 #2. D: Ventana del rolling window para calcular las volatilidades
27
28 ##### Regresa un diccionario con 4 bases resultado:
29 #1. Datos_iniciales: Base inicial que se carga desde el csv
30 #2. Datos_insumo: Base con los calculos de los diferentes precios intraday
31 #3. Vols_diarias: Base con las Vols Diarias sobre las metodologias que aplican
32 #4. Vols_anuales: Base final, con las volatilidades calculadas a una ventana D
   , anualizadas
33
34 #Funcion que recibe La ruta donde esta el CSV y calcula las diferentes
   volatilidades
35 ##La funcion imputa datos diarios en la salida_insumo con el metodo bfill
36
37 def Get_Vols(Path, D):
38
39     Datos=pd.read_csv(Path, sep=";", usecols=['Date', 'Close'])
40     Datos['Date'] = pd.to_datetime(Datos['Date'], format='%d/%m/%Y %H%M')
41     Datos['Fecha'] = Datos['Date'].dt.normalize()
42     Datos['Hora'] = Datos['Date'].dt.time
43     Datos = Datos.set_index('Date')
44     Datos=Datos[['Fecha', 'Hora', 'Close']]
45     ##calcula los insumos para calcular las vol diarias
46     def intraday_info(data):
47         Salida=data.groupby('Fecha', as_index=False).agg({'Close':[( '
   Opening-price', 'first'), ('Closing-price', 'last'),\
   ('Low-price'
```

```

, np.min), ('High_price', np.max)]}).set_index('Fecha')
49 Salida.columns=Salida.columns.droplevel()
50 Salida['O(t)']=np.log(Salida.Opening_price)
51 Salida['C(t)']=np.log(Salida.Closing_price)
52 Salida['L(t)']=np.log(Salida.Low_price)
53 Salida['H(t)']=np.log(Salida.High_price)
54 Salida['c(t)']=Salida['C(t)']-Salida['O(t)']
55 Salida['h(t)']=Salida['H(t)']-Salida['O(t)']
56 Salida['l(t)']=Salida['L(t)']-Salida['O(t)']
57 Salida['o(t)']=Salida['O(t)']-Salida['C(t)'].shift(1)
58 Salida=Salida[['Closing_price', 'O(t)', 'C(t)', 'L(t)', 'c(t)', 'h(t)', 'l(t)
)', 'o(t)']]
59 Salida=Salida.asfreq(BDay(), method='ffill')
60 return(Salida)
61 Datos_insumo=intraday_info(Datos)
62
63 ##calcula STDEV - esta ya viene anual
64 def Calculo_STDEV(data,D):
65     def STDEV(vec):
66         vec=pd.DataFrame(vec)
67         Rt=vec-vec.shift(1)
68         Rbar=np.mean(Rt)
69         Sigma_STDEV=np.sum((Rt-Rbar)**2)
70         return(Sigma_STDEV)
71
72     Close=pd.DataFrame(data['C(t)'])
73     Close['R(t)']=Close['C(t)']-Close['C(t)'].shift(1)
74     Close['Sigma_STDEV']=(261/D)*(Close['C(t)'].rolling(window=D+1).apply(
lambda x: STDEV(x), raw=True))
75     Close=Close.drop(['R(t)', 'C(t)'], axis=1)
76     return(Close)
77
78 ##calcula de la volatilidad RV diaria
79 def Calculo_VolRV(data):
80     dataRV=data.copy()
81     dataRV['Log(S)']=np.log(dataRV['Close'])
82     dataRV['Sigma']=(dataRV['Log(S)']-dataRV['Log(S)'].shift(1))**2
83     Salida=dataRV.groupby('Fecha', as_index=False).agg({'Sigma':[(
Sigma_RV', 'sum')]}).set_index('Fecha')
84     Salida.columns=Salida.columns.droplevel()
85     Salida=Salida.asfreq(BDay(), method='bfill')
86     return(Salida) #RV=Calculo_VolRV(Datos)
87
88 ##volatilidades diarias
89 def Calculo_volatilidades_diarias(data):
90     Vol=pd.DataFrame()
91     Vol['Sigma_PK']=(1/(4*np.log(2)))*(data['h(t)']-data['l(t)'])**2
92     Vol['Sigma_GK']=(0.5*(data['h(t)']-data['l(t)'])**2)-((2*np.log(2)-1)
*(data['h(t)']**2))
93     Vol['Sigma_GKYZ']=Vol['Sigma_GK']+(data['o(t)']**2)
94     Vol['Sigma_RS']=(data['h(t)']*(data['h(t)']-data['c(t)'])+(data['l(t)
']*(data['l(t)']-data['c(t)'])))
95     Vol=Vol.asfreq(BDay(), method='bfill')

```

```

96         return (Vol)
97
98     Vols=Calculo_volatilidades_diarias (Datos_insumo)
99     Vols=Vols.join (Calculo_VolRV (Datos), how='inner')
100
101     ##Volatilidades anuales
102     def Calculo_volatilidades_anual (data, D):
103         Salida=pd.DataFrame()
104         Salida ['Sigma_RV']=(261/D)*data ['Sigma_RV'].rolling (D).sum ()
105         Salida ['Sigma_PK']=(261/D)*data ['Sigma_PK'].rolling (D).sum ()
106         Salida ['Sigma_GK']=(261/D)*data ['Sigma_GK'].rolling (D).sum ()
107         Salida ['Sigma_GKYZ']=(261/D)*data ['Sigma_GKYZ'].rolling (D).sum ()
108         Salida ['Sigma_RS']=(261/D)*data ['Sigma_RS'].rolling (D).sum ()
109         return (Salida)
110
111     Vols_Anuales=Calculo_volatilidades_anual (Vols,D)
112
113     ##calculo de open para obtener el estimador YZ
114     def Calculo_OPEN (data,D):
115         def SCE (ot):
116             ot=pd.DataFrame (ot)
117             otbar=np.mean (ot)
118             sum_ot=np.sum ((ot-otbar)**2)
119             return (sum_ot)
120         opent=pd.DataFrame (data ['o(t)'])
121         opent ['Sigma_OPEN']=(261/D)*opent ['o(t)'].rolling (window=D+1).apply (
lambda x: SCE (x),raw=True)
122         opent=opent.drop (['o(t)'], axis=1)
123         return (opent) #Calculo_OPEN (Datos_finales ,60
124
125     Vols_Anuales=Vols_Anuales.join (Calculo_OPEN (Datos_insumo,D), how='outer')
126     Vols_Anuales=Vols_Anuales.join (Calculo_STDEV (Datos_insumo,D), how='outer')
127
128     #Calculo de YZ
129     k=0.34/(1.34+((D+1)/(D-1)))
130     Vols_Anuales ['Sigma_YZ']=Vols_Anuales ['Sigma_OPEN']+k*Vols_Anuales ['
Sigma_STDEV']+(1-k)*Vols_Anuales ['Sigma_RS']
131     Vols_Anuales=Vols_Anuales.drop (['Sigma_OPEN'], axis=1)
132
133     ret = {'Datos_iniciales': Datos,
134           'Datos_insumo': Datos_insumo,
135           'Vols_diarias': Vols,
136           'Vols_anual': Vols_Anuales}
137     return (ret)
138
139     #####
140     ##Funcion para calcular sobre todos los tickers
141
142     def cal_Resul (ruta,D,files):
143         Resultados={}
144         ticker=[]
145         for file in files:
146             if file.endswith ('.csv'):

```

```

147         ticker=file [ file .rindex ('\\')+1:-4]
148         Resultados [ ticker]=Get_Vols ( file , D)
149     return (Resultados)
150
151 ruta='C:/Users/Esstefania/Desktop/Maestria Urosario/Tesis/Prueba/COLOMBIA/*.
152     csv'
153 D=60 ##Ventana de dias para el calculo de la volatilidad
154 files = glob.glob(os.path.join(ruta))
155 Resultados=cal_Resul(ruta=ruta ,D=D, files=files)
156
157 D={}
158 tickers=list (Resultados.keys ())
159 for ticker in tickers:
160     B=pd.DataFrame (Resultados [ ticker ] [ 'Datos_insumo' ] [ 'Closing_price' ])
161     B.columns=[ticker]
162     D[ticker]=B
163 D=pd.concat (D,1)
164 D.columns=D.columns.droplevel ()
165 #####
166 ##Graficas
167 fig , axs = plt.subplots (int (len (tickers)/3), 3, sharex='col' , sharey=False ,
168     figsize=(25,30))
169 axs = axs.T.flatten ()
170 for i in range (int (len (tickers))):
171     axs [ i ]. plot (pd.DataFrame (D[D.columns [ i ]]))
172     axs [ i ]. set_title (D.columns [ i ], fontsize=18)
173     for ax in axs.flat:
174         ax.set (xlabel='', ylabel='')
175         ax.tick_params (axis='x' , which='major' , labelsz=15,rotation=90)
176         ax.tick_params (axis='y' , which='major' , labelsz=15)
177 #####
178 #Calculo de descriptivos
179
180 RetM=D.asfreq ('BM').apply (lambda x : x.pct_change (1))
181 RetD=D.apply (lambda x : x.pct_change (1))
182 SigmaM=RetM.apply (lambda x : np.std (x))
183 Skew=RetD.iloc [2: ,:].apply (lambda x: skew (x))
184 Kurt=RetD.iloc [2: ,:].apply (lambda x: kurtosis (x))
185 Autocorr=RetD.iloc [2: ,:].apply (lambda x: stats.diagnostic.acorr_ljungbox (x,
186     lags=1) [1]).transpose ()
187 JB=RetM.iloc [2: ,:].apply (lambda x: stats.stattools.jarque_bera (x) [1])
188
189 def anualizar (x):
190     a=((x+1)**(12))-1
191     return (a)
192
193 Tasas=pd.DataFrame (RetM.apply (lambda x: x.mean (0)))
194 Tasas.columns=['Retorno Mensual']
195 Tasas ['Retorno Anual']=Tasas ['Retorno Mensual'].apply (lambda x: anualizar (x))
196 Tasas ['Vol.Mensual']=SigmaM
197 Tasas ['Vol.Anual']=Tasas ['Vol.Mensual'].apply (lambda x: anualizar (x))
198 Tasas ['Skew']=Skew

```

```

197 Tasas [ 'Kurtosis ']=Kurt
198 Tasas [ 'p_LJBox ']=Autocorr
199 Tasas [ 'p_JBera ']=JB
200
201 #####
202 ###Calcula Sesgo de los estimadores de volatilidad
203
204 def Bias(data, D):
205     data=data.iloc [D:]
206     sigmaPK=np.sum((1/(len (data)-D))*(np.sqrt (data [ 'Sigma_RV '])–np.sqrt (data [ '
Sigma_PK ' ])))
207     sigmaGK=np.sum((1/(len (data)-D))*(np.sqrt (data [ 'Sigma_RV '])–np.sqrt (data [ '
Sigma_GK ' ])))
208     sigmaGKYZ=np.sum((1/(len (data)-D))*(np.sqrt (data [ 'Sigma_RV '])–np.sqrt (data
[ 'Sigma_GKYZ ' ])))
209     sigmaRS=np.sum((1/(len (data)-D))*(np.sqrt (data [ 'Sigma_RV '])–np.sqrt (data [ '
Sigma_RS ' ])))
210     sigmaSTDEV=np.sum((1/(len (data)-D))*(np.sqrt (data [ 'Sigma_RV '])–np.sqrt (
data [ 'Sigma_STDEV ' ])))
211     sigmaYZ=np.sum((1/(len (data)-D))*(np.sqrt (data [ 'Sigma_RV '])–np.sqrt (data [ '
Sigma_YZ ' ])))
212     data = { 'Sesgos ': [sigmaPK, sigmaGK, sigmaGKYZ, sigmaRS, sigmaSTDEV,
sigmaYZ]}
213     Biases = pd.DataFrame(data, index = [ 'sigmaPK', 'sigmaGK', 'sigmaGKYZ', '
sigmaRS', 'sigmaSTDEV', 'sigmaYZ'])
214     return (Biases)
215
216 #####
217 ###Calcula sesgo sobre todos los tickers
218
219 def cal_sesgos(vols, tickers, D):
220     Sesgos={}
221     for ticker in tickers:
222         Sesgos [ticker]=Bias (vols [ticker] [ 'Vols_anual' ], D)
223     sesgos_tot=pd.concat (Sesgos, 1) ###pega todos los sesgos por el eje 1 para
todos los tickers
224     sesgos_tot.columns=sesgos_tot.columns.droplevel (1)
225     return (sesgos_tot)
226
227 ruta='C:/Users/Esstefania/Desktop/Maestria Urosario/Tesis/Prueba/*.csv'
228 D=60 ##Ventana de dias para el calculo de la volatilidad
229 files = glob.glob (os.path.join (ruta))
230 tickers=Resultados.keys ()
231 Sesgos_tot=cal_sesgos (vols=Resultados, tickers=tickers, D=D)
232 Sesgos_tot.transpose ()
233
234 ##indicador Menor Sesgo
235 tickers=Resultados.keys ()
236 for ticker in tickers:
237     Sesgos_tot=Sesgos_tot.sort_values (ticker)
238     Sesgos_tot [ticker+'_o'] = range (1, len (Sesgos_tot)+1)
239
240 Sesgos_tot_or=Sesgos_tot.filter (like='_o', axis=1).copy ()

```

```

241 Sesgos_tot_or ['rank_sesgo_promedio']=Sesgos_tot_or.mean(axis=1)
242 Sesgos_tot_or.sort_values('rank_sesgo_promedio').transpose()
243
244 #####
245 ###Calcula turnover del estimador de volatilidad
246
247 def VIO(data, D):
248     data=data.iloc[D+1:]
249     sigmaRV=np.sum(np.abs((1/(len(data)-D-1))*((1/np.sqrt(data['Sigma_RV']))
250     - (1/np.sqrt(data['Sigma_RV'].shift(1))))))
251     sigmaPK=np.sum(np.abs((1/(len(data)-D-1))*((1/np.sqrt(data['Sigma_PK']))
252     - (1/np.sqrt(data['Sigma_PK'].shift(1))))))
253     sigmaGK=np.sum(np.abs((1/(len(data)-D-1))*((1/np.sqrt(data['Sigma_GK']))
254     - (1/np.sqrt(data['Sigma_GK'].shift(1))))))
255     sigmaGKYZ=np.sum(np.abs((1/(len(data)-D-1))*((1/np.sqrt(data['Sigma_GKYZ']
256     ))-(1/np.sqrt(data['Sigma_GKYZ'].shift(1))))))
257     sigmaRS=np.sum(np.abs((1/(len(data)-D-1))*((1/np.sqrt(data['Sigma_RS'])
258     - (1/np.sqrt(data['Sigma_RS'].shift(1))))))
259     sigmaSTDEV=np.sum(np.abs((1/(len(data)-D-1))*((1/np.sqrt(data['Sigma_STDEV
260     ']))-(1/np.sqrt(data['Sigma_STDEV'].shift(1))))))
261     sigmaYZ=np.sum(np.abs((1/(len(data)-D-1))*((1/np.sqrt(data['Sigma_YZ'])
262     - (1/np.sqrt(data['Sigma_YZ'].shift(1))))))
263     data = {'Turnover':[sigmaRV, sigmaPK, sigmaGK, sigmaGKYZ, sigmaRS,
264     sigmaSTDEV, sigmaYZ]}
265     Turnover = pd.DataFrame(data, index =['sigmaRV', 'sigmaPK', 'sigmaGK', '
266     sigmaGKYZ', 'sigmaRS', 'sigmaSTDEV', 'sigmaYZ'])
267     return (Turnover)
268
269 #####
270 ###Calcula turnover sobre todos los tickers
271
272 def cal_VTO(vols, tickers, D):
273     ROT={}
274     for ticker in tickers:
275         ROT[ticker]=VIO(vols[ticker]['Vols_anual'], D)
276     VTO_total=pd.concat(ROT,1)
277     VTO_total.columns=VTO_total.columns.droplevel(1)
278     return (VTO_total)
279
280 ruta='C:/Users/Esstefania/Desktop/Maestria Urosario/Tesis/Prueba/*.csv'
281 D=60 ##Ventana de dias para el calculo de la volatilidad
282 files = glob.glob(os.path.join(ruta))
283 tickers=Resultados.keys()
284 VTO_tot=cal_VTO(vols=Resultados, tickers=tickers, D=D)
285 VTO_tot.transpose()
286
287 ##indicador Menor turnover
288 tickers=Resultados.keys()
289 for ticker in tickers:
290     VTO_tot=VTO_tot.sort_values(ticker)
291     VTO_tot[ticker+'_o'] = range(1, len(VTO_tot)+1)
292 VTO_tot_or=VTO_tot.filter(like='_o', axis=1).copy()
293 VTO_tot_or['rank_turnover_promedio']=VTO_tot_or.mean(axis=1)

```

```

285 VTO_tot_or.transpose()
286
287 #####Correlaciones promedio sobre todos os tickers
288 corr={}
289 tickers=Resultados.keys()
290 for ticker in tickers:
291     corr[ticker]=Resultados[ticker]['Vols_anual'].corr()
292 c=np.zeros((7,7))
293
294 for ticker in tickers:
295     c=c+corr[ticker]
296 Corr_Promedio=c/len(list(tickers))
297
298 #####
299 ###Funcion para calcular senales
300 ##### Recibe 4 parametros:
301 #1. data: Dataframe con la fecha como indice y el precio del activo (El precio
      se debe llamar Closing_price)
302 #2. ticker: Corresponde al ticker que se quiera graficar (La idea es que se
      apalanque en datos_insumo(get_vols))
303 #3. J: Correspondiente al lookback period (Tener en cuenta las unidades de
      tiempo del indice del Dataframe)
304 #4. K: Correspondiente al holding period donde se mide el desempeño
305 #Tiene 3 parametros mas para las graficas , pero son opcionales
306 #Nota. Es importante tener en cuenta la frecuencia para generar las senales ,
      para ello de debe llevar la serie al intervalo de tiempo deseado: (Y: anos
      , Q: trimestres , M:Meses , W:weeks D:Dias (BM y BD son habiles)) con #la
      funcion asfreq:
307 #data=data.asfreq(freq)
308
309 ##### Regresa como resultado:
310 #1. Signals: Base inicial que se carga desde el csv
311 #2. Graf_Total: Base con los calculos de los diferentes precios intraday
312 #3. Graf_Returnos: Base con las Vols Diarias sobre las metodologias que
      aplican
313 #4. Graf_Signals: Base final , con las volaitidades calculadas a una ventana D,
      anualizadas
314
315 def signals(data , ticker , J , K , plotSt=True , plotSignal=True , plotRt=True):
316     #Signals
317     def SMT(vec , J):
318         dat=pd.DataFrame(vec)
319         res={}
320         res1={}
321         datan={}
322         signal=[]
323         final_signal=0
324         for i in range(4,10):
325             interv=int(J/i)
326             name=str(i)
327             temp=pd.DataFrame(dat.rolling(interv).mean()).iloc[interv::interv
      ,:]
328             temp.columns=['mean_subinter'+name]

```

```

329         temp1=pd.DataFrame(pd.Series(range(1, len(dat)+1,1), index=dat.index
    )) .rolling(interv).mean().iloc[interv::interv,:]
330         temp1.columns=['subinter'+name]
331         datan[i-4]=pd.concat([temp, temp1],1)
332         res[i-4]=sm.OLS(datan[i-4]['mean_subinter'+name], sm.add_constant(
    datan[i-4]['subinter'+name]), df=datan[i-4]).fit().tvalues[1]
333         res1[i-4]=sm.OLS(datan[i-4]['mean_subinter'+name], sm.add_constant(
    datan[i-4]['subinter'+name]), df=datan[i-4]).fit().rsquared
334         if res[i-4]>2 and res[i-4]>0.65:
335             signal.append(1)
336         elif res[i-4]<-2 and res[i-4]>0.65:
337             signal.append(-1)
338         else:
339             signal.append(0)
340     if 1 in signal:
341         final_signal=1
342     elif -1 in signal:
343         final_signal=-1
344     else:
345         final_signal=0
346     ret = {
347         'tstat': res,
348         'RSquared': res1,
349         'data': datan,
350         'signals': signal,
351         'final_signal': final_signal }
352     return (final_signal)
353
354     data['Retorno_Signo'] = data['Closing_price'].pct_change(J)
355     data['Trade_pos_Signo'] = np.where(data['Retorno_Signo']>0, 1, -1)
356     data['Precio_MA'] = data['Closing_price'].rolling(J).mean()
357     data['Trade_pos_MA'] = np.where(data['Precio_MA']<data['Closing_price'],
    1, -1)
358     data['statTrend'] = PandasRollingOLS(y=data['Closing_price'], x=pd.Series(
    range(1, len(data)+1,1), index=data.index), window=J).tstat_beta
359     data['Trade_pos_TREND'] = np.where(data['statTrend']>2, 1, np.where(data['
    statTrend']<(-2), -1, 0))
360     data['Trade_pos_SMT'] = data['Closing_price'].rolling(window=J).apply(
    lambda x: SMT(x, J), raw=True)
361     ##rezagos de las senales
362     data['Trade_pos_Signo']=data['Trade_pos_Signo'].shift(1)
363     data['Trade_pos_MA']=data['Trade_pos_MA'].shift(1)
364     data['Trade_pos_TREND']=data['Trade_pos_TREND'].shift(1)
365     data['Trade_pos_SMT']=data['Trade_pos_SMT'].shift(1)
366     #Retornos
367     data['log_ret'] = np.log(data['Closing_price']).diff()
368     data['ret_signo'] = data['Trade_pos_Signo'] * data['log_ret']
369     data['ret_ma'] = data['Trade_pos_MA'] * data['log_ret']
370     data['ret_TREND'] = data['Trade_pos_TREND'] * data['log_ret']
371     data['ret_SMT'] = data['Trade_pos_SMT'] * data['log_ret']
372     ##Retornos Acumulados
373     dataret=data.iloc[J:J+K,:].copy()
374     dataret['ret_acum_Buy_Hold'] = dataret['log_ret'].cumsum()

```



```

375 dataret['ret_acum_signo'] = dataret['ret_signo'].cumsum()
376 dataret['ret_acum_ma'] = dataret['ret_ma'].cumsum()
377 dataret['ret_acum_TREND'] = dataret['ret_TREND'].cumsum()
378 dataret['ret_acum_SMT'] = dataret['ret_SMT'].cumsum()
379 ###Graficas
380 if plotSt==True:
381     fig = plt.figure(figsize=(15, 4))
382     t='Serie del precio de '+ticker
383     ax = fig.add_subplot(1,1,1)
384     ax.plot(data.index[:J+K], data.Closing_price[:J+K], label='precio')
385     ax.set_ylabel('Precio')
386     ax.set_title(t, fontsize=16)
387     ax.xaxis.set_major_locator(WeekdayLocator())
388     ax.set_xticklabels(dataret.index, rotation=90)
389     plt.axvline(data.index[J], linewidth=1, color='deeppink', ls='--')
390     ax.xaxis.set_major_formatter(mdates.DateFormatter('%Y-%m-%d'))
391     plt.show()
392 if plotSignal==True:
393     fig = plt.figure(figsize=(16, 4))
394     ax = fig.add_subplot(1,1,1)
395     ax.plot(dataret.index, dataret['Trade_pos_Signo'], label='')
396     ax.plot(dataret.index, dataret['Trade_pos_Signo'], label='SIGN')
397     ax.plot(dataret.index, dataret['Trade_pos_MA'], label='MA')
398     ax.plot(dataret.index, dataret['Trade_pos_TREND'], label='TREND')
399     ax.plot(dataret.index, dataret['Trade_pos_SMT'], label='SMT')
400     ax.set_ylabel('Trading position')
401     ax.set_title('Posiciones por Estrategia', fontsize=16)
402     ax.xaxis.set_major_locator(WeekdayLocator())
403     ax.set_xticklabels(dataret.index, rotation=90)
404     ax.xaxis.set_major_formatter(mdates.DateFormatter('%Y-%m-%d'))
405     ax.legend(bbox_to_anchor=(1, 1), loc=2)
406     plt.show()
407 if plotRt==True:
408     fig = plt.figure(figsize=(16, 4))
409     ax = fig.add_subplot(1,1,1)
410     ax.plot(dataret.index, dataret.ret_acum_Buy_Hold, label='BUY HOLD')
411     ax.plot(dataret.index, dataret.ret_acum_signo, label='SIGN')
412     ax.plot(dataret.index, dataret.ret_acum_ma, label='MA')
413     ax.plot(dataret.index, dataret.ret_acum_TREND, label='TREND')
414     ax.plot(dataret.index, dataret.ret_acum_SMT, label='SMT')
415     ax.set_ylabel('Retornos Acumulados')
416     ax.legend(bbox_to_anchor=(1, 1), loc=2)
417     plt.axhline(y=0, linewidth=1, color='deeppink', ls='--')
418     ax.set_title('Retornos Acumulados por estrategias', fontsize=16)
419     ax.xaxis.set_major_locator(WeekdayLocator())
420     ax.set_xticklabels(dataret.index, rotation=90)
421     ax.xaxis.set_major_formatter(mdates.DateFormatter('%Y-%m-%d'))
422     plt.show()
423 ret = {
424     'Retorno_t+K': dataret.iloc[:, -5:].tail(1),
425     'Serie retornos': dataret,
426     'Posiciones': dataret[['Trade_pos_Signo', 'Trade_pos_MA', 'Trade_pos_TREND',
427     'Trade_pos_SMT']]

```

```

427     }
428     return(ret)
429
430 #####
431 ###Funcion para calcular senales sobre multiples tickers
432
433 def ret_tot(data, tickers, J, K):
434     Signals_ret_final={}
435     Signals_rets={}
436     Posiciones={}
437     for ticker in tickers:
438         data1=data[ticker]['Datos_insumo'].iloc[-K-J-1:,0:1].copy()
439         Signals_ret_final[ticker]=signals(data=data1, ticker=ticker, J=J, K=K,
440         plotRt=False, plotSignal=False, plotSt=False)['Retorno_t+K']
441         Posiciones[ticker]=signals(data=data1, ticker=ticker, J=J, K=K, plotRt
442 =False, plotSignal=False, plotSt=False)['Posiciones']
443         Signals_rets[ticker]=signals(data=data1, ticker=ticker, J=J, K=K,
444 plotRt=False, plotSignal=False, plotSt=False)['Serie_retornos']
445         Signals_tot=pd.concat(Signals_ret_final,0)
446     ret = {
447         'Signals_finalK': Signals_tot,
448         'Signals_rets': Signals_rets,
449         'Posiciones': Posiciones
450     }
451     return(ret)
452
453 #####
454 ###Funcion para construir TSMOM
455 ## Recibe n parametros
456 ##1. Signals_ret: resultados de la funcion signals
457 ##2. Resultados: Resultados de la funcion get_vols
458 ##3. tickers: lista de los que se quieren evaluar
459 ##4. vols: lista con las metodologias de volatilidad que se quieran evaluar:
460 #['RV', 'YZ', 'GKYZ', 'STDEV', 'RS', 'GK']
461 ##5. signs: lista con las metodologias de senales que se quieran evaluar
462 #['TREND', 'SMT', 'SIGNO', 'MA']
463 ##6. porc: porcentaje de volatilidad que se quiere alcanzar, por defecto 40%
464
465 ##Regresa un diccionario con los siguientes resultados
466 ##1. Un dataframe con ctodas las combinaciones de volatilidades y senales para
467 la respectiva venta de K dias
468 ##2. Dependiendo de las senales y volatilidades escogidas como parametros,
469 retornara para cada combinacion
470
471 def R_TSMOM(Signals_rets, Resultados, tickers, vols, signs, porc):
472     Keys=[]
473     Keys2=[]
474     dic={}
475     for sign in signs:
476         for vol in vols:
477             temp={}
478             name=sign+'_'+vol
479             locals()[name] = temp

```

```

475         Keys.append('Estr_'+sign+'_'+vol)
476         Keys2.append('Estr_'+sign+'_'+vol+'[['+'R.tsMOM'+']]')
477         for ticker in tickers:
478             ret_sig=Signals_rets[ticker].iloc[:,-5:].copy()
479             size_sig=(porc/np.sqrt(Resultados[ticker]['Vols_anual']))*(1/
len(tickers))
480             R_ts=pd.concat([ret_sig, size_sig], axis=1, join='inner')
481             a=sign+'_'+vol+'[['+ticker+']] =pd.DataFrame({''+ticker+''':
R_ts'+[[''+ret_acum_'+sign+']]*R_ts'+[[''+Sigma_'+vol+']]')
482             exec(a)
483
484             a='Estr_'+sign+'_'+vol+'=pd.concat('+sign+'_'+vol+',1, join='+
'''+inner'+')'
485             exec(a)
486             b='Estr_'+sign+'_'+vol+'[['+'R.tsMOM'+']] ='+ 'Estr_'+sign+'_'+
vol+'.sum(axis=1)'
487             exec(b)
488             c='Estr_'+sign+'_'+vol+'.columns='+ 'Estr_'+sign+'_'+vol+'.
columns.droplevel(1)'
489             exec(c)
490             x='dic[['+'Estr_'+sign+'_'+vol+']] ='+ 'Estr_'+sign+'_'+vol+'[['
+'R.tsMOM'+']]'
491             exec(x)
492         RETORNOS.TSMOM=pd.concat(dic, axis=1, join='inner')
493
494         ret = { 'RETORNOS.TSMOM': RETORNOS.TSMOM }
495         for sign in signs:
496             for vol in vols:
497                 x='ret[['+'Estr_'+sign+'_'+vol+']] ='+ 'Estr_'+sign+'_'+vol+'
498                 exec(x)
499
500         return(ret)
501
502 #####
503 ###Contruccion de TSMOM para una grilla de K y J
504 ##Al final crea dos diccionarios uno con los retornos para cada (J,K) y otro
diccionario con las senales que genera cada combinacion
505 ticker=Resultados.keys()
506 data=Resultados
507 porc=0.4
508 signs=['TREND', 'SMT', 'ma', 'signo']
509 vols=['RV', 'YZ', 'GKYZ']
510 Js=[21,42,63,126,261]
511 Ks=[21,42,63,126,261]
512 R_TSMOM_final={}
513 signals_final={}
514 for J in Js:
515     for K in Ks:
516         indice='('+str(J)+','+str(K)+')'
517         ret=ret_tot(data, tickers, J, K)
518         rets_portafolio=ret['Signals_rets']
519         signals_final[indice]=ret['Posiciones']
520         A=R_TSMOM(Resultados=data, Signals_rets=Signals_rets, tickers=tickers,

```

```
521     vols=vols , signs=signs , porc=porc) [ 'RETORNOS.TSMOM' ]. tail(1)
522     A.columns=A.columns.droplevel(1)
523     R.TSMOM_final[indice]=A
```

Listing A.1: Código TSMOM

# Bibliografía

- T. Andersen and T. Bollerslev. Answering the skeptics: Yes, standard volatility models do provide accurate forecasts. *International Economic Review*, 39(4):885–905, 1998.
- A.-N. Balta and R. Kosowski. Improving time-series momentum strategies: The role of trading signals and volatility estimators. 2012.
- O. E. Barndorff-Nielsen and N. Shephard. Econometric analysis of realized volatility and its use in estimating stochastic volatility models. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, 64(2):253–280, 2002.
- A. C. Bryhn and P. H. Dimberg. An operational definition of a statistically meaningful trend. *PLOS ONE*, 6:1–9, 04 2011.
- M. B. Garman and M. J. Klass. On the estimation of security price volatilities from historical data. *The Journal of Business*, 53(1):67–78, 1980.
- P. Hansen and A. Lunde. Realized variance and market microstructure noise. *Journal of Business and Economic Statistics*, 24:127–161, 2006.
- T. J. Moskowitz, Y. H. Ooi, and L. H. Pedersen. Time series momentum. *Journal of Financial Economics*, 104(3):228–250, 2012.
- M. Parkinson. The extreme value method for estimating the variance of the rate of return. *The Journal of Business*, 53(1):61–65, 1980.
- C. Pirrong. Momentum in futures markets. *SSRN Electronic Journal*, 02 2005. doi: 10.2139/ssrn.671841.
- L. C. G. Rogers and S. E. Satchell. Estimating variance from high, low and closing prices. *Ann. Appl. Probab.*, 1(4):504–512, 11 1991. doi: 10.1214/aoap/1177005835.
- M. W Brandt and J. Kinlay. Estimating historical volatility. 01 2005.
- D. Yang and Q. Zhang. Drift-independent volatility estimation based on high, low, open, and close prices. *The Journal of Business*, 73(3):477–91, 2000.