


Facultad de Ciencias Económicas y Empresariales | ICADE

# REACCIONES BURSÁTILES DEL SECTOR DEFENSA ANTE SHOCKS GEOPOLÍTICOS: UN ANÁLISIS COMPARATIVO ENTRE EMPRESAS PURE PLAY Y DEFENSE TECH (2008–2026)

**Autor:** Alfonso Carlos Carrillo Encinar (202107060)
**Director:** Alejandro Rodríguez Gallego

MADRID | ABRIL – 2026

**RESUMEN**

Este trabajo analiza las reacciones bursátiles del sector defensa ante cinco shocks geopolíticos entre 2008 y 2026: la Guerra de Georgia, la Anexión de Crimea, la Invasión de Ucrania, los Ataques de Hamás y la Captura de Nicolás Maduro. La muestra incluye 64 empresas cotizadas clasificadas en dos tipologías (Pure Play y Defense Tech) mediante criterios de exposición de ingresos y datos de FactSet. El análisis combina un *event study* clásico bajo el marco CAPM de MacKinlay (1997) con un panel de datos con efectos fijos bidireccionales siguiendo a Clarke y Tapia-Schythe (2021). El *event study* detecta retornos anormales positivos y significativos en los eventos de mayor escala (Ucrania y Maduro acumulan en torno al 18-19% en las ventanas más amplias), con reacciones más moderadas en Georgia y Crimea. Las diferencias entre tipologías no alcanzan significatividad estadística en la mayoría de los casos. En Crimea, la única diferencia con significatividad marginal entre tipologías, Defense Tech se mantiene visualmente por encima de Pure Play durante toda la ventana. El panel no detecta efectos significativos al estimar los cinco shocks conjuntamente, aunque los coeficientes son cualitativamente coherentes con el *event study*. El trabajo muestra que el sector defensa no reacciona de forma uniforme y que las diferencias entre modelos de negocio dependen de la naturaleza del shock, no de un patrón sistemático entre eventos.

**PALABRAS CLAVE:** sector defensa, shocks geopolíticos, *event study*, retornos anormales acumulados, panel con efectos fijos, Pure Play, Defense Tech

**ABSTRACT**

This paper examines stock market reactions in the defense sector to five geopolitical shocks between 2008 and 2026: the Georgia War, the Annexation of Crimea, the Invasion of Ukraine, the Hamas Attacks, and the Capture of Nicolás Maduro. The sample comprises 64 listed companies classified into two typologies (Pure Play and Defense Tech) based on revenue exposure criteria and FactSet data. Two methodologies are applied: a classical *event study* under the CAPM framework of MacKinlay (1997) and a panel model with two-way fixed effects following Clarke and Tapia-Schythe (2021). The *event study* finds positive and statistically significant abnormal returns in the largest-scale events (Ukraine and Maduro accumulate around 18-19% in the widest windows), while Georgia and Crimea produce more contained responses. Differences between typologies are not statistically significant in most cases. In Crimea, the only case with marginal statistical significance between typologies, Defense Tech remains visually above Pure Play throughout the event window. The panel detects no significant effects when pooling the five shocks into a single regression, although the estimated coefficients are qualitatively consistent with the *event study* findings. The results show that the defense sector does not react as a homogeneous block, and that differences between business models depend on the nature of each shock rather than on any consistent cross-event pattern.

**KEY WORDS:** defense sector, geopolitical shocks, *event study*, cumulative abnormal returns, panel fixed effects, Pure Play, Defense Tech

# ÍNDICE

1. Introducción ..... 8

2. Marco teórico ..... 11

2.1. La hipótesis de eficiencia de mercado (Fama, 1970) ..... 11

2.2. Revisión de estudios previos: geopolítica y comportamiento bursátil en empresas de defensa 12

2.3. La metodología del event study (MacKinlay, 1997) ..... 14

2.3.1. Definición de las ventanas ..... 15

2.3.2. Cálculo de los retornos esperados: modelo de referencia e índice de mercado ..... 16

2.3.3. Retornos anormales (AR) y retornos anormales acumulados (CAR) ..... 19

2.3.4. Test de significancia estadística ..... 20

2.4. Introducción de la metodología de panel (DiD con efectos fijos) y sus ventajas ..... 24

3. Definición del problema ..... 25

4. Metodología ..... 26

4.1. Preparación de la muestra ..... 26

4.1.1. Selección de empresas y clasificación (Pure Play vs Defense Tech) ..... 26

4.1.2. Selección y definición de eventos geopolíticos ..... 33

4.1.3. Fuentes de datos, frecuencia y periodo temporal ..... 38

4.2. Especificación econométrica ..... 40

4.2.1. Event Study clásico ..... 40

4.2.2. Panel con efectos fijos ..... 40

5. Resultados ..... 41

5.1. Resultados del event study clásico (MacKinlay): resultados agregados ..... 41

5.1.1. Retornos anormales en t=0: AR y SAR ..... 41

5.1.2. Retornos anormales acumulados por ventana ..... 44

5.2. Event study clásico: comparación Pure Play vs Defense Tech ..... 47

5.2.1. Diferencias entre Pure Play y Defense Tech en t=0 ..... 47

5.2.2. Dinámica temporal por evento ..... 48

5.3. Síntesis del event study (MacKinlay) ..... 61

5.4. Resultados del panel con efectos fijos (DiD) ..... 62
5.4.1. Resultados para Pure Play ..... 63
5.4.2. Resultados para Defense Tech ..... 66
6. Conclusiones ..... 68
6.1. Interpretación de los resultados ..... 68
6.2. Limitaciones del estudio y líneas futuras de investigación ..... 70
7. Bibliografía ..... 72
8. Uso de IA ..... 78

# ÍNDICE DE ILUSTRACIONES

Ilustración 1. Fuerza Aérea de EE.UU.: evolución del gasto en RDT&E y adquisiciones (FY2017–FY2023, en miles de millones de USD constantes de FY2024). ..... 9

Ilustración 2. Gasto militar mundial por región, 1988–2024 (en miles de millones de USD constantes de 2023)..... 10

Ilustración 3. Número de aliados de la OTAN que cumplen el objetivo del 2% del PIB en gasto militar (2014–2025). ..... 10

Ilustración 4. Proceso de selección y clasificación de la muestra. ..... 30

Ilustración 5. Georgia: ubicación de Abjasia y Osetia del Sur, regiones en disputa durante el conflicto de agosto de 2008. ..... 35

Ilustración 6. Ucrania: ubicación de la península de Crimea, anexionada por Rusia en marzo de 2014. ..... 36

Ilustración 7. La Franja de Gaza: contexto geográfico del Ataque de Hamás del 7 de octubre de 2023. ..... 37

Ilustración 8. Portada de El Mundo del domingo 4 de enero de 2026, tras la captura de Nicolás Maduro por fuerzas estadounidenses. ..... 38

Ilustración 9. AR medio por evento. ..... 43

Ilustración 10. SAR medio por evento. ..... 44

Ilustración 11. CAR acumulado medio por evento. ..... 45

Ilustración 12. SAR acumulado medio por evento. ..... 47

Ilustración 13. AR medio: Pure Play vs Defense Tech - Guerra de Georgia. ..... 49

Ilustración 14. CAR acumulado: Pure Play vs Defense Tech - Guerra de Georgia. ..... 50

Ilustración 15. AR medio: Pure Play vs Defense Tech - Anexión de Crimea. ..... 51

Ilustración 16. CAR acumulado: Pure Play vs Defense Tech - Anexión de Crimea. ..... 52

Ilustración 17. AR medio: Pure Play vs Defense Tech - Invasión de Ucrania. ..... 53

Ilustración 18. SAR medio: Pure Play vs Defense Tech - Invasión de Ucrania. ..... 54

Ilustración 19. CAR acumulado: Pure Play vs Defense Tech - Invasión de Ucrania. ..... 54

Ilustración 20. SAR acumulado: Pure Play vs Defense Tech - Invasión de Ucrania. ..... 55

Ilustración 21. AR medio: Pure Play vs Defense Tech - Ataques de Hamás. ..... 56

Ilustración 22. CAR acumulado: Pure Play vs Defense Tech - Ataques de Hamás. ..... 57

Ilustración 23. SAR acumulado: Pure Play vs Defense Tech - Ataques de Hamás. ..... 58

Ilustración 24. AR medio: Pure Play vs Defense Tech - Captura de Maduro. ..... 59

Ilustración 25. CAR acumulado: Pure Play vs Defense Tech - Captura de Maduro. ..... 60

Ilustración 26. SAR acumulado: Pure Play vs Defense Tech - Captura de Maduro. ..... 61

Ilustración 27. Panel event study de Pure Play. ..... 64

Ilustración 28. Efecto acumulado del panel: Pure Play. ..... 65

Ilustración 29. Panel event study de Defense Tech. ..... 67

Ilustración 30. Efecto acumulado del panel: Defense Tech. ..... 67

## ÍNDICE DE TABLAS

Tabla 1. Muestra ilustrativa de empresas del sector defensa. ..... 31

Tabla 2. Empresas adicionales y exposición a defensa según RBICS (FactSet). ..... 32

Tabla 3. Resumen de los eventos geopolíticos seleccionados. ..... 34

Tabla 4. Retorno anormal medio en t=0 por evento. ..... 42

Tabla 5. Retorno anormal estandarizado (SAR) medio en t=0 por evento. ..... 43

Tabla 6. CAR medio por evento y ventana. ..... 44

Tabla 7. SCAR medio por evento y ventana. ..... 46

Tabla 8. AR medio en t=0 por tipología: Pure Play vs Defense Tech. ..... 47

Tabla 9. SAR medio en t=0 por tipología: Pure Play vs Defense Tech. ..... 48

Tabla 10. Coeficientes del panel con efectos fijos: Pure Play. ..... 63

Tabla 11. Coeficientes del panel con efectos fijos: Defense Tech. ..... 66

# 1. Introducción

El sector defensa presenta una dinámica bursátil estrechamente vinculada al entorno geopolítico y a la evolución del gasto militar. A diferencia de otros sectores, una parte relevante de sus expectativas de ingresos se apoya en decisiones públicas, programas de adquisición de largo plazo y cambios en prioridades de seguridad nacional (Rogerson, 1994). Por este motivo, eventos geopolíticos relevantes pueden alterar de forma repentina las expectativas del mercado sobre demanda, presupuestos y riesgo, generando reacciones visibles en la valoración de las compañías del sector (Klein, 2024; Panazan & Gheorghe, 2025). Bajo la hipótesis de eficiencia, dicha información se refleja con rapidez en los precios, al ajustarse las expectativas de los inversores sobre beneficios futuros y primas de riesgo (Fama, 1970).

Sin embargo, el sector defensa no es homogéneo. En las últimas décadas, junto a los grandes contratistas industriales tradicionales, han ganado peso capacidades tecnológicas con aplicaciones de doble uso, como software, datos, ciberseguridad, comunicaciones, sensores y electrónica avanzada. Esta transformación se refleja en la evolución del presupuesto de defensa estadounidense: entre 2017 y 2023, la inversión en investigación, desarrollo, pruebas y evaluación (RDT&E) de la Fuerza Aérea creció de $19,6 mil millones a $50,5 mil millones (+158%), mientras que las adquisiciones de equipamiento tradicional aumentaron de $22,4 mil millones a $34,1 mil millones (+52%), invirtiendo la tendencia histórica en la que el gasto en adquirir equipamiento había superado tradicionalmente al de I+D (Beaver et al., 2024).

Esta tendencia queda confirmada cuando se examinan los outlays reales de la Fuerza Aérea. Según los datos de ejecución presupuestaria recogidos en la Tabla 6-24 del Green Book del Departamento de Defensa, el gasto efectivo en RDT&E pasó de 24.900 millones de dólares en FY2017 a 53.600 millones en FY2023, mientras que el gasto en adquisiciones creció de forma más moderada, de 40.500 a 48.600 millones en el mismo periodo. El cruce entre ambas partidas se produjo en torno a FY2022, de modo que en FY2023 el gasto real en I+D superó al de adquisiciones por primera vez en términos de outlays. La Ilustración 1 recoge esta evolución y permite apreciar visualmente la compresión progresiva de la brecha entre ambas categorías a lo largo del periodo.

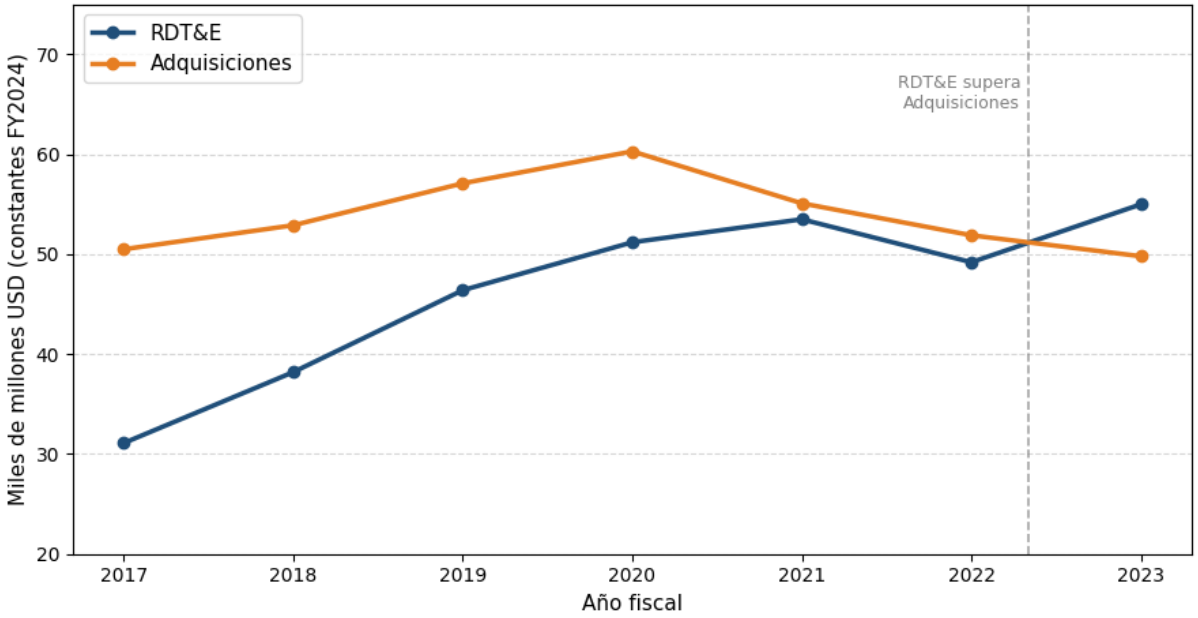


**Ilustración 1.** Fuerza Aérea de EE.UU.: evolución del gasto en RDT&E y adquisiciones (FY2017–FY2023, en miles de millones de USD constantes de FY2024).
**Fuente:** Elaboración propia a partir de Office of the Under Secretary of Defense (Comptroller) (2023), Table 6-24.

Este crecimiento tecnológico se produce en un contexto de expansión del gasto militar global. En 2024, el gasto mundial alcanzó los $2.718 miles de millones (en adelante, "miles de millones" equivale al término anglosajón billion), registrando el aumento interanual más pronunciado desde al menos el final de la Guerra Fría. El incremento ha sido especialmente notable en Europa, donde la invasión rusa de Ucrania en febrero de 2022 marcó un punto de inflexión. En 2024, el gasto militar europeo alcanzó $693 mil millones, un 17% más que en 2023, superando los niveles registrados al final de la Guerra Fría. Países como Alemania, que anunció un fondo especial de €100 mil millones para defensa en febrero de 2022, aumentaron su gasto un 28% en 2024, convirtiéndose en el cuarto mayor gastador mundial. Polonia, por su parte, alcanzó un 4,2% de su PIB en gasto militar, reflejando la percepción de amenaza directa en el flanco oriental de la OTAN (Stockholm International Peace Research Institute [SIPRI], 2025). La Ilustración 2 muestra la evolución regional de este gasto desde 1988, donde el punto de inflexión post-2022 es especialmente visible en Europa.

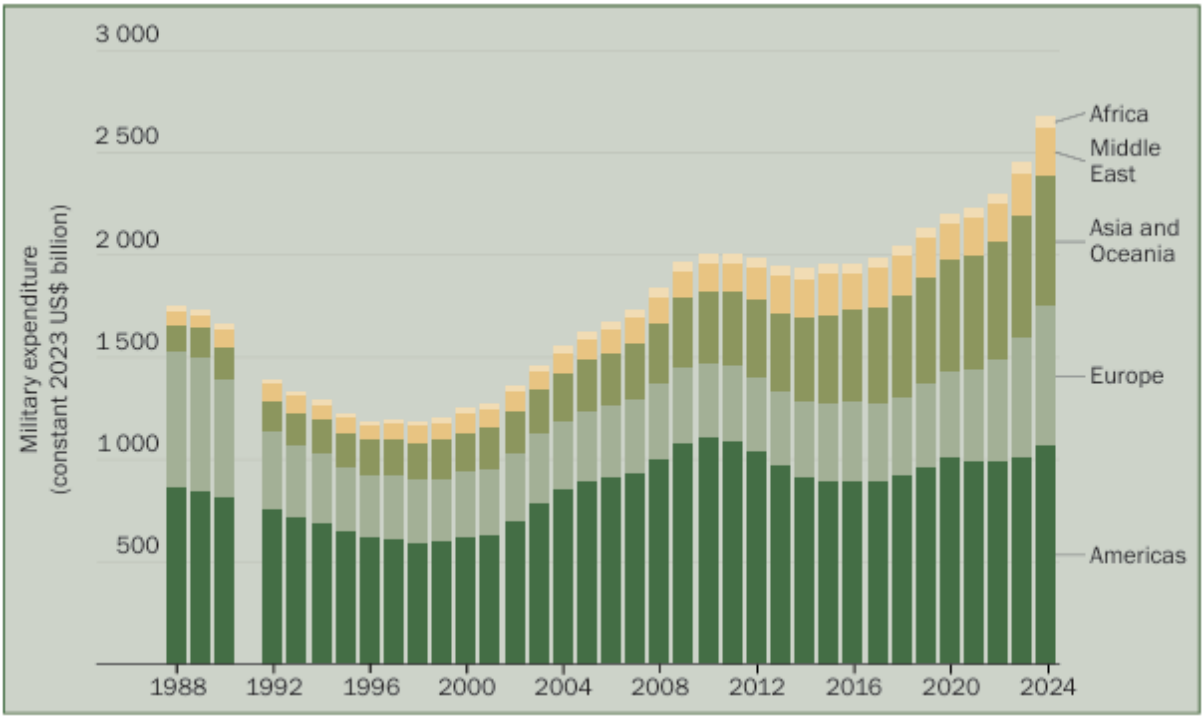


**Ilustración 2.** Gasto militar mundial por región, 1988–2024 (en miles de millones de USD constantes de 2023).
**Fuente:** Liang et al., (2025).

Este cambio se refleja también en el cumplimiento de los compromisos de la OTAN: mientras que en 2023 solo 10 países miembros alcanzaban el objetivo del 2% del PIB en gasto militar, en 2024 esta cifra ascendió a 18 países, el nivel más alto desde la adopción de esta guía en 2014. La Ilustración 3 recoge la evolución completa desde 2014.

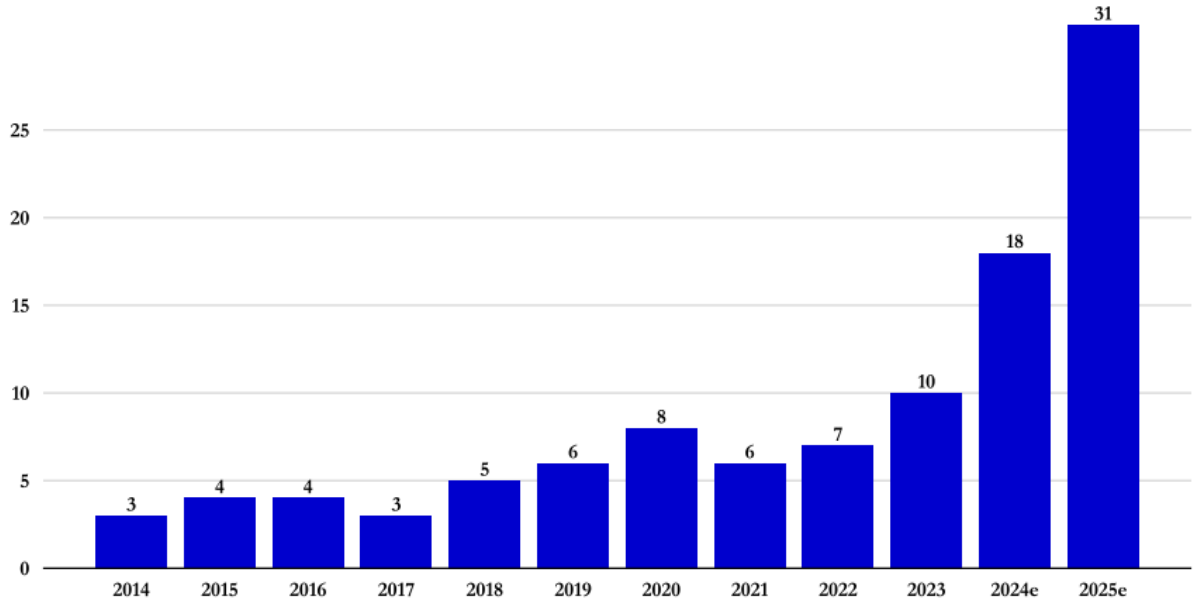


**Ilustración 3.** Número de aliados de la OTAN que cumplen el objetivo del 2% del PIB en gasto militar (2014–2025).
**Fuente:** NATO (2025).

Fuera del ámbito europeo, el conflicto entre Israel y Hamás iniciado el 7 de octubre de 2023 generó un incremento del 65% en el gasto militar israelí en 2024, el mayor aumento anual desde la Guerra de los Seis Días de 1967 (Stockholm International Peace Research Institute [SIPRI], 2025). A nivel empresarial, el impacto de este entorno se traduce en cifras como los $218 mil millones de pedidos acumulados (backlog) de RTX Corporation en 2024, reflejando la creciente demanda de sistemas de defensa en un contexto de mayor incertidumbre geopolítica (Mathews, 2025).

Este cambio en la composición del sector sugiere que empresas con modelos de negocio distintos pueden reaccionar de forma diferente ante el mismo evento, tanto por la naturaleza de su oferta como por su exposición a programas, ciclos de innovación y riesgo regulatorio. Por ello, este trabajo distingue entre dos tipologías operativas dentro del sector: Pure Play, asociada a actividades industriales y programas tradicionales de defensa, y Defense Tech, asociada a capacidades tecnológicas y digitales aplicadas a defensa. Esta clasificación permite analizar si la reacción del mercado ante eventos geopolíticos varía de forma sistemática según el modelo de negocio. El presente trabajo examina esta cuestión mediante un análisis de eventos aplicado a cinco episodios geopolíticos entre 2008 y 2026, combinando la metodología clásica de *event study* con un enfoque de panel con efectos fijos.

# 2. Marco teórico

## 2.1. La hipótesis de eficiencia de mercado (Fama, 1970)

El marco conceptual que sustenta el uso del *event study* en este trabajo arranca de la hipótesis de eficiencia de mercado, cuya formulación sistemática se debe a Fama (1970). En su artículo seminal, Fama define un mercado eficiente como aquel en el que los precios reflejan en todo momento la totalidad de la información disponible. Esta definición, aunque intuitivamente clara, no tiene contenido empírico por sí sola: para hacerla contrastable es necesario especificar qué conjunto de información se considera relevante y a qué velocidad se supone que esta información queda incorporada en los precios. Con ese objetivo, Fama propone distinguir tres formulaciones de la hipótesis según el subconjunto de información al que se refieren, lo que da lugar a los tests de forma débil, semi-fuerte y fuerte.

La forma débil plantea que los precios ya incorporan toda la información contenida en la historia de cotizaciones y retornos pasados, por lo que estudiar el comportamiento histórico de

un activo no permite anticipar rentabilidades superiores a las del mercado. La forma semi-fuerte sostiene que los precios reflejan también toda la información pública disponible, como anuncios de resultados, divisiones de acciones o nuevas emisiones, y que el mercado la absorbe de forma rápida e imparcial cuando se produce. Por último, la forma fuerte postula que los precios incorporan incluso la información privada, aquella a la que solo acceden determinados agentes con una posición privilegiada (Fama, 1970).

De estas tres formulaciones, la relevante para este trabajo es la eficiencia de forma semi-fuerte. Un evento geopolítico como los analizados aquí constituye exactamente el tipo de información pública repentina cuya incorporación al precio interesa evaluar. Si el mercado es eficiente en este sentido, el ajuste debería producirse de forma rápida y sin dejar retornos anormales persistentes en los días siguientes al evento. El *event study* es precisamente la herramienta metodológica diseñada para contrastar esta hipótesis, ya que permite medir si el retorno observado alrededor de la fecha del suceso se desvía de forma significativa del retorno que cabría esperar en ausencia del mismo (Fama, 1970; MacKinlay, 1997).

## 2.2. Revisión de estudios previos: geopolítica y comportamiento bursátil en empresas de defensa

La literatura empírica sobre el sector defensa ha prestado especial atención a la relación entre shocks geopolíticos y comportamiento bursátil, dado que una parte relevante de la demanda del sector está mediada por decisiones de gasto público y por cambios en prioridades de seguridad. El argumento central de esta literatura es que un aumento repentino del riesgo geopolítico puede modificar expectativas sobre presupuestos de defensa, reposición de inventarios y ritmo de contratación, lo que se traduce en reacciones del mercado en torno a eventos concretos o a episodios de escalada internacional.

Una línea de evidencia se centra en episodios geopolíticos concretos y documenta que determinados eventos pueden estar asociados a revalorizaciones en compañías de defensa, especialmente cuando el mercado anticipa un cambio persistente en el gasto militar. En el caso de la invasión rusa de Ucrania, varios estudios señalan reacciones positivas en empresas del sector, con especial intensidad en Europa, en un contexto de anuncios de incremento presupuestario y de planes de rearme (Martins et al., 2025). Sin embargo, esta evidencia no es uniforme: la magnitud y el signo de la reacción pueden variar por país, por empresa y por el

tipo de exposición operativa, lo que sugiere que el sector no responde como un bloque homogéneo (Gheorghe & Panazan, 2024; Zhang et al., 2022).

Un segundo resultado recurrente es que el impacto del riesgo geopolítico no se limita a retornos, sino que se manifiesta también en medidas de riesgo, especialmente en volatilidad. Con enfoques que explotan noticias o medidas de riesgo geopolítico, se observa que los episodios de escalada tienden a reflejarse de forma rápida en la volatilidad de compañías vinculadas al sector, algo que apunta a un ajuste inmediato en la incertidumbre percibida (Klein, 2024; Panazan & Gheorghe, 2025). Esta dimensión es relevante porque indica que un mismo shock puede alterar simultáneamente expectativas de beneficio y percepción de riesgo, afectando tanto a la valoración como a la dispersión de resultados esperados.

La evidencia previa apoya dos conclusiones útiles para este trabajo. En primer lugar, los shocks geopolíticos pueden estar asociados a cambios significativos en la valoración de empresas de defensa, pero el efecto no es necesariamente homogéneo entre compañías. En segundo lugar, el impacto puede operar tanto a través de retornos como a través de cambios en el riesgo percibido, especialmente en volatilidad.

No obstante, la mayor parte de los estudios analiza el sector defensa de forma agregada (por índices, carteras sectoriales o muestras heterogéneas), lo que dificulta identificar si la reacción ante un mismo shock difiere entre empresas con perfiles operativos distintos. Este trabajo introduce una clasificación operativa entre Pure Play y Defense Tech para explorar explícitamente esa heterogeneidad dentro del sector, manteniendo criterios replicables basados en segmentación y exposición de ingreso, en línea con el enfoque del JRC (2018), que documenta la heterogeneidad operativa y tecnológica dentro del sector defensa y distingue entre empresas con exposición predominante a armamento y empresas con actividad civil-militar mixta (European Commission. Joint Research Centre., 2018).

En este contexto, este estudio realiza tres aportaciones operativas. En primer lugar, analiza una selección de eventos geopolíticos relevantes para el sector defensa, priorizando aquellos donde sea posible aislar el efecto específico sobre estas empresas frente a shocks de mercado excesivamente generalizados. En segundo lugar, introduce una comparación explícita por tipología (Pure Play frente a Defense Tech) para evaluar si la reacción del mercado varía de forma sistemática según el modelo de negocio. En tercer lugar, complementa el análisis con un enfoque de datos de panel que incorpora efectos fijos de empresa y fecha, lo que permite

contrastar los resultados desde un marco empírico alternativo y más robusto frente a factores confusores (Clarke & Tapia-Schythe, 2021).

## 2.3. La metodología del event study (MacKinlay, 1997)

La metodología del *event study* se utiliza para evaluar si un evento identificable en el tiempo produce un efecto medible sobre el retorno de una acción. La idea central consiste en comparar el retorno observado alrededor de la fecha del evento con un retorno esperado, estimado a partir de un modelo que captura el comportamiento habitual del activo en condiciones normales. La diferencia entre ambos se interpreta como retorno anormal, es decir, como la parte del retorno que no se explica por los factores sistemáticos incorporados en el modelo y que, por tanto, es atribuible al evento bajo análisis (MacKinlay, 1997).

Siguiendo la descripción metodológica estándar de los *event studies* recogida por Kothari & Warner (2004), la implementación de un *event study* puede estructurarse en los siguientes pasos:

1. Definición del evento y del tiempo de evento: se identifica el evento y se fija la escala temporal en tiempo de evento, tomando $t = 0$ como el momento del suceso para alinear las observaciones alrededor de la misma referencia temporal.

2. Especificación del modelo de retornos esperados: se define un modelo para calcular los retornos esperados, entendido como el retorno que se observaría si no ocurriese el evento. Esto está condicionado a la información disponible y a los factores sistemáticos incluidos en el modelo.

3. Cálculo de retornos anormales (AR): se obtienen los retornos anormales como la diferencia entre el retorno observado y el retorno normal estimado por el modelo, de modo que el componente no explicado se interpreta como la parte atribuible al evento.

4. Agregación transversal: se agregan los retornos anormales entre empresas para obtener el retorno anormal medio en cada periodo de la ventana del evento, lo que permite analizar patrones comunes en la muestra.

5. Cálculo de retornos anormales acumulados (CAR): se acumulan los retornos anormales a lo largo de un intervalo $[t_1, t_2]$ para capturar efectos que puedan distribuirse en varios días y sintetizar el impacto total en la ventana analizada.

6. Contrastes de significancia: se construyen estadísticos de contraste para evaluar si los AR y CAR difieren significativamente de cero, utilizando varianzas estimadas y supuestos distribucionales que permitan realizar inferencia estadística sobre el efecto del evento.

### 2.3.1. Definición de las ventanas

**a) Ventana de evento**

La ventana de evento corresponde al intervalo temporal en el que se espera observar la reacción del mercado ante el suceso que estamos analizando. En un *event study* con datos diarios, esta ventana suele definirse incluyendo días alrededor de la fecha del evento ($t = 0$), de forma que se capture no solo el ajuste inmediato, sino también posibles efectos previos o posteriores ligados al proceso de incorporación de la información a precios (Kothari & Warner, 2004; MacKinlay, 1997).

La elección de la longitud de la ventana de evento implica una decisión relevante. Por un lado, una ventana demasiado estrecha puede infraestimar el efecto si existe anticipación del mercado, filtraciones o una incorporación progresiva de la información. Por otro, una ventana excesivamente amplia incrementa el riesgo de incorporar noticias no relacionadas que introduzcan ruido y dificulten atribuir el movimiento observado al evento. Por ello, la práctica habitual es definir una ventana de evento razonable, justificada por el contexto informativo del evento, y complementar el análisis con pruebas de sensibilidad utilizando ventanas alternativas (Kothari & Warner, 2004).

En eventos políticos o geopolíticos, la literatura suele utilizar ventanas relativamente amplias respecto a las empleadas en anuncios corporativos muy acotados, precisamente porque el flujo informativo puede concentrarse en varios días y no siempre se limita a un único anuncio. Por ejemplo, Dangol (2008) analiza eventos políticos no anticipados con una ventana de evento de 21 días $(-10, +10)$. En un contexto distinto pero igualmente geopolítico, Yudaruddin et al. (2024) emplean una ventana de ±15 días para estudiar la reacción de mercado al conflicto entre Israel y Hamás. Estos ejemplos ilustran que, en este tipo de shocks, resulta razonable partir de ventanas que cubran varias sesiones de negociación y evaluar posteriormente si el efecto se concentra en un intervalo más corto alrededor del evento.

En este trabajo, la longitud concreta de la ventana de evento se establecerá de forma consistente con la literatura previa y se validará mediante análisis de sensibilidad, comparando los resultados en ventanas alternativas más estrechas o más amplias, con el objetivo de comprobar la estabilidad de los AR y CAR estimados (Kothari & Warner, 2004; MacKinlay, 1997).

**b) Ventana de estimación**

La ventana de estimación se utiliza para calibrar el modelo de retornos esperados que servirá como referencia durante la ventana de evento. En el enfoque estándar, los parámetros del modelo (por ejemplo, en un *market model* o modelo de mercado) se estiman a partir de retornos observados en un periodo previo al evento y posteriormente se usan para obtener el retorno esperado en la ventana de evento. Un requisito metodológico básico es evitar que la ventana de estimación se solape con la ventana de evento, ya que ello podría contaminar la estimación del comportamiento normal incorporando parte del efecto del suceso (MacKinlay, 1997).

Para estudios que utilizan datos diarios, la literatura suele situar el tamaño de la ventana de estimación dentro de ciertos rangos. En particular, Yudaruddin et al., (2024), apoyándose en Peterson (1989), proponen como guía trabajar con una ventana de predicción entre 100 y 300 días cuando se utilizan datos diarios, lo que refleja un equilibrio entre contar con suficientes observaciones para estimar parámetros de forma estable y evitar periodos excesivamente largos donde puedan aparecer cambios estructurales en la relación entre el activo y el mercado.

La elección final de la ventana de estimación también depende de consideraciones empíricas: ventanas más largas tienden a estabilizar las estimaciones, pero pueden incorporar cambios en la empresa o en el entorno de mercado. Por otro lado, ventanas más cortas reducen este riesgo, pero pueden aumentar la varianza de las estimaciones y debilitar la potencia estadística de los contrastes. Por ello, en este trabajo el tamaño de la ventana de estimación se fijará dentro del rango habitual indicado en la literatura, y se acompañará de comprobaciones de robustez para asegurar que los resultados no dependen de una única especificación temporal (Kothari & Warner, 2004; Peterson, 1989).

### 2.3.2. Cálculo de los retornos esperados: modelo de referencia e índice de mercado

Una vez definidas las ventanas temporales, es necesario elegir un modelo para estimar los retornos esperados. Para ello existen dos grandes familias. La primera agrupa los modelos

estadísticos, que describen el comportamiento de los retornos a partir de sus propiedades históricas, sin apoyarse en ninguna teoría sobre cómo se forman los precios en equilibrio. El más sencillo de esta familia es el modelo de retorno medio constante, que asume que el retorno esperado de un activo es estable en el tiempo. Algo más sofisticado es el modelo de mercado, que establece una relación lineal entre el retorno de una acción y el del mercado en su conjunto, lo que permite aislar el componente sistemático del retorno y reducir la varianza de los retornos anormales estimados (MacKinlay, 1997).

El modelo de retorno medio constante se expresa como:

$$R_{it} = \mu_i + \varepsilon_{it}$$

donde $R_{it}$ es el retorno de la empresa $i$ en el periodo $t$, $\mu_i$ es el retorno medio estimado durante la ventana de estimación, y $\varepsilon_{it}$ es el término de error, con media cero y varianza constante $\sigma_i^2$.

El modelo de mercado se expresa como:

$$R_{it} = \alpha_i + \beta_i R_{mt} + u_{it}$$

donde $R_{it}$ es el retorno de la empresa $i$ en el periodo $t$, $R_{mt}$ es el retorno del mercado en ese mismo periodo, $\alpha_i$y $\beta_i$ son parámetros estimados durante la ventana de estimación, y $u_{it}$ es el término de error con media cero y varianza constante $\sigma_i^2$.

Este modelo, frente al modelo constante, mejora la precisión del retorno anormal al controlar por el movimiento general del mercado, reduciendo así la varianza del término de error (MacKinlay, 1997). Sin embargo, al carecer de fundamento económico explícito, no incorpora restricciones sobre cómo se forman los precios en equilibrio, lo que motiva el uso de modelos económicos como los que se presentan a continuación.

La segunda familia agrupa los modelos económicos, que además de supuestos estadísticos incorporan restricciones sobre el comportamiento de los inversores y el equilibrio del mercado. El más conocido de esta familia es el Capital Asset Pricing Model (CAPM), desarrollado por Sharpe (1964) y Lintner (1965), que explica el retorno esperado de un activo en función de su riesgo sistemático, medido por el coeficiente beta. La idea central es que los inversores solo son compensados por el riesgo que no pueden eliminar mediante diversificación, es decir, el riesgo asociado al movimiento conjunto del mercado. Modelos posteriores como el de tres factores de Fama & French (1993), el de cinco factores de Fama & French (2015) o el de cuatro factores

de Carhart (1997) amplían este marco incorporando factores adicionales como el tamaño de la empresa, la rentabilidad, la inversión o el momentum, y resultan especialmente útiles cuando se trabaja con ventanas de estimación largas donde la influencia de estos factores puede ser relevante (MacKinlay, 1997).

El Capital Asset Pricing Model (CAPM) desarrollado por Sharpe (1964) y Lintner (1965) establece que el retorno esperado de un activo depende de la tasa libre de riesgo más una prima por el riesgo sistemático que el activo aporta a una cartera diversificada. Su formulación es la siguiente:

$$E(R_i) = r_f + \beta_i \cdot (E(R_m) - r_f)$$

Donde $E(R_i)$ es la rentabilidad esperada del activo $i$, $r_f$ representa la tasa libre de riesgo, $\beta_i$ mide la sensibilidad del activo respecto al mercado, y $E(R_m)$ es la rentabilidad esperada del mercado. El CAPM clasifica el riesgo en dos categorías: el riesgo sistemático, asociado a factores macroeconómicos que afectan al conjunto del mercado y que no puede eliminarse mediante diversificación, y el riesgo no sistemático, vinculado a características propias de cada empresa y que sí puede reducirse diversificando la cartera. Solo el primero requiere compensación por parte del mercado (Lintner, 1965; Sharpe, 1964). No obstante, el modelo presenta limitaciones relevantes, como la asunción de un único factor de riesgo o la estabilidad del coeficiente $\beta$ en el tiempo, aspectos que pueden afectar a la precisión de los retornos anormales estimados (Kothari & Warner, 2004).

El modelo de tres factores de Fama & French (1993) amplía el CAPM incorporando dos factores adicionales que la evidencia empírica había identificado como determinantes del retorno esperado:

$$R_{it} - r_f = \alpha_i + \beta_i \cdot \left(R_{mt} - r_f\right) + s_i \cdot SMB_t + h_i \cdot HML_t + u_{it}$$

donde $s_i$ mide la sensibilidad del activo al factor tamaño ($SMB$, diferencia entre retornos de empresas pequeñas y grandes) y $h_i$ mide la sensibilidad al factor valor ($HML$, diferencia entre retornos de empresas con alto y bajo ratio book-to-market). El resto de términos mantienen la misma definición que en el CAPM.

El modelo de cinco factores de Fama & French (2015) extiende el anterior añadiendo dos factores más relacionados con la rentabilidad y la política de inversión de las empresas:

$$R_{it} - r_f = \alpha_i + \beta_i \cdot (R_{mt} - r_f) + s_i \cdot SMB_t + h_i \cdot HML_t + r_i \cdot RMW_t + c_i \cdot CMA_t + u_{\mathrm{it}}$$

donde $r_i$ mide la sensibilidad al factor rentabilidad ($RMW$, diferencia entre retornos de empresas con rentabilidad operativa alta y baja) y $c_i$ mide la sensibilidad al factor inversión ($CMA$, diferencia entre retornos de empresas con inversión conservadora y agresiva). Los demás símbolos son los definidos en los modelos anteriores.

Por último, el modelo de cuatro factores de Carhart (1997) incorpora al modelo de tres factores de Fama & French un factor de momentum, capturando la tendencia de los activos con buenos retornos recientes a seguir comportándose mejor que el mercado a corto plazo:

$$R_{it} - r_f = \alpha_i + \beta_i \cdot (R_{mt} - r_f) + s_i \cdot SMB_t + h_i \cdot HML_t + m_i \cdot UMD_t + u_{it}$$

donde $m_i$ mide la sensibilidad del activo al factor momentum ($UMD$, diferencia entre retornos de activos ganadores y perdedores en el año previo), manteniéndose el resto de símbolos tal y como se han definido en el modelo de tres factores.

En este trabajo se opta por el CAPM como modelo de referencia para estimar los retornos esperados. La elección responde a la naturaleza del análisis: las ventanas de evento utilizadas son cortas, y en horizontes reducidos la evidencia metodológica muestra que modelos más sencillos capturan el grueso del efecto sin que la ganancia en precisión de los modelos multifactoriales compense la complejidad adicional que introducen (Brown & Warner, 1985; MacKinlay, 1997). Además, a diferencia del modelo de mercado, el CAPM incorpora explícitamente el coste de oportunidad del capital a través del tipo libre de riesgo, lo que tiene peso particular en un análisis que cubre casi dos décadas con entornos de tipos de interés muy distintos entre sí.

### 2.3.3. Retornos anormales (AR) y retornos anormales acumulados (CAR)

Con el modelo de retornos esperados especificado y estimado en la ventana de estimación, se procede al cálculo de los retornos anormales. El objeto central de un *event study* es medir si, alrededor del evento, el retorno observado de una acción difiere del retorno que cabría esperar en ausencia del suceso. Una vez estimado el modelo de retornos esperados, para cada empresa *i* y cada día *t* de la ventana de evento, se define $R_{it}$ como el retorno observado (simple) calculado a partir del precio de cierre, y $E(R_{it})$ como el retorno esperado estimado mediante el CAPM calibrado en la ventana de estimación. El retorno anormal se calcula entonces como:

$$AR_{it} = R_{it} - E(R_{it})$$

donde $R_{it}$ es el retorno observado y $E(R_{it})$ es el retorno esperado según el modelo estimado en la ventana de estimación. Dado que el modelo de referencia elegido es el CAPM, el retorno esperado se obtiene como:

$$E(R_{it}) = R_{f,t} + \hat{\beta}_i(R_{mt} - R_{f,t})$$

Bajo esta formulación, el retorno anormal coincide con el residuo del modelo durante la ventana del evento y se interpreta como la parte del retorno no explicada por el comportamiento "normal" del activo condicionado al mercado (Kothari & Warner, 2004; MacKinlay, 1997).

Dado que el efecto del evento puede no concentrarse en un único día, es habitual analizar también el impacto agregado en un intervalo $[T_1, T_2]$ mediante el retorno anormal acumulado:

$$\widehat{CAR}_i(T_1, T_2) = \sum_{t=T_1}^{T_2} \widehat{AR}_{it}$$

Esta medida permite capturar reacciones que se distribuyen a lo largo de varias sesiones, bien por difusión progresiva de la información, o bien por ajustes graduales del mercado. Además, facilita comparaciones entre eventos y entre submuestras, por ejemplo, al contrastar patrones de $CAR$ entre tipologías de empresas dentro del sector (MacKinlay, 1997).

En este trabajo, los $AR$ y $CAR$ constituyen las variables principales para describir y comparar la respuesta bursátil ante cada evento geopolítico, tanto a nivel agregado como por grupos de empresas.

### 2.3.4. Test de significancia estadística

Una vez calculados los AR y los CAR, el siguiente paso consiste en evaluar si la reacción estimada difiere significativamente de cero. El enfoque clásico utiliza contrastes paramétricos basados en la varianza del término de error estimada en la ventana de estimación, lo que permite construir un t-test para el retorno anormal medio en un día concreto o para el CAR medio acumulado en una ventana (Kothari & Warner, 2004; MacKinlay, 1997).

1. Planteamiento de hipótesis

En términos agregados, el contraste habitual se formula como:

$$H_0: \widehat{\mathrm{AR}}_t = 0$$

o bien

$$H_0: \widehat{CAR}(T_1, T_2) = 0$$

frente a la alternativa:

$$H_1: \widehat{AR}_t \neq 0$$

o bien

$$H_1: \widehat{CAR}(T_1, T_2) \neq 0$$

donde el objetivo es comprobar si el evento genera una reacción anormal estadísticamente detectable (MacKinlay, 1997).

2. Agregación transversal y temporal

Dado un conjunto de $N$ empresas, se define el retorno anormal medio en el día $t$ como:

$$\widehat{AR}_t = \frac{1}{N} \sum_{i=1}^{N} \widehat{AR}_{it}$$

y el retorno anormal acumulado medio en una ventana $[T_1, T_2]$ como:

$$\widehat{CAR}(T_1, T_2) = \sum_{t=T_1}^{T_2} \widehat{AR}_t$$

Esta expresión acumula primero en el tiempo los retornos anormales medios entre empresas. El resultado es el mismo si se invierte el orden, es decir, si se calcula primero el CAR de cada empresa y después se promedia entre las $N$ empresas:

$$\widehat{CAR}(T_1, T_2) = \frac{1}{N} \sum_{i=1}^{N} \widehat{CAR}_i\,(T_1, T_2)$$

Esta agregación permite evaluar el efecto conjunto del evento sobre el retorno medio de la muestra (Kothari & Warner, 2004; MacKinlay, 1997) y facilita comparaciones entre submuestras definidas por características de las empresas, como Pure Play vs Defense Tech, mediante el cálculo de CARs separados para cada grupo y la evaluación de diferencias estadísticas entre ellos.

3. Construcción del estadístico de contraste

El enfoque más directo para contrastar si el retorno anormal medio difiere de cero consiste en dividir $\widehat{AR}_t$ por una estimación de su desviación típica, construida a partir de la varianza de los residuos del CAPM en la ventana de estimación. Este procedimiento asume implícitamente que la varianza de los retornos anormales es homogénea entre empresas y que no se ve alterada por el propio evento. Sin embargo, cuando se agregan retornos anormales de compañías con volatilidades distintas, las empresas con mayor dispersión reciben implícitamente más peso en el test, lo que puede distorsionar la inferencia. Para corregir este problema, una modificación habitual consiste en estandarizar cada retorno anormal individual por una estimación de su desviación típica antes de agregar entre empresas (Boehmer et al., 1991; MacKinlay, 1997).

El retorno anormal estandarizado (SAR) para la empresa $i$ en el periodo $t$ se define como:

$$\widehat{SAR}_{it} = \frac{\widehat{AR}_{it}}{[\hat{\sigma}^2(\mathrm{AR_{it}})]^{1/2}}$$

donde $[\hat{\sigma}^2(AR_{it})]^{1/2}$ es la desviación típica estimada de los retornos anormales de la empresa $i$ durante la ventana de estimación, que constituye una aproximación válida del error de predicción fuera de muestra cuando la ventana de estimación es suficientemente larga. Esta estandarización cumple dos funciones. En primer lugar, ajusta por el hecho de que el retorno anormal en la ventana de evento es una predicción fuera de muestra y, por tanto, presenta mayor varianza que los residuos utilizados en la estimación. En segundo lugar, al expresar cada retorno anormal en unidades de su propia desviación típica, el resultado queda centrado en cero y es comparable entre empresas, independientemente de su volatilidad individual (Boehmer et al., 1991).

De forma análoga, cuando el efecto del evento se evalúa a lo largo de varios días, se define el retorno anormal acumulado estandarizado (SCAR) como:

$$\widehat{SCAR}_i(T_1, T_2) = \frac{\widehat{CAR}_i(T_1,T_2)}{\left[\hat{\sigma}^2\left(CAR_i(T_1,T_2)\right)\right]^{1/2}}$$

donde $\widehat{CAR}_i(T_1, T_2)$ es el retorno anormal acumulado de la empresa $i$ en la ventana $[T_1, T_2]$ y el denominador escala por la raíz del número de periodos acumulados, bajo el supuesto de independencia serial de los retornos anormales. El SCAR permite agregar entre empresas y contrastar si el efecto acumulado difiere de cero sin que la heterogeneidad de volatilidades entre compañías distorsione el resultado. En este trabajo, los SAR y SCAR se utilizan como base

para la construcción de los estadísticos de contraste y para las comparaciones entre los grupos Pure Play y Defense Tech (Boehmer et al., 1991; MacKinlay, 1997).

El SCAR definido se calcula sobre una ventana fija ($T_1$, $T_2$) y sirve como estadístico de contraste: bajo la hipótesis nula tiene varianza uno, lo que permite hacer inferencia directa. Las gráficas que aparecen más adelante no representan exactamente esta cantidad, sino la suma acumulada de los SAR diarios, que es más fácil de leer porque mantiene la forma de escalón del CAR. Ambas medidas contienen la misma información y están relacionadas por un factor √L, siendo L el número de días acumulados. En el trabajo se usan las dos: el SCAR formal en las tablas, donde lo que interesa es el contraste estadístico, y la suma acumulada de SAR en las gráficas, donde lo que interesa es ver la dinámica del efecto a lo largo de la ventana.

4. Supuestos y alcance de la inferencia

La validez de estos tests se basa en supuestos estándar, como la correcta especificación del modelo de retornos esperados, estabilidad de la varianza y ausencia de dependencias problemáticas entre empresas.

Una limitación inherente a cualquier *event study* es el denominado problema de hipótesis conjunta (*joint hypothesis problem*), señalado por Fama (1970). Cuando se rechaza la hipótesis nula de retorno anormal igual a cero, el resultado puede deberse a que el evento efectivamente generó una reacción del mercado, pero también a que el modelo utilizado para estimar los retornos esperados no captura correctamente el comportamiento normal del activo, produciendo residuos que se interpretan erróneamente como retornos anormales. Dado que ambas explicaciones son indistinguibles dentro del propio test, la inferencia sobre el efecto del evento está siempre condicionada a la correcta especificación del modelo subyacente (Kothari & Warner, 2004; MacKinlay, 1997). En este trabajo, la elección del CAPM y el uso de ventanas de estimación suficientemente largas buscan minimizar este riesgo, y el análisis de panel con efectos fijos proporciona una vía complementaria de contraste que no depende de la misma estructura de modelo.

Estas consideraciones se retoman en la parte aplicada, donde se reportan resultados por distintas ventanas y se discuten posibles limitaciones de inferencia en eventos asociados a condiciones de mercado especialmente inusuales (Kothari & Warner, 2004; MacKinlay, 1997).

## 2.4. Introducción de la metodología de panel (DiD con efectos fijos) y sus ventajas

Aunque el *event study* tradicional permite medir reacciones de mercado en torno a un evento concreto, su aplicación a conflictos geopolíticos presenta un desafío importante: estos episodios suelen coincidir con cambios generalizados en volatilidad, primas de riesgo o condiciones financieras globales. En este contexto, parte de la reacción observada puede deberse al impacto común sobre todo el mercado y no necesariamente a la exposición específica al sector defensa. Además, en periodos de alta volatilidad, la especificación del modelo de retornos esperados puede afectar significativamente a los resultados (Goldsmith-Pinkham & Lyu, 2025; Kothari & Warner, 2004).

Para abordar estas limitaciones, el diseño empírico se estructura en dos niveles. En primer lugar, en todo *event study* el grupo de control está representado implícitamente por el índice de mercado utilizado como benchmark: al estimar los retornos esperados a partir del MSCI World, se compara cada empresa del sector defensa con un conjunto suficientemente amplio y diversificado de activos como para que el efecto específico del evento sobre el sector se diluya en el agregado (MacKinlay, 1997). En segundo lugar, para evaluar si la reacción difiere entre tipologías de modelo de negocio, se ejecutan dos *event studies* en paralelo, uno para el grupo Pure Play y otro para el grupo Defense Tech, cada uno contrastado contra el mismo benchmark de mercado. Este enfoque permite comparar los coeficientes $\beta_k$ entre grupos, y es coherente con la estructura estándar de MacKinlay (1997), donde cada submuestra se evalúa frente al mercado en su conjunto.

Una ventaja adicional del enfoque de panel, frente a una estimación estática del impacto del evento, es que permite estimar la dinámica temporal del impacto en "tiempo de evento". En la práctica, esto se implementa mediante indicadores de distancia temporal al evento (leads y lags), de modo que cada coeficiente $\beta_k$ captura el efecto relativo en un periodo concreto respecto a un periodo base. Esta parametrización permite dos comprobaciones relevantes: primero, evaluar si existen efectos anticipatorios antes de $t = 0$, lo que actúa como test informal de pre-tendencias. Segundo, describir si la reacción es inmediata o si se acumula gradualmente en los días posteriores (Clarke & Tapia-Schythe, 2021).

La especificación se completa incorporando efectos fijos por empresa y por fecha. Los efectos fijos por empresa absorben diferencias estructurales y constantes en el tiempo (tamaño, perfil

de riesgo, composición de negocio), mientras que los efectos fijos temporales capturan shocks comunes a todas las empresas en un mismo día (movimientos globales del mercado, noticias macro, episodios de risk off). Con ello, el contraste se apoya en variación diferencial entre grupos alrededor del evento, manteniendo constante el componente agregado. La variable dependiente es el retorno diario simple de cada empresa ($R_{it}$), de modo que la especificación puede expresarse como:

$$R_{it} = \mu_i + \lambda_t + \sum_{j=2}^{J} \beta_j (\text{Lag } j)_{it} + \sum_{k=0}^{K} \gamma_k (\text{Lead } k)_{it} + u_{it}$$

donde:

$$(\text{Lag } J)_{it} = \mathbb{1}[t \leq t_{0,i} - J]$$
$$(\text{Lag } j)_{it} = \mathbb{1}[t = t_{0,i} - j] \text{ para } j \in \{2, \dots, J-1\}$$
$$(\text{Lead } k)_{it} = \mathbb{1}[t = t_{0,i} + k] \text{ para } k \in \{0, \dots, K-1\}$$
$$(\text{Lead } K)_{it} = \mathbb{1}[t \geq t_{0,i} + K]$$

$\mu_i$ son los efectos fijos por empresa, $\lambda_t$ son los efectos fijos por periodo, $t_{0,i}$ es la fecha del evento para la empresa $i$, y los indicadores (Lag $j$) y (Lead $k$) toman valor 1 cuando la empresa se encuentra a $j$ días antes o $k$ días después de su evento. Los extremos $J$ y $K$ acumulan todas las observaciones más allá de la ventana de análisis, lo que permite incorporar el panel completo sin dejar observaciones sin clasificar (Clarke & Tapia-Schythe, 2021). Se omite el primer lag ($j = 1$) como periodo de referencia para evitar multicolinealidad, de modo que los coeficientes $\beta$ y $\gamma$ capturan el efecto promedio del evento en cada distancia temporal relativa al periodo base. La comparación entre grupos se realiza estimando la especificación por separado para las empresas Pure Play y Defense Tech.

## 3. Definición del problema

La evidencia revisada en el apartado 2.2 muestra que los shocks geopolíticos pueden generar reacciones significativas en empresas de defensa, pero también que la magnitud y el signo de la reacción varían según el tipo de exposición operativa, lo que sugiere que el sector no responde como un bloque homogéneo. Sin embargo, la mayor parte de los estudios lo analiza de forma agregada, lo que dificulta identificar si la reacción ante un mismo shock difiere entre empresas

con perfiles operativos distintos. Este trabajo parte de esa laguna para plantear una pregunta concreta: a lo largo de cinco episodios geopolíticos entre 2008 y 2026, ¿varía la reacción bursátil de forma sistemática según el modelo de negocio, distinguiendo entre empresas Pure Play y Defense Tech?

## 3.1. Objetivos del estudio

1. Medir la reacción bursátil de empresas con exposición material al sector defensa en torno a una selección de eventos geopolíticos, mediante el cálculo de retornos anormales y retornos anormales acumulados en ventanas temporales definidas.
2. Evaluar si la reacción difiere entre tipologías de modelo de negocio, distinguiendo entre empresas Pure Play y Defense Tech, utilizando una clasificación operativa y replicable basada en información pública y datos de FactSet.
3. Separar el componente agregado del componente diferencial, controlando por movimientos comunes del mercado y verificando la robustez de los resultados.
4. Reforzar la interpretación empírica complementando el *event study* clásico con una aproximación de panel con efectos fijos y estructura tipo event time, que permita observar dinámicas previas y posteriores y contrastar supuestos de tendencia paralela cuando sea aplicable (Callaway & Sant'Anna, 2021).

# 4. Metodología

## 4.1. Preparación de la muestra

### 4.1.1. Selección de empresas y clasificación (Pure Play vs Defense Tech)

Como se señaló en la introducción, el sector defensa ha experimentado una transformación hacia capacidades tecnológicas digitales, lo que justifica distinguir entre empresas Pure Play (núcleo industrial) y Defense Tech (núcleo tecnológico). Esta clasificación permite evaluar si la reacción del mercado ante eventos geopolíticos varía de forma sistemática según el modelo de negocio.

La muestra se construye con el objetivo de representar, de forma operativa y replicable, un conjunto de compañías cotizadas con exposición significativa al sector defensa, y permitir comparaciones consistentes entre modelos de negocio. La literatura reciente subraya que las

compañías de defensa no constituyen un bloque homogéneo, sino que presentan diferencias relevantes en capacidades, productos y potencial de diversificación, lo que justifica analizar subgrupos dentro del sector (Panazan & Gheorghe, 2025).

**a) Universo base: VanEck Defense Index**

El universo inicial se define a partir del VanEck Defense Index (VanEck Asset Management B.V., 2025a, 2025b) que proporciona un criterio externo y documentado de elegibilidad sectorial basado en la exposición de ingresos a actividades vinculadas con defensa. Según la documentación del producto, el universo elegible incluye compañías que derivan una parte sustancial de sus ingresos de la industria militar o de defensa, utilizando como referencia un umbral general del 50% (y del 25% para componentes actuales) asociado a productos y servicios relacionados (VanEck Asset Management B.V., 2025a). Este marco sirve como referencia, pero no se adopta de forma mecánica, porque el objetivo del TFG no es replicar el índice, sino construir una muestra adecuada para un análisis empírico basado en reacciones bursátiles ante eventos geopolíticos.

Esta elección aporta dos ventajas prácticas. Primero, ofrece una muestra internacional ya filtrada por relevancia sectorial, lo que facilita la comparabilidad posterior en el análisis de eventos. Segundo, permite aplicar criterios replicables para la clasificación interna entre Pure Play y Defense Tech.

**b) Clasificación por tipología: Pure Play vs Defense Tech**

A partir de este universo, se clasifican las empresas en dos categorías según su actividad principal:

- Pure Play: empresas cuyo modelo de negocio se centra predominantemente en plataformas industriales, sistemas de armas convencionales, vehículos militares y capacidades tradicionales de defensa.
- Defense Tech: empresas con un núcleo tecnológico orientado a capacidades digitales avanzadas, sensores, electrónica de defensa, ciberseguridad, sistemas autónomos y software especializado. Estas compañías combinan exposición al sector defensa con competencias en tecnologías emergentes.

Para asegurar consistencia en la clasificación, cuando existe diversificación relevante se utiliza (i) la segmentación por líneas de negocio y ventas reportada en FactSet, y (ii) la fuente principal de ingresos identificada en los desgloses sectoriales. Evidencia sectorial muestra que una proporción elevada del defense revenue global se concentra en empresas con exposición mixta defensa y civil, lo que refuerza la necesidad de documentar y justificar la clasificación cuando no se trata de una Pure Play evidente (Berenson & Higgins, 2020).

**c) Ampliación de la muestra: empresas adicionales**

Además del universo base, se incorporan empresas adicionales relevantes para el sector que no figuran en el ETF, con dos motivaciones principales. En primer lugar, ampliar la potencia estadística y la variación de la muestra, especialmente en un estudio que, por diseño, analiza reacciones en ventanas temporales alrededor de eventos. En segundo lugar, capturar actores principales del sector defensa que, por tamaño, peso geográfico o estructura corporativa, pueden quedar fuera de un ETF concreto, pero resultan informativos para contrastar patrones de reacción.

La inclusión de estas empresas se justifica mediante dos filtros complementarios basados en FactSet: (i) la exposición de ingresos a sectores o industrias de defensa (Revenue Exposure by Sector/Industry), y (ii) la clasificación industrial RBICS y los desgloses de segmentos ("Business Segments") cuando existe diversificación relevante. Esto permite aproximar el peso de actividades de defensa dentro de las ventas totales de cada compañía (FactSet, 2019).

Se adopta un umbral operativo del 30% de ingresos en defensa para considerar que la empresa tiene exposición material al sector. Esta elección responde a un equilibrio entre inclusión de compañías relevantes y exclusión de empresas con presencia marginal. La literatura sectorial y metodologías de índices sitúan umbrales entre 25% y 50% según el objetivo: índices más inclusivos adoptan 25%, mientras que criterios más restrictivos emplean 50% (Gupta & Zhu, 2025; VanEck Asset Management B.V., 2025a; Wille et al., 2024). El 30% permite capturar empresas cuyo desempeño bursátil está significativamente vinculado a la dinámica del sector defensa.

**d) Composición final y disponibilidad temporal**

La disponibilidad de datos condiciona el panel efectivo del estudio. No todas las empresas presentan series completas para todo el horizonte temporal (2008-2026) debido a salidas a bolsa

posteriores, fusiones, adquisiciones, delistings o limitaciones de histórico en FactSet. Por ello, el análisis se realiza con un panel no balanceado, registrando para cada compañía el primer año con datos disponibles.

La composición efectiva de la muestra varía entre eventos. Cada empresa entra en el análisis solo si dispone de los 130 días de negociación previos a t=0 que requiere la ventana de estimación CAPM, lo que excluye automáticamente a las firmas con IPO posterior. Como consecuencia, la muestra crece desde 40 empresas en Georgia (2008) hasta 64 en Maduro (2026), conforme se incorporan compañías cotizadas en periodos más recientes. Este desequilibrio afecta a la comparabilidad entre eventos y se tiene en cuenta al interpretar las diferencias de magnitud, especialmente entre los shocks tempranos y los recientes. La columna N de cada tabla refleja el número exacto de empresas que entra en cada estimación.

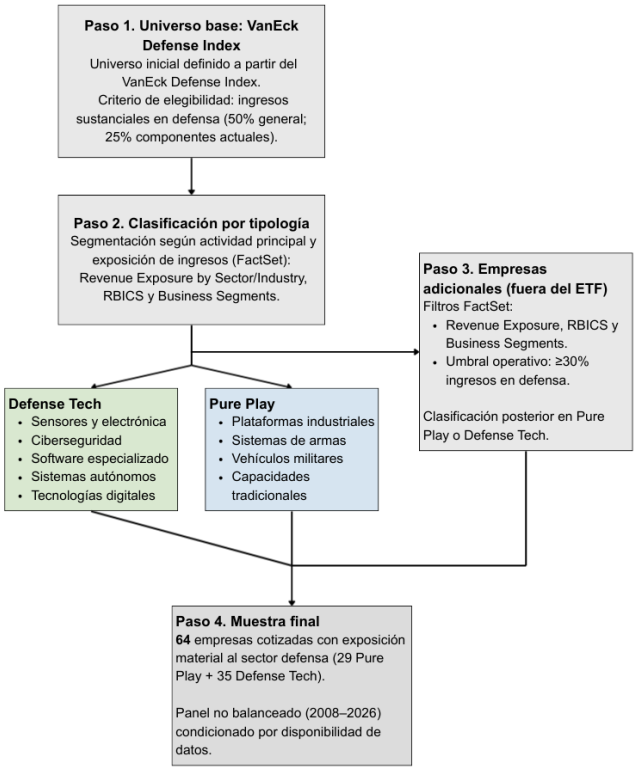


**Ilustración 4.** Proceso de selección y clasificación de la muestra.
**Fuente:** Elaboración propia a partir de VanEck Defense UCITS ETF (VanEck Asset Management B.V., 2025a, 2025b) y datos de FactSet (RBICS, Revenue Exposure by Sector/Industry y Business Segments).

La muestra final incluye 64 empresas cotizadas con exposición material al sector defensa, clasificadas según su modelo de negocio en dos tipologías. La Tabla 1 presenta una selección ilustrativa de la muestra, mientras que la lista completa con descripción detallada se presenta en el Anexo A.

**Tabla 1.** Muestra ilustrativa de empresas del sector defensa.

| Empresa | Tipología | País |
|---|---|---|
| *Lockheed Martin* | Pure Play | USA |
| *Northrop Grumman* | Pure Play | USA |
| *BAE Systems* | Pure Play | UK |
| *General Dynamics* | Pure Play | USA |
| *Rheinmetall* | Pure Play | Alemania |
| *Palantir Technologies* | Defense Tech | USA |
| *L3Harris Technologies* | Defense Tech | USA |
| *Leonardo* | Pure Play | Italia |
| *Thales* | Defense Tech | Francia |
| *SAAB* | Pure Play | Suecia |

**Fuente:** Elaboración propia a partir de VanEck Defense UCITS ETF (VanEck Asset Management B.V., 2025b, 2025a) y datos de FactSet.

Con el fin de complementar la muestra principal y documentar de forma transparente los casos incorporados fuera del ETF, se presenta una tabla adicional con las empresas "extra" y su exposición cuantitativa a defensa. En concreto, la Tabla 2 recoge, para cada compañía añadida, el nodo relevante de FactSet y el porcentaje de ingresos atribuible a actividades de defensa según la clasificación RBICS with Revenue, lo que permite justificar la inclusión con un criterio homogéneo y verificable.

**Tabla 2.** Empresas adicionales y exposición a defensa según RBICS (FactSet).

| Empresa | Ticker | Nodo FactSet relevante (%) |
|---|---|---|
| *CAE Inc.* | CAE-CA | Defense Training and Testing Providers (100.00%) |
| *Serco Group plc* | SRP-GB | Diversified Defense Providers (31.30%) |
| *Indra Sistemas, S.A.* | IDR-ES | Aerospace and Defense IT Services (30.96%) |
| *Lockheed Martin Corporation* | LMT-US | Defense Contractors (82.43%) |
| *Northrop Grumman Corp.* | NOC-US | Other Defense Manufacturing (100.00%) |
| *BAE Systems plc* | BA-GB | Defense Manufacturing (90.40%) |
| *L3Harris Technologies Inc* | LHX-US | Defense Manufacturing (68.69%) |
| *Kongsberg Gruppen ASA* | KOG-NO | Other Defense Manufacturing (34.96%) |
| *General Dynamics Corporation* | GD-US | Other Defense Manufacturing (74.05%) |
| *Rheinmetall AG* | RHM-DE | Other Defense Manufacturing (78.15%) |
| *BWX Technologies, Inc.* | BWXT-US | Advanced Combat and Support Parts Manufacturing (62.59%) |
| *Hindustan Aeronautics Ltd.* | 541154-IN | Defense Manufacturing (98.71%) |
| *Bharat Electronics Ltd.* | 500049-IN | Defense Electronics Equipment Manufacturing (97.31%) |
| *Chemring Group Plc* | CHG-GB | Defense Manufacturing (100.00%) |
| *TransDigm Group, Inc.* | TDG-US | Defense Manufacturing (42.59%) |
| *Ducommun, Inc.* | DCO-US | Defense Manufacturing (53.39%) |
| *V2X, Inc.* | VVX-US | Defense Contractors (100.00%) |
| *Aselsan Elektronik Sanayi ve Ticaret AS* | ASELS.E-TR | Diversified Defense Providers (100.00%) |
| *LIG Nex1 Co., Ltd.* | 079550-KR | Defense Manufacturing (97.32%) |
| *Bharat Dynamics Ltd.* | 541143-IN | Defense Manufacturing (99.38%) |
| *Mazagon Dock Shipbuilders Ltd.* | 543237-IN | Defense Manufacturing (86.16%) |
| *Lubawa SA* | LBW-PL | Defense Manufacturing (48.07%) |
| *VICTEK Co., Ltd.* | 065450-KR | Defense Electronics Equipment Manufacturing (94.92%) |
| *Huneed Technologies Co., Ltd.* | 005870-KR | Defense Electronics Equipment Manufacturing (88.81%) |
| *Firstec Co., Ltd.* | 010820-KR | Defense Manufacturing (100.00%) |
| *Zen Technologies Ltd.* | 533339-IN | Defense Training and Testing Providers (100.00%) |

**Fuente:** Elaboración propia a partir de FactSet, RBICS with Revenue (Revenue Exposure by Sector/Industry).

### 4.1.2. Selección y definición de eventos geopolíticos

#### a) Criterios metodológicos de selección

La selección de eventos sigue las recomendaciones metodológicas establecidas en la literatura de event studies. Después de identificar el tipo de evento de interés, es necesario determinar los criterios de selección para la inclusión de cada episodio en el estudio (Kothari & Warner, 2004; MacKinlay, 1997). Se priorizan shocks que cumplen cuatro criterios:

1. Claridad temporal inequívoca con una fecha t = 0 precisa y objetiva, dado que los métodos de *event study* de horizonte corto son especialmente potentes cuando el efecto anormal está concentrado en la ventana de evento y la fecha del suceso puede ser datada con precisión (Kothari & Warner, 2004).
2. Relevancia estratégica para la seguridad internacional y el gasto en defensa, garantizando que los eventos representen shocks materiales con potencial impacto sectorial.
3. Cobertura mediática e institucional suficiente para tratarlos como shocks informativos creíbles que alteren expectativas de mercado en un contexto de eficiencia razonable (Fama, 1970).
4. Distribución temporal amplia (2008 a 2026), dado que las propiedades de los métodos de *event study* pueden variar según el período calendario analizado y dependen de características de las firmas de la muestra, lo que permite examinar la estabilidad temporal de las reacciones sectoriales y posibles cambios en la sensibilidad del mercado a lo largo del tiempo (Kothari & Warner, 2004).

Se identifican cinco eventos principales que satisfacen estos criterios, distribuidos entre 2008 y 2026: Guerra de Georgia (2008), Anexión de Crimea (2014), Invasión de Ucrania (2022), Ataques de Hamás (2023) y Captura de Maduro (2026).

**Tabla 3.** Resumen de los eventos geopolíticos seleccionados.

| Evento | Fecha ($t = 0$) | Región | Tipo de shock | Canal esperado sobre defensa |
|---|---|---|---|---|
| *Guerra de Georgia* | 12/08/2008 | Cáucaso | Conflicto convencional interestatal | Refuerzo flanco oriental OTAN |
| *Anexión de Crimea* | 18/03/2014 | Europa del Este | Guerra híbrida / anexión | Sanciones, rearme Europa del Este |
| *Invasión de Ucrania* | 24/02/2022 | Europa | Guerra convencional a gran escala | Rearme europeo generalizado |
| *Ataques de Hamás* | 07/10/2023 | Oriente Medio | Conflicto asimétrico de alta intensidad | Demanda urgente sistemas antimisiles, drones, C4ISR |
| *Captura de Maduro* | 03/01/2026 | Caribe / Latinoamérica | Operación especial unilateral | Proyección aeronaval, inteligencia, guerra electrónica |

**Fuente:** Elaboración propia.

### b) Descripción de los eventos seleccionados

**Evento 1**: Guerra de Georgia (12 de agosto de 2008)

El 12 de agosto de 2008, el presidente ruso Dmitry Medvedev anunció el fin de las operaciones militares contra Georgia, marcando el clímax de una confrontación directa entre Rusia y un vecino del antiguo bloque soviético desde el fin de la Guerra Fría. La operación culminó con el reconocimiento ruso de Osetia del Sur y Abjasia como estados independientes el 26 de agosto de 2008, alterando las percepciones sobre la seguridad en el flanco oriental de la OTAN y generando las primeras discusiones serias sobre refuerzo de capacidades defensivas en Europa del Este (de Haas, 2009).

Relevancia para el análisis: Representa el shock geopolítico de referencia "pre-Crimea", permitiendo contrastar si la sensibilidad del sector defensa ha aumentado con el tiempo ante amenazas rusas similares.




**Ilustración 5.** Georgia: ubicación de Abjasia y Osetia del Sur, regiones en disputa durante el conflicto de agosto de 2008.
**Fuente:** Wikimedia Commons, autor Orlovic (licencia CC BY-SA 3.0). Etiquetas añadidas por el autor.

### Evento 2: Anexión de Crimea (18 de marzo de 2014)

El 18 de marzo de 2014, el presidente ruso Vladimir Putin firmó la ley de anexión de Crimea tras la ocupación militar iniciada el 27 de febrero, violando el Memorándum de Budapest de 1994, entre otros tratados internacionales (Pifer, 2020). Este evento provocó sanciones económicas inmediatas de la UE y EE.UU., un aumento del 22% en el gasto militar de Polonia entre 2014 y 2015, alcanzando el 2,2% de su PIB (Perlo-Freeman et al., 2016).

Relevancia para el análisis: Punto de inflexión que marca el inicio de la confrontación estratégica Rusia-OTAN, con impacto directo en contratos de misiles tierra-aire, inteligencia electrónica y ciberdefensa.




**Ilustración 6.** Ucrania: ubicación de la península de Crimea, anexionada por Rusia en marzo de 2014.
**Fuente:** (Don Alessandro, 2006). Etiquetas añadidas por el autor.

**Evento 3:** Invasión a gran escala de Ucrania (24 de febrero de 2022)

El 24 de febrero de 2022, fuerzas rusas cruzaron la frontera ucraniana en múltiples frentes, iniciando la mayor guerra convencional en Europa desde 1945. El gasto militar en Europa alcanzó 588 miles de millones de dólares en 2023, un 16% más que en 2022 y un 62% más que en 2014 (Nan et al., 2024). Alemania anunció el 27 un fondo especial de 100.000 millones de euros para defensa, comprometiéndose a alcanzar el objetivo de gasto militar del 2% del PIB de la OTAN (Federal Ministry of Defence, 2022; Solana, 2022).

Relevancia para el análisis: Shock definitivo que disparó contratos de artillería, vehículos blindados, sistemas antiaéreos Patriot, drones y munición de precisión en toda Europa Occidental.

**Evento 4:** Ataques de Hamás y escalada Israel Gaza (7 de octubre de 2023)

El 7 de octubre de 2023, Hamás lanzó 5.000 cohetes y un ataque terrestre coordinado contra Israel, matando a aproximadamente 1.200 civiles e iniciando la guerra más intensa del conflicto palestino-israelí desde 1973 (Global Affairs Canada, 2025). Israel activó inmediatamente el sistema Cúpula de Hierro y movilizó 360.000 reservistas en la mayor movilización desde la

Guerra de Yom Kippur de 1973, generando demanda urgente de munición guiada, drones de vigilancia, sistemas de guerra electrónica y capacidades C4ISR (Heimann, 2024; Keinon, 2025).

Relevancia para el análisis: Demuestra la reacción del sector ante conflictos asimétricos de alta intensidad con fuerte componente tecnológico.




**Ilustración 7.** La Franja de Gaza: contexto geográfico del Ataque de Hamás del 7 de octubre de 2023.
**Fuente:** (Gringer, 2009).

**Evento 5:** Captura de Nicolás Maduro por fuerzas estadounidenses (3 de enero de 2026)

El 3 de enero de 2026, fuerzas especiales estadounidenses ejecutaron la Operación Absolute Resolve, capturando al presidente venezolano Nicolás Maduro en Caracas, sin pérdidas de aeronaves estadounidenses pese al despliegue de más de 150 aviones militares. La operación,

ordenada por el presidente Donald Trump, se basó en cargos federales por narcotráfico vigentes desde 2020 y generó tensiones inmediatas con China y Rusia. Aunque Rusia conocía la inminencia de la acción militar, no notificó a China, cuyos diplomáticos se habían reunido con Maduro apenas 24 horas antes del asalto (Ziemer, 2026).

Relevancia para el análisis: Shock político militar contemporáneo que combina operaciones especiales, inteligencia satelital, guerra electrónica y proyección de poder aeronaval en el Caribe.



EL MUNDO

ESTADOS UNIDOS DERROCA AL DICTADOR Y DECAPITA AL RÉGIMEN

Trump caza a Maduro y mandará en Venezuela

**OPERACIÓN** Los Delta Force sacan de su refugio a Maduro tras bombardear por tierra, mar y aire

**NARCOTERRORISTA** El dictador, recluido en un buque, será juzgado por tráfico de drogas en EEUU

**CRUDO** Promete que empresas americanas se repartirán las reservas: «El petróleo fluirá como debe»

**ESPAÑA** Sánchez rechaza la intervención, pero ofrece sus «buenos oficios» como mediador con el chavismo

POR DANIEL LOZANO, PABLO SCARPELLINI, ALBERTO ROJAS, MARINA PINA, CANDELA IBÁÑEZ, MARCOS BIZARTE Y PABLO PARDO (MISMO PLANO)

*La nueva gramática del poder* — ANA PALACIO

*Petróleo y esferas de influencia* — PABLO R. SUANZES

*Venezuela, tres etapas y una hora decisiva* — JULIO BORGES

Un gobierno por control remoto de EEUU con jerarcas del chavismo

Marco Rubio ignora por ahora a Machado y negocia con el régimen una administración mixta hasta convocar elecciones

Pete Hegseth explica la operación a Donald Trump. E. M. POR DANIEL LOZANO

El ex líder chavista Nicolás Maduro, ayer, a bordo del USS Iowa. Zoma tras ser capturado. EFE

**Ilustración 8.** Portada de El Mundo del domingo 4 de enero de 2026, tras la captura de Nicolás Maduro por fuerzas estadounidenses.
**Fuente:** El Mundo (4 de enero de 2026), vía El Nacional.cat.

### 4.1.3. Fuentes de datos, frecuencia y periodo temporal

#### a) Fuentes de datos y trazabilidad

Los datos financieros se obtienen de dos fuentes. Las series de Total Return Index (Gross) de cada empresa y del MSCI World se descargan directamente desde FactSet en frecuencia diaria, expresadas en dólares estadounidenses (USD). Esta conversión a una moneda común es una práctica estándar en estudios de eventos internacionales, ya que permite la agregación consistente de retornos anormales y elimina distorsiones causadas por fluctuaciones cambiarias no relacionadas con el evento estudiado (El Ghoul et al., 2023). El Total Return Index incorpora la reinversión de dividendos brutos y el efecto de acciones corporativas, de modo que refleja el retorno económico completo para el accionista. Como proxy de la tasa libre de riesgo se utiliza el tipo a un mes de las letras del Tesoro estadounidense (Market Yield on U.S. Treasury Securities at 1-Month Constant Maturity, código DGS1MO), obtenido del Federal Reserve Economic Data (FRED) en frecuencia diaria. Una vez extraídas, las series se consolidan y exportan para su tratamiento en Python (Google Colab).

**b) Índice de mercado**

Como proxy del mercado global, se utiliza el MSCI World Index, un índice de capitalización ponderada que cubre aproximadamente el 85% de la capitalización de mercado ajustada por free-float en 23 mercados desarrollados con 1.320 constituyentes (MSCI, 2025). Su uso permite controlar por movimientos generales del mercado global no relacionados con los eventos geopolíticos específicos analizados.

**c) Frecuencia**

La frecuencia de análisis es diaria, ya que la literatura metodológica documenta que el uso de retornos diarios (y en ocasiones intradía) se ha generalizado por permitir una medición más precisa de retornos anormales y un análisis más informativo de efectos de anuncio (Kothari & Warner, 2004). Además, bajo el supuesto de mercados altamente eficientes, la utilidad del *event study* descansa en que el impacto del evento se incorpora rápidamente al precio (MacKinlay, 1997).

**d) Periodo temporal**

El periodo de estudio se define a partir del primer evento considerado, la Guerra de Georgia (12 de agosto de 2008), y se extiende hasta la última fecha con datos disponibles en FactSet para cada activo e índice. Dado que algunas compañías tienen salida a bolsa posterior o historial

incompleto, el conjunto final puede implicar un panel no balanceado, circunstancia que se documenta en la tabla de muestra y en el apartado de disponibilidad de datos.

## 4.2. Especificación econométrica

Esta sección detalla la implementación empírica de los dos métodos descritos en el marco teórico. Primero se especifica el *event study* clásico bajo el modelo CAPM, indicando ventanas, frecuencia y procedimiento de inferencia. A continuación, se describe el panel con efectos fijos bidireccionales, su ventana de observación y la estrategia de estimación. Los apartados 5.1 a 5.4 presentan los resultados obtenidos con cada una de estas especificaciones.

### 4.2.1. Event Study clásico

Los retornos anormales se calculan como la diferencia entre el retorno observado y el retorno esperado según el CAPM, calibrado en una ventana de estimación de 120 días de negociación comprendida entre los días –130 y –11 relativos a cada fecha de evento. Este rango garantiza un periodo de estimación libre de contaminación por el shock y se sitúa dentro de los límites recomendados por la literatura (Peterson, 1989). La tasa libre de riesgo, obtenida en frecuencia diaria desde FRED, se convierte a tasa diaria dividiendo el tipo anualizado entre 252 días de negociación. La significatividad de los AR y CAR se evalúa en seis ventanas: (–1, 0), (–1, 1), (–3, 3), (–5, 5), (–10, 10) y (–15, 15).

### 4.2.2. Panel con efectos fijos

El panel se estima siguiendo la especificación descrita en el apartado 2.4. Se trata de un panel *event study* con efectos fijos de empresa y de fecha, donde los efectos fijos de empresa absorben diferencias estructurales constantes (tamaño, perfil de riesgo, composición de negocio) y los efectos fijos temporales capturan los movimientos comunes del mercado en cada sesión. La estimación se realiza con PanelOLS y errores estándar corregidos para que sean válidos, aunque la varianza de los residuos no sea constante entre empresas, algo que es habitual en paneles donde existen tanto firmas grandes y estables como otras más pequeñas y volátiles.

La ventana de observación se fija en (–10, +10) días naturales alrededor de la fecha de evento de cada empresa. El time to event se comprime al rango (–5, +5), una decisión que busca limitar el número de parámetros estimados manteniendo la potencia del modelo. Las observaciones que se encuentran entre cinco y diez días del evento se agrupan en los indicadores extremos (Lag 5 y Lead 5), mientras que los indicadores intermedios capturan un único día cada uno. El

primer lag (Lag $j$) se omite y se usa como periodo de referencia, así que todos los demás coeficientes $\beta$ y $\gamma$ se interpretan como diferencias respecto a ese día base. Esa omisión es necesaria para evitar un problema técnico de la regresión cuando se trabaja con dummies temporales y efectos fijos al mismo tiempo, y aparece ya en la formulación del apartado 2.4.

El MSCI World entra como grupo de control sin fecha de evento, con todas sus observaciones del periodo y sin recibir indicadores de distancia temporal. Esto permite que los efectos fijos de tiempo absorban los movimientos comunes del mercado en cada sesión, separándolos del efecto específico atribuible al shock geopolítico sobre las empresas analizadas. Los cinco eventos entran agrupados en la misma regresión, cada empresa con su fecha específica, y el modelo se estima por separado para cada tipología.

# 5. Resultados

Esta sección presenta los resultados empíricos en dos bloques, ambos estimados según la especificación detallada en 4.2. El primero recoge el *event study* clásico basado en el CAPM: retornos anormales en t=0 y su versión estandarizada, acumulación por ventana en términos de CAR y SCAR, diferencias entre Pure Play y Defense Tech, y dinámica temporal completa. El segundo bloque presenta el panel con efectos fijos estimado por separado para cada tipología.

## 5.1. Resultados del event study clásico (MacKinlay): resultados agregados

### 5.1.1. Retornos anormales en t=0: AR y SAR

En la Tabla 4 se presenta el retorno anormal medio en t=0 para los cinco eventos analizados. Estos retornos anormales han sido calculados como la diferencia entre el retorno observado y el retorno esperado según el CAPM, calibrado en la ventana de estimación (-130, -11).

**Tabla 4.** Retorno anormal medio en t=0 por evento.

| Evento | AR medio | T-stat | P-valor | Sig. | N |
|---|---|---|---|---|---|
| Guerra de Georgia | 0,68% | 1,810 | 0,078 | * | 40 |
| Anexión de Crimea | 0,72% | 2,564 | 0,014 | ** | 46 |
| Invasión de Ucrania | 3,44% | 14,692 | <0,001 | *** | 61 |
| Ataques de Hamás | 4,20% | 19,735 | <0,001 | *** | 61 |
| Captura de Maduro | 4,17% | 14,318 | <0,001 | *** | 64 |

**Fuente:** Elaboración propia. Nota: *p<0,10; **p<0,05; ***p<0,01.

Los tres eventos más recientes son los que producen unos retornos anormales de magnitud más elevada. Hamás alcanza el 4,20%, Maduro queda muy cerca con un 4,17% y Ucrania se sitúa en el 3,44%. Los tres son significativos al 1%. El mercado incorporó con rapidez una revalorización del sector en cada una de estas sesiones.

Por otro lado, la Guerra de Georgia y la Anexión de Crimea muestran reacciones más contenidas, de un 0,68% y un 0,72% respectivamente. Crimea alcanza significatividad al 5%, mientras que Georgia solo la alcanza al 10% (p=0,078). Dos posibles factores pueden contribuir a esta diferencia de magnitud respecto a eventos posteriores. Primero, ni la Guerra de Georgia ni la anexión de Crimea desencadenaron programas de rearme comparables a los que siguieron a la invasión de Ucrania, lo que limita el ajuste de expectativas sobre demanda futura que el mercado podía anticipar. Segundo, la muestra disponible es menor (40 y 46 empresas frente a 61 y 64 en los eventos recientes), lo que reduce la potencia estadística.

Los AR, sin embargo, ponderan implícitamente más a las empresas con mayor volatilidad. La Tabla 5 presenta los retornos anormales estandarizados (SAR), que corrigen esa distorsión expresando cada AR individual en unidades de su desviación típica estimada en la ventana de estimación.

**Tabla 5.** Retorno anormal estandarizado (SAR) medio en t=0 por evento.

| Evento | SAR medio | t-stat | p-valor | Sig. | N |
|---|---|---|---|---|---|
| Guerra de Georgia | 0,29 | 1,810 | 0,078 | * | 40 |
| Anexión de Crimea | 0,38 | 2,564 | 0,014 | ** | 46 |
| Invasión de Ucrania | 1,88 | 14,692 | <0,001 | *** | 61 |
| Ataques de Hamás | 2,53 | 19,735 | <0,001 | *** | 61 |
| Captura de Maduro | 1,79 | 14,318 | <0,001 | *** | 64 |

**Fuente:** Elaboración propia. Nota: *p<0,10; **p<0,05; ***p<0,01.

Hamás registra el SAR más alto (2,53), por encima de Ucrania (1,88) y Maduro (1,79). Eso indica que, en términos relativos a la dispersión habitual de cada acción, el shock del 7 de octubre fue el que más se alejó del comportamiento normal. Ucrania parte de un impacto puntual algo menor en escala estandarizada.

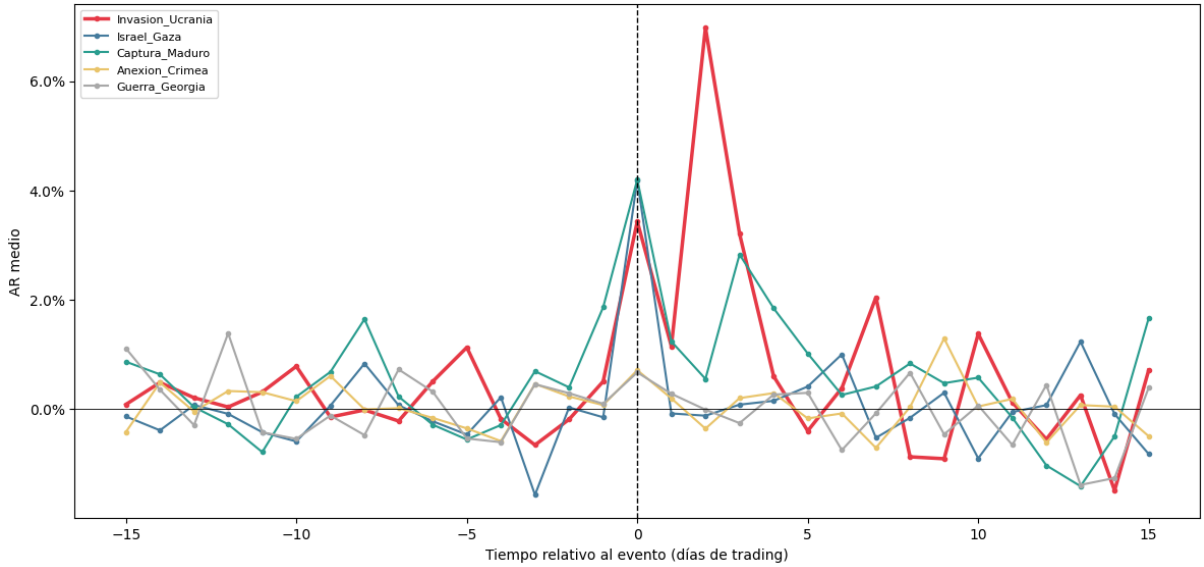


**Ilustración 9.** AR medio por evento.
**Fuente:** Elaboración propia.

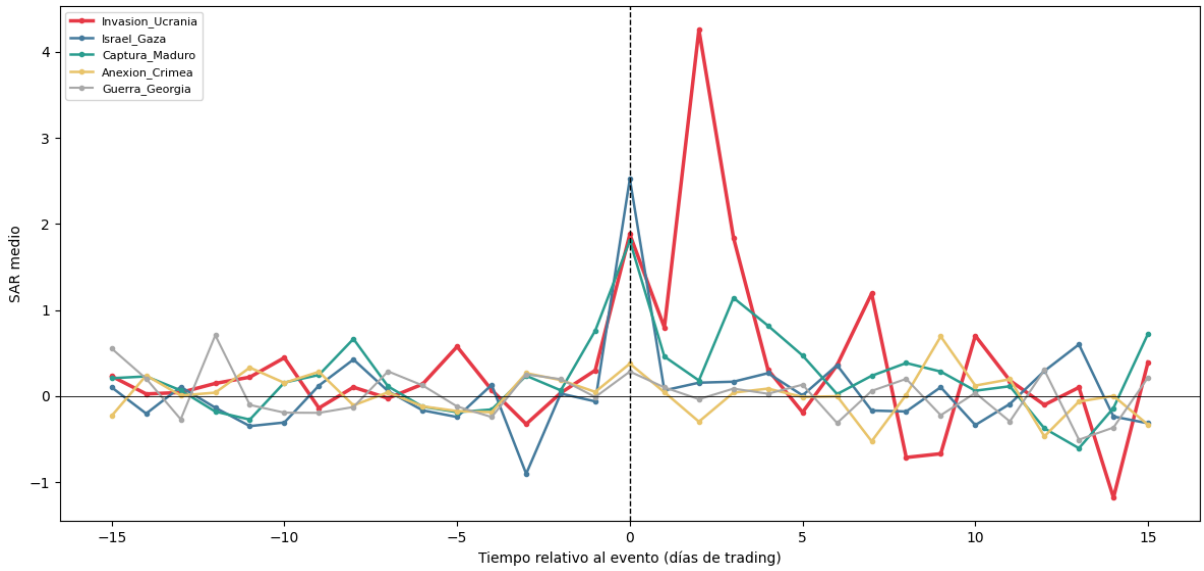


**Ilustración 10.** SAR medio por evento.
**Fuente:** Elaboración propia.

Las Ilustraciones 9 y 10 muestran las series diarias de AR y SAR. En ambas se aprecia un repunte en torno a t=0 que destaca sobre el ruido de las sesiones próximas. En la versión estandarizada, el pico del conflicto Israel-Gaza domina con claridad en t=0, mientras que en la serie bruta queda más igualado con los eventos de Ucrania y Maduro. Además, Ucrania muestra retornos positivos relevantes en t=+2 y t=+3, mientras que en Maduro la reacción diaria se reparte en varias sesiones posteriores al evento.

### 5.1.2. Retornos anormales acumulados por ventana

La Tabla 6 presenta los CAR medios en seis ventanas progresivamente más amplias.

**Tabla 6.** CAR medio por evento y ventana.

| Ventana | Georgia | Crimea | Ucrania | Ataque de Hamás | Maduro |
|---|---|---|---|---|---|
| (–1, 0) | 0,78% | 0,79%** | 3,95%*** | 4,05%*** | 6,08%*** |
| (–1, 1) | 1,06% | 0,99%* | 5,10%*** | 3,98%*** | 7,29%*** |
| (–3, 3) | 1,56%** | 1,55%* | 14,46%*** | 2,42%*** | 11,78%*** |
| (–5, 5) | 1,00% | 0,75% | 15,63%*** | 2,75%*** | 13,82%*** |
| (–10, 10) | 0,39% | 1,98% | 18,61%*** | 2,66%*** | 18,87%*** |
| (–15, 15) | 0,10% | 1,88% | 18,83%*** | 2,09%** | 17,94%*** |

**Fuente:** Elaboración propia. Nota: *p<0,10; **p<0,05; ***p<0,01.

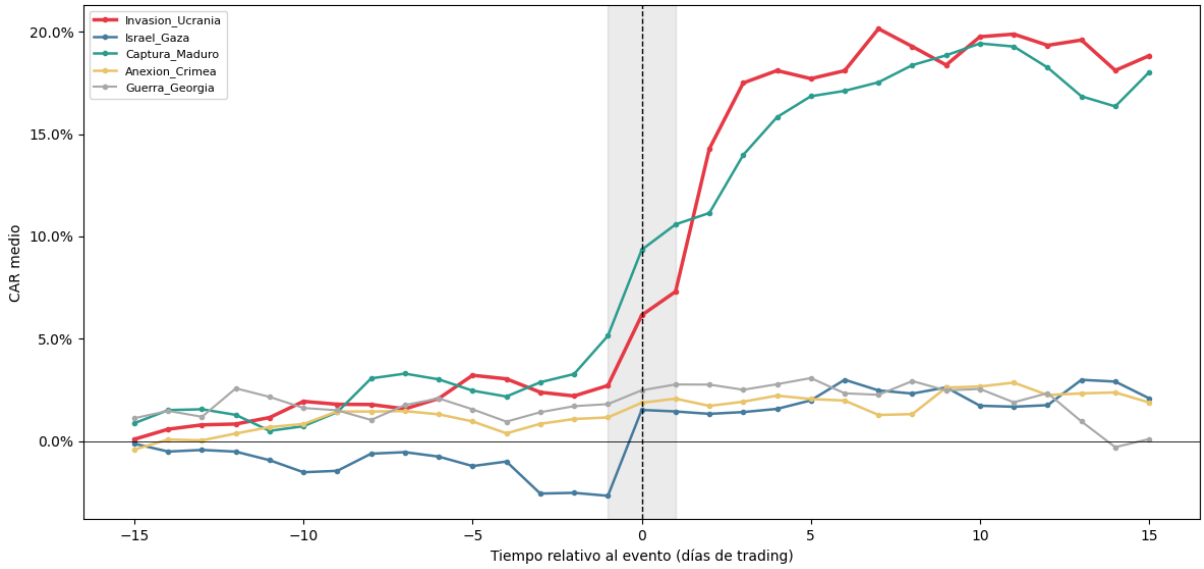


**Ilustración 11.** CAR acumulado medio por evento.
**Fuente:** Elaboración propia.

La Ilustración 11 es la gráfica más informativa del análisis. Dos eventos se despegan con claridad del resto, la invasión de Ucrania y la captura de Maduro. La invasión de Ucrania acumula un 18,83% en (–15, +15) sin reversión, impulsada por el AR del 6,98% en t=+2 y el 3,21% de t=+3. El fondo especial alemán de 100.000 millones de euros, comunicado el 27 de febrero, es un ejemplo claro de shock informativo posterior a t=0 que alimenta esta acumulación.

La captura de Maduro es similar en magnitud a Ucrania. El CAR en (–1, 0) alcanza el 6,08% (significativo al 1%), y la acumulación continúa con fuerza en las sesiones siguientes: 11,78% en (–3, 3), 13,82% en (–5, 5) y 18,87% en (–10, 10). La corrección hasta el 17,94% en (–15, 15) es marginal, lo que indica que el efecto se sostuvo prácticamente intacto durante las tres semanas posteriores al shock. Conviene notar que ese 6,08% en (–1, 0) es mayor que el AR del propio día del evento (4,17%), lo que implica un retorno anormal positivo del 1,91% en t=–1. Esto se debe a que la operación se ejecutó en la madrugada del sábado 3 de enero, la primera sesión de mercado que pudo recoger el shock fue el lunes 5, y t=–1 corresponde por tanto al viernes 2 de enero. En esa sesión Trump anunció públicamente que el ejército estadounidense conduciría ataques militares dentro de Venezuela, una declaración independiente del operativo contra Maduro, que se mantuvo en secreto, pero suficiente por sí sola para mover al alza al sector defensa. El AR(–1) recoge la reacción a ese anuncio, no una filtración del operativo. Tras

el impulso inicial, la trayectoria muestra que el mercado siguió incorporando información durante las semanas posteriores.

Por otro lado, el Ataque de Hamás muestra un perfil opuesto. Toda la reacción se produce en t=0 (CAR de 4,05% en (–1, 0)). Al ampliar la ventana, el CAR cae hasta el 2,09% en (–15, +15). Tras el impulso inicial, la reacción perdió intensidad a medida que el mercado ajustó su valoración del impacto esperado del conflicto sobre el sector.

Finalmente, Georgia y Crimea generan CAR más reducidos y con una significatividad menos consistente. En el caso de Georgia, solo se obtiene significatividad al 5% en la ventana (–3, 3), con un CAR del 1,56%, y el efecto se desvanece al ampliar la ventana. Crimea presenta un patrón similar.

La Tabla 7 reproduce el mismo ejercicio en términos de SCAR.

**Tabla 7.** SCAR medio por evento y ventana.

| Ventana | Georgia | Crimea | Ucrania | Ataque de Hamás | Maduro |
|---|---|---|---|---|---|
| (–1, 0) | 0,20 | 0,30** | 1,54*** | 1,74*** | 1,81*** |
| (–1, 1) | 0,22 | 0,27* | 1,72*** | 1,46*** | 1,74*** |
| (–3, 3) | 0,33** | 0,25* | 3,32*** | 0,75*** | 1,75*** |
| (–5, 5) | 0,21 | 0,12 | 2,88*** | 0,65*** | 1,69*** |
| (–10, 10) | 0,08 | 0,21 | 2,39*** | 0,45*** | 1,67*** |
| (–15, 15) | 0,14 | 0,12 | 1,98*** | 0,33** | 1,33*** |

**Fuente:** Elaboración propia. Nota: *p<0,10; **p<0,05; ***p<0,01.

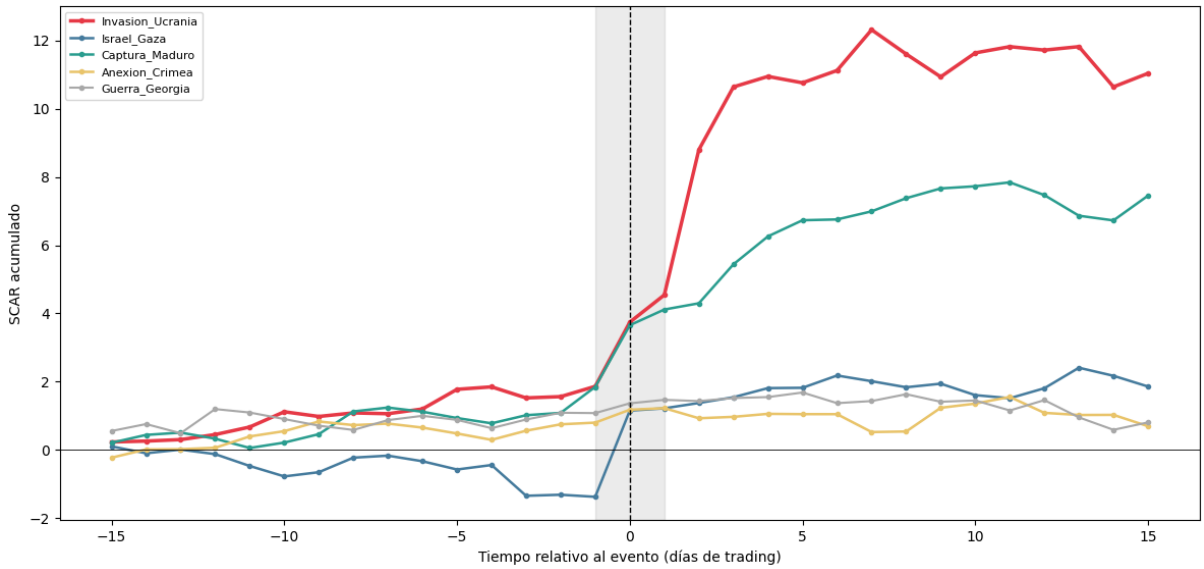


**Ilustración 12.** SAR acumulado medio por evento.
**Fuente:** Elaboración propia.

La Tabla 7 matiza el patrón observado en los CAR. En las ventanas más estrechas, Maduro registra el mayor impacto estandarizado, con un SCAR de 1,81 en (–1, 0), por encima de Hamás (1,74) y Ucrania (1,54). Al ampliar la ventana, Ucrania pasa a la primera posición, alcanza 3,32 en (–3, 3) y se mantiene como el evento de mayor intensidad relativa en el resto. La Ilustración 12, que representa la suma acumulada de los SAR diarios, muestra además que Maduro presenta una trayectoria ascendente y persistente tras el evento, aunque por debajo de Ucrania. La estandarización deja a los dos episodios como los shocks más fuertes del periodo, pero cuál de ellos lidera depende del horizonte considerado.

## 5.2. Event study clásico: comparación Pure Play vs Defense Tech

### 5.2.1. Diferencias entre Pure Play y Defense Tech en t=0

Las Tablas 8 y 9 comparan el retorno anormal medio en t=0 entre ambos grupos, primero en AR y después en SAR.

**Tabla 8.** AR medio en t=0 por tipología: Pure Play vs Defense Tech.

| Evento | AR PP | AR DT | Diferencia | T-stat | P-valor | Sig. |
|---|---|---|---|---|---|---|
| Georgia | 0,84% | 0,53% | +0,32 pp | 0,524 | 0,604 | |
| Crimea | –0,17% | 1,60% | –1,77 pp | –1,899 | 0,068 | * |
| Ucrania | 2,53% | 4,16% | –1,63 pp | –0,619 | 0,539 | |
| Ataque de Hamás | 4,14% | 4,24% | –0,09 pp | –0,060 | 0,952 | |
| Maduro | 3,77% | 4,57% | –0,80 pp | –1,078 | 0,285 | |

**Fuente:** Elaboración propia. Nota: *p<0,10; **p<0,05; ***p<0,01.

**Tabla 9.** SAR medio en t=0 por tipología: Pure Play vs Defense Tech.

| Evento | SAR PP | SAR DT | Dif. | t-stat | p-valor | Sig. |
|---|---|---|---|---|---|---|
| **Georgia** | 0,34 | 0,24 | +0,10 | 0,361 | 0,721 | |
| **Crimea** | –0,07 | 0,83 | –0,90 | –1,817 | 0,079 | * |
| **Ucrania** | 1,55 | 2,14 | –0,59 | –0,423 | 0,675 | |
| **Ataque de Hamás** | 2,73 | 2,36 | +0,37 | 0,440 | 0,662 | |
| **Maduro** | 1,69 | 1,91 | –0,22 | –0,795 | 0,430 | |

**Fuente:** Elaboración propia. Nota: *p<0,10; **p<0,05; ***p<0,01.

En AR, Defense Tech supera a Pure Play en cuatro de los cinco eventos analizados. En SAR, sin embargo, esa ventaja solo aparece en tres, ya que en Georgia y Hamás los valores de Pure Play son ligeramente superiores. Crimea es, además, el único caso en el que aparece una diferencia con significatividad marginal. En ese evento, Defense Tech alcanza un AR del 1,60%, frente al –0,17% de Pure Play, y un SAR de 0,83 frente a –0,07. Esto sugiere que la anexión benefició relativamente más a las firmas de perfil tecnológico que a las más vinculadas a plataformas industriales.

En Ucrania vuelve a verse una pauta parecida: Defense Tech registra un AR del 4,16%, frente al 2,53% de Pure Play, aunque la diferencia no es estadísticamente significativa. En Hamás, en cambio, ambas tipologías reaccionan de forma muy similar, e incluso en SAR Pure Play queda ligeramente por encima. Maduro también deja valores algo más altos en Defense Tech, pero sin significatividad. En conjunto, los resultados en t=0 no permiten sostener con suficiente respaldo estadístico que el mercado diferenciara con claridad entre ambas tipologías. Aun así, la recurrencia con la que Defense Tech aparece por delante justifica extender el análisis más allá de t=0 y observar la evolución completa de los retornos en torno a cada evento.

### 5.2.2. Dinámica temporal por evento

Los contrastes del apartado anterior miden la reacción en una sola sesión, la del propio shock. Para completar la imagen, este apartado examina cómo evolucionan los retornos anormales de cada grupo en los días previos y posteriores al evento, que es donde la eventual diferenciación por tipología puede hacerse más visible.

Para cada uno de los cinco eventos, en orden cronológico, disponemos de cuatro series posibles: AR y SAR diarios, que permiten observar la evolución diaria de la reacción al shock, y CAR y

SCAR acumulados, que reflejan su persistencia a lo largo de la ventana. En cada evento se comentan primero las versiones brutas (AR y CAR) y, cuando las versiones estandarizadas (SAR y SCAR) cambian la lectura, se incluyen también y se explica qué añaden. Cuando la estandarización muestra la misma información que la versión bruta, se menciona brevemente y no se incluye la gráfica adicional.

### a) Guerra de Georgia (2008)

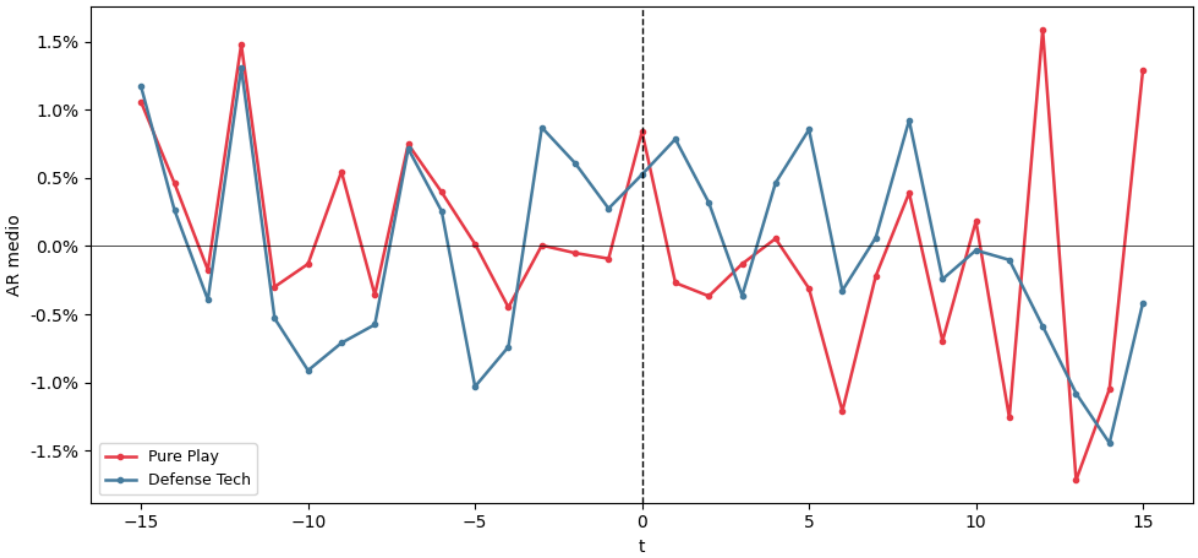


**Ilustración 13.** AR medio: Pure Play vs Defense Tech - Guerra de Georgia.
**Fuente:** Elaboración propia.

En t=0 ambos grupos muestran un pequeño repunte positivo, pero sin un pico claro que destaque sobre el ruido del resto de la ventana. La diferencia entre Pure Play y Defense Tech en ese punto es mínima y prácticamente coincide con otros movimientos puntuales del periodo. Los mayores movimientos de la serie no aparecen en torno al evento, sino en sesiones bastante alejadas. En t=–12 ambos grupos repuntan con fuerza a la vez, y en torno a t=+12 Pure Play registra un pico positivo seguido de una caída brusca al día siguiente, mientras que Defense Tech se mantiene en niveles más estables. Esto es coherente con lo apuntado en 5.1.1, donde Georgia aparecía como una de las reacciones más contenidas de la muestra (AR del 0,68%, significativo solo al

10%). La versión estandarizada (SAR) reproduce el mismo perfil y no aporta una lectura distinta.

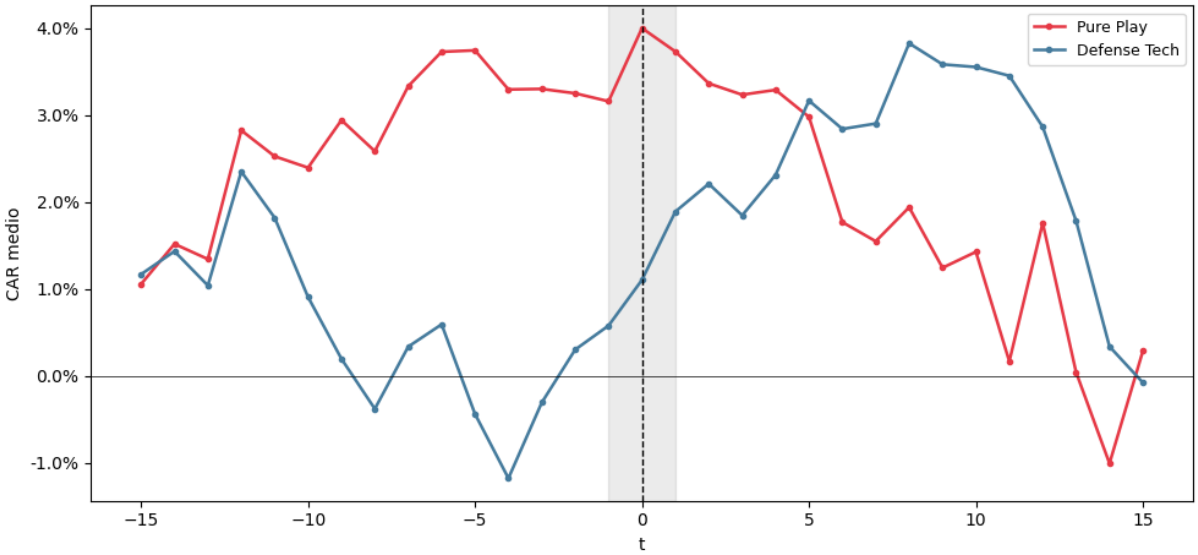


**Ilustración 14.** CAR acumulado: Pure Play vs Defense Tech - Guerra de Georgia.
**Fuente:** Elaboración propia.

El CAR muestra dos trayectorias bastante distintas pese a converger al final. Pure Play empieza la ventana acumulando retornos positivos y alcanzando un máximo cercano al 4% en t=0. Se mantiene en niveles relativamente altos durante varios días antes de iniciar un descenso pronunciado en la segunda mitad de la ventana, hasta cerrar próximo a cero. Defense Tech sigue una trayectoria muy diferente. Empieza más débil y llega a estar en –1% en torno a t=–4. Después del evento, el grupo Defense Tech empieza a tener retornos positivos hasta alcanzar un máximo cercano al 3,8% en torno a t=+8, también terminando con una caída que la lleva al cierre cerca de cero.

Este perfil añade un matiz a lo que el AR no permitía ver. Aunque las dos tipologías acaban en el mismo punto, su manera de llegar es distinta. Pure Play parte ya con cierta acumulación previa al evento y reacciona positivamente en el momento del shock antes de revertir, mientras

que Defense Tech tarda más en tener retornos positivos. Por tanto, la trayectoria muestra que Pure Play fue más sensible al evento en términos absolutos, al menos en la fase inicial.

### Anexión de Crimea (2014)

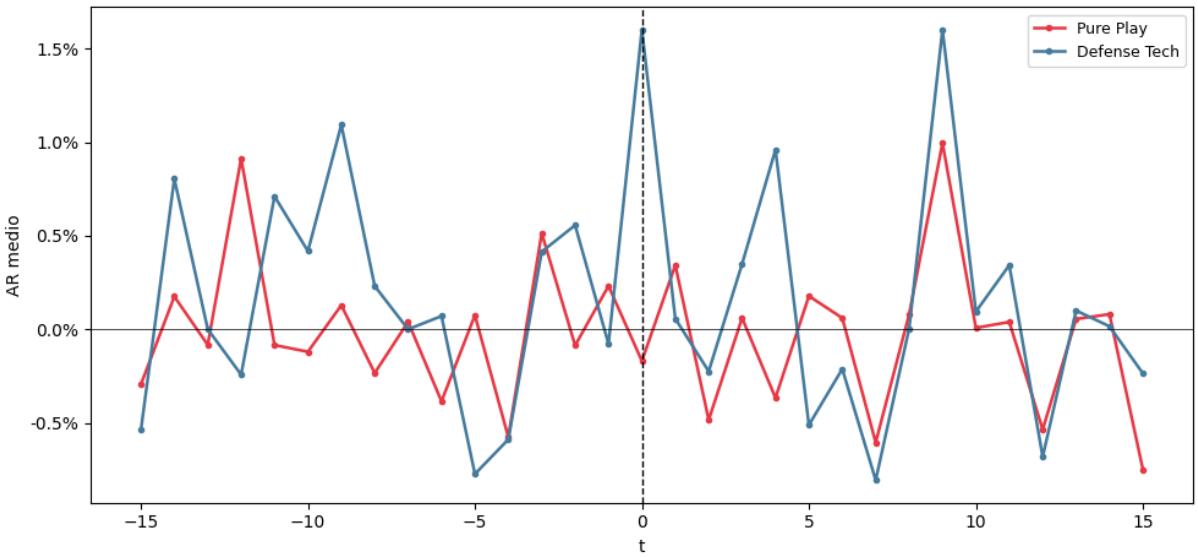


**Ilustración 15.** AR medio: Pure Play vs Defense Tech - Anexión de Crimea.
**Fuente:** Elaboración propia.

En t=0 aparece la divergencia más visible de la ventana analizada, Defense Tech marca un pico positivo claro mientras Pure Play queda ligeramente por debajo de cero. Sin embargo, debemos observar el resto de la ventana ya que hay otros puntos del periodo donde Defense Tech alcanza niveles comparables al de t=0, como en torno a t=–14, t=–9 o t=+9. Estos repuntes anteriores tienen una explicación razonable. La ocupación militar rusa de Crimea comenzó el 27 de febrero de 2014, casi tres semanas antes de la firma de la anexión que se toma como fecha del evento, y ese periodo estuvo marcado por un flujo continuo de noticias, sanciones preliminares y deterioro diplomático, algo que pudo ir reflejándose en el sector antes del t=0 formal. En t=+9, ambos grupos repuntan a la vez, lo que parece ser un movimiento común del sector más que una respuesta diferenciada al shock. La gráfica diaria de AR aporta información limitada. Permite identificar el punto de separación en t=0, pero el ruido de las sesiones próximas impide sacar conclusiones claras sobre la dinámica entre las tipologías.

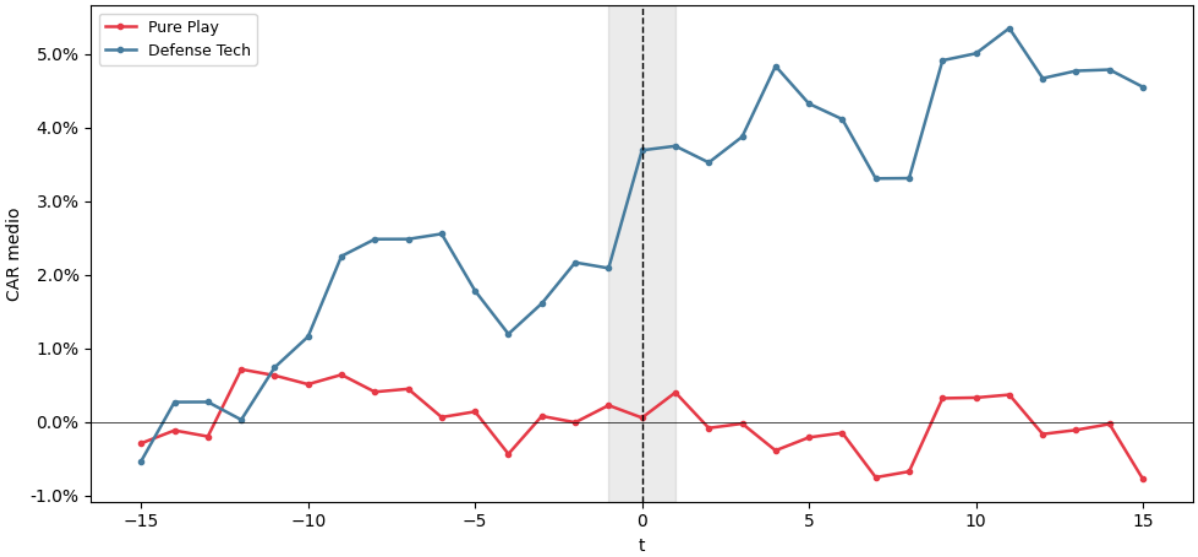


**Ilustración 16.** CAR acumulado: Pure Play vs Defense Tech - Anexión de Crimea.
**Fuente:** Elaboración propia.

El CAR acumulado ofrece una imagen mucho más clara que la serie diaria. Defense Tech empieza a despegarse de Pure Play ya en las ventanas previas, en torno a t=–10, y mantiene una trayectoria ascendente a lo largo de todo el periodo hasta cerrar por encima del 4,5% en t=+15, con un máximo superior al 5% unos días antes. Pure Play, en cambio, apenas se mueve del entorno de cero durante toda la ventana y termina ligeramente por debajo del 0%. La separación entre las dos líneas aparece antes del día formal del evento y no vuelve a cerrarse.

El hecho de que la brecha se abra semanas antes es coherente con lo que ya se apuntaba en el análisis del AR. La ocupación militar rusa había comenzado tres semanas antes de la firma de la anexión, y el flujo continuo de noticias previas pudo ser suficiente para que el mercado empezara a reposicionarse en favor del segmento Defense Tech. Crimea marcó el inicio de la confrontación estratégica entre Rusia y Occidente, constituyendo la implementación operativa de la denominada “guerra de nueva generación” ideada por Gerasimov (Martínez, 2024; Pifer, 2020). Esa naturaleza del shock podría ser la explicación de por qué la acumulación se concentra en Defense Tech y no en Pure Play.

### b) Invasión de Ucrania (2022)

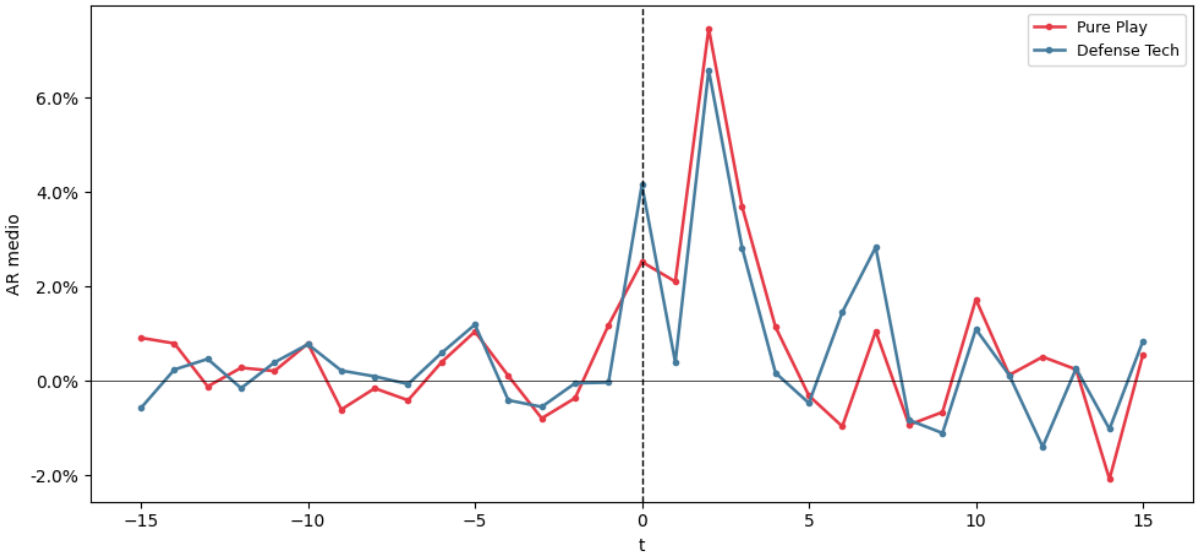


**Ilustración 17.** AR medio: Pure Play vs Defense Tech - Invasión de Ucrania.
**Fuente:** Elaboración propia.

Ucrania presenta el perfil más limpio de los cinco eventos. La ventana previa al shock muestra retornos pequeños y cercanos a cero para ambos grupos, sin movimientos llamativos. A partir de t=0 aparece un pico claro y, sobre todo, en t=+2 ambos grupos registran su mayor retorno anormal de toda la ventana, con Pure Play un poco por encima de Defense Tech. El día t=+3 también muestra una reacción positiva fuerte en ambos grupos, antes de que la serie vuelva a niveles más normales en torno a t=+5. Aun así, la serie posterior no es completamente plana: en torno a t=+7 Defense Tech vuelve a repuntar y en t=+10 ambos grupos registran un pequeño rebote, pero ninguno alcanza la magnitud del pico inicial. La forma del shock es la de una respuesta inmediata pero que no termina en t=0, sino que sigue apareciendo en algunas sesiones tras el evento.

La distribución del pico entre t=0, t=+2 y t=+3 encaja con cómo llegó la información sobre la invasión al mercado. El día del evento ya hubo reacción, pero la magnitud completa del conflicto y las primeras señales sobre rearme europeo se fueron incorporando en las sesiones siguientes.

Llama la atención también el reparto de la reacción entre ambos grupos. En t=0 Defense Tech está por encima de Pure Play, pero en t=+2 la situación se invierte y Pure Play registra el mayor pico de toda la ventana, algo por encima de Defense Tech.

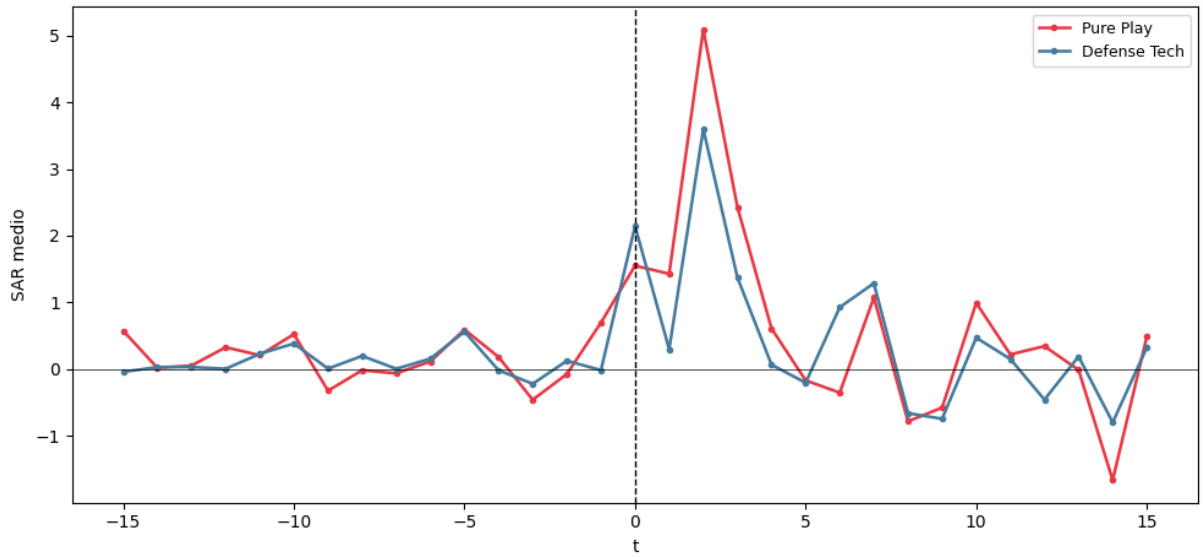


**Ilustración 18.** SAR medio: Pure Play vs Defense Tech - Invasión de Ucrania.
**Fuente:** Elaboración propia.

La versión estandarizada aumenta la ventaja de Pure Play en t=+2, donde el pico es notablemente más alto que el de Defense Tech, una diferencia más visible que en el AR bruto. En t=0, en cambio, Defense Tech sigue ligeramente por encima.

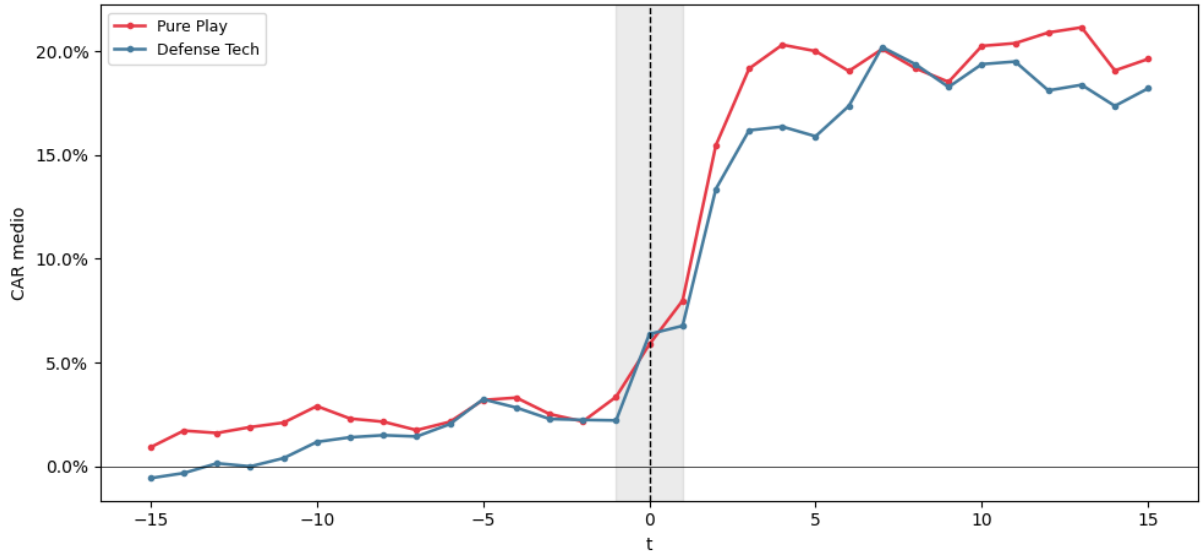


**Ilustración 19.** CAR acumulado: Pure Play vs Defense Tech - Invasión de Ucrania.
**Fuente:** Elaboración propia.

El CAR de Ucrania confirma lo que ya sugería el análisis del AR. Ambos grupos arrancan la ventana con una acumulación moderada, en torno al 1-3%, sin grandes diferencias entre tipologías y sin tendencia clara hasta el día del evento. A partir de t=0, ambas curvas se disparan. En apenas tres sesiones (t=+1, t=+2 y t=+3), ambos grupos suman la mayor parte de su CAR

final, hasta llegar a niveles mayores del 15%. A partir de t=+4 las dos líneas empiezan a estabilizarse en una banda estrecha, con variaciones pequeñas que no rompen el nivel alcanzado. Ambas tipologías cierran la ventana muy cerca, con Pure Play algo por encima del 19% y Defense Tech alrededor del 18%.

Sin embargo, a pesar de que la cifra final sea similar en ambas, hay una tendencia distinta durante la ventana. Pure Play acumula más rápido durante todo el primer tramo posterior al shock, especialmente entre t=+1 y t=+5, donde la separación llega a ser de varios puntos porcentuales. Por otro lado, Defense Tech aumenta los retornos después y termina prácticamente al mismo nivel, pero el orden temporal de la reacción no es simétrico.

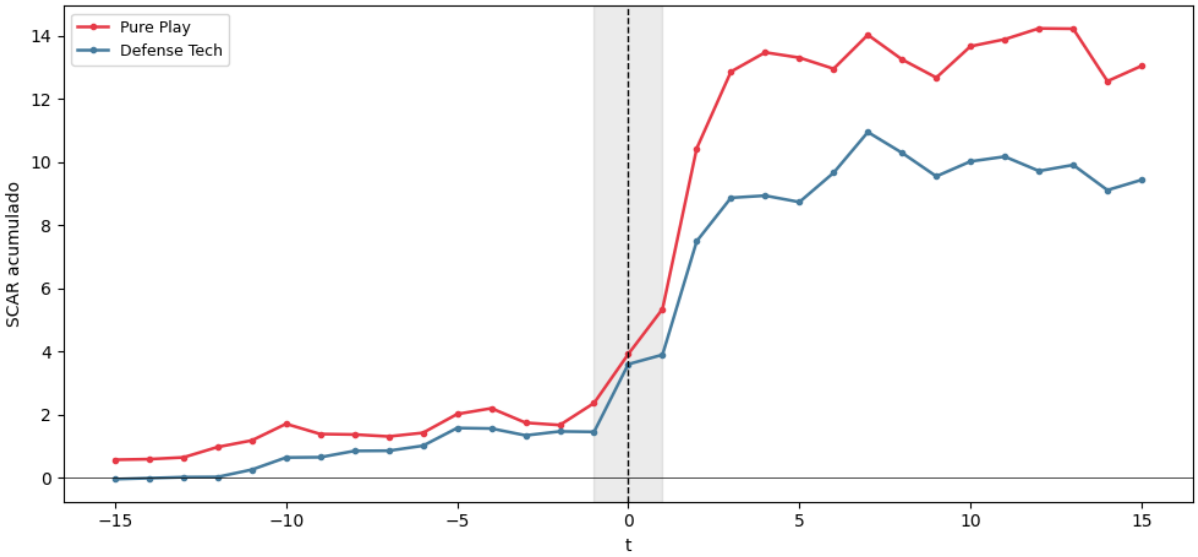


**Ilustración 20.** SAR acumulado: Pure Play vs Defense Tech - Invasión de Ucrania.
**Fuente:** Elaboración propia.

La versión estandarizada cambia bastante la lectura. En el CAR ambos grupos cierran prácticamente igualados, pero en el SAR acumulado la diferencia entre Pure Play y Defense Tech es muy marcada y se mantiene durante todo el periodo posterior al shock. Pure Play alcanza valores cercanos a 14 mientras Defense Tech se queda en torno a 9-10. La explicación más razonable es que las empresas Pure Play tienen en este evento una volatilidad efectiva menor que las Defense Tech: cuando un mismo movimiento absoluto se mide en unidades de

la propia desviación típica, las acciones más estables aparecen como más alejadas de su patrón habitual.

En magnitud absoluta los dos grupos reaccionan parecido a Ucrania, pero en escala relativa Pure Play se aleja mucho más de su comportamiento habitual. Para Pure Play, la invasión fue un evento más fuera de lo normal de lo que indica el CAR sin estandarizar.

### c) Ataques de Hamás (2023)

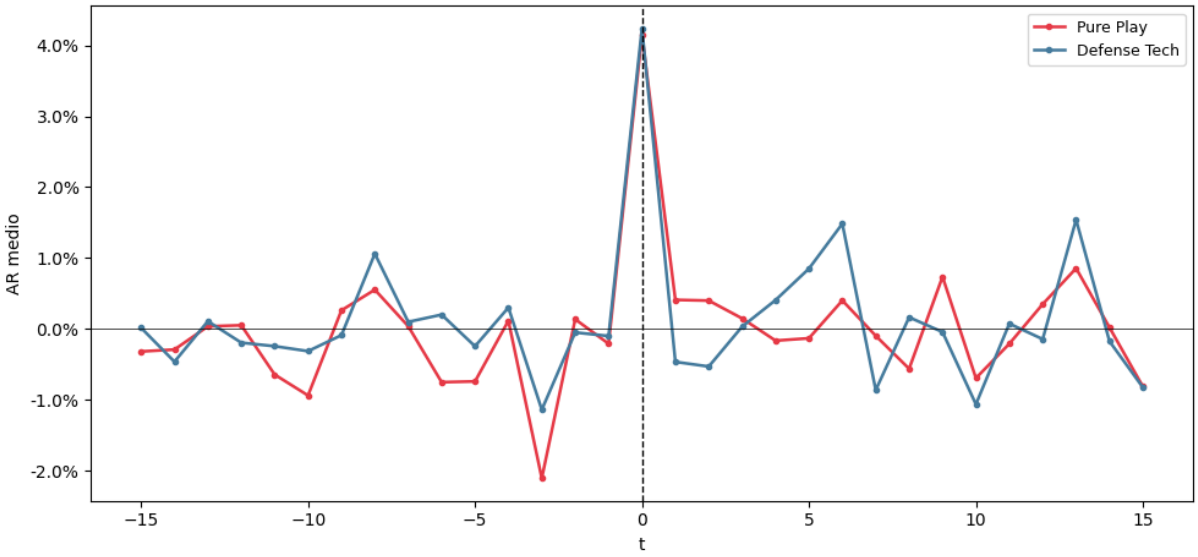


**Ilustración 21.** AR medio: Pure Play vs Defense Tech - Ataques de Hamás.
**Fuente:** Elaboración propia.

Los ataques de Hamás presentan el perfil más concentrado de los cinco eventos en t=0. Ambos grupos registran un pico claro y prácticamente idéntico, en torno al 4%. Se trata del día con la reacción más nítida de toda la ventana, sin que ningún otro punto se le acerque. Las reacciones de Pure Play y Defense Tech son muy similares durante la ventana, lo que apunta a una respuesta del sector como bloque y no tanto a una diferenciada por modelo de negocio.

La ventana previa al evento muestra una tendencia algo negativa en ambos grupos, sobre todo en Pure Play, con una caída notable en torno a t=–3. Esa tendencia previa no se debe al ataque, pero conviene tenerla en cuenta. Una serie que viene de varios días en negativo puede experimentar parte de su repunte posterior por mecánica de mercado y no solo por información

nueva, así que no se puede descartar que parte del salto de t=0 incorpore también un componente de rebote técnico junto con la reacción al propio ataque.

La ventana posterior al shock no añade movimientos relevantes. Hay algunos picos menores en torno a t=+6 y t=+13, sobre todo en Defense Tech, pero ninguno se aproxima a la magnitud de t=0.

La versión estandarizada (SAR) reproduce el mismo perfil sin añadir información distinta. Las dos líneas vuelven a coincidir prácticamente sobre el pico de t=0 y permanecen pegadas durante todo el periodo.

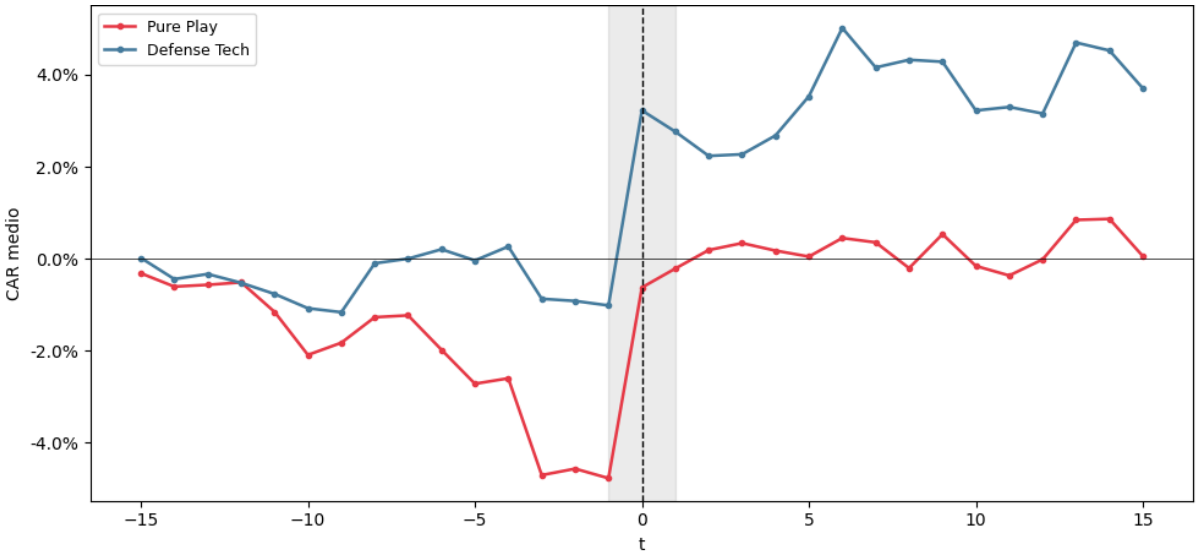


**Ilustración 22.** CAR acumulado: Pure Play vs Defense Tech - Ataques de Hamás.
**Fuente:** Elaboración propia.

El CAR de Hamás muestra una separación clara entre tipologías que el AR no permitía ver con tanta claridad. Pure Play arrastra una caída pronunciada durante los días previos al evento, llegando a niveles cercanos al –4,5% en torno a t=–1. Defense Tech, en cambio, se mantiene prácticamente estable alrededor de cero durante todo el periodo previo.

Cuando llega el shock, ambos grupos saltan, pero el punto de partida es muy distinto. Pure Play sube lo suficiente para anular su caída previa y volver a un nivel cercano a cero, donde permanece prácticamente plano durante el resto de la ventana. Por otro lado, Defense Tech salta desde cero hasta valores cercanos al 3% y sigue acumulando ligeramente en los días posteriores cerrando en torno al 4%.

El resultado final es que Defense Tech mantiene un CAR positivo durante todo el periodo posterior al evento, mientras Pure Play oscila alrededor de cero. La separación entre las dos líneas empieza a abrirse en torno a t=–8, cuando Pure Play comienza a caer mientras Defense Tech se mantiene plano. La demanda generada por el conflicto, ligada como se apuntaba en 4.1.2 a sistemas de interceptación, drones, inteligencia y guerra electrónica (Heimann, 2024; Keinon, 2025), parece haber beneficiado más a las firmas con un perfil tecnológico que con uno tradicional.

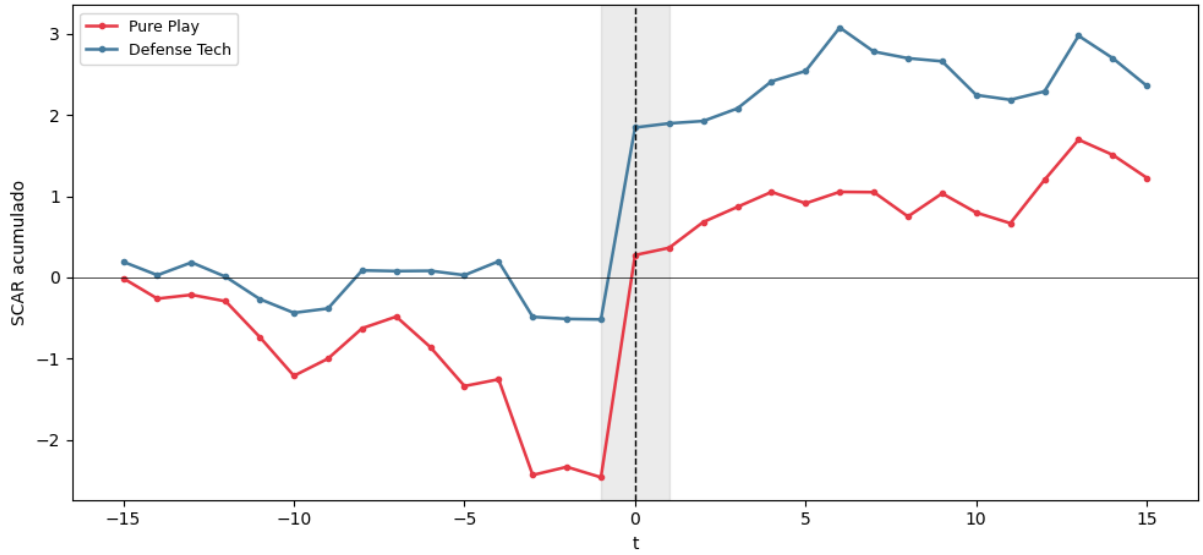


**Ilustración 23.** SAR acumulado: Pure Play vs Defense Tech - Ataques de Hamás.
**Fuente:** Elaboración propia.

La versión estandarizada cambia un detalle. En el CAR, Pure Play termina prácticamente en cero, lo que sugeriría que su reacción al shock fue nula. Pero el SAR acumulado lo sitúa en torno a 1,2, claramente positivo, mientras Defense Tech queda alrededor de 2,5. La diferencia viene de que Pure Play arrastraba una caída fuerte previa al shock, y la recuperación de t=0 solo le devolvió al punto de partida en términos absolutos, aunque sí supuso un movimiento grande respecto a su comportamiento habitual. La comparación entre grupos no cambia, pero el SAR acumulado deja claro que Pure Play sí tuvo una reacción relevante al shock.

### d) Captura de Maduro (2026)

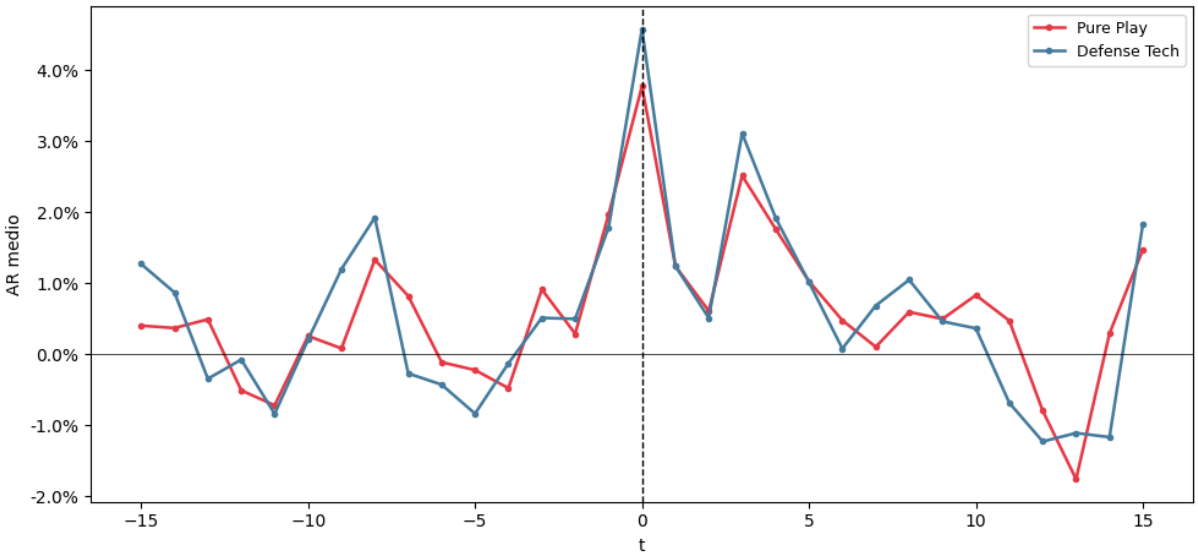


**Ilustración 24.** AR medio: Pure Play vs Defense Tech - Captura de Maduro.
**Fuente:** Elaboración propia.

El AR de la captura de Maduro presenta un perfil claro y distinto al de los demás eventos. En t=0 ambos grupos registran un pico prácticamente igual, con Defense Tech ligeramente por encima de Pure Play (en torno al 4,5% frente al 3,8%). Lo interesante es que la reacción no se concentra en una sola sesión. Tras el pico inicial, la serie no vuelve a niveles normales, sino que mantiene retornos positivos durante varios días. Incluso en t=+3 y t=+4 ambos grupos vuelven a repuntar con fuerza, alcanzando picos secundarios cercanos al 2-3%. El periodo posterior al evento muestra retornos positivos hasta más allá de t=+5. La forma de este evento se parece más a la de Ucrania que a la de Hamás, con la reacción distribuida en varias sesiones consecutivas en lugar de concentrada en un solo día. En el tramo final de la ventana, en torno a t=+13, ambos grupos registran una caída similar, pero sin llegar a borrar la acumulación previa.

La ventana previa también muestra un comportamiento llamativo. Hay un repunte notable en torno a t=–8, especialmente en Defense Tech. La proximidad temporal y la forma del pico sugieren que pudo haber tensiones acumuladas o flujo de noticias relacionadas con la operación en los días anteriores.

El reparto entre tipologías es muy parejo en toda la ventana. Las dos líneas se cruzan varias veces, con diferencias pequeñas en cada sesión, sin que un grupo domine sobre el otro de forma sostenida. Es el evento donde Pure Play y Defense Tech se mueven más en paralelo, lo que

apunta a una respuesta del sector en bloque, similar a lo que ocurría en Hamás, pero distribuida en más sesiones.

La versión estandarizada (SAR) reproduce el mismo perfil sin matices nuevos. Las dos líneas se solapan prácticamente durante todo el periodo, con el mismo pico principal en t=0 y la misma distribución de la reacción en sesiones posteriores.

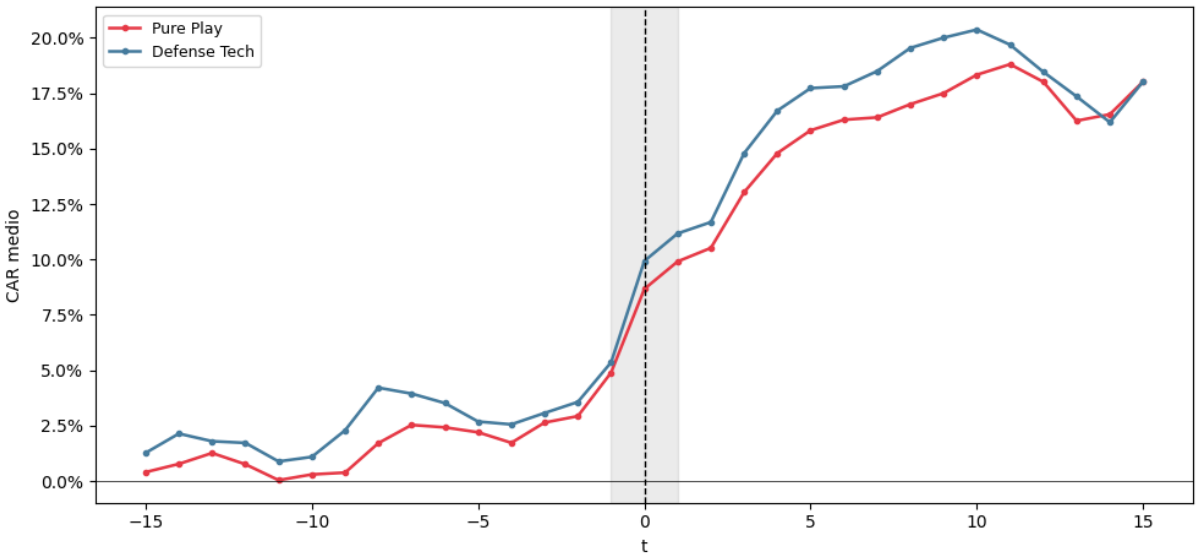


**Ilustración 25.** CAR acumulado: Pure Play vs Defense Tech - Captura de Maduro.
**Fuente:** Elaboración propia.

El CAR de Maduro confirma que la reacción tiene una magnitud comparable a la de Ucrania. Ambos grupos arrancan la ventana con una acumulación moderada, en torno al 1-3%, sin grandes diferencias entre tipologías. Defense Tech muestra valores ligeramente superiores durante todo el periodo. A partir de t=–1, las dos curvas se disparan en paralelo. Defense Tech alcanza un máximo cercano al 20% en torno a t=+10 y empieza a corregir. Pure Play sigue una trayectoria muy similar, con un máximo algo inferior y la misma corrección final. En el cierre de la ventana, ambos grupos quedan prácticamente igualados, justo por debajo del 18%.

La forma del shock se parece a la de Ucrania, con una acumulación que no se agota en t=0 sino que se distribuye a lo largo de varias sesiones, alcanzando su máximo más de una semana después del evento.

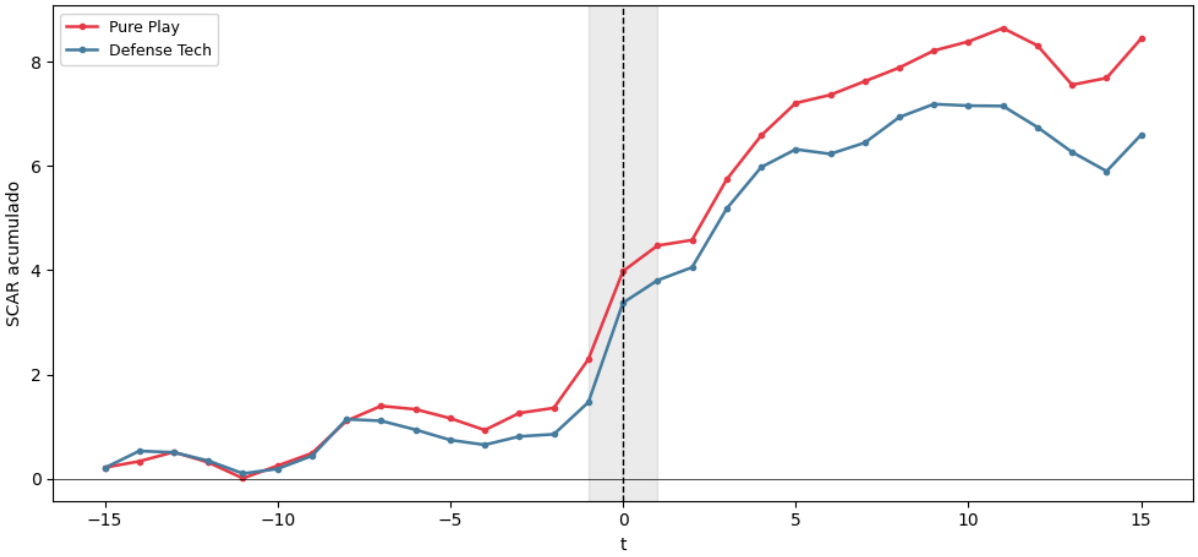


**Ilustración 26.** SAR acumulado: Pure Play vs Defense Tech - Captura de Maduro.
**Fuente:** Elaboración propia.

La versión estandarizada muestra una situación distinta a la del CAR, igual que pasaba en Ucrania. En el CAR ambos grupos terminan prácticamente igualados, pero en el SAR acumulado Pure Play se sitúa por encima de Defense Tech durante todo el periodo posterior al shock, alcanzando valores cercanos a 8,5 frente al 6,5 de Defense Tech.

Maduro repite el patrón de Ucrania. Los dos grupos reaccionan con una intensidad parecida en magnitud absoluta, pero en escala relativa Pure Play se aleja más de su comportamiento habitual. La operación contra Maduro generó una revalorización extraordinaria para las dos tipologías, pero para Pure Play fue un evento más fuera de lo normal de lo que indica el CAR sin estandarizar.

## 5.3. Síntesis del event study (MacKinlay)

Los resultados del *event study* se pueden resumir en tres ideas.

Los cinco eventos producen retornos anormales positivos en t=0, pero no todos con la misma fuerza. Ucrania, Hamás y Maduro generan reacciones grandes, en torno al 3,5–4%, y son significativos al 1%. Georgia y Crimea quedan muy por detrás, con magnitudes pequeñas y significatividad débil. La estandarización reproduce este orden y deja a Hamás como el shock más intenso en escala estandarizada, con un SAR cercano a 2,5.

La duración del efecto no depende solo del tamaño de la reacción inicial. Ucrania y Maduro acumulan crecimiento hasta llegar a CAR cercano al 18% al final de la ventana. Hamás concentra toda la reacción en t=0 y luego se estabiliza. Georgia y Crimea generan respuestas transitorias que se diluyen al ampliar el horizonte. La diferencia parece estar en si el mercado interpreta el shock como un cambio duradero en las perspectivas del sector o solo como un episodio acotado.

La diferencia entre Pure Play y Defense Tech en t=0 no es estadísticamente clara. Solo Crimea alcanza significatividad marginal. La dinámica temporal sí muestra patrones, pero distintos según el evento. En Crimea, Defense Tech se separa de Pure Play desde antes de t=0 y se mantiene superior durante toda la ventana. En Hamás, la diferencia también favorece a Defense Tech, aunque por una caída previa de Pure Play más que por una reacción más fuerte. En Ucrania y Maduro, los dos grupos terminan en niveles muy parecidos, sin que ninguna tipología domine. En Georgia, las dos respuestas son demasiado débiles como para sostener una conclusión.

Hay un matiz que solo aparece en la versión estandarizada. En Ucrania y Maduro, el SAR acumulado sitúa a Pure Play por encima de Defense Tech, a pesar de que en términos absolutos los dos grupos terminan igualados. La razón es la misma volatilidad relativa que ya se ha discutido en los apartados anteriores: con un mismo movimiento absoluto, las acciones más estables parecen alejarse más de su patrón habitual.

El sector defensa no reacciona como un bloque homogéneo, pero tampoco se diferencia de forma sistemática por tipología. Las diferencias entre Pure Play y Defense Tech aparecen en algunos eventos, son más visibles en la dinámica temporal que en el contraste puntual de t=0, y dependen tanto de la naturaleza del shock como de la volatilidad relativa de cada grupo.

## 5.4. Resultados del panel con efectos fijos (DiD)

El panel de Pure Play incluye 30 entidades (29 empresas más el MSCI World), 7.770 observaciones y 6.022 periodos temporales. El de Defense Tech incluye 35 entidades, 8.084 observaciones y los mismos 6.022 periodos. Los apartados 5.4.1 y 5.4.2 presentan los resultados de cada estimación.

### 5.4.1. Resultados para Pure Play

La Tabla 10 recoge los coeficientes estimados del panel para Pure Play. El modelo explica alrededor de un 4,5% de la variación de los retornos una vez descontados los efectos fijos de empresa y de tiempo.

**Tabla 10.** Coeficientes del panel con efectos fijos: Pure Play.

| k | Coef. | Std. Err. | t-stat | p-valor | IC inf. | IC sup. |
|---|---|---|---|---|---|---|
| -5 | -0,0062 | 0,0102 | -0,607 | 0,544 | -0,0262 | 0,0138 |
| -4 | -0,0058 | 0,0109 | -0,536 | 0,592 | -0,0272 | 0,0155 |
| -3 | -0,0152 | 0,0165 | -0,918 | 0,359 | -0,0476 | 0,0172 |
| -2 | -0,0028 | 0,0113 | -0,243 | 0,808 | -0,0250 | 0,0195 |
| -1 | — | — | — | — | — | — |
| 0 | 0,0044 | 0,0233 | 0,188 | 0,851 | -0,0413 | 0,0501 |
| +1 | -0,0024 | 0,0131 | -0,187 | 0,852 | -0,0281 | 0,0232 |
| +2 | 0,0091 | 0,0234 | 0,389 | 0,697 | -0,0368 | 0,0550 |
| +3 | -0,0003 | 0,0120 | -0,027 | 0,979 | -0,0238 | 0,0231 |
| +4 | 0,0234 | 0,0410 | 0,572 | 0,567 | -0,0569 | 0,1037 |
| +5 | -0,0021 | 0,0116 | -0,180 | 0,857 | -0,0247 | 0,0206 |

**Fuente:** Elaboración propia.

Ninguno de los coeficientes alcanza significatividad estadística. El coeficiente del día del evento, $\beta_0$ , es de 0,0044 con un p-valor de 0,851. El panel no consigue distinguir el efecto del shock del ruido habitual de los retornos diarios. El F-test conjunto, que comprueba si todos los coeficientes son simultáneamente distintos de cero, tampoco permite rechazar esa hipótesis. La tabla muestra solo una parte del análisis. La dinámica temporal del modelo, que se analiza a continuación, aporta matices que no se ven en estos valores puntuales.

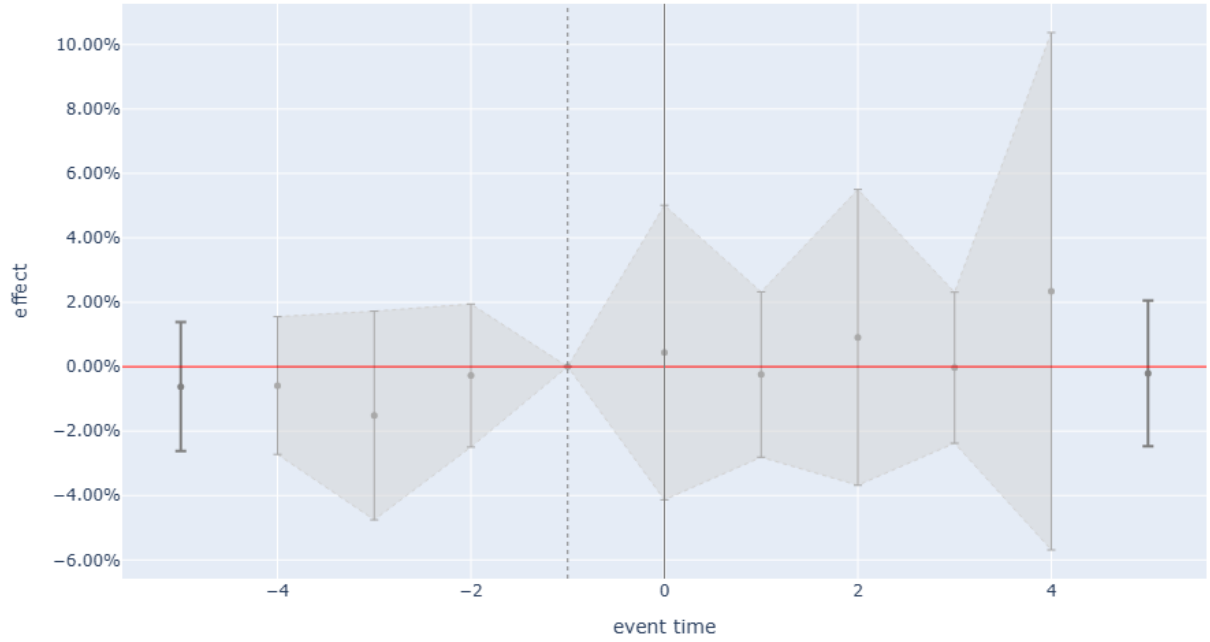


**Ilustración 27.** Panel event study de Pure Play.
**Fuente:** Elaboración propia.

La Ilustración 27 muestra los coeficientes individuales con sus intervalos de confianza al 95%. Todos los intervalos cruzan el cero, lo que deja ver que ninguna sesión alrededor del evento se distingue del comportamiento normal de forma estadísticamente clara. Las bandas son además bastante amplias, especialmente en k=+4, donde el intervalo va de aproximadamente –6% a +10%. La incertidumbre alrededor de cada estimación puntual es muy grande y el panel, con esta especificación y este grupo de control, no tiene potencia suficiente para detectar efectos del tamaño que el *event study* clásico sí encontraba. La razón es que agrupa en una sola regresión cinco eventos de magnitud muy distinta, desde el 0,68% de Georgia hasta el 4,20% de Hamás. El coeficiente promedio queda por debajo de las reacciones individuales más fuertes.

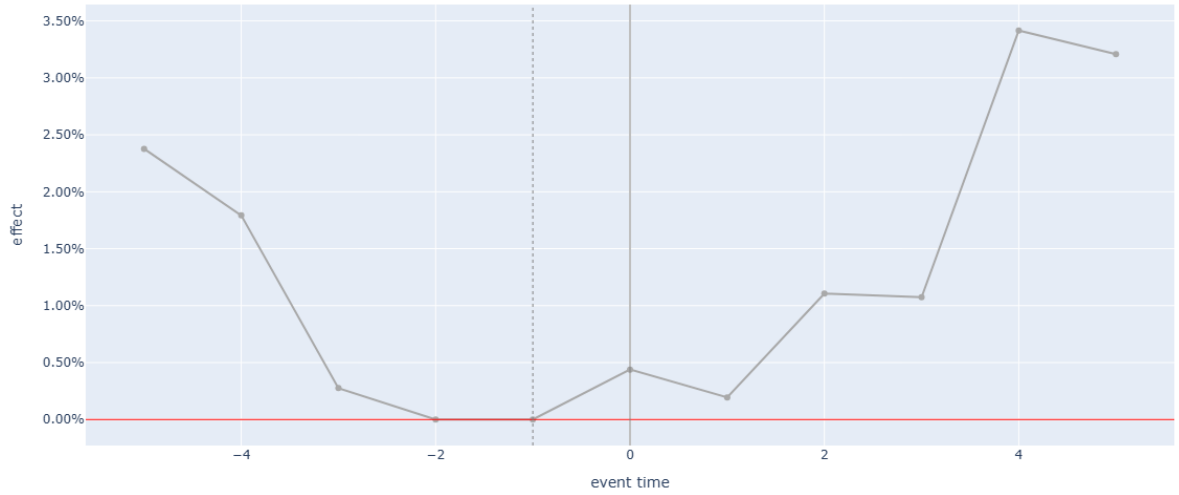


**Ilustración 28.** Efecto acumulado del panel: Pure Play.
**Fuente:** Elaboración propia.

La Ilustración 28 representa el efecto acumulado a lo largo de la ventana, es decir, la suma progresiva de los coeficientes desde el extremo izquierdo hasta cada punto. Esta es la gráfica más informativa del apartado, porque revela un patrón que la tabla por sí sola no transmite con claridad.

El efecto acumulado parte de un nivel positivo cercano al 2,4% en k=–5 y desciende de forma continuada hasta volver a cero en torno a k=–2. Esa trayectoria descendente indica que, durante los días anteriores al evento, las empresas Pure Play estuvieron perdiendo terreno frente al mercado. A partir de t=0, la curva vuelve a subir, alcanza un máximo cercano al 3,4% en k=+4 y se estabiliza alrededor del 3,2% al cierre de la ventana.

Conviene detenerse en esta caída pre-evento. En un diseño DiD ideal, los coeficientes anteriores al evento deberían oscilar en torno a cero sin una tendencia definida, lo que confirma que el grupo tratado se comporta de forma estable antes del shock. Aquí, en cambio, aparece una forma de U: descenso previo al evento y recuperación posterior. Pure Play ya se estaba moviendo antes del día cero, así que parte de la subida posterior podría estar ligada a esas dinámicas previas y no exclusivamente a la reacción al shock geopolítico. Aun así, esta lectura debe interpretarse con cautela, porque el patrón previo al evento no es estable y los coeficientes individuales no son significativos.

La subida del efecto acumulado tras t=0 no se puede interpretar de forma limpia como un efecto causal del shock, porque el grupo Pure Play no tiene un comportamiento previo lo bastante estable como para servir de referencia clara frente a lo que se observa después del evento.

Aun así, la dirección general del efecto coincide con lo observado en el *event study* clásico. Pure Play respondía positivamente a los shocks geopolíticos en el análisis de MacKinlay, con CARs significativos en varios eventos. Lo que el panel añade es que esa respuesta, una vez se controlan los efectos fijos de empresa y de tiempo y se agrupan los cinco eventos en la misma regresión, queda demasiado diluida para detectarla con precisión estadística.

### 5.4.2. Resultados para Defense Tech

La Tabla 11 recoge los coeficientes estimados del panel para Defense Tech. El modelo explica alrededor de un 4% de la variación de los retornos una vez descontados los efectos fijos de empresa y de tiempo, una cifra similar a la del panel de Pure Play.

**Tabla 11.** Coeficientes del panel con efectos fijos: Defense Tech.

| *k* | *Coef.* | *Std. Err.* | *t-stat* | *p-valor* | *IC inf.* | *IC sup.* |
|---|---|---|---|---|---|---|
| *-5* | -0,0036 | 0,0086 | -0,423 | 0,672 | -0,0205 | 0,0132 |
| *-4* | -0,0003 | 0,0091 | -0,034 | 0,973 | -0,0182 | 0,0176 |
| *-3* | -0,0058 | 0,0127 | -0,461 | 0,645 | -0,0307 | 0,0190 |
| *-2* | 0,0035 | 0,0167 | 0,212 | 0,833 | -0,0293 | 0,0363 |
| *-1* | — | — | — | — | — | — |
| *0* | 0,0180 | 0,0212 | 0,848 | 0,397 | -0,0236 | 0,0596 |
| *+1* | 0,00002 | 0,0114 | 0,002 | 0,999 | -0,0224 | 0,0224 |
| *+2* | 0,0152 | 0,0213 | 0,712 | 0,477 | -0,0266 | 0,0569 |
| *+3* | 0,0043 | 0,0123 | 0,350 | 0,727 | -0,0198 | 0,0284 |
| *+4* | 0,0202 | 0,0359 | 0,564 | 0,573 | -0,0502 | 0,0907 |
| *+5* | 0,0029 | 0,0094 | 0,306 | 0,760 | -0,0156 | 0,0213 |

**Fuente:** Elaboración propia.

Como ocurría en Pure Play, ningún coeficiente alcanza significatividad estadística. El coeficiente del día del evento, $\beta_0$ , es de 0,0180 con un p-valor de 0,397. Es el valor más alto de toda la estimación y el que tiene el p-valor más bajo de las dos regresiones, lo que sugiere que la dirección del efecto es consistente con el *event study* clásico, aunque el panel no tenga potencia para detectarlo. El F-test conjunto robusto da un estadístico de 0,36 con p=0,96, por

lo que tampoco se puede rechazar que los coeficientes sean simultáneamente cero, igual que en el panel anterior.

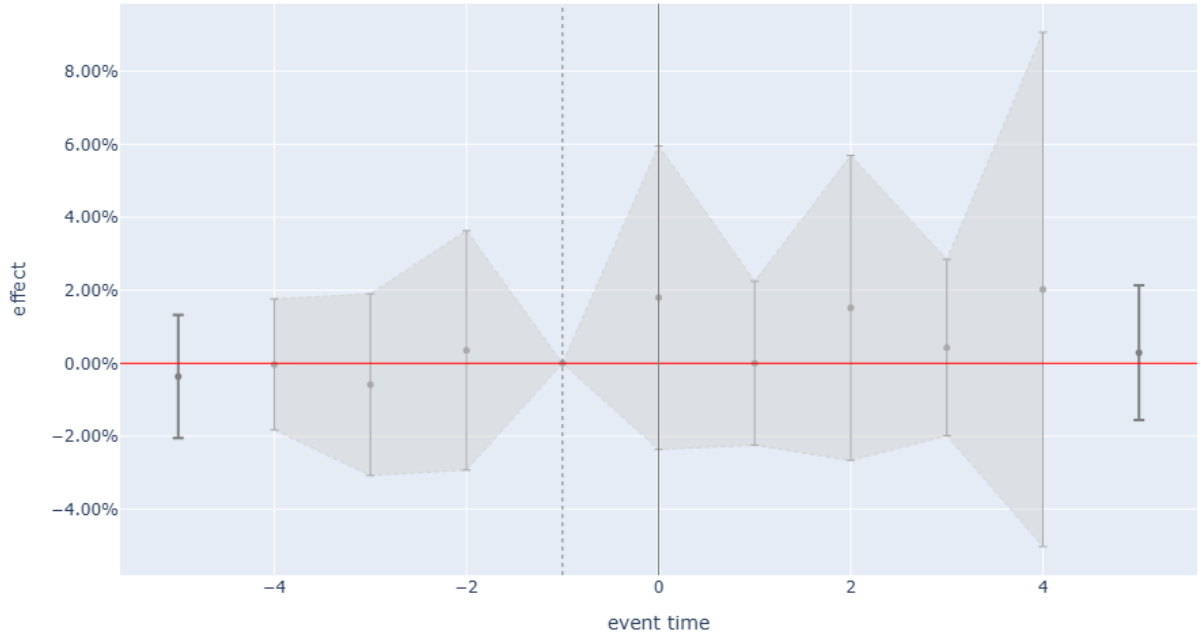


**Ilustración 29.** Panel event study de Defense Tech.
**Fuente:** Elaboración propia.

La Ilustración 29 muestra los coeficientes individuales con sus intervalos de confianza al 95%. Las bandas son amplias y contienen el cero en todos los puntos, lo que confirma que ninguna sesión se distingue del comportamiento normal de forma estadísticamente robusta. Pero el patrón visual ya deja ver algo distinto a lo que veíamos en Pure Play. Los coeficientes anteriores al evento están mucho más cerca de cero y sin una tendencia clara, mientras que los posteriores al shock se mueven sistemáticamente por encima.

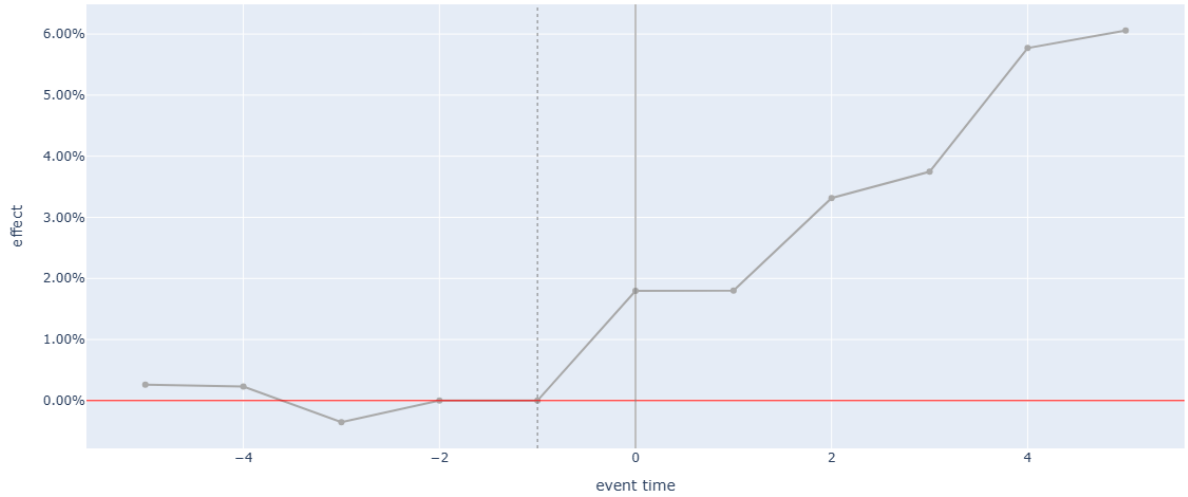


**Ilustración 30.** Efecto acumulado del panel: Defense Tech.
**Fuente:** Elaboración propia.

La Ilustración 30 representa el efecto acumulado a lo largo de la ventana y muestra la diferencia más relevante respecto al panel de Pure Play. En la fase pre-evento, la curva se encuentra muy cerca de cero entre k=–5 y k=–2, sin la caída pronunciada que veíamos antes. Los coeficientes pre-evento no son individualmente distintos de cero ni siguen una tendencia visible, lo que es compatible con el supuesto de tendencias paralelas, aunque esta especificación no permite confirmarlo formalmente. Esa estabilidad pre-evento es la condición básica para poder atribuir al shock los cambios posteriores.

A partir de t=0, la curva sube con claridad. El efecto acumulado alcanza aproximadamente un 1,8% en el propio día del evento, se mantiene plano durante t=+1 y después vuelve a subir hasta llegar a un 6,1% al cierre de la ventana en k=+5.

Al comparar los dos paneles aparecen tres diferencias. Defense Tech tiene un $\beta_0$ mayor en términos puntuales y un efecto acumulado casi el doble al cierre de la ventana, 6,1% frente a 3,2%, aunque ninguna de estas diferencias alcanza significatividad estadística. El panel de Defense Tech tiene además una fase pre-evento mucho más estable, lo que hace que los coeficientes anteriores al shock funcionen como una referencia más sólida para leer la reacción posterior. Los dos grupos van en la dirección positiva que ya mostraba el *event study* clásico, donde Defense Tech reaccionaba con más fuerza en cuatro de los cinco eventos en t=0 y Crimea era el caso más claro de ventaja sostenida. El panel no detecta estos efectos como estadísticamente significativos, pero los reproduce en la misma dirección al estimar los cinco eventos en una sola regresión.

# 6. Conclusiones

## 6.1. Interpretación de los resultados

Este trabajo ha buscado responder a una pregunta concreta. A lo largo de cinco episodios geopolíticos entre 2008 y 2026, ¿varía la reacción bursátil del sector defensa según el modelo de negocio de cada empresa, distinguiendo entre firmas Pure Play y Defense Tech? Para contestarla se ha recurrido a una doble estrategia empírica. Por un lado, un *event study* clásico siguiendo a MacKinlay (1997), y por otro, un panel con efectos fijos en la línea de Clarke y Tapia-Schythe (2021), ambos aplicados a una muestra de 64 empresas cotizadas con exposición significativa al sector.

Los resultados confirman que el sector defensa reacciona ante los shocks geopolíticos con la rapidez que cabría esperar de un mercado eficiente en sentido semi-fuerte (Fama, 1970). En los cinco episodios analizados, el retorno anormal medio del día del evento es positivo, y en tres de ellos la magnitud resulta tanto económicamente relevante como estadísticamente significativa al 1%. La reacción existe en todos los casos, pero lo relevante es explicar por qué la duración es distinta según el evento. Algunos generan saltos puntuales que se diluyen en pocas sesiones mientras que otros producen desplazamientos que se mantienen durante semanas.

La distinción entre shocks duraderos y transitorios depende de cómo el mercado lee las implicaciones del conflicto sobre el gasto militar futuro. Ucrania y Maduro son los dos casos donde el efecto se sostiene durante toda la ventana posterior, sin reversión. Ucrania fue el shock con mayor intensidad, ya que la invasión provocó un giro inmediato en las expectativas de gasto militar europeo, reforzado por anuncios concretos como el plan de rearme alemán. Maduro generó también una acumulación sostenida y aunque las razones de fondo son menos evidentes, probablemente combinen el impacto inmediato del operativo con expectativas más amplias sobre la postura militar de Estados Unidos en la región.

Los demás eventos siguieron otra pauta. Hamás produjo una reacción intensa pero concentrada en t=0, sin acumulación posterior, lo que apunta a que el mercado lo leyó como un episodio acotado a la región. Georgia y Crimea generaron reacciones débiles que apenas dejan huella en las ventanas más amplias.

La pregunta central de este trabajo es si Pure Play y Defense Tech responden de forma sistemáticamente distinta a los shocks geopolíticos. La respuesta es matizada: sí hay diferencias entre tipologías, pero no de forma sistemática en todos los eventos. El contraste estadístico en el día del evento solo arroja diferencias significativas en Crimea, donde Defense Tech reaccionó con claridad mientras Pure Play apenas se movió.

La dinámica temporal completa deja ver matices que el contraste puntual no captura, aunque cada evento muestra una reacción distinta. En Crimea, la separación entre ambos grupos se abre antes del propio día del evento, lo que probablemente refleja que el mercado ya venía reaccionando a la ocupación militar rusa iniciada tres semanas antes de la firma de la anexión. Lo más interesante es que la ventaja se concentra en Defense Tech, lo que encaja con el carácter híbrido del conflicto, donde las capacidades tecnológicas pesaron tanto como las militares

convencionales. En Hamás, la diferencia también favorece a Defense Tech, pero por motivos distintos, ya que Pure Play arrastraba una caída previa que lastraba su acumulación. En Ucrania y Maduro, ambos grupos reaccionan en paralelo y terminan en niveles muy parecidos, sin que ninguna tipología domine. Y en Georgia, la respuesta de ambos grupos resulta demasiado limitada como para interpretar una diferencia real entre ellos.

El panel con efectos fijos no detecta estos efectos como significativos, pero apunta cualitativamente en la misma dirección que el *event study* clásico, con un coeficiente del día del evento mayor en Defense Tech que en Pure Play y un perfil pre-evento más estable. La respuesta a la pregunta inicial no permite extraer una conclusión firme. No se puede concluir que el sector defensa se diferencie de forma sistemática por tipología, porque ninguno de los dos grupos reacciona consistentemente más que el otro. Cuando aparecen diferencias, suelen favorecer a Defense Tech, y esa dirección se repite tanto en el *event study* como en el panel, aunque solo una alcanza significatividad marginal. El modelo de negocio parece importar en casos concretos, pero el efecto es pequeño y depende mucho del tipo de shock.

## 6.2. Limitaciones del estudio y líneas futuras de investigación

### a) Limitaciones

La interpretación de los resultados debe tener en cuenta varias limitaciones metodológicas. La primera afecta al panel con efectos fijos. Los cinco eventos se estiman conjuntamente, y eso obliga al modelo a producir un coeficiente promedio que mezcla shocks de magnitudes muy distintas, desde el 0,68% de Georgia hasta el 4,20% de Hamás. La consecuencia es que la señal de los eventos más fuertes queda diluida por la de los más débiles, lo que reduce la potencia estadística para detectar efectos individuales.

La segunda limitación afecta al grupo de control. El MSCI World es un benchmark amplio y diversificado, lo que lo convierte en una referencia razonable y consistente con la literatura clásica del *event study* (MacKinlay, 1997). Sin embargo, en un panel con efectos fijos por fecha, toda la variación temporal común a las empresas queda absorbida por esos efectos fijos, incluida la serie del MSCI World. Como consecuencia, el control no contribuye activamente a la identificación: queda como referencia formal, y el contraste descansa en la variación diferencial entre las empresas tratadas alrededor de sus fechas de evento.

La tercera afecta a la clasificación entre Pure Play y Defense Tech. Aunque se ha construido sobre criterios replicables y datos de FactSet, hay empresas en la frontera entre ambas categorías cuya asignación no es del todo nítida, como muestran las clasificaciones borderline del anexo. La diferenciación entre tipologías es operativamente útil, pero no perfecta.

La cuarta es de naturaleza muestral. La composición del panel es ex-post, en el sentido de que se ha definido en 2026 a partir de las empresas que hoy cotizan y tienen exposición significativa al sector. Algunas firmas relevantes para los eventos más recientes (Palantir, Aerovironment, Planet Labs, BigBear, Karman, entre otras) no existían como cotizadas en 2008, lo que introduce un sesgo de selección. La muestra efectiva crece de unas 40 empresas en Georgia hasta 64 en Maduro, y eso reduce la comparabilidad directa entre eventos.

Finalmente, el modelo CAPM utilizado como referencia para calcular los retornos esperados está sujeto al problema de hipótesis conjunta señalado por Fama (1970), ya descrito en el marco teórico. Especificaciones alternativas, como modelos multifactoriales del tipo Fama-French, podrían arrojar resultados ligeramente distintos.

### b) Líneas futuras de investigación

Una posible primera extensión es sustituir el CAPM por modelos multifactoriales como Fama-French (3 o 5 factores) o Carhart (1997), que añaden tamaño, book-to-market y momentum. El CAPM lo reduce todo a la exposición al mercado y deja abierto el problema de hipótesis conjunta ya explicado: parte del retorno anormal podría estar recogiendo una mala especificación del modelo y no una reacción al evento.

Otra línea consiste en apoyarse en regresiones transversales sobre los CARs estimados, como plantea Brooks (2014). Se tomaría el CAR de cada empresa como variable dependiente y se estudiaría contra características observables (porcentaje de ingresos de defensa, tamaño, región, exposición geográfica al conflicto). Esto permitiría pasar de ver si hay diferencias entre grupos a entender qué características concretas explican la magnitud de la reacción.

Una tercera opción es estimar el panel con efectos fijos por separado para cada shock. En este análisis, se responde a si existe un patrón sistemático entre eventos y por ello los cinco eventos se agregan en una misma regresión. Una vez confirmada la ausencia de ese patrón, el próximo paso sería estudiar cada shock de forma aislada dentro del marco del panel.

Adicionalmente, podría refinarse la clasificación dentro de Defense Tech. Este grupo reúne empresas distintas entre sí, desde software y datos (Palantir, BigBear) hasta drones o componentes electrónicos (Aerovironment, Karman). Subdividirlo en categorías más homogéneas ayudaría a ver si la reacción tecnológica es uniforme o si proviene de algún subgrupo concreto.

Por último, se podría analizar otro horizonte temporal. El CAR suma retornos anormales día a día, lo que funciona en ventanas cortas, pero pierde precisión en horizontes más largos ya que no captura el efecto de la composición. Brooks (2014) describe como alternativa el Buy-and-Hold Abnormal Return (BHAR), que compone los retornos y refleja la experiencia real del inversor.

# 7. Bibliografía

Beaver, W., Peters, R., Venable, J., & Di Pane, J. (2024). *Prioritizing Procurement over Research and Development* (No. 3804). The Heritage Foundation. https://www.heritage.org/defense/report/prioritizing-procurement-over-research-and-development

Berenson, D., & Higgins, C. (2020, agosto 17). *Market exposure in the Top 100: Defense, commercial aviation and much more*. Defense News. https://www.defensenews.com/opinion/commentary/2020/08/17/market-exposure-in-the-top-100-defense-commercial-aviation-and-much-more/

Boehmer, E., Masumeci, J., & Poulsen, A. B. (1991). Event-study methodology under conditions of event-induced variance. *Journal of Financial Economics*, *30*(2), 253-272. https://doi.org/10.1016/0304-405X(91)90032-F

Brown, S. J., & Warner, J. B. (1985). Using daily stock returns. *Journal of Financial Economics*, *14*(1), 3-31. https://doi.org/10.1016/0304-405X(85)90042-X

Callaway, B., & Sant'Anna, P. H. C. (2021). Difference-in-Differences with multiple time periods. *Journal of Econometrics*, *225*(2), 200-230. https://doi.org/10.1016/j.jeconom.2020.12.001

Carhart, M. M. (1997). On Persistence in Mutual Fund Performance. *The Journal of Finance*, *52*(1), 57-82. https://doi.org/10.1111/j.1540-6261.1997.tb03808.x

Clarke, D., & Tapia-Schythe, K. (2021). Implementing the panel event study. *The Stata Journal: Promoting Communications on Statistics and Stata*, *21*(4), 853-884. https://doi.org/10.1177/1536867X211063144

Dangol, J. (2008). Unanticipated Political Events and Stock Returns: An Event Study. *NRB Economic Review*, *20*(1), 86-110. https://doi.org/10.3126/nrber.v20i1.52973

de Haas, M. (2009). NATO-Russia Relations after the Georgian Conflict. *Atlantisch Perspectief*. https://www.clingendael.org/sites/default/files/pdfs/20090000_cscp_artikel_mhaas.pdf

Don Alessandro. (2006). *LocationCrimea* [PNG map]. https://commons.wikimedia.org/wiki/File:LocationCrimea.PNG

El Ghoul, S., Guedhami, O., Mansi, S. A., & Sy, O. (2023). Event studies in international finance research. *Journal of International Business Studies*, *54*(2), 344-364. https://doi.org/10.1057/s41267-022-00534-6

European Commission. Joint Research Centre. (2018). *Assessing the innovation capability of EU companies in developing dual use technologies*. Publications Office. https://data.europa.eu/doi/10.2760/032120

FactSet. (2019). *FactSet Revere Business and Industry Classification System (RBICS) Data and Methodology Guide* [Methodology Guide]. FactSet. https://assets.ctfassets.net/lmz2w5z92b9u/67nHF3Io7Zg8Ka1eQSqWsi/73277f7a9bc6250c727c8625bdc55164/factset_rbics_methodology_guide.pdf

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

Fama, E. F., & French, K. R. (1993). Common risk factors in the returns on stocks and bonds. *Journal of Financial Economics*, *33*(1), 3-56. https://doi.org/10.1016/0304-405X(93)90023-5

Fama, E. F., & French, K. R. (2015). A five-factor asset pricing model. *Journal of Financial Economics*, *116*(1), 1-22. https://doi.org/10.1016/j.jfineco.2014.10.010

Federal Ministry of Defence. (2022, septiembre 15). *Policy Speech by Federal Minister of Defence on the National Security Strategy*. https://www.bmvg.de/en/news/policy-speech-on-the-national-security-strategy-5497180

Gheorghe, C., & Panazan, O. (2024). Investigating the effect of geopolitical risk on defense companies' stock returns. *Heliyon*, *10*(24), e40974. https://doi.org/10.1016/j.heliyon.2024.e40974

Global Affairs Canada. (2025, octubre 7). *Statement by Minister Anand on second anniversary of Hamas attacks on Israel* [Statements]. https://www.canada.ca/en/global-affairs/news/2025/10/statement-by-minister-anand-on-second-anniversary-of-hamas-attacks-on-israel.html

Goldsmith-Pinkham, P., & Lyu, T. (2025). *Causal Inference in Financial Event Studies*. Yale University & NBER. https://paulgp.com/papers/financial_event_studies_nov18.pdf

Gringer. (2009). *Gaza Strip map2* [SVG map]. Wikimedia Commons. https://commons.wikimedia.org/wiki/File:Gaza_Strip_map2.svg

Gupta, A., & Zhu, B. (2025). *Invest in Europe's defence renaissance*. WisdomTree.

Heimann, A. (2024, enero 7). The Reserve Forces in the Gaza War: Challenges for the Continuation of the Fighting. *Institute for National Security Studies (INSS)*. https://www.inss.org.il/publication/reserve-october-7/

Keinon, H. (2025, agosto 20). *IDF's reservists wrestle with motivation, sacrifice in Gaza*. The Jerusalem Post. https://www.jpost.com/israel-news/defense-news/article-864829

Klein, T. (2024). Investor behavior in times of conflict: A natural experiment on the interplay of geopolitical risk and defense stocks. *Journal of Economic Behavior & Organization*, *222*, 294-313. https://doi.org/10.1016/j.jebo.2024.04.020

Kothari, S. P., & Warner, J. B. (2004). Econometrics of Event Studies. En B. E. Eckbo (Ed.), *Handbook of Corporate Finance: Empirical Corporate Finance*. Elsevier/North-Holland.

Liang, X., Tian, N., Lopes Da Silva, D., Scarazzato, L., Karim, Z. A., & Guiberteau Ricard, J. (2025). *Trends in World Military Expenditure, 2024*. Stockholm International Peace Research Institute. https://doi.org/10.55163/AVEC8366

Lintner, J. (1965). The Valuation of Risk Assets and the Selection of Risky Investments in Stock Portfolios and Capital Budgets. *The Review of Economics and Statistics*, *47*(1), 13-37. https://doi.org/10.2307/1924119

MacKinlay, A. C. (1997). Event Studies in Economics and Finance. *Journal of Economic Literature*, *35*(1), 13-39.

Martínez, J. M. (2024). Conflicto en Ucrania. Cuando la estrategia híbrida no funciona. *Revista de Estudios en Seguridad Internacional*, *10*(1), 39-67. https://doi.org/10.18847/1.19.4

Martins, A. M., Correia, P., & Gouveia, R. (2025). War! Good news for defense firms? Analysis of the impact of Russia–Ukraine conflict. *Journal of Economic Studies*, *52*(2), 303-321. https://doi.org/10.1108/JES-11-2023-0667

Mathews, J. (2025, enero 29). *RTX now has a $218 billion backlog for its commercial aircraft and defense products*. Yahoo Finance. https://finance.yahoo.com/news/rtx-now-218-billion-backlog-004334760.html

MSCI. (2025). *MSCI World Index (USD)—Index Factsheet*. MSCI Inc. https://www.msci.com/documents/10199/255599/msci-world-index.pdf

Nan, T., Lopes da Silva, D., Liang, X., & Scarazzato, L. (2024). *Trends in World Military Expenditure, 2023*. Stockholm International Peace Research Institute (SIPRI). https://www.sipri.org/publications/2024/sipri-fact-sheets/trends-world-military-expenditure-2023

NATO. (2025). *Defence Expenditure of NATO Countries (2014-2025)* (Press Release). NATO Public Diplomacy Division. https://www.nato.int/content/dam/nato/webready/documents/finance/def-exp-2025-en.pdf

Office of the Under Secretary of Defense (Comptroller). (2023). *National Defense Budget Estimates for FY 2024*. U.S. Department of Defense. https://comptroller.war.gov/portals/45/documents/defbudget/fy2024/fy24_green_book.pdf

Panazan, O., & Gheorghe, C. (2025). Impact of geopolitical risks and innovation on global defense stock return. *PLOS ONE*, *20*(2), e0312155. https://doi.org/10.1371/journal.pone.0312155

Perlo-Freeman, S., Fleurant, A., Wezeman, P., & Wezeman, Si. (2016). *Trends in World Military Expenditure, 2015*. Stockholm International Peace Research Institute (SIPRI). https://www.sipri.org/sites/default/files/EMBARGO%20FS1604%20Milex%202015.pdf

Peterson, P. P. (1989). Event Studies: A Review of Issues and Methodology. *Quarterly Journal of Business and Economics*, *28*(3), 36-66.

Pifer, S. (2020, marzo 17). Crimea: Six Years Post-Annexation Analysis. *Brookings*. https://www.brookings.edu/articles/crimea-six-years-after-illegal-annexation/

Rogerson, W. P. (1994). Economic Incentives and the Defense Procurement Process. *Journal of Economic Perspectives*, *8*(4), 65-90. https://doi.org/10.1257/jep.8.4.65

Sharpe, W. F. (1964). Capital asset prices: A theory of market equilibrium under conditions of risk. *The Journal of Finance*, *19*(3), 425-442. https://doi.org/10.1111/j.1540-6261.1964.tb02865.x

Solana, J. (2022, junio 24). European security after NATO's Madrid summit. *Brookings Institution*. https://www.brookings.edu/articles/european-security-after-natos-madrid-summit/

Stockholm International Peace Research Institute (SIPRI). (2025, abril 28). *Unprecedented rise in global military expenditure as European and Middle East spending surges*. https://www.sipri.org/media/press-release/2025/unprecedented-rise-global-military-expenditure-european-and-middle-east-spending-surges

VanEck Asset Management B.V. (2025a). *VanEck Defense UCITS ETF - Documento de Datos Fundamentales (KID)*. VanEck Asset Management B.V. https://www.vaneck.com/globalassets/home/ucits/documents/kids/kid_vaneck-defense-ucits-etf_es-es.pdf

VanEck Asset Management B.V. (2025b). *VanEck Defense UCITS ETF - Factsheet* (DFNS). VanEck Asset Management B.V. https://www.vaneck.com/es/en/library/fact-sheets/dfns-fact-sheet.pdf

Wille, J. H., Keller, A., Förster, N., Kutschera, H.-J., & Reiff, N. (2024). The evolving role of ESG in the defense industry amid the war in Ukraine. *Strategy&*.

Yudaruddin, R., Lesmana, D., Ekşi, İ. H., & Ginn, W. (2024). Market reactions to the Israel-hamas conflict: A comparative event study of the US and Chinese markets. *Borsa Istanbul Review*, *24*(6), 1345-1357. https://doi.org/10.1016/j.bir.2024.10.005

Zhang, Z., Bouri, E., Klein, T., & Jalkh, N. (2022). Geopolitical risk and the returns and volatility of global defense companies: A new race to arms? *International Review of Financial Analysis*, *83*, 102327. https://doi.org/10.1016/j.irfa.2022.102327

Ziemer, H. (2026, enero 20). *The Geopolitics of Maduro's Capture: What Does Operation Absolute Resolve Mean for Russia?* Center for Strategic and International Studies (CSIS). https://www.csis.org/analysis/geopolitics-maduros-capture-what-does-operation-absolute-resolve-mean-russia

# 8. Uso de IA

Por la presente, yo, Alfonso Carrillo, estudiante de ADE y Business Analytics (E-2 Analytics) de la Universidad Pontificia Comillas, al presentar mi Trabajo Fin de Grado titulado *"Reacciones bursátiles del sector defensa ante shocks geopolíticos: un análisis comparativo entre empresas Pure Play y Defense Tech (2008–2026)"*, declaro que he utilizado herramientas de Inteligencia Artificial Generativa únicamente en el contexto de las actividades descritas a continuación:

1. **Brainstorming de ideas de investigación:** Utilizado para idear y esbozar posibles áreas de investigación.
2. **Crítico:** Para encontrar contra-argumentos a una tesis específica que pretendo defender.
3. **Referencias:** Usado conjuntamente con otras herramientas, como Science, para identificar referencias preliminares que luego he contrastado y validado.
4. **Metodólogo:** Para descubrir métodos aplicables a problemas específicos de investigación.
5. **Interpretador de código:** Para realizar análisis de datos preliminares.
6. **Constructor de plantillas:** Para diseñar formatos específicos para secciones del trabajo.
7. **Corrector de estilo literario y de lenguaje:** Para mejorar la calidad lingüística y estilística del texto.
8. **Sintetizador y divulgador de libros complicados:** Para resumir y comprender literatura compleja.
9. **Revisor:** Para recibir sugerencias sobre cómo mejorar y perfeccionar el trabajo con diferentes niveles de exigencia.
10. **Traductor:** Para traducir textos de un lenguaje a otro.

Afirmo que toda la información y contenido presentados en este trabajo son producto de mi investigación y esfuerzo individual, excepto donde se ha indicado lo contrario y se han dado los créditos correspondientes. Soy consciente de las implicaciones académicas y éticas de presentar un trabajo no original y acepto las consecuencias de cualquier violación a esta declaración.

Fecha: 22/04/2026

Firma: 

# ANEXOS

**Anexo A.** Muestra completa de empresas del sector defensa

| *Empresa* | *FactSet Ticker* | *Tipología* | *País* | *Actividad principal* | *Año Base* |
|---|---|---|---|---|---|
| *Thales SA* | HO-FR | Defense Tech | Francia | Sistemas electrónicos para los mercados de defensa, aeroespacial y seguridad. Incluye protección de infraestructuras, aviónica, satélites y soluciones de identidad digital. | 1990 |
| *Rtx Corp* | RTX-US | Pure Play | Estados Unidos | Proveedor global de sistemas aeroespaciales y defensa. Opera mediante: Collins (aviónica/sistemas), Pratt & Whitney (motores), Intelligence & Space (sensores/ciber) y Missiles & Defense (sistemas antimisiles). | 1978 |
| *Leonardo Spa* | LDO-IT | Pure Play | Italia | Aeronáutica, defensa y seguridad. Áreas principales: helicópteros, electrónica y sistemas de misión (sensores/integración), aeronáutica (combate, UAV), espacio y sistemas de defensa (misiles, naval, blindados). | 1985 |
| *Saab Ab* | SAAB.B-SE | Pure Play | Suecia | Soluciones para defensa, aviación y seguridad civil. Áreas: Aeronautics (tecnología aérea), Dynamics (armamento, misiles, submarinos), Surveillance (vigilancia y detección), Kockums (naval) y Combitech (consultoría tecnológica). | 1998 |
| *Hanwha Aerospace Co Ltd* | 012450-KR | Pure Play | Corea del Sur | Actividad aeroespacial y de defensa. Principales negocios: motores y componentes aeronáuticos (turbinas), equipamiento militar, seguridad (CCTV, IT) y sistemas satelitales de observación. | 1994 |
| *Palantir Technologies Inc* | PLTR-US | Defense Tech | Estados Unidos | Desarrollo de plataformas de datos y sistemas operativos para organizaciones. Opera en segmentos Comercial y Gobierno (defensa/inteligencia). Especializada en integración de datos, analítica a gran escala y soporte a decisiones operativas. | 2020 |
| *Elbit Systems Ltd* | ESLT-IL | Defense Tech | Israel | Sistemas de defensa y seguridad nacional para aplicaciones aéreas, terrestres y navales. Provee servicios de entrenamiento, soporte y mantenimiento orientados a defensa y *homeland security*. | 1999 |
| *Leidos Holdings Inc* | LDOS-US | Defense Tech | Estados Unidos | Servicios para defensa, inteligencia y sector público. Se organiza en: Defense Solutions (modernización digital, C4ISR, logística, espacio), Civil (infraestructura, seguridad) y Health (soluciones para clientes federales y veteranos). | 2006 |
| *Curtiss-Wright Corp* | CW-US | Pure Play | Estados Unidos | Ingeniería para aeroespacial, defensa y energía. Divisiones: Aerospace & Industrial (sensores, actuadores, servicios), Defense Electronics (computación COTS, comunicaciones tácticas) y Naval & Power (propulsión naval, energía nuclear). | 1972 |
| *Karman Holdings Inc* | KRMN-US | Pure Play | Estados Unidos | Diseño, testeo y fabricación de sistemas para misiles. Su oferta incluye soluciones de protección y despliegue de carga útil, sistemas aerodinámicos interetapa y propulsión. | 2025 |
| *Kratos Defense & Security Solutions Inc* | KTOS-US | Defense Tech | Estados Unidos | Productos y servicios para misiones críticas de seguridad nacional. Opera en: Government Solutions (microondas, espacio, ciber, entrenamiento) y Unmanned Systems (sistemas no tripulados aéreos, terrestres y marítimos; mando y control). | 1999 |
| *Singapore Technologies Engineering Ltd* | S63-SG | Pure Play | Singapur | Ingeniería y servicios industriales para defensa. Incluye integración, mantenimiento y capacidades de plataforma en dominios terrestre y naval. | 1998 |
| *Caci International Inc* | CACI-US | Defense Tech | Estados Unidos | Servicios de información para seguridad nacional y sector público. Opera en: Domestic Operations (C2, ciber, IT, inteligencia) e International Operations (servicios IT, software y datos). | 1980 |

| | | | | | |
|---|---|---|---|---|---|
| *Huntington Ingalls Industries Inc* | HII-US | Pure Play | Estados Unidos | Construcción naval militar. Divisiones: Ingalls (buques no nucleares, anfibios, combate), Newport News (portaaviones y submarinos nucleares) y Mission Technologies (soluciones IT/misión, sistemas no tripulados, soporte flotas). | 2011 |
| *Booz Allen Hamilton Holding Corp* | BAH-US | Defense Tech | Estados Unidos | Consultoría de gestión y tecnología con foco en defensa y sector público. Ofrece servicios de analítica, soluciones digitales, ingeniería y ciberseguridad. | 2011 |
| *Babcock International Group Plc* | BAB-GB | Pure Play | Reino Unido | Soporte e ingeniería *through life* para gobiernos. Opera en: Marine (submarinos y buques), Land (gestión de flotas, formación), Aviation (entrenamiento aéreo, emergencias) y Nuclear (ingeniería, desmantelamiento). | 1992 |
| *Hyundai Rotem Co Ltd* | 064350-KR | Pure Play | Corea del Sur | Material ferroviario y defensa terrestre. Divisiones: Railway (trenes), Defense (carros de combate, blindados, simuladores) y Plant (ingeniería de plantas industriales). | 2013 |
| *Aerovironment Inc* | AVAV-US | Defense Tech | Estados Unidos | Sistemas robóticos no tripulados para defensa. Incluye UAS pequeños (drones), municiones merodeadoras y servicios asociados. Área de I+D (MacCready Works) en plataformas de gran altitud, robótica y sensores. | 2007 |
| *Dassault Aviation Sa* | AM-FR | Pure Play | Francia | Fabricante de aviones militares y jets ejecutivos. Produce la familia Falcon (negocios) y aeronaves militares, incluyendo servicios de soporte y mantenimiento. | 1990 |
| *Hensoldt Ag* | HAG-DE | Defense Tech | Alemania | Sensores para defensa y seguridad. Opera en: Sensors (radar, soluciones navales, dominio del espectro, aéreo) y Optronics (optrónica, óptica e instrumentos de precisión para tierra, mar y aire). | 2020 |
| *Planet Labs Pbc* | PL-US | Defense Tech | Estados Unidos | Observación de la Tierra mediante constelación de satélites. Ofrece datos e *insights* de alta frecuencia a través de una plataforma web de imágenes y analítica para la toma de decisiones. | 2021 |
| *Korea Aerospace Industries Ltd* | 047810-KR | Pure Play | Corea del Sur | Fabricante aeroespacial de aeronaves de ala fija y rotatoria, estructuras y modernización. Desarrolla sistemas de entrenamiento, UAV y programas espaciales. | 2011 |
| *Renk Group Ag* | R3NK-DE | Pure Play | Alemania | Soluciones de transmisión y propulsión para aplicaciones civiles y militares. Cartera: cajas de engranajes, *power packs*, propulsión híbrida, suspensión, rodamientos, embragues y sistemas de test. | 2024 |
| *Next Vision Stabilized Systems Ltd* | NXSN-IL | Defense Tech | Israel | Diseño y fabricación de cámaras estabilizadas (*gimbals*) para uso diurno y nocturno. Sistemas para vehículos terrestres y aéreos, con especialización en micro y mini drones. | 2021 |
| *Moog Inc* | MOG.A-US | Pure Play | Estados Unidos | Sistemas de control de movimiento y fluidos de alta precisión. Divisiones: Space & Defense, Military Aircraft, Commercial Aircraft e Industrial. | 1980 |
| *Hanwha Systems Co Ltd* | 272210-KR | Defense Tech | Corea del Sur | Equipos de defensa y soluciones tecnológicas. Opera en: Defensa (sistemas tierra, aire y naval) e ICT (*Information and Communication Technology*). | 2019 |
| *Science Applications International Corp* | SAIC-US | Defense Tech | Estados Unidos | Servicios técnicos, de ingeniería e IT para proyectos complejos del sector público. Foco en integración de sistemas e infraestructuras. Clientes clave: DoD, NASA y agencias de inteligencia | 2013 |
| *Parsons Corp* | PSN-US | Defense Tech | Estados Unidos | Tecnología y servicios para seguridad nacional e infraestructuras críticas. Opera en: Federal Solutions (ciber, defensa antimisiles, C5ISR, espacio, geoespacial) y Critical Infrastructure (diseño e ingeniería de infraestructuras físicas y digitales). | 2019 |

| | | | | | |
|---|---|---|---|---|---|
| *Ondas Holdings Inc* | ONDS-US | Defense Tech | Estados Unidos | Sistemas de comunicaciones inalámbricas seguras para redes críticas. Opera en: Ondas Networks (conectividad industrial crítica) y Ondas Autonomous Systems (drones comerciales, sistemas Optimus y Scout). | 2018 |
| *Kbr Inc* | KBR-US | Defense Tech | Estados Unidos | Servicios de ingeniería y soporte tecnológico para proyectos públicos. Se organiza en: Government Solutions (I+D, ingeniería de sistemas, C5ISR, ciber, espacio, logística) y Sustainable Technology Solutions (refino, petroquímica y procesos químicos). | 2006 |
| *Amentum Holdings Inc* | AMTM-US | Defense Tech | Estados Unidos | Servicios para misiones críticas en mercados públicos y comerciales. Opera en: Digital Solutions (analítica, espacio, ciber, IT) y Global Engineering Solutions (remediación ambiental, energía/nuclear, ingeniería de plataformas, cadena de suministro). | 2024 |
| *Mercury Systems Inc* | MRCY-US | Defense Tech | Estados Unidos | Soluciones de procesamiento para misiones aeroespaciales y de defensa. Incluye: procesamiento seguro, soluciones de señal, *disPlays*, software, redes y almacenamiento. | 1998 |
| *Leonardo Drs Inc* | DRS-US | Defense Tech | Estados Unidos | Tecnología de defensa para clientes militares y de inteligencia. Opera en: Advanced Sensors & Computing (sensores, electrónica y computación de red) e Integrated Mission Systems (integración de vehículos terrestres y propulsión naval). | 1985 |
| *Qinetiq Group Plc* | QQ-GB | Defense Tech | Reino Unido | Desarrollo tecnológico y consultoría para defensa y seguridad. Se organiza en: EMEA Services (ensayo, evaluación, formación) y Global Products (resto de líneas de producto y negocio global). | 2006 |
| *Osi Systems Inc* | OSIS-US | Defense Tech | Estados Unidos | Sistemas electrónicos especializados para aplicaciones críticas. Opera en: Security (inspección y seguridad), Optoelectronics & Manufacturing (componentes y fabricación) y Healthcare (monitorización y *connected care*). | 1997 |
| *Bigbear.Ai Holdings Inc* | BBAI-US | Defense Tech | Estados Unidos | Analítica avanzada y plataformas de datos para la toma de decisiones. Soluciones de IA y *machine learning* enfocadas principalmente a clientes de defensa e inteligencia, además del mercado comercial. | 2021 |
| *CAE Inc* | CAE-US | Borderline (inclinación Defense Tech) | Canadá | Entrenamiento y simulación para Aviación Civil y Defensa y Seguridad. Ofrece centros de formación, servicios y productos de simulación para entornos aéreo, terrestre y naval. | 1990 |
| *Serco Group Plc* | SRP-GB | Borderline (inclinación Pure Play) | Reino Unido | Servicios para gobiernos (*outsourcing* y operación). Actividad en: defensa, justicia e inmigración, transporte y sanidad. | 1988 |
| *Indra Sistemas SA* | IDR-ES | Borderline (inclinación Defense Tech) | España | Servicios y productos de tecnología. Segmentos: Defence (radares, defensa aérea y sistemas), Air Traffic y Mobility. | 1988 |
| *Lockheed Martin Corp* | LMT-US | Pure Play | Estados Unidos | Contratista aeroespacial y de defensa. Diseña y fabrica aeronaves militares, sistemas de misiles y control de fuego, sistemas de misión (navales y terrestres) y soluciones espaciales. | 1972 |
| *Northrop Grumman Corp* | NOC-US | Pure Play | Estados Unidos | Contratista aeroespacial y de defensa. Desarrolla y fabrica: sistemas aeronáuticos, sistemas de misión, sistemas de defensa y soluciones espaciales y de misiles para clientes gubernamentales. | 1972 |
| *BAE Systems Plc* | BA-GB | Pure Play | Reino Unido | Contratista de defensa para fuerzas aéreas, terrestres y navales. Suministra plataformas, munición, electrónica avanzada y capacidades de ciber e inteligencia. | 1985 |
| *L3Harris Technologies Inc* | LHX-US | Defense Tech | Estados Unidos | Tecnologías de defensa enfocadas en sistemas espaciales y aerotransportados, integración de sistemas de misión, comunicaciones críticas y propulsión (Aerojet Rocketdyne) para clientes gubernamentales. | 1976 |

| | | | | | |
|---|---|---|---|---|---|
| *Kongsberg Gruppen ASA* | KOG-NO | Borderline (inclinación Defense Tech) | Noruega | Grupo tecnológico con dos segmentos clave: Defence & Aerospace (mando y control, guiado, vigilancia, misiles) y Maritime (sistemas para flota mercante y *offshore*). | 1993 |
| *Avio SpA* | AVIO-IT | Pure Play | Italia | Fabricante de sistemas de propulsión y componentes aeroespaciales, especializado en módulos de motores y propulsión para aplicaciones espaciales y de misiles | 2015 |
| *General Dynamics Corp* | GD-US | Pure Play | Estados Unidos | Contratista aeroespacial y de defensa. Segmentos: Sistemas Navales, Sistemas de Combate Terrestres, Tecnologías y Aeroespacial. Diseña y fabrica plataformas y sistemas para clientes gubernamentales. | 1972 |
| *Rheinmetall AG* | RHM-DE | Pure Play | Alemania | Fabricante de sistemas de defensa. Foco en: vehículos militares, armas y munición, soluciones electrónicas y sistemas de potencia para plataformas. | 1985 |
| *BWX Technologies, Inc.* | BWXT-US | Pure Play | Estados Unidos | Fabricante de componentes nucleares. Produce reactores y combustible para submarinos y portaaviones de la US Navy y fabrica equipos nucleares para clientes civiles. | 2010 |
| *Hindustan Aeronautics Ltd.* | 541154-IN | Pure Play | India | Fabricante aeroespacial de defensa. Productos principales: aeronaves militares, helicópteros, motores (power plant), aviónica, sistemas y accesorios, y materiales aeroespaciales. | 2018 |
| *Bharat Electronics Ltd.* | 500049-IN | Defense Tech | India | Productos y sistemas avanzados para clientes militares, gubernamentales y civiles. Áreas principales: sistemas de comunicación y C4I, sistemas de armas, guerra electrónica, aviónica, radares y sistemas de control de fuego, electro-óptica, y sistemas SATCOM. | 1997 |
| *Chemring Group Plc* | CHG-GB | Pure Play | Reino Unido | Fabricante de productos tecnológicos para defensa y seguridad. Opera en dos segmentos: Sensors & Information (consultoría y servicios tecnológicos de seguridad) y Countermeasures & Energetics (contramedidas para plataformas aéreas y navales, componentes de misiles, propulsantes, dispositivos pirotécnicos y materiales energéticos). | 1985 |
| *TransDigm Group, Inc.* | TDG-US | Pure Play | Estados Unidos | Diseño, producción y suministro de componentes aeronáuticos. Opera en tres segmentos: Power and Control (actuadores electromecánicos, sistemas de ignición, bombas y válvulas especializadas), Airframe (dispositivos de anclaje, conectores y soluciones de sellado) y Non-Aviation (sistemas de satélites y espacio, vehículos off-road). | 2006 |
| *Ducommun, Inc.* | DCO-US | Defense Tech | Estados Unidos | Servicios de ingeniería y fabricación para aeroespacial y defensa. Opera en dos segmentos: Electronic Systems (productos electrónicos y electromecánicos, RF, interfaz hombre-máquina) y Structural Systems (estructuras contorneadas, ensamblajes compuestos y estructuras metal-bonded). | 1972 |
| *V2X, Inc.* | VVX-US | Defense Tech | Estados Unidos | Soluciones integradas y soporte para clientes de defensa. Opera en mercados de operaciones y logística, aeroespacial, entrenamiento y tecnología, para clientes de seguridad nacional, defensa, civiles e internacionales. | 2014 |
| *Aselsan Elektronik Sanayi ve Ticaret AS* | ASELS.E-TR | Borderline (inclinación Defense Tech) | Turquía | Diseño, desarrollo y producción de sistemas tecnológicos para defensa y aplicaciones civiles. Actividades principales en electrónica de defensa, comunicaciones militares, radares, sistemas electroópticos y guerra electrónica. | 1992 |
| *LIG Nex1 Co., Ltd.* | 079550-KR | Defense Tech | Corea del Sur | Fabricación y desarrollo de tecnología para productos de defensa y seguridad. Productos principales: misiles guiados antisubmarinos, sistemas de vigilancia submarina portuaria, radares de vigilancia, y productos para ejército de tierra, armada y fuerza aérea. | 2015 |
| *Bharat Dynamics Ltd.* | 541143-IN | Pure Play | India | Fabricante de equipos de defensa. Especialización en misiles superficie-aire, sistemas de defensa aérea, torpedos pesados, misiles aire-aire y equipos asociados. | 2018 |

| | | | | | |
|---|---|---|---|---|---|
| *Mazagon Dock Shipbuilders Ltd.* | 543237-IN | Pure Play | India | Construcción y reparación naval. Opera en dos segmentos: Shipbuilding y Submarine. Servicios principales para la armada india, incluyendo submarinos y buques de combate. | 2020 |
| Data Patterns (India) Ltd. | 543428-IN | Borderline (inclinación Defense Tech) | India | Fabricación de placas y sistemas electrónicos para defensa. Productos principales: radares y procesadores de radar, aviónica y guerra electrónica, equipos automáticos de test y dispositivos de comunicación. | 2021 |
| *Lubawa SA* | LBW-PL | Pure Play | Polonia | Fabricación de sistemas de seguridad, equipamiento y ropa especial. Productos principales: tiendas, ropa de camuflaje, cascos, chalecos antibalas, barreras de inundación, escudos balísticos y equipos logísticos para uso militar y policial. | 1996 |
| *VICTEK Co., Ltd.* | 065450-KR | Defense Tech | Corea del Sur | Producción y desarrollo de tecnologías defensivas de alta tecnología. Productos principales: sistemas de guerra electrónica, fuentes de alimentación, amplificadores de alta potencia y procesamiento de señal. | 2003 |
| *Huneed Technologies Co., Ltd.* | 005870-KR | Defense Tech | Corea del Sur | Fabricación de equipos de comunicación inalámbrica y dispositivos de transmisión para defensa. Productos principales: radios tácticas MANET, módulos FANET, sistemas de mando y control, y sistemas de armas. | 1993 |
| *Firstec Co., Ltd.* | 010820-KR | Pure Play | Corea del Sur | Desarrollo y fabricación de sistemas de armas. Opera en dos divisiones: Defense Industry (equipos móviles, armamento, armas guiadas, negocio de aviación y sistemas de supresión automatizada) y Security Service (reconocimiento facial). | 1993 |
| *Zen Technologies Ltd.* | 533339-IN | Defense Tech | India | Proveedor de sistemas de entrenamiento y soluciones anti-drones. Productos principales: simuladores de armas avanzados, campos de tiro tubulares, simuladores de conducción, simulación virtual y en vivo, y sistemas anti-drones para fuerzas armadas y de seguridad. | 2004 |

**Fuente**: FactSet (RBICS, Revenue Exposure y Business Segments); factsheet del VanEck Defense UCITS ETF (31/12/2025). Elaboración propia.

**Anexo B.** Código de Python. Event Study (MacKinlay)

0. Configuración del análisis

0.1. Librerías

```
# Instalamos librerías necesarias
!pip install linearmodels

# Cargamos librerías básicas
import pandas as pd
import numpy as np
import statsmodels.api as sm
from scipy import stats
import matplotlib.pyplot as plt
import seaborn as sns
import warnings
warnings.filterwarnings('ignore')
```

0.2. Parámetros

```
# Definimos la ventana de estimación
estimation_window_inicio = -130
estimation_window_fin    = -11

# Definimos las ventanas de evento
ventanas_evento = [(-1, 0), (-1, 1), (-3, 3), (-5,5), (-10, 10), (-15, 15)]

# Conversión de Rf (viene en % anualizado, lo pasamos a diario)
```

```
DIAS_TRADING = 252
```

1. Carga de datos y tabla maestra de eventos

1.1. Carga de datos

```
# Cargamos los cuatro ficheros
data   = pd.read_excel('DATA_BA.xlsx')
market = pd.read_excel('MARKET_BA.xlsx')
rf     = pd.read_excel('DATA_RF.xlsx')
events = pd.read_excel('EVENTS_BA.xlsx')

# Nos aseguramos de que las fechas son datetime
data['date']    = pd.to_datetime(data['date'])
market['date']  = pd.to_datetime(market['date'])
rf['date']      = pd.to_datetime(rf['date'])
events['Fecha'] = pd.to_datetime(events['Fecha'])

# Eliminamos filas sin precio (empresa no cotizaba aún)
data = data.dropna(subset=['tr_gross_usd']).reset_index(drop=True)
```

1.2. Tabla maestra de eventos

```
# Contador de días de trading por empresa (solo datos reales)
data = data.sort_values(['ticker', 'date']).reset_index(drop=True)
data['day_count'] = data.groupby('ticker').cumcount()

# Para cada evento-empresa, buscamos el primer día de trading >= Fecha
# Si ese día está a más de 5 días naturales del evento, descartamos
def find_t0(row, data):
    sub = data[(data['ticker'] == row['Compañía']) & (data['date'] >= row['Fecha'])]
    if len(sub) == 0:
        return pd.Series({'day_count_t0': np.nan, 'date_t0': pd.NaT})
    first = sub.iloc[0]
    if (first['date'] - row['Fecha']).days > 5:
        return pd.Series({'day_count_t0': np.nan, 'date_t0': pd.NaT})
    return pd.Series({'day_count_t0': first['day_count'], 'date_t0': first['date']})

events[['day_count_t0', 'date_t0']] = events.apply(find_t0, axis=1, data=data)

# Quitamos eventos sin datos
print(f"Eventos sin datos: {events['day_count_t0'].isna().sum()}")
events = events.dropna(subset=['day_count_t0']).reset_index(drop=True)
events['day_count_t0'] = events['day_count_t0'].astype(int)

print(f"Eventos válidos: {len(events)}")
events.groupby('Evento')['Compañía'].count()
```

1.3. Preparación de retornos

```
# Retornos simples de cada empresa
data = data.sort_values(['ticker', 'date'])
data['ret'] = data.groupby('ticker')['tr_gross_usd'].pct_change()
```

```
# Retorno simple del mercado
market = market.sort_values('date')
market['ret_m'] = market['msci_world (990100)'].pct_change()

# Rf diaria (de % anualizado a decimal diario)
rf['rf_daily'] = rf['Rf'] / 100 / DIAS_TRADING

# Unimos mercado y Rf al dataframe de empresas por fecha
data = data.merge(market[['date', 'ret_m']], on='date', how='left')
data = data.merge(rf[['date', 'rf_daily']], on='date', how='left')

# Forward-fill Rf para días donde FRED no tiene dato
data['rf_daily'] = data.groupby('ticker')['rf_daily'].ffill()

# Excesos de retorno
data['excess_ret'] = data['ret'] - data['rf_daily']
data['excess_mkt'] = data['ret_m'] - data['rf_daily']
```

2. Doble bucle: estimación CAPM y cálculo de AR

```
# Rango del event window (cubre todas las ventanas definidas)
ew_min = min(v[0] for v in ventanas_evento)
ew_max = max(v[1] for v in ventanas_evento)

lista = []

for _, row in events.iterrows():
    ticker = row['Compañía']
    evento = row['Evento']
    dc_t0  = row['day_count_t0']

    # Datos de esta empresa
    sub = data[data['ticker'] == ticker]

    # 1. Extraer estimation window
    est = sub[(sub['day_count'] >= dc_t0 + estimation_window_inicio) &
              (sub['day_count'] <= dc_t0 + estimation_window_fin)]
    est = est.dropna(subset=['excess_ret', 'excess_mkt'])
    if len(est) < 30:
        continue

    # 2. CAPM: excess_ret = alpha + beta * excess_mkt → OLS
    X = sm.add_constant(est['excess_mkt'])
    model = sm.OLS(est['excess_ret'], X).fit()
    beta_hat  = model.params.iloc[1]
    sigma_est = np.sqrt(model.mse_resid)

    # 3. Extraer event window
    ew = sub[(sub['day_count'] >= dc_t0 + ew_min) &
             (sub['day_count'] <= dc_t0 + ew_max)].copy()
    ew = ew.dropna(subset=['excess_ret', 'excess_mkt'])
```

```
    # 4. AR = excess_ret - beta_hat * excess_mkt
    ew['AR'] = ew['excess_ret'] - beta_hat * ew['excess_mkt']
    ew['time_to_event'] = ew['day_count'] - dc_t0

    # 5. Guardamos
    ew['asset']    = ticker
    ew['evento']   = evento
    ew['sigma_est'] = sigma_est
    lista.append(ew[['asset', 'evento', 'time_to_event', 'date', 'AR', 'sigma_est']])

# Concatenamos fuera del bucle
ar_df = pd.concat(lista).reset_index(drop=True)
print(f"Filas en ar_df: {len(ar_df)}")
ar_df.head(10)
```

4. Estandarización: SAR y SCAR

```
# SAR = AR / sigma de la estimation window (Boehmer, 1991)
ar_df['SAR'] = ar_df['AR'] / ar_df['sigma_est']

# SCAR para cada ventana de evento definida en Bloque 0
for v_start, v_end in ventanas_evento:
    L = v_end - v_start + 1
    col_name = f'SCAR_{v_start}_{v_end}'

    # CAR por empresa-evento en esta ventana
    mask = (ar_df['time_to_event'] >= v_start) & (ar_df['time_to_event'] <= v_end)
    car = ar_df[mask].groupby(['asset', 'evento']).agg(
        CAR=('AR', 'sum'),
        sigma_est=('sigma_est', 'first')
    )
    car[col_name] = car['CAR'] / (car['sigma_est'] * np.sqrt(L))

    print(f"Ventana ({v_start}, {v_end}): SCAR medio = {car[col_name].mean():.4f}")
```

5. Clasificación por grupo

```
# Creamos diccionario de tipología desde la tabla del Anexo A
# Borderline se asigna a su inclinación
pure_Play = ['RTX-US', 'LDO-IT', 'SAAB.B-SE', '012450-KR', 'CW-US', 'S63-SG',
    'HII-US', '064350-KR', 'AM-FR', '047810-KR', 'R3NK-DE', 'MOG.A-US',
    'AVIO-IT', 'LMT-US', 'NOC-US', 'BA-GB', 'GD-US', 'RHM-DE',
    'BWXT-US', 'BAB-GB', 'KRMN-US', 'SRP-GB',
    '541154-IN', 'CHG-GB', 'TDG-US', '541143-IN', '543237-IN', 'LBW-PL', '010820-KR']

defense_tech = ['HO-FR', 'PLTR-US', 'ESLT-IL', 'LDOS-US', 'KTOS-US', 'CACI-US',
    'BAH-US', 'AVAV-US', 'HAG-DE', 'PL-US', 'NXSN-IL', '272210-KR',
    'SAIC-US', 'PSN-US', 'ONDS-US', 'KBR-US', 'AMTM-US', 'MRCY-US',
    'DRS-US', 'QQ-GB', 'OSIS-US', 'BBAI-US', 'LHX-US',
    'CAE-US', 'IDR-ES', 'KOG-NO',
    '500049-IN', 'DCO-US', 'VVX-US', '079550-KR', '065450-KR', '005870-KR',
```

```
    '533339-IN', 'ASELS.E-TR', '543428-IN']

def assign_group(ticker):
    if ticker in pure_Play:
        return 'Pure Play'
    elif ticker in defense_tech:
        return 'Defense Tech'
    else:
        return 'Sin clasificar'

ar_df['group'] = ar_df['asset'].apply(assign_group)
```

6. Tests de significancia

6.1. AR medio y t-test por evento en t=0

```
# AR medio y t-test en t=0 por evento
t0 = ar_df[ar_df['time_to_event'] == 0]

for evento in t0['evento'].unique():
    sub = t0[t0['evento'] == evento]
    ar_mean = sub['AR'].mean()
    sar_mean = sub['SAR'].mean()
    t_stat = sar_mean * np.sqrt(len(sub))
    p_val = 2 * (1 - stats.t.cdf(abs(t_stat), df=len(sub)-1))
    sig = '***' if p_val < 0.01 else '**' if p_val < 0.05 else '*' if p_val < 0.10 else ''
    print(f"{evento:25s}  AR={ar_mean:+.4f}  t={t_stat:+.3f}  p={p_val:.4f} {sig}  N={len(sub)}")
```

6.2. CAR y t-test por evento y ventana

```
# CAR y test para cada ventana de evento
for v_start, v_end in ventanas_evento:
    L = v_end - v_start + 1
    print(f"\n=== Ventana ({v_start}, {v_end}) ===")

    mask = (ar_df['time_to_event'] >= v_start) & (ar_df['time_to_event'] <= v_end)
    car = ar_df[mask].groupby(['asset', 'evento']).agg(
        CAR=('AR', 'sum'),
        sigma_est=('sigma_est', 'first')
    ).reset_index()
    car['SCAR'] = car['CAR'] / (car['sigma_est'] * np.sqrt(L))

    for evento in car['evento'].unique():
        sub = car[car['evento'] == evento]
        car_mean = sub['CAR'].mean()
        scar_mean = sub['SCAR'].mean()
        t_stat = scar_mean * np.sqrt(len(sub))
        p_val = 2 * (1 - stats.t.cdf(abs(t_stat), df=len(sub)-1))
        sig = '***' if p_val < 0.01 else '**' if p_val < 0.05 else '*' if p_val < 0.10 else ''
        print(f"  {evento:25s}  CAR={car_mean:+.4f}  t={t_stat:+.3f}  p={p_val:.4f} {sig}  N={len(sub)}")
```

6.3. Comparación Pure Play vs Defense Tech en t=0

```
# Test de diferencia de medias entre grupos en t=0
```

```
t0 = ar_df[ar_df['time_to_event'] == 0]

for evento in t0['evento'].unique():
    pp = t0[(t0['evento'] == evento) & (t0['group'] == 'Pure Play')]['AR']
    dt = t0[(t0['evento'] == evento) & (t0['group'] == 'Defense Tech')]['AR']
    t_stat, p_val = stats.ttest_ind(pp, dt, equal_var=False)
    sig = '***' if p_val < 0.01 else '**' if p_val < 0.05 else '*' if p_val < 0.10 else ''
    print(f"{evento:25s}  PP={pp.mean():+.4f}  DT={dt.mean():+.4f}  diff={pp.mean()-
dt.mean():+.4f}  t={t_stat:+.3f}  p={p_val:.4f} {sig}")
```

7. Gráficos

7.1. AR por evento (todas las empresas)

```
# AR medio por evento y time_to_event
ar_mean = ar_df.groupby(['evento', 'time_to_event'])['AR'].mean().reset_index()

estilos = {
    'Invasion_Ucrania': {'color': '#e63946', 'lw': 2.5},
    'Israel_Gaza':      {'color': '#457b9d', 'lw': 1.5},
    'Captura_Maduro':   {'color': '#2a9d8f', 'lw': 1.5},
    'Anexion_Crimea':   {'color': '#e9c46a', 'lw': 1.5},
    'Guerra_Georgia':   {'color': '#a8a8a8', 'lw': 1.5},
}

fig, ax = plt.subplots(figsize=(12, 6))

for evento, style in estilos.items():
    sub = ar_mean[ar_mean['evento'] == evento].sort_values('time_to_event')
    ax.plot(sub['time_to_event'], sub['AR'],
            label=evento, color=style['color'],
            linewidth=style['lw'], marker='o', markersize=3)

ax.axhline(0, color='black', linewidth=0.6)
ax.axvline(0, color='black', linestyle='--', linewidth=1)
ax.set_xlabel('Tiempo relativo al evento (días de trading)')
ax.set_ylabel('AR medio')
ax.set_title('Retorno anormal medio por evento (AR)')
ax.legend(fontsize=8, loc='upper left')
ax.yaxis.set_major_formatter(plt.FuncFormatter(lambda y, _: f'{y:.1%}'))
plt.tight_layout()
plt.show()
```

7.2. CAR acumulado por evento (todas las empresas)

```
# CAR acumulado por evento — "La Gráfica"
ar_mean = ar_df.groupby(['evento', 'time_to_event'])['AR'].mean().reset_index()
ar_mean = ar_mean.sort_values(['evento', 'time_to_event'])
ar_mean['CAR'] = ar_mean.groupby('evento')['AR'].cumsum()

estilos = {
    'Invasion_Ucrania': {'color': '#e63946', 'lw': 2.5},
    'Israel_Gaza':      {'color': '#457b9d', 'lw': 1.8},
```

```
    'Captura_Maduro':   {'color': '#2a9d8f', 'lw': 1.8},
    'Anexion_Crimea':   {'color': '#e9c46a', 'lw': 1.8},
    'Guerra_Georgia':   {'color': '#a8a8a8', 'lw': 1.5},
}

fig, ax = plt.subplots(figsize=(12, 6))

for evento, style in estilos.items():
    sub = ar_mean[ar_mean['evento'] == evento].sort_values('time_to_event')
    ax.plot(sub['time_to_event'], sub['CAR'],
            label=evento, color=style['color'],
            linewidth=style['lw'], marker='o', markersize=3)

ax.axvspan(-1, 1, alpha=0.08, color='black')
ax.axhline(0, color='black', linewidth=0.6)
ax.axvline(0, color='black', linestyle='--', linewidth=1)
ax.set_xlabel('Tiempo relativo al evento (días de trading)')
ax.set_ylabel('CAR medio')
ax.set_title('Retorno anormal acumulado medio por evento (CAR)', fontweight='bold')
ax.yaxis.set_major_formatter(plt.FuncFormatter(lambda y, _: f'{y:.1%}'))
ax.legend(fontsize=8, loc='upper left')
plt.tight_layout()
plt.show()
```

7.3. AR por grupo (Pure Play vs Defense Tech)

```
# AR medio por evento, grupo y time_to_event
ar_group = ar_df.groupby(['evento', 'group', 'time_to_event'])['AR'].mean().reset_index()

colores = {'Pure Play': '#e63946', 'Defense Tech': '#457b9d'}
eventos = sorted(ar_group['evento'].unique())

fig, axes = plt.subplots(1, len(eventos), figsize=(5 * len(eventos), 5), sharey=True)

for i, evento in enumerate(eventos):
    ax = axes[i]
    for grupo in ['Pure Play', 'Defense Tech']:
        sub = ar_group[(ar_group['evento'] == evento) &
                       (ar_group['group'] == grupo)].sort_values('time_to_event')
        ax.plot(sub['time_to_event'], sub['AR'],
                label=grupo, color=colores[grupo],
                linewidth=1.8, marker='o', markersize=3)
    ax.axhline(0, color='black', linewidth=0.5)
    ax.axvline(0, color='black', linestyle='--', linewidth=1)
    ax.set_title(evento, fontsize=9)
    ax.set_xlabel('t')
    if i == 0:
        ax.set_ylabel('AR medio')
    ax.yaxis.set_major_formatter(plt.FuncFormatter(lambda y, _: f'{y:.1%}'))
    ax.legend(fontsize=7)
```

```
plt.suptitle('AR medio: Pure Play vs Defense Tech', fontsize=12, fontweight='bold')
plt.tight_layout()
plt.show()
```

7.4. CAR acumulado por grupo (Pure Play vs Defense Tech)

```
# CAR acumulado por evento, grupo y time_to_event
ar_group = ar_df.groupby(['evento', 'group', 'time_to_event'])['AR'].mean().reset_index()
ar_group = ar_group.sort_values(['evento', 'group', 'time_to_event'])
ar_group['CAR'] = ar_group.groupby(['evento', 'group'])['AR'].cumsum()

colores = {'Pure Play': '#e63946', 'Defense Tech': '#457b9d'}
eventos = sorted(ar_group['evento'].unique())

fig, axes = plt.subplots(1, len(eventos), figsize=(5 * len(eventos), 5), sharey=True)

for i, evento in enumerate(eventos):
    ax = axes[i]
    for grupo in ['Pure Play', 'Defense Tech']:
        sub = ar_group[(ar_group['evento'] == evento) &
                       (ar_group['group'] == grupo)].sort_values('time_to_event')
        ax.plot(sub['time_to_event'], sub['CAR'],
                label=grupo, color=colores[grupo],
                linewidth=1.8, marker='o', markersize=3)
    ax.axvspan(-1, 1, alpha=0.08, color='black')
    ax.axhline(0, color='black', linewidth=0.5)
    ax.axvline(0, color='black', linestyle='--', linewidth=1)
    ax.set_title(evento, fontsize=9)
    ax.set_xlabel('t')
    if i == 0:
        ax.set_ylabel('CAR medio')
    ax.yaxis.set_major_formatter(plt.FuncFormatter(lambda y, _: f'{y:.1%}'))
    ax.legend(fontsize=7)

plt.suptitle('CAR acumulado: Pure Play vs Defense Tech', fontsize=12, fontweight='bold')
plt.tight_layout()
plt.show()
```

7.5. SAR medio por evento

```
# SAR medio por evento y time_to_event
sar_mean = ar_df.groupby(['evento', 'time_to_event'])['SAR'].mean().reset_index()

fig, ax = plt.subplots(figsize=(12, 6))

for evento, style in estilos.items():
    sub = sar_mean[sar_mean['evento'] == evento].sort_values('time_to_event')
    ax.plot(sub['time_to_event'], sub['SAR'],
            label=evento, color=style['color'],
            linewidth=style['lw'], marker='o', markersize=3)

ax.axhline(0, color='black', linewidth=0.6)
```

```
ax.axvline(0, color='black', linestyle='--', linewidth=1)
ax.set_xlabel('Tiempo relativo al evento (días de trading)')
ax.set_ylabel('SAR medio')
ax.set_title('Retorno anormal estandarizado medio por evento (SAR)', fontweight='bold')
ax.legend(fontsize=8, loc='upper left')
plt.tight_layout()
plt.show()
```

7.6. SAR acumulado por evento

```
sar_mean = ar_df.groupby(['evento', 'time_to_event'])['SAR'].mean().reset_index()
sar_mean = sar_mean.sort_values(['evento', 'time_to_event'])
sar_mean['SAR_cum'] = sar_mean.groupby('evento')['SAR'].cumsum()

fig, ax = plt.subplots(figsize=(12, 6))

for evento, style in estilos.items():
    sub = sar_mean[sar_mean['evento'] == evento].sort_values('time_to_event')
    ax.plot(sub['time_to_event'], sub['SAR_cum'],
            label=evento, color=style['color'],
            linewidth=style['lw'], marker='o', markersize=3)

ax.axvspan(-1, 1, alpha=0.08, color='black')
ax.axhline(0, color='black', linewidth=0.6)
ax.axvline(0, color='black', linestyle='--', linewidth=1)
ax.set_xlabel('Tiempo relativo al evento (días de trading)')
ax.set_ylabel('SAR acumulado')
ax.set_title('SAR acumulado por evento', fontweight='bold')
ax.legend(fontsize=8, loc='upper left')
plt.tight_layout()
plt.show()
```

7.7. SAR por grupo Pure Play vs Defense Tech

```
# SAR medio por evento, grupo y time_to_event
sar_group = ar_df.groupby(['evento', 'group', 'time_to_event'])['SAR'].mean().reset_index()

colores = {'Pure Play': '#e63946', 'Defense Tech': '#457b9d'}
eventos = sorted(sar_group['evento'].unique())

fig, axes = plt.subplots(1, len(eventos), figsize=(5 * len(eventos), 5), sharey=True)

for i, evento in enumerate(eventos):
    ax = axes[i]
    for grupo in ['Pure Play', 'Defense Tech']:
        sub = sar_group[(sar_group['evento'] == evento) &
                        (sar_group['group'] == grupo)].sort_values('time_to_event')
        ax.plot(sub['time_to_event'], sub['SAR'],
                label=grupo, color=colores[grupo],
                linewidth=1.8, marker='o', markersize=3)
    ax.axhline(0, color='black', linewidth=0.5)
    ax.axvline(0, color='black', linestyle='--', linewidth=1)
```

```
    ax.set_title(evento, fontsize=9)
    ax.set_xlabel('t')
    if i == 0:
        ax.set_ylabel('SAR medio')
    ax.legend(fontsize=7)

plt.suptitle('SAR medio: Pure Play vs Defense Tech', fontsize=12, fontweight='bold')
plt.tight_layout()
plt.show()
```

7.8. SAR acumulado por grupo Pure Play vs Defense Tech

```
# SAR acumulado por evento, grupo y time_to_event
sar_group = ar_df.groupby(['evento', 'group', 'time_to_event'])['SAR'].mean().reset_index()
sar_group = sar_group.sort_values(['evento', 'group', 'time_to_event'])
sar_group['SAR_cum'] = sar_group.groupby(['evento', 'group'])['SAR'].cumsum()

colores = {'Pure Play': '#e63946', 'Defense Tech': '#457b9d'}
eventos = sorted(sar_group['evento'].unique())

fig, axes = plt.subplots(1, len(eventos), figsize=(5 * len(eventos), 5), sharey=True)

for i, evento in enumerate(eventos):
    ax = axes[i]
    for grupo in ['Pure Play', 'Defense Tech']:
        sub = sar_group[(sar_group['evento'] == evento) &
                        (sar_group['group'] == grupo)].sort_values('time_to_event')
        ax.plot(sub['time_to_event'], sub['SAR_cum'],
                label=grupo, color=colores[grupo],
                linewidth=1.8, marker='o', markersize=3)
    ax.axvspan(-1, 1, alpha=0.08, color='black')
    ax.axhline(0, color='black', linewidth=0.5)
    ax.axvline(0, color='black', linestyle='--', linewidth=1)
    ax.set_title(evento, fontsize=9)
    ax.set_xlabel('t')
    if i == 0:
        ax.set_ylabel('SAR acumulado')
    ax.legend(fontsize=7)

plt.suptitle('SAR acumulado: Pure Play vs Defense Tech', fontsize=12, fontweight='bold')
plt.tight_layout()
plt.show()
```

**Anexo C.** Código de Python. Panel DiD

```
pip install linearmodels
```

```
OLS_CONSTANT = False
OLS_FIXED_EFFECTS_ENTITY = True
OLS_FIXED_EFFECTS_TIME = True
```

```
DATA_FILE = 'DATA_BA.xlsx'
```

```
MARKET_FILE = 'MARKET_BA.xlsx'
EVENTS_FILE = 'EVENTS_BA.xlsx'
```

1. Read data

```
# Cargamos empresas y calculamos retornos
data = pd.read_excel(DATA_FILE)
data['date'] = pd.to_datetime(data['date'])
data = data.dropna(subset=['tr_gross_usd'])
data = data.sort_values(['ticker', 'date'])
data['Metric'] = data.groupby('ticker')['tr_gross_usd'].pct_change()

# Añadimos MSCI World (grupo de control)
mkt = pd.read_excel(MARKET_FILE)
mkt['date'] = pd.to_datetime(mkt['date'])
mkt = mkt.sort_values('date')
mkt['Metric'] = mkt['msci_world (990100)'].pct_change()
mkt['ticker'] = 'MSCI_WORLD'

# Unimos
data = pd.concat([
    data[['date', 'ticker', 'Metric']],
    mkt[['date', 'ticker', 'Metric']]
]).reset_index(drop=True)
data
```

Show data ranges per entity.

```
df = data.dropna()
df[['ticker', 'date']].groupby('ticker').agg(['min', 'max'])
```

```
events = pd.read_excel(EVENTS_FILE)
events = events.rename(columns={'Compañía': 'ticker', 'Fecha': 'EventDate'})
events['EventDate'] = pd.to_datetime(events['EventDate'])

# Añadimos MSCI World sin fecha de evento (grupo de control)
control = pd.DataFrame({'ticker': ['MSCI_WORLD'], 'EventDate': [pd.NaT], 'Evento': ['Control']})
events = pd.concat([events, control]).reset_index(drop=True)
events
```

```
check_control_group = events[events['EventDate'].isna()]

if check_control_group.empty:
    print("WARNING: No control group found!")
```

```
data = pd.merge(data, events, on='ticker')
data
```

```
# Listas de grupos
pure_Play = ['RTX-US', 'LDO-IT', 'SAAB.B-SE', '012450-KR', 'CW-US', 'S63-SG',
    'HII-US', '064350-KR', 'AM-FR', '047810-KR', 'R3NK-DE', 'MOG.A-US',
```

```
    'AVIO-IT', 'LMT-US', 'NOC-US', 'BA-GB', 'GD-US', 'RHM-DE',
    'BWXT-US', 'BAB-GB', 'KRMN-US', 'SRP-GB',
    '541154-IN', 'CHG-GB', 'TDG-US', '541143-IN', '543237-IN', 'LBW-PL', '010820-KR']

defense_tech = ['HO-FR', 'PLTR-US', 'ESLT-IL', 'LDOS-US', 'KTOS-US', 'CACI-US',
    'BAH-US', 'AVAV-US', 'HAG-DE', 'PL-US', 'NXSN-IL', '272210-KR',
    'SAIC-US', 'PSN-US', 'ONDS-US', 'KBR-US', 'AMTM-US', 'MRCY-US',
    'DRS-US', 'QQ-GB', 'OSIS-US', 'BBAI-US', 'LHX-US',
    'CAE-US', 'IDR-ES', 'KOG-NO',
    '500049-IN', 'DCO-US', 'VVX-US', '079550-KR', '065450-KR', '005870-KR',
    '533339-IN', 'ASELS.E-TR', '543428-IN']

# Cambiar aquí entre pure_Play y defense_tech
data = data[data['ticker'].isin(pure_Play + ['MSCI_WORLD'])].copy()
```

2. Calculate "time to event"

```
if NATURAL_DAY_DIFF:
    data['TimeToEvent'] = data['date'] - data['EventDate']
    data['TimeToEvent'] = data['TimeToEvent'].dt.days

else: # workdays
    valid_rows = data[['date', 'EventDate']].notna().all(axis=1)
    data.loc[valid_rows, 'TimeToEvent'] = data[valid_rows].apply(lambda row:
np.busday_count(row['EventDate'].date(), row['date'].date()), axis=1)
```

```
# retain only observations within the window (treated group) or with no event date (control group)
data = data[ (data['TimeToEvent'].between(PRE_WINDOW, POST_WINDOW)) |
(data['TimeToEvent'].isna())].copy()
```

```
# clip time to event to the event range
data['TimeToEvent'] = data['TimeToEvent'].clip(PRE_EVENT, POST_EVENT)
```

```
df = data[['TimeToEvent', 'Metric']].groupby('TimeToEvent').mean()
px.line(
    x=df.index,
    y=df['Metric'],
    title='Average Metric by Time to Event',
    labels={'x':'Time to Event', 'y':'Average Metric'})
```

```
df = data[['TimeToEvent', 'Metric']].groupby('TimeToEvent').count()
px.bar(
    x=df.index,
    y=df['Metric'],
    title='Number of Observations by Time to Event',
    labels={'x':'Time to Event', 'y':'Number of Observations'})
```

3. Prepare the OLS panel

```
dummies = pd.get_dummies(data['TimeToEvent']).astype(int)
data = data.join(dummies)
data = data.set_index(['ticker', 'date'])
data
```

4. Solve fixed-effects panel

```
data = data.dropna(subset=['Metric'])

dependent = data['Metric']
exog = data.drop(columns=['Metric', BASELINE_LAG, 'EventDate', 'TimeToEvent', 'Evento'])

if OLS_CONSTANT:
    exog['const'] = 1.0

fe_model = PanelOLS(
    dependent,
    exog,
    time_effects=OLS_FIXED_EFFECTS_TIME,
    entity_effects=OLS_FIXED_EFFECTS_ENTITY,
    drop_absorbed=False,
    check_rank=True)

fe_result = fe_model.fit(cov_type='robust')

print(fe_result)
fe_result.estimated_effects
```

5. Plot the event

```
result = fe_result

# get confidence interval for given level
alpha = 0.05
solution = result.conf_int(level = 1 - alpha)

# calculate middle of interval (the actual values)
solution['value'] = solution.mean(axis=1)
solution.loc[BASELINE_LAG, 'value'] = 0.0
solution.loc[BASELINE_LAG, 'upper'] = 0.0
solution.loc[BASELINE_LAG, 'lower'] = 0.0

# add constant ??
if 'const' in result.params:
    #solution = solution + result.params['const']
    solution = solution.drop(index=['const'])

solution = solution.sort_index()
```

solution

```
def plotly_event_study(data, baseline, plot_ends, title, filename=None):

    fig = go.Figure()

    # Add a horizontal line at y=0 (or any other y-value you need)
    fig.add_hline(y=0, line={'dash': 'solid', 'width': 1, 'color': 'red'})
    fig.add_vline(x=0, line={'dash': 'solid', 'width': 1, 'color': 'gray'})
    if baseline != 0:
        fig.add_vline(x=baseline, line={'dash': 'dot', 'width': 1, 'color': 'gray'})

    if plot_ends:
        left_end = data.iloc[:1]
        right_end = data.iloc[-1:]
        data = data.iloc[1:-1]

    # point estimate and error bars of left accumulation
    fig.add_trace(
        go.Scatter(
            x=left_end.index,  # or another column if your DataFrame has a specific column for the x-axis
            y=left_end['value'],
            error_y=dict(
                type='data',  # indicates that the values for the error bars are given explicitly
                symmetric=False,  # indicates that the error bars are not symmetric
                array=left_end['upper'] - left_end['value'],
                # specifies the length of the portion of the error bar above the value
                arrayminus=left_end['value'] - left_end['lower'],
                # specifies the length of the portion of the error bar below the value
                color='gray',
                thickness=2,
                width=4
            ),
            name='left accum: point estimate & error bars',
            marker=dict(
                color='gray',
                size=5
                # symbol='diamond'
            ),
            mode='markers')  # you can change to 'lines' or 'lines+markers' if that's more appropriate for your data
    )

    # point estimate and error bars of right accumulation
    fig.add_trace(
        go.Scatter(
            x=right_end.index,  # or another column if your DataFrame has a specific column for the x-axis
            y=right_end['value'],
            error_y=dict(
                type='data',  # indicates that the values for the error bars are given explicitly
```

```
            symmetric=False,  # indicates that the error bars are not symmetric
            array=right_end['upper'] - right_end['value'],
            # specifies the length of the portion of the error bar above the value
            arrayminus=right_end['value'] - right_end['lower'],
            # specifies the length of the portion of the error bar below the value
            color='gray',
            thickness=2,
            width=4
        ),
        name='right accum: point estimate & error bars',
        marker=dict(
            color='gray',
            size=5
            # symbol='diamond'
        ),
        mode='markers')  # you can change to 'lines' or 'lines+markers' if that's more appropriate for your data
)

# Upper Bound
fig.add_trace(
    go.Scatter(x=data.index,
               y=data['upper'],
               line_color='lightgray',
               line={'dash': 'dot', 'width': 1},
               name='CI upper band',
               mode='lines',
               opacity=0.15)
)

# Lower Bound fill in between with parameter 'fill': 'tonexty'
fig.add_trace(
    go.Scatter(x=data.index,
               y=data['lower'],
               line_color='lightgray',
               line={'dash': 'dot', 'width': 1},
               fill='tonexty',
               name='CI lower band',
               mode='lines',
               opacity=0.15)
)

# event point estimate and error bars
fig.add_trace(
    go.Scatter(
        x=data.index,  # or another column if your DataFrame has a specific column for the x-axis
        y=data['value'],
        error_y=dict(
            type='data',  # indicates that the values for the error bars are given explicitly
            symmetric=False,  # indicates that the error bars are not symmetric
            array=data['upper'] - data['value'],
```

```
            # specifies the length of the portion of the error bar above the value
            arrayminus=data['value'] - data['lower'],
            # specifies the length of the portion of the error bar below the value
            color='darkgray',
            thickness=1,
            width=3
        ),
        name='event: point estimate & error bars',
        marker=dict(
            color='darkgray',
            size=5
            # symbol='diamond'
        ),
        mode='markers')  # you can change to 'lines' or 'lines+markers' if that's more appropriate for your data
)

#fig.update_xaxes(
#    dtick=steps_year
#)

# use percentages in axes
fig.update_layout(
    width=1200,
    height=600,
    title=title,
    xaxis_title='event time',
    yaxis_title=r'effect',
    yaxis_tickformat = '.2%'
)

fig.show()

if filename:
    fig.write_image(filename)
```

```
plotly_event_study(solution, BASELINE_LAG, (PRE_EVENT, POST_EVENT), 'Event Study')
```

6. Cumulative effect

```
effect = solution['value']
accum = effect.cumsum()
accum = accum - accum.loc[BASELINE_LAG]
accum = accum.loc[ PRE_EVENT : POST_EVENT ]

fig = go.Figure()

# Add a horizontal line at y=0 (or any other y-value you need)
fig.add_hline(y=0, line={'dash': 'solid', 'width': 1, 'color': 'red'})
fig.add_vline(x=0, line={'dash': 'solid', 'width': 1, 'color': 'gray'})
fig.add_vline(x=BASELINE_LAG, line={'dash': 'dot', 'width': 1, 'color': 'gray'})
```

```
fig.add_trace(
    go.Scatter(
        x=accum.index,
        y=accum,
        mode='lines+markers',
        name='Cumulative Effect',
        line=dict(color='darkgray', width=2),
        marker=dict(size=6, color='darkgray'),
    )
)

# use percentages in axes
fig.update_layout(
    width=1200,
    height=600,
    title='Cumulative effect',
    xaxis_title='event time',
    yaxis_title='effect',
    yaxis_tickformat = '.2%'
)

fig.show()
```