



MÁSTER EN INGENIERÍA INDUSTRIAL

TRABAJO FIN DE MÁSTER
ANTICIPANDO EL MERCADO: MATEMÁTICAS DE UN
ALGORITMO PREVISOR

Autor: Álvaro Guibelalde Rodríguez

Director: Miguel Zaballa Pardo

Madrid

Julio de 2026

Declaro, bajo mi responsabilidad, que el Proyecto presentado con el título
Anticipando El Mercado: Matemáticas De Un Algoritmo Previsor
en la ETS de Ingeniería - ICAI de la Universidad Pontificia Comillas en el
curso académico 2025/26 es de mi autoría, original e inédito y
no ha sido presentado con anterioridad a otros efectos.

El Proyecto no es plagio de otro, ni total ni parcialmente y la información que ha sido
tomada de otros documentos está debidamente referenciada.

Fdo.: Álvaro Guibelalde

Fecha: 07/ 07/ 2026



Autorizada la entrega del proyecto

EL DIRECTOR DEL PROYECTO

Fdo.: Miguel Zaballa Pardo

Fecha: 07/ 07/ 2026



MÁSTER EN INGENIERÍA INDUSTRIAL

TRABAJO FIN DE MÁSTER
ANTICIPANDO EL MERCADO: MATEMÁTICAS DE UN
ALGORITMO PREVISOR

Autor: Álvaro Guibelalde Rodríguez

Director: Miguel Zaballa Pardo

Madrid

Julio de 2026

ANTICIPANDO EL MERCADO: MATEMÁTICAS DE UN ALGORITMO

PREVISOR

Autor: Álvaro Guibelalde Rodríguez.

Director: Miguel Zaballa Pardo.

Entidad colaboradora: ICAI - Universidad Pontificia Comillas.

RESUMEN DEL PROYECTO

Este Trabajo Fin de Máster estudia la incorporación de estimadores de drift a un algoritmo de market making basado en Avellaneda-Stoikov mediante un banco de pruebas sintético y controlado. La pregunta central no es si un filtro más complejo gana siempre, sino cuándo una señal estadística puede monetizarse después de ejecución, inventario, costes y control de quotes obsoletas.

La evidencia se obtiene con 50 semillas reproducibles, escenarios con drift latente conocido, ejecución pasiva corregida, controles de señal invertida, ausencia de comisiones, sensibilidad de Q , sensibilidad de τ , proxy OFI y validación walk-forward. El resultado principal es deliberadamente prudente: la agregación temporal mejora la relación señal-ruido, pero no garantiza PnL neto positivo si el motor de cotización genera quotes cruzadas, stale quotes o fills adversos.

Arquitectura experimental del nuevo TFM



Arquitectura del pipeline de experimentación.

INTRODUCCIÓN

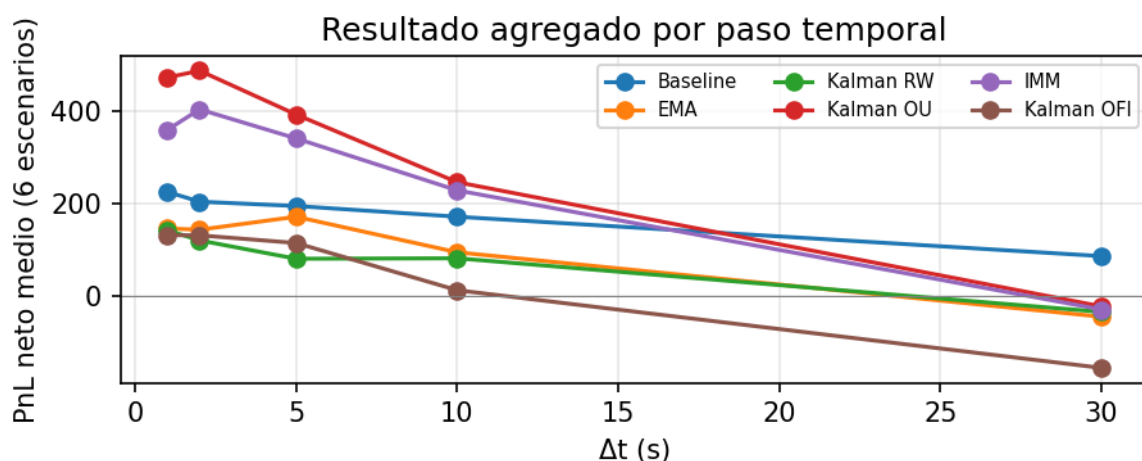
El market maker proporciona liquidez colocando simultáneamente órdenes de compra y venta. Su beneficio esperado procede de capturar el spread, pero queda expuesto al riesgo de inventario y a la posibilidad de que agentes mejor informados ejecuten sus quotes en momentos desfavorables. La hipótesis natural es que una estimación del drift del precio puede desplazar el precio de reserva y reducir esa selección adversa. Sin embargo, en escalas de alta frecuencia, la componente de drift es pequeña frente al ruido microestructural.

DEFINICIÓN DEL PROYECTO

El proyecto desarrolla un banco de pruebas reproducible con datos sintéticos controlados y escenarios de mercado diseñados para aislar la contribución de cada mecanismo. Se comparan modelos sin drift, suavizados EMA, filtros de Kalman con caminata aleatoria, filtros con reversión a la media, modelos IMM de cambio de régimen y una extensión con Order Flow Imbalance. Cada modelo se evalúa bajo varios valores de Δt y con controles específicos: sin comisiones, drift invertido y validación walk-forward.

DESCRIPCIÓN DEL SISTEMA

El sistema está formado por cuatro bloques: generación de datos, estimación de drift, cálculo de quotes y evaluación. El generador produce escenarios con drift conocido, ruido gaussiano, cambios de régimen y rebote bid-ask. Los estimadores procesan observaciones secuenciales y devuelven una estimación $\hat{\mu}$. El motor de Avellaneda-Stoikov calcula reservation price y spread. Finalmente, el módulo de evaluación separa PnL bruto, comisiones, PnL neto, fill rate, inventario, drawdown, quote crossing, rechazos por límite y precisión direccional.



Resultado agregado por paso temporal en todos los escenarios.

RESULTADOS

En el promedio de escenarios sintéticos corregidos y con horizonte de riesgo $\tau = 60$ s, el Kalman RW pasa de 142.2 unidades monetarias sintéticas a $\Delta t = 1$ s a -35.0 a $\Delta t = 30$ s; en microestructura pasa de 191.8 a 80.8. Con τ más corto el deterioro se atenúa, de modo que la cifra describe una configuración concreta y no una ley general. La SNR limpia a 30s es 0.581, inferior a 1: la señal queda menos enterrada en ruido, pero sigue siendo débil frente a la volatilidad del bloque. Parte de esa mejora procede de que el rebote bid-ask sintético es una alternancia determinista que la agregación con Δt par elimina por completo, un matiz que el capítulo de resultados desarrolla.

CONCLUSIONES

La conclusión defendible es metodológica y operativa: estimar drift puede aportar información, pero su valor desaparece si la señal desplaza las quotes hacia ejecuciones adversas. Por eso el cuello de botella del sistema está menos en elegir entre RW, OU, IMM u OFI y más en controlar quote crossing, horizonte τ , calibración Q, inventario y realismo de ejecución.

Palabras clave: market making; filtro de Kalman; microestructura de mercado; Avellaneda-Stoikov; estimación de drift; riesgo de ejecución; backtesting sintético.

ANTICIPATING THE MARKET: THE MATHEMATICS OF A FORECASTING ALGORITHM

Author: Álvaro Guibelalde Rodríguez.

Advisor: Miguel Zaballa Pardo.

Collaborating Institution: ICAI - Comillas Pontifical University.

PROJECT ABSTRACT

This Master's Thesis examines the incorporation of drift estimators into an Avellaneda-Stoikov-based market-making algorithm using a synthetic and controlled test bed. The central question is not whether a more complex filter always outperforms, but rather when a statistical signal can be monetized after accounting for execution, inventory, costs, and the management of obsolete quotes.

Evidence is obtained using 50 reproducible seeds, scenarios with known latent drift, corrected passive execution, inverted signal controls, no commissions, Q sensitivity, τ sensitivity, an OFI proxy, and walk-forward validation. The main result is deliberately conservative: temporal aggregation improves the signal-to-noise ratio, but does not guarantee positive net PnL if the quote engine generates cross quotes, stale quotes, or adverse fills.

Arquitectura experimental del nuevo TFM



Experimentation pipeline architecture.

INTRODUCTION


The market maker provides liquidity by simultaneously placing buy and sell orders. Its expected profit comes from capturing the spread, but it is exposed to inventory risk and the possibility that better-informed agents will execute its quotes at unfavorable times. The natural hypothesis is that an estimate of price drift can shift the reserve price and reduce this adverse selection. However, at high-frequency scales, the drift component is small compared to microstructural noise.

PROJECT DEFINITION

The project develops a reproducible test bed with controlled synthetic data and market scenarios designed to isolate the contribution of each mechanism. Models without drift, EMA-smoothed models, Kalman filters with random walks, mean-reverting filters, IMM regime-switching models, and an extension with Order Flow Imbalance are compared. Each model is evaluated under various values of Δt and with specific controls: no commissions, inverted drift, and walk-forward validation.

SYSTEM DESCRIPTION

The system consists of four blocks: data generation, drift estimation, quote calculation, and evaluation. The generator produces scenarios with known drift, Gaussian noise, regime shifts, and bid-ask bounce. The estimators process sequential observations and return an estimate $\hat{\alpha}$. The Avellaneda-Stoikov engine calculates the reservation price and spread. Finally, the evaluation module separates gross PnL, commissions, net PnL, fill rate, inventory, drawdown, quote crossing, limit-based rejections, and directional accuracy.



Aggregated results by time step across all scenarios.

RESULTS

On average across corrected synthetic scenarios with a risk horizon of $\tau = 60$ s, the Kalman RW declines from 142.2 synthetic monetary units at $\Delta t = 1$ s to -35.0 at $\Delta t = 30$ s; in microstructure, it declines from 191.8 to 80.8. With a shorter τ , the deterioration is mitigated, so the figure describes a specific configuration rather than a general rule. The clean SNR at 30 s is 0.581, which is less than 1: the signal is less buried in noise, but it remains weak relative to the block's volatility. Part of this improvement stems from the fact that the synthetic bid-ask bounce is a deterministic alternation that aggregation with an even Δt completely eliminates—a nuance discussed in the results chapter.

CONCLUSIONS

The defensible conclusion is both methodological and operational: estimating drift can provide information, but its value disappears if the signal shifts quotes toward adverse executions. Therefore, the system's bottleneck lies less in choosing between RW, OU, IMM, or OFI and more in controlling quote crossing, the τ horizon, Q calibration, inventory, and execution realism.

Keywords: market making; Kalman filter; market microstructure; Avellaneda-Stoikov; drift estimation; execution risk; synthetic backtesting.

ÍNDICE DE LA MEMORIA

<i>Anticipando el mercado: matemáticas de un algoritmo previsor.....</i>	<i>4</i>
RESUMEN DEL PROYECTO	4
Introducción.....	5
Definición del proyecto	5
Descripción del sistema	5
Resultados.....	6
Conclusiones.....	6
ANTICIPATING THE MARKET: THE MATHEMATICS OF A FORECASTING ALGORITHM	
7	
PROJECT ABSTRACT	7
INTRODUCTION	8
PROJECT DEFINITION	8
SYSTEM DESCRIPTION	8
RESULTS	9
CONCLUSIONS	9
<i>Índice de la memoria.....</i>	<i>10</i>
<i>Índice de figuras.....</i>	<i>13</i>
<i>Índice de ecuaciones.....</i>	<i>14</i>
<i>Índice de tablas.....</i>	<i>15</i>
Capítulo 1. Introducción.....	16
1.1 Motivación del proyecto	16
1.2 Problema de investigación	16
1.3 Objetivos	17
1.4 Estructura de la memoria	17
Capítulo 2. Descripción de las Tecnologías	18
2.1 Herramientas y entorno de trabajo	18
2.2 Microestructura y libro de órdenes límite	18
2.3 Modelo de Avellaneda-Stoikov.....	19
2.4 Filtro de Kalman aplicado al drift	19
2.5 Modelo IMM de cambio de régimen.....	21
2.6 Máxima verosimilitud para Q	21

2.7	Desarrollo detallado de conceptos técnicos	23
2.7.1	<i>Lectura operativa de Q y R</i>	23
2.7.2	<i>Innovación y ganancia</i>	23
2.7.3	<i>Reversión OU y regímenes</i>	23
2.7.4	<i>Order Flow Imbalance</i>	24
Capítulo 3. Estado de la Cuestión.....		25
3.1	Avellaneda-Stoikov y extensiones	25
3.2	Cartea y Jaimungal frente a este TFM	25
3.3	Limitaciones de la ecuación HJB con régimen	26
3.4	Filtrado de estados latentes y regímenes en finanzas	26
3.5	Hueco que cubre el trabajo.....	27
Capítulo 4. Definición del Trabajo.....		28
4.1	Justificación	28
4.2	Objetivos experimentales	28
4.3	Metodología	28
4.4	Diseño experimental detallado.....	29
4.5	Planificación temporal del trabajo	30
Capítulo 5. Sistema Desarrollado.....		32
5.1	Análisis del Sistema	32
5.2	Diseño	33
5.3	Implementación.....	33
5.4	Métricas.....	34
5.5	Detalles de implementación y flujo de datos	35
5.5.1	<i>Generación de datos y resampling</i>	35
5.5.2	<i>Estado financiero, inventario y volatilidad</i>	35
5.5.3	<i>Reproducibilidad y trazabilidad</i>	36
5.6	Validación del motor de ejecución.....	36
Capítulo 6. Análisis de Resultados		39
6.1	Escala temporal y relación señal-ruido	39
6.2	Sensibilidad a Δt	40
6.3	Comisiones y PnL bruto.....	43
6.4	Drift invertido y ausencia de comisiones	44
6.5	Fill rate y saturación.....	45
6.6	Lectura operativa de la simulación	46
6.7	Sensibilidad de Q, τ y proxy OFI.....	46
6.8	Riesgo, inventario y valor económico de la señal	47

6.8.1 Cuando acertar dirección no basta.....	48
6.9 Sensibilidad de parámetros de mercado	50
6.10 Validación walk-forward	51
6.11 Resumen de métricas y trazabilidad.....	52
6.12 Interpretación de los mecanismos	54
6.12.1 Baseline y benchmarks simples	54
6.12.2 Modelos Kalman, OU e IMM.....	54
6.12.3 El contraste RW-OU como mecanismo.....	55
6.12.4 OFI y accuracy.....	55
6.12.5 Ejecución, inventario y coste económico	55
6.13 Matriz de riesgos interpretativos	56
Capítulo 7. Conclusiones y Trabajos Futuros	58
7.1 Discusión de alcance	58
7.1.1 Simulación frente a producción	58
7.2 Líneas futuras.....	59
7.2.1 Operativas.....	59
7.2.2 Académicas	59
Bibliografía 60	

ÍNDICE DE FIGURAS

Figura 1. Perfil de máxima verosimilitud para Q en el escenario de microestructura

Figura 2. Arquitectura del pipeline de experimentación

Figura 3. SNR y autocorrelación por escala temporal

Figura 4. Sensibilidad del PnL neto al paso temporal en microestructura

Figura 5. Resultado agregado por paso temporal en todos los escenarios

Figura 6. Descomposición entre PnL bruto, comisiones y PnL neto

Figura 7. Controles sin comisiones y drift invertido

Figura 8. Fill rate por paso temporal

Figura 9. Validación walk-forward frente a backtest estático

Figura 10. Métricas principales a $\Delta t = 1s$

ÍNDICE DE ECUACIONES

Ecuaciones (1)-(2): planteamiento del problema y control de señal invertida.

Ecuaciones (3)-(5): microestructura, midprice, retorno agregado y autocorrelación.

Ecuaciones (6)-(11): Avellaneda-Stoikov, utilidad, intensidades, reservation price y spread.

Ecuaciones (12)-(18): filtro de Kalman RW y discretización OU.

Ecuaciones (19)-(23): IMM, mezcla de regímenes, verosimilitud y estimación combinada.

Ecuaciones (24)-(25): máxima verosimilitud para Q.

Ecuaciones (26)-(28): separación estimación-control y HJB con regímenes como motivación.

Ecuaciones (29)-(31): generador sintético de precios y proxy OFI.

Ecuaciones (32)-(36): mecánica del backtest, fills, inventario, cash y comisiones.

Ecuaciones (37)-(41): métricas de ejecución, precisión y SNR.

Ecuaciones (42)-(47): autocorrelación, costes, controles y walk-forward.

ÍNDICE DE TABLAS

- Tabla 1. Parámetros numéricos de los escenarios sintéticos
- Tabla 2. Planificación temporal estimada del trabajo
- Tabla 3. Cronograma del trabajo
- Tabla 4. Modelos comparados en la implementación
- Tabla 5. Comparación de motores de ejecución: legacy, corregida y dual fill (12 semillas)
- Tabla 6. Alcance estadístico de las evidencias usadas en resultados
- Tabla 7. Diagnóstico SNR y autocorrelación en microestructura (media de 50 semillas)
- Tabla 8. Descomposición del rebote bid-ask observado frente al precio eficiente (media de 50 semillas)
- Tabla 9. Sensibilidad agregada a Δt con IC95
- Tabla 10. Separación entre escala de estimación y exposición
- Tabla 11. Control multiescala: estimación lenta con recotización a 1s
- Tabla 12. Diferencias pareadas por semilla en las comparaciones afirmadas
- Tabla 13. Sensibilidad Q fijo frente a Q MLE
- Tabla 14. Sensibilidad del horizonte τ
- Tabla 15. Controles de fuga del proxy OFI
- Tabla 16. Métricas de riesgo y ejecución en microestructura
- Tabla 17. Métricas normalizadas por fill y notional
- Tabla 18. Sensibilidad one-at-a-time de parámetros de mercado (12 semillas)
- Tabla 19. Métricas agregadas a $\Delta t = 1s$
- Tabla 20. PnL neto medio por escenario, modelo y Δt
- Tabla 21. Validación walk-forward ampliada
- Tabla 22. Síntesis causal del hallazgo de Δt
- Tabla 23. Matriz de riesgos interpretativos

Capítulo 1. INTRODUCCIÓN

1.1 MOTIVACIÓN DEL PROYECTO

La función económica de un market maker es ofrecer liquidez de forma continua. Para ello publica precios de compra y venta, asumiendo que una parte de las órdenes será ejecutada y que el diferencial entre ambos lados compensará los riesgos asumidos. Esta actividad parece sencilla en su formulación básica, pero combina tres problemas difíciles: riesgo de inventario, riesgo de selección adversa y ruido microestructural (Harris, 2003; Hasbrouck, 2007).

El modelo de Avellaneda-Stoikov proporciona una base matemática clara para decidir dónde colocar las quotes. El market maker no solo mira el precio medio actual, sino también su inventario, la volatilidad y la intensidad de llegada de órdenes. La tentación natural consiste en añadir una predicción direccional: si se espera que el precio suba, se desplaza el centro de las quotes hacia arriba; si se espera que baje, se desplaza hacia abajo.

La dificultad aparece porque el drift de corto plazo es una magnitud pequeña. En escalas de un segundo, el movimiento medio esperado suele estar enterrado bajo ruido, rebote bid-ask y cambios discretos del libro. Por ello, una estimación sofisticada puede empeorar el resultado si desplaza las quotes con confianza excesiva. Esta observación define el problema de investigación.

1.2 PROBLEMA DE INVESTIGACIÓN

El título del trabajo se interpreta en sentido diagnóstico. Anticipar el mercado no significa afirmar que el algoritmo prediga precios de forma explotable, sino estudiar cuándo una señal débil de drift puede detectarse y qué condiciones de ejecución impiden convertirla en PnL neto.

La pregunta de investigación es a qué escala temporal contiene el precio información suficiente para estimar drift y cómo se traduce esa estimación en PnL después de costes y ejecución. La respuesta exige separar predictibilidad estadística, mejora de quotes y resultado neto.

Que un modelo con drift pierda dinero no implica que el control de inversión de señal genere ganancias. La pérdida neta surge de un sistema completo: precisión direccional, inventario, fill rate, comisiones, latencia implícita y modelo de ejecución. Invertir el signo de $\hat{\alpha}$ modifica una pieza, pero no elimina las demás fuentes de pérdida.

$$PnL_{neto,k} = C_k^{neto} + q_k S_k, C_k^{neto} = C_k^{bruto} - \sum_{j \leq k} fee_j \quad (1)$$

El inventario no se resta como coste contable separado: queda marcado a mercado en $q_k S_k$ y se analiza como exposición, drawdown y penalización en el control.

$$\hat{\alpha}_t^{inv} = -\hat{\alpha}_t, r_t^{inv} = S_t + \hat{\alpha}_t \tau - q_t \gamma \sigma_t^2 \tau \quad (2)$$

El control de drift invertido modifica solo el signo de la señal; no cambia la mecánica de fills, comisiones ni riesgo de inventario.

1.3 OBJETIVOS

- Construir un pipeline reproducible que genere datos, ejecute backtests y produzca las evidencias de la memoria.
- Comparar modelos de drift bajo condiciones homogéneas y separar PnL bruto, comisiones y PnL neto.
- Medir el efecto de Δt sobre SNR, autocorrelación, fill rate e inventario.
- Incorporar controles de drift invertido, ausencia de comisiones y escenarios sintéticos para separar predictibilidad y rentabilidad neta.
- Defender el hallazgo como diagnóstico sintético: la escala temporal condiciona la señal, pero la ejecución condiciona su valor económico.

1.4 ESTRUCTURA DE LA MEMORIA

La memoria se organiza en siete capítulos, la bibliografía y dos anexos. Tras esta introducción, el segundo capítulo define los modelos matemáticos; el tercero sitúa la contribución frente a la literatura; el cuarto describe metodología y escenarios; el quinto presenta el sistema implementado y la validación de su motor de ejecución; el sexto analiza resultados, controles y robustez; el séptimo recoge conclusiones y líneas futuras; la bibliografía cierra el cuerpo y los anexos documentan la reproducibilidad y la alineación con los ODS.

Capítulo 2. DESCRIPCIÓN DE LAS TECNOLOGÍAS

2.1 HERRAMIENTAS Y ENTORNO DE TRABAJO

El banco de pruebas se implementa íntegramente en Python 3 con bibliotecas de código abierto: numpy para el cálculo numérico, matplotlib para las figuras y python-docx para construir esta memoria desde la plantilla institucional. No se emplea ninguna dependencia propietaria; los resultados se materializan como ficheros CSV y las figuras como PNG con nombres estables, lo que permite auditar cada cifra sin ejecutar el código. El resto del capítulo desarrolla los fundamentos matemáticos sobre los que se apoya el sistema: microestructura, el modelo de Avellaneda-Stoikoy, el filtrado de Kalman y sus variantes.

2.2 MICROESTRUCTURA Y LIBRO DE ÓRDENES LÍMITE

Un libro de órdenes límite organiza las intenciones de compra y venta por precio y prioridad temporal (Gould et al., 2013). El mejor bid representa el precio más alto al que alguien está dispuesto a comprar y el mejor ask el precio más bajo al que alguien está dispuesto a vender. El midprice se define como el punto medio entre ambos y se usa como aproximación del precio eficiente, aunque a alta frecuencia puede contener ruido mecánico.

El rebote bid-ask, formalizado por Roll (1984), aparece cuando las transacciones alternan entre bid y ask. En ese caso, un movimiento observado al alza puede ir seguido por otro a la baja sin que exista reversión económica real. Para un estimador de drift, este patrón es peligroso: el filtro interpreta como información direccional algo que en realidad procede de la mecánica de cotización.

En la memoria se usa el término microestructura para referirse a estos efectos de granularidad: discreción del precio, alternancia bid-ask, intensidades de llegada de órdenes y ejecución condicionada a la distancia de la quote al midprice. Estos elementos son esenciales para interpretar por qué el resultado de un backtest no puede leerse como una predicción pura.

$$S_t^{mid} = \frac{P_t^{bid} + P_t^{ask}}{2}, S_t = P_t^{ask} - P_t^{bid} \quad (3)$$

El midprice resume el centro del libro y el spread observado mide la fricción inmediata entre compra y venta.

$$z_k(\Delta t) = \frac{S_k - S_{k-1}}{\Delta t}, S_k = S_{k\Delta t}^{mid} \quad (4)$$

La observación que entra en Kalman no es el precio bruto, sino el retorno por unidad de tiempo a la escala de muestreo elegida.

$$\rho_1 = \text{Corr}(\Delta S_k, \Delta S_{k-1}) < 0 \quad (5)$$

Una autocorrelación negativa a un segundo es compatible con rebote bid-ask y no implica necesariamente reversión económica explotable.

2.3 MODELO DE AVELLANEDA-STOIKOV

$$dS_t = \alpha_t dt + \sigma_t dW_t \quad (6)$$

El precio eficiente se modela localmente como un movimiento browniano con drift instantáneo α_t y volatilidad σ_t .

$$U(x) = -\exp(-\gamma x) \quad (7)$$

La aversión al riesgo γ entra mediante utilidad exponencial; penaliza resultados inciertos de forma creciente.

$$\lambda^b(\delta^b) = Ae^{-k\delta^b}, \lambda^a(\delta^a) = Ae^{-k\delta^a} \quad (8)$$

La probabilidad de ejecución cae cuando la quote se aleja del midprice; k controla la pendiente de esa caída.

$$r_t = S_t + \hat{\alpha}_t \tau - q_t \gamma \sigma_t^2 \tau \quad (9)$$

El precio de reserva desplaza el centro de las quotes por drift esperado y por penalización de inventario.

$$\delta_t^* = \gamma \sigma_t^2 \tau + \frac{2}{\gamma} \ln\left(1 + \frac{\gamma}{k}\right) \quad (10)$$

En esta memoria δ^* se interpreta como spread total; las distancias individuales al precio de reserva son $\delta^*/2$.

$$p_t^{bid} = r_t - \frac{\delta_t^*}{2}, p_t^{ask} = r_t + \frac{\delta_t^*}{2} \quad (11)$$

El drift no cambia directamente la anchura del spread; mueve el centro alrededor del cual se colocan bid y ask. P mayúscula denota en (3) los mejores precios del libro; p minúscula, las quotes propias del market maker; ϕ , la probabilidad de fill de (32).

El precio de reserva representa el punto de indiferencia del market maker. Si el inventario es positivo, el término de inventario reduce r_t para favorecer ventas y reducir exposición. Si el drift estimado es positivo, el término $\alpha_t \tau$ desplaza las quotes hacia arriba. La tensión entre ambos efectos es el núcleo del sistema.

El spread óptimo no depende directamente del signo del drift, sino de volatilidad, horizonte, aversión al riesgo y parámetro de ejecución k . En la implementación, δ^* se usa como spread total: bid = $r - \delta^*/2$ y ask = $r + \delta^*/2$. Esta convención evita confundir δ^* con las distancias unilaterales que aparecen en otras formulaciones de la literatura.

2.4 FILTRO DE KALMAN APLICADO AL DRIFT

$$\alpha_k = F\alpha_{k-1} + w_k, w_k \sim \mathcal{N}(0, Q\Delta t) \quad (12)$$

La ecuación de transición describe cómo evoluciona el drift latente entre dos observaciones; Q se define como varianza de proceso por unidad de tiempo, de modo que su efecto por paso es $Q\Delta t$, en coherencia con (14) y (18).

$$z_k = H\alpha_k + v_k, v_k \sim \mathcal{N}(0, R) \quad (13)$$

La ecuación de observación conecta el drift oculto con el retorno observado.

$$\hat{\alpha}_{k|k-1} = F\hat{\alpha}_{k-1|k-1}, P_{k|k-1} = FP_{k-1|k-1}F^T + Q\Delta t \quad (14)$$

La fase de predicción propaga estimación e incertidumbre antes de ver el nuevo retorno. La varianza de proceso se parametriza por unidad de tiempo y entra escalada por Δt , igual que en la implementación.

$$v_k = z_k - H\hat{\alpha}_{k|k-1}, \Omega_k = HP_{k|k-1}H^T + R \quad (15)$$

La innovación v_k mide la sorpresa del dato; Ω_k es su varianza predictiva. Se evita la notación S_k para no confundirla con el precio.

$$K_k = P_{k|k-1}H^T\Omega_k^{-1} \quad (16)$$

La ganancia de Kalman pondera cuánto se corrige la predicción con la nueva observación.

$$\hat{\alpha}_{k|k} = \hat{\alpha}_{k|k-1} + K_kv_k, P_{k|k} = (I - K_kH)P_{k|k-1} \quad (17)$$

La actualización produce el drift estimado que se introduce después en el reservation price.

En el Modelo Kalman RW se toma $F = 1$ y $H = 1$. La variable oculta α_k es el drift en unidades de precio por segundo. La observación z_k es el retorno escalado, calculado como $(S_k - S_{k-1})/\Delta t$. Q mide cuánto se permite mover el drift entre observaciones y R mide el ruido de la observación.

La ganancia de Kalman K_k determina cuánto peso recibe la nueva observación frente a la predicción previa. Si P es grande o R pequeño, el filtro confía más en el dato reciente. En la implementación, al observar retornos por segundo tras agregar bloques, R se escala como $R/\Delta t$ para reflejar que la varianza efectiva de una media temporal cae con la longitud del bloque, y la varianza de proceso entra como $Q\Delta t$, de forma que ambas escalas son coherentes; son hipótesis de modelado contrastadas con la sensibilidad de Q . El escalado $R/\Delta t$ es exacto para la componente difusiva, pero no para el ruido de microestructura aditivo, cuya contribución a la varianza del retorno por segundo decae como $1/\Delta t^2$; en el escenario de rebote, la especificación de R a Δt bajos es por tanto conservadora.

El Modelo OU sustituye la caminata aleatoria por una dinámica con reversión a la media. En tiempo discreto, $F = \exp(-\kappa\Delta t)$. Un κ alto fuerza al drift a volver rápidamente a cero; un κ bajo lo aproxima al random walk. Esta diferencia es importante cuando la señal direccional es transitoria.

$$F_{OU} = e^{-\kappa\Delta t}, \text{Var}(w_k) = Q\Delta t \quad (18)$$

La discretización OU usada en la implementación combina la disipación exacta del estado, $F = \exp(-\kappa\Delta t)$, con varianza de proceso $Q\Delta t$, aproximación de primer orden de la forma exacta $\eta^2/(2\kappa) \cdot (1 - \exp(-2\kappa\Delta t))$; con $\kappa = 0.055$ la diferencia deja de ser despreciable en $\Delta t = 30s$ y queda cubierta por la sensibilidad de Q .

2.5 MODELO IMM DE CAMBIO DE RÉGIMEN

El algoritmo IMM (Blom y Bar-Shalom, 1988) ejecuta varios filtros en paralelo, cada uno asociado a un régimen. En este TFM los regímenes representan comportamientos estilizados: tendencia persistente, reversión a la media y alta volatilidad. El sistema no elige un único filtro de forma irreversible, sino que mantiene probabilidades de régimen actualizadas en cada paso.

La matriz de transición Π contiene las probabilidades de pasar de un régimen i a un régimen j . Antes de observar el nuevo dato, las probabilidades se mezclan usando Π . Después, cada filtro produce una innovación y una verosimilitud. Los regímenes que explican mejor la observación aumentan su peso posterior.

La estimación final de drift es una media ponderada de las estimaciones por régimen. También se combina la incertidumbre: no basta con promediar $\hat{\alpha}$, porque la dispersión entre regímenes aporta información sobre el riesgo de modelo. Esta explicación término por término es esencial para que el IMM no parezca una caja negra.

$$c_j = \sum_i \pi_{ij} \mu_{k-1}^{(i)}, \mu_{k-1|k-1}^{(i|j)} = \frac{\pi_{ij} \mu_{k-1}^{(i)}}{c_j} \quad (19)$$

Antes de filtrar, el IMM mezcla las creencias previas según la matriz de transición entre regímenes.

$$\hat{\alpha}_{0,k}^{(j)} = \sum_i \mu_{k-1|k-1}^{(i|j)} \hat{\alpha}_{k-1}^{(i)} \quad (20)$$

Cada filtro j arranca desde una condición inicial mezclada con los regímenes que podrían haber llegado a j .

$$P_{0,k}^{(j)} = \sum_i \mu_{k-1|k-1}^{(i|j)} \left[P_{k-1}^{(i)} + \left(\hat{\alpha}_{k-1}^{(i)} - \hat{\alpha}_{0,k}^{(j)} \right)^2 \right] \quad (21)$$

La covarianza mezclada recoge tanto la incertidumbre de cada filtro como la dispersión entre hipótesis de régimen.

$$L_k^{(j)} = \frac{1}{\sqrt{2\pi\Omega_k^{(j)}}} \exp\left(-\frac{(v_k^{(j)})^2}{2\Omega_k^{(j)}}\right) \quad (22)$$

La verosimilitud escalar mide qué régimen explica mejor la observación recibida en el instante k .

$$\mu_k^{(j)} = \frac{L_k^{(j)} c_j}{\sum_\ell L_k^{(\ell)} c_\ell}, \hat{\alpha}_k = \sum_j \mu_k^{(j)} \hat{\alpha}_k^{(j)} \quad (23)$$

La estimación final de drift es la media de los filtros ponderada por probabilidades posteriores de régimen.

2.6 MÁXIMA VEROSIMILITUD PARA Q

$$\ell(Q) = -\frac{1}{2} \sum_k \left[\log(2\pi\Omega_k) + \frac{v_k^2}{\Omega_k} \right] \quad (24)$$

v_k es la innovación y Ω_k su varianza predictiva en el caso escalar.

$$\hat{Q}_{MLE} = \underset{Q}{\operatorname{argmax}} \ell(Q) \quad (25)$$

La calibración por máxima verosimilitud selecciona Q por ajuste estadístico, no por PnL.

La calibración por MLE elige el valor de Q que hace más probables las innovaciones observadas en entrenamiento. En los resultados principales se mantiene un Q fijo para comparar modelos de forma homogénea, y se añade una sensibilidad específica Q fijo frente a Q MLE para no sugerir que el perfil MLE gobierna todos los backtests. Esto no maximiza PnL directamente; calibra el modelo estadístico del filtro. En los escenarios con drift casi constante el perfil resulta monótono y el máximo cae en la frontera inferior del grid explorado (Q tendiendo a cero): el ajuste estadístico prefiere un drift fijo, así que ese óptimo no es un máximo interior y el Q MLE se trata como diagnóstico degenerado in-sample, no como calibración recomendada. Dos detalles completan la especificación: la varianza de observación se fija en $R = \operatorname{Var}(z)$ del tramo de entrenamiento, que la sobreestima al incluir la varianza del propio drift (elección conservadora que empuja hacia Q bajos), la incertidumbre inicial es $P_0 = R$, y la selección y el perfil de la figura comparten el mismo grid logarítmico de 10^{-6} a 10^{-2} .

La verosimilitud mostrada es el caso escalar usado para Kalman RW, Kalman OU e IMM. La extensión OFI del experimento se implementa como dos actualizaciones escalares sucesivas, precio y proxy OFI sintético, por lo que no se presenta como una likelihood multivariante general con determinante e inversa de matriz de covarianza.

La lectura de unidades es la siguiente: α se mide en precio por segundo; σ representa precio por raíz de segundo en la dinámica continua, mientras que la volatilidad rolling del backtest se calcula sobre retornos por segundo del bloque (equivale a σ de bloque dividida por Δt), por lo que su magnitud decrece mecánicamente al agregar y con ella la penalización de inventario $\gamma\sigma^2\tau$; Q y R son varianzas del estado y de la observación; el PnL se expresa en unidades monetarias sintéticas por simulación de 3600 segundos; y la comisión es una fracción del notional ejecutado.

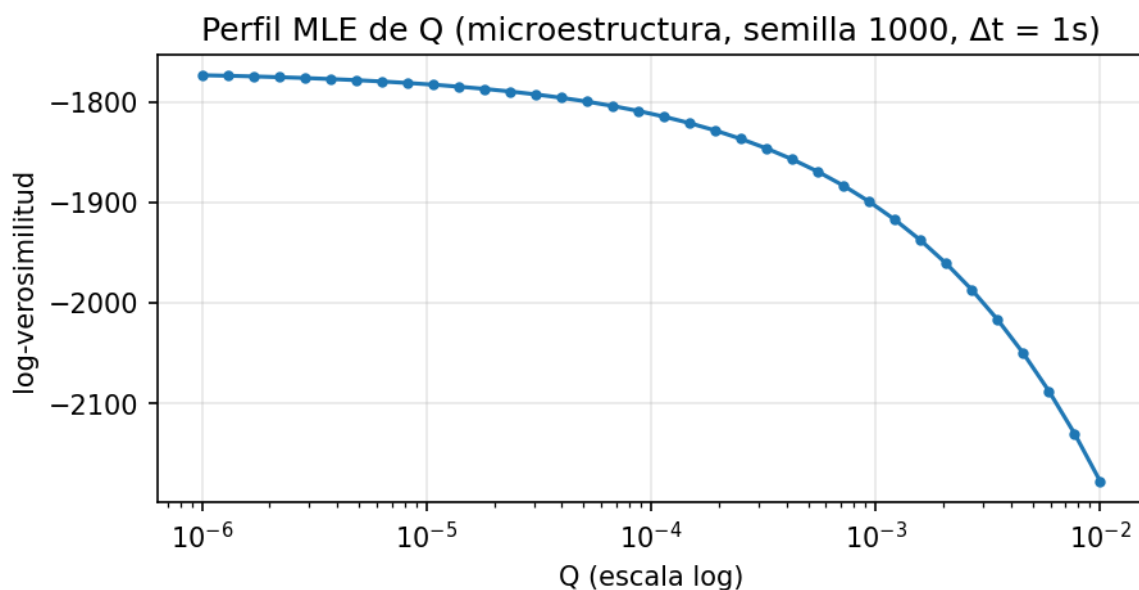


Figura 1. Perfil de máxima verosimilitud para Q en el escenario de microestructura (semilla 1000; el máximo cae en la frontera inferior del grid).

La Figura 1 materializa esa calibración: la verosimilitud decrece de forma monótona en Q y el máximo queda en el borde del grid.

2.7 DESARROLLO DETALLADO DE CONCEPTOS TÉCNICOS

2.7.1 LECTURA OPERATIVA DE Q Y R

Las definiciones formales de Q y R quedaron fijadas en las ecuaciones (12) a (17); aquí se añade su lectura operativa. Al multiplicar $\hat{\alpha}$ por τ en el reservation price, la estimación se convierte en un desplazamiento esperado de precio durante el horizonte operativo, directamente comparable con el spread y con la penalización de inventario. Un Q alto deja que $\hat{\alpha}$ persiga los retornos recientes; un Q bajo fuerza una estimación suave y persistente. R juega el papel contrario: cuando es grande, la ganancia de Kalman baja y el filtro ignora parte del dato nuevo. No debe perderse de vista que el mercado observado no es una medición limpia del precio eficiente, sino una mezcla de ruido y mecánica de libro: reducir R de forma agresiva fabrica confianza en señales microestructurales que quizá no existan, y el perfil MLE selecciona Q desde las innovaciones sin incorporar comisiones, inventario ni selección adversa.

2.7.2 INNOVACIÓN Y GANANCIA

La innovación v_k es la pieza más informativa del sistema: su varianza Ω_k determina la ganancia y la log-verosimilitud usada para calibrar Q, y examinar su serie temporal permite detectar si el filtro está sistemáticamente sorprendido, algo que mirar solo $\hat{\alpha}$ oculta. Sus colas y su dependencia temporal pueden romper la hipótesis normal del filtro básico. En alta frecuencia, una ganancia K alta convierte rebote bid-ask en drift estimado y una K baja hace que el modelo llegue tarde; aunque la agregación temporal aumenta la proporción de señal útil en cada observación, K sigue traduciendo ruido reciente en desplazamientos de quote, y la ganancia óptima en sentido estadístico no garantiza ganancia económica después de costes.

2.7.3 REVERSIÓN OU Y REGÍMENES

El modelo OU introduce la idea de que el drift no puede alejarse indefinidamente de cero: la matriz $F = \exp(-\kappa\Delta t)$ disipa la predicción anterior, un supuesto razonable para señales transitorias que penaliza en cambio los mercados con tendencia persistente, porque la elección de κ impone una hipótesis fuerte sobre cuánto dura la oportunidad predictiva. El IMM generaliza esa disyuntiva sin resolverla a priori: mantiene creencias sobre varios regímenes, deja que la verosimilitud de cada filtro las actualice en secuencia y combina las estimaciones en lugar de elegir una. Un régimen con alta probabilidad estadística no es necesariamente el más rentable, pero el mecanismo evita casarse con una única hipótesis de persistencia.

2.7.4 ORDER FLOW IMBALANCE

El OFI (Cont, Kukanov y Stoikov, 2014) entra como segunda observación asociada al desequilibrio entre presión compradora y vendedora, de modo que el filtro deja de depender solo del retorno, dominado a alta frecuencia por el rebote bid-ask. Comparar esta variante con el filtro de solo precio mide si enriquecer el vector de observación mejora la precisión direccional; el matiz, desarrollado en resultados, es que el OFI de este trabajo es sintético y captura un mecanismo controlado, no la complejidad de un libro real.

Capítulo 3. ESTADO DE LA CUESTIÓN

3.1 AVELLANEDA-STOIKOV Y EXTENSIONES

Avellaneda y Stoikov (2008) formulan uno de los modelos de referencia para market making óptimo. Su contribución consiste en vincular utilidad exponencial, inventario y llegada de órdenes a una regla explícita para reservation price y spread. El modelo es suficientemente simple para implementarse y suficientemente rico para explicar la tensión entre capturar spread y controlar inventario.

Guéant, Lehalle y Fernandez-Tapia (2013) desarrollan extensiones prácticas del problema de inventario, incluyendo inventario acotado y formulaciones más cercanas a la implementación real. Guéant (2016) sistematiza esa línea en forma monográfica. La revisión de esta literatura obliga a matizar la contribución del TFM: no se pretende inventar la idea de market making con drift, sino estudiar empíricamente cómo se estima ese drift y cuándo aporta valor.

Fodra y Labadie (2012) analizan market making con apuestas direccionales y riesgo de inventario. Su perspectiva es relevante porque conecta la señal direccional con la decisión de cotización. Esta memoria se sitúa en una línea complementaria: toma una regla de cotización conocida y evalúa qué ocurre cuando la señal se estima online con filtros de Kalman bajo distintos Δt .

3.2 CARTEA Y JAIMUNGAL FRENTE A ESTE TFM

Cartea, Jaimungal y Penalva (2015) ofrecen un marco amplio de trading algorítmico y control óptimo. En sus formulaciones, las señales predictivas y las métricas de riesgo pueden entrar dentro del problema de optimización (Cartea y Jaimungal, 2015). En cambio, este TFM adopta una aproximación de separación: primero estima $\hat{\alpha}$ y después introduce esa estimación en la fórmula del reservation price.

La diferencia de fórmula es relevante. En este TFM no se resuelve una nueva HJB acoplada con cambio de régimen; se usa $r = S + \hat{\alpha}\tau - q\gamma\sigma^2\tau$ como puente entre estimación y ejecución. Esta decisión reduce la ambición teórica, pero aumenta la transparencia empírica. El trabajo se concentra en medir si $\hat{\alpha}$ es suficientemente fiable para mover quotes.

$$\hat{\alpha}_t = \mathcal{F}_t(z_1, \dots, z_t), r_t = S_t + \hat{\alpha}_t\tau - q_t\gamma\sigma_t^2\tau \quad (26)$$

La arquitectura separa estimación y control: el filtro produce $\hat{\alpha}$ y Avellaneda-Stoikov lo usa como entrada.

$$\text{Control completo: } \max_{\delta^b, \delta^a} \mathbb{E}[-e^{-\gamma X_T} | S_t, q_t, \mathcal{Y}_t] \quad (27)$$

En un marco de control óptimo, la señal predictiva se integraría directamente en la optimización dinámica.

3.3 LIMITACIONES DE LA ECUACIÓN HJB CON RÉGIMEN

Una HJB con cambio de régimen incorporaría directamente el estado latente del mercado en el problema de control. Sin embargo, afirmar que esa ecuación tiene solución cerrada o que ha sido resuelta en este trabajo sería excesivo; aquí se presenta como motivación teórica y línea futura, no como resultado demostrado.

La aproximación implementada es más modesta: estimación separada y control con input estimado. Esta separación es habitual en sistemas de ingeniería financiera cuando resolver el sistema acoplado completo no es el objetivo principal. La validez de la aproximación no se da por supuesta: se evalúa mediante backtests, controles y validación walk-forward.

$$0 = \partial_t V_i + \mathcal{L}_i V_i + \max_{\delta^b, \delta^a} \{ \lambda^b (\delta^b) \Delta_b V_i + \lambda^a (\delta^a) \Delta_a V_i \} + \sum_j q_{ij} (V_j - V_i) \quad (28)$$

Esta forma ilustra una HJB acoplada por regímenes; la memoria la presenta como motivación, no como ecuación resuelta.

En esa ecuación, V_i representa la función de valor bajo el régimen i ; \mathcal{L}_i resume la dinámica del precio y del estado bajo ese régimen; $\Delta_b V_i$ y $\Delta_a V_i$ son los saltos de valor al ejecutarse bid o ask; y q_{ij} recoge la intensidad de transición entre regímenes. Resolver numéricamente esa ecuación exigiría especificar condiciones terminales, frontera de inventario y dinámica completa del libro, por lo que queda fuera del alcance experimental de esta memoria.

3.4 FILTRADO DE ESTADOS LATENTES Y REGÍMENES EN FINANZAS

La estimación de estados latentes con el filtro de Kalman (1960) tiene una tradición consolidada en finanzas: Wells (1996) recopila aplicaciones a tipos, betas y primas variables en el tiempo, y Durbin y Koopman (2012) sistematizan los modelos de espacio de estados que este trabajo usa en su versión más simple, un drift escalar observado a través de retornos ruidosos. La combinación con regímenes markovianos procede del algoritmo IMM de Blom y Bar-Shalom (1988), diseñado para seguimiento de objetivos con dinámicas conmutantes; el M4 de este trabajo es exactamente esa arquitectura con tres hipótesis de drift.

Del lado de la microestructura, el rebote bid-ask que el generador introduce de forma controlada es el mecanismo clásico de Roll (1984): transacciones que alternan entre bid y ask crean autocorrelación negativa en los retornos observados sin reversión económica real; la dinámica del libro admite además modelos estocásticos explícitos (Cont, Stoikov y Talreja, 2010) y la selección adversa asociada al flujo informado cuenta con métricas propias (Easley, López de Prado y O'Hara, 2012). La versión sintética de este trabajo lo lleva al extremo determinista para que su efecto sobre la SNR sea trazable, y esa elección tiene la consecuencia de paridad que el capítulo de resultados documenta.

3.5 HUECO QUE CUBRE EL TRABAJO

El hueco de este TFM no está en proponer una fórmula nueva para el market maker, sino en construir una evaluación que separe escala temporal, calidad de señal y rentabilidad neta. La memoria responde a una pregunta práctica: cuándo una señal de drift estimada con filtros simples deja de ser ruido y cuándo su uso operativo queda anulado por costes o supuestos de ejecución.

Capítulo 4. DEFINICIÓN DEL TRABAJO

Este capítulo concreta el problema de investigación en un diseño experimental: qué se mide, con qué escenarios sintéticos y bajo qué controles.

4.1 JUSTIFICACIÓN

El trabajo no se formula como una competición para encontrar un único modelo ganador; se plantea como un estudio de mecanismos. Las pérdidas o ganancias de un market maker con drift no son una señal unidimensional: emergen de un circuito de estimación, cotización, ejecución, inventario y costes.

El foco pasa a ser Δt porque cambiar la frecuencia modifica simultáneamente la SNR del drift, la autocorrelación observada, el número de oportunidades de ejecución y la vida efectiva de las quotes. Por eso el experimento separa, hasta donde permite el simulador, frecuencia de estimación y exposición de ejecución.

4.2 OBJETIVOS EXPERIMENTALES

Los objetivos generales quedaron fijados en el Capítulo 1; aquí se concretan en decisiones experimentales medibles.

- Seis escenarios sintéticos con drift conocido y 50 semillas por configuración, para que ninguna conclusión dependa de un tramo o una realización.
- Cinco escalas temporales (1, 2, 5, 10 y 30 segundos) evaluadas con las mismas métricas y separando escala de estimación, vida de quote y frecuencia de recotización.
- Controles específicos por mecanismo: sin comisiones, drift invertido, ablación y fuga del proxy OFI, sensibilidad de Q y de τ , y comparación de motores de ejecución.
- Validación walk-forward y diferencias pareadas por semilla para las comparaciones que se afirmen.

4.3 METODOLOGÍA

La metodología se divide en cuatro capas. La primera genera escenarios sintéticos con drift conocido, para medir precisión direccional o silencio correcto cuando el drift es nulo. La segunda ejecuta estimadores online. La tercera calcula quotes con Avellaneda-Stoikov y simula fills mediante intensidades Poisson. La cuarta resume métricas financieras y estadísticas con medias, desviaciones, percentiles e intervalos de confianza.

La elección de un banco íntegramente sintético es deliberada y exige justificación, porque versiones preliminares de este trabajo usaban series reales. Con datos reales el drift verdadero no es observable, de modo que la precisión direccional no puede medirse; un único tramo de mercado impone su tendencia

a todas las conclusiones (la objeción clásica: si el precio siempre baja, todo modelo largo pierde); y no es posible separar señal, ejecución y fricción porque nada del entorno está bajo control. El generador sintético invierte esa situación: el drift es conocido, los regímenes se imponen a voluntad y cada mecanismo se puede encender y apagar. El precio de esa identificación causal es la validez externa, y por eso las conclusiones se restringen al simulador.

$$S_{k+1}^{eff} = S_k^{eff} + \alpha_k \Delta t + \sigma \sqrt{\Delta t} \varepsilon_k, \varepsilon_k \sim \mathcal{N}(0,1) \quad (29)$$

El precio eficiente sintético permite conocer el drift verdadero y medir si el estimador recupera su signo. El generador opera a paso base de un segundo, de modo que σ multiplica directamente a ε_k ; las series a otros Δt se obtienen por resampling posterior, no reescalando esta ecuación.

$$S_k^{obs} = S_k^{eff} + b(-1)^k + \xi_k \quad (30)$$

El término alternante $b(-1)^k$ introduce rebote bid-ask controlado y genera autocorrelación negativa de corto plazo. En los seis escenarios de la Tabla 1 el término ξ_k se fija a cero, de modo que todo el ruido observacional procede del rebote alternante; se mantiene en la ecuación por generalidad.

$$z_k = \alpha_k + v_k^p, o_k = \alpha_k + v_k^{ofi}, v_k^{ofi} \sim \mathcal{N}(0, R_{ofi}) \quad (31)$$

El proxy OFI sintético se genera en la misma escala que el drift latente y se incorpora como una segunda actualización escalar; no se interpreta como prueba de que un OFI real tenga esa relación directa.

4.4 DISEÑO EXPERIMENTAL DETALLADO

Tabla 1. Parámetros numéricos de los escenarios sintéticos.

Escenario	Modo	alpha	vol alpha	sigma	rebote	ruido OFI	patron
Tendencia alcista limpia	constant	0.035	0.003	0.160	0.000	0.055	constante
Tendencia bajista ruidosa	constant	-0.030	0.003	0.220	0.000	0.075	constante
Mercado lateral	flat	0.000	0.003	0.200	0.000	0.120	alpha=0
Cambio de régimen	regime	0.040	0.003	0.190	0.000	0.075	20% +alpha, 20% 0.9alpha, 20% 0.35alpha, 20% 0.45alpha, 20% 0
Microestructura bid-ask	micro	0.012	0.003	0.110	0.190	0.100	constante
Alta volatilidad sin drift	flat	0.000	0.003	0.340	0.000	0.160	alpha=0

Estos parámetros fijan el laboratorio causal del TFM. No son una calibración a un venue real: sirven para conocer el drift verdadero, controlar el ruido y separar recuperación estadística de monetización.

Los seis escenarios cubren el espacio de situaciones que un estimador de drift debe distinguir. Los dos primeros contienen señal real: la tendencia alcista limpia comprueba si los estimadores desplazan las quotes hacia arriba sin acumular inventario excesivo (si un modelo falla en este entorno controlado, difícilmente se defenderá sobre datos reales más ruidosos), y la tendencia bajista ruidosa invierte el

signo para que ninguna conclusión dependa de un mercado que siempre sube; acertar el signo, por sí solo, no elimina por sí solo el riesgo de inventario.

Los dos siguientes no contienen señal explotable y funcionan como pruebas de sobriedad. El mercado lateral tiene drift verdadero nulo y obliga al estimador a no inventar dirección: un modelo demasiado reactivo desplaza quotes por ruido y pierde dinero aunque su arquitectura sea sofisticada, un síntoma clásico de sobreajuste que en datos reales sería difícil de aislar porque casi nunca se sabe con certeza que el drift es exactamente cero. La alta volatilidad sin drift lleva la misma idea al extremo: cuando el ruido domina, desplazar quotes por una señal débil aumenta la actividad sin mejorar el precio esperado, aunque un generador gaussiano no reproduce las colas pesadas ni los saltos de un mercado real.

Los dos últimos introducen estructura temporal. El cambio de régimen alterna tramos alcistas, bajistas y laterales para evaluar si el IMM aporta valor adaptando sus probabilidades en tiempo real, y es el entorno elegido para la validación walk-forward porque fuerza transferencia temporal; sus transiciones son, eso sí, más limpias que los cambios graduales de un mercado. La microestructura bid-ask añade una oscilación alternante que produce autocorrelación negativa a un segundo y convierte la intuición sobre la escala temporal en una magnitud medible, con la salvedad de que el rebote real depende del libro y del tipo de dato, no de una alternancia determinista.

4.5 PLANIFICACIÓN TEMPORAL DEL TRABAJO

Tabla 2. Planificación temporal estimada del trabajo.

Actividad	Estimación	Descripción
Estudio de literatura	30 h	Avellaneda-Stoikov, Guéant, Cartea-Jaimungal, microestructura y filtrado
Diseño del pipeline	25 h	Definición de escenarios, métricas y estructura reproducible
Implementación	60 h	Estimadores, backtest, controles y generación de figuras
Validación y sensibilidad	40 h	Q, τ , OFI, walk-forward, ejecución y revisión de resultados
Análisis de resultados	30 h	Interpretación, contrastes y matriz de riesgos
Redacción	70 h	Memoria final, revisión de narrativa y adaptación a plantilla
Reuniones y tutorías	10 h	Seguimiento con el director y revisión de comentarios

Tabla 3. Cronograma del trabajo (curso 2025/26).

Actividad	Feb	Mar	Abr	May	Jun	Jul
Estudio de literatura	X	X				
Diseño del pipeline		X	X			
Implementación			X	X		
Validación y sensibilidad				X	X	
Análisis de resultados					X	X
Redacción y revisión				X	X	X

El total estimado asciende a 265 horas de trabajo efectivo.

Capítulo 5. SISTEMA DESARROLLADO

Definido el diseño experimental, este capítulo describe el sistema que lo implementa y las decisiones de ingeniería que condicionan la lectura de los resultados. La validación del motor de ejecución se incluye aquí, y no en el capítulo de resultados, porque valida el instrumento de medida antes de usarlo.

5.1 ANÁLISIS DEL SISTEMA

El código se organiza como un pipeline autocontenido dentro de la carpeta code adjunta a esta memoria. El script `run_all.py` ejecuta los experimentos completos y produce tablas CSV, figuras y controles de sensibilidad. La lógica principal está en `src/tfm_pipeline.py`, lo que permite regenerar la evidencia sin depender de notebooks manuales.

El sistema no persigue alta fidelidad de exchange. Su objetivo es diagnóstico: aislar mecanismos. Por ello, los escenarios sintéticos incluyen drift verdadero, proxy OFI sintético y rebote bid-ask. La ventaja es que se conoce la señal latente y se puede medir si el filtro la recupera; la desventaja es que el PnL se expresa en unidades monetarias sintéticas por unidad nominal y simulación de 3600 segundos, no en euros de mercado real.

La escala económica del simulador parte de un precio inicial 100, order size 1.0, horizonte de 3600 segundos y comisión de 0.0002 del notional por operación. Una ejecución típica tiene notional cercano a precio por cantidad, de modo que el coste por fill ronda unas pocas centésimas de unidad sintética cuando el precio está cerca de 100. Magnitudes extremas como 1267 o -594 en los escenarios de tendencia son resultados mark-to-market acumulados de una simulación sintética con muchas oportunidades de quote; sirven para comparar mecanismos dentro del experimento, no para inferir tamaño monetario real.

5.2 DISEÑO

Arquitectura experimental del nuevo TFM



Figura 2. Arquitectura del pipeline de experimentación.

La Figura 2 muestra los cuatro bloques y sus dependencias; los modelos comparados se listan a continuación.

Tabla 4. Modelos comparados en la implementación.

Modelo	Ecuación/idea	Uso
M0 Baseline	$\alpha = 0$	Referencia sin drift
M1 EMA	Media exponencial de retornos	Suavizado simple
M2 Kalman RW	$\alpha \ k = \alpha \ {k-1} + w \ k$	Drift persistente
M3 Kalman OU	$\alpha \ k = \exp(-\kappa\Delta t) \alpha \ {k-1} + w \ k$	Reversión a cero
M4 IMM	Mezcla de filtros	Cambio de régimen
M5 Kalman OFI	Precio + proxy OFI sintético	Vector de observación enriquecido

5.3 IMPLEMENTACIÓN

Cada backtest recorre la serie temporal de precios y mantiene estado financiero: cash, inventario, PnL bruto, PnL neto y comisiones acumuladas. En cada paso se estima $\hat{\alpha}$, se actualiza la volatilidad rolling, se calculan bid y ask, se simula la ejecución y se registran métricas.

El fill rate se define como $\text{total_fills}/(2N)$, donde N es el número de pasos y existen dos oportunidades de ejecución por paso: bid y ask. Por tanto, un fill rate elevado no mide calidad predictiva, sino la propensión del simulador a ejecutar las quotes colocadas; con el motor corregido, que permite como máximo un fill por paso, el techo efectivo de esta métrica es el 50%. Esta definición evita interpretar la saturación de fills como una medida directa de calidad predictiva.

La simulación de ejecución usa la probabilidad de fill $\varphi = 1 - \exp(-\lambda T)$, con $\lambda = A \exp(-k\delta)$ y T igual a la vida de la quote. En el backtest principal T coincide con Δt ; en el control de descomposición se fija $T = 1s$ para separar estimación y exposición. Este mecanismo explica por qué los resultados a 30

segundos deben interpretarse con cautela: el simulador no modela cancelaciones ni obsolescencia de quotes. El motor corregido añade otro supuesto activo, un máximo de un fill por paso, que es conservador a $\Delta t = 1s$ y restrictivo a $\Delta t = 30s$ (en 30 segundos ambos lados podrían ejecutarse de forma legítima); por eso el capítulo de resultados lo contrasta con un modo dual fill.

$$\varphi_k^{side} = 1 - \exp[-A \exp(-k \delta_k^{side}) \Delta t], side \in \{bid, ask\} \quad (32)$$

La probabilidad de fill crece con el tiempo de exposición Δt y decrece con la distancia δ de la quote al midprice.

$$q_{k+1} = q_k + \mathbf{1}_{bid,k} v - \mathbf{1}_{ask,k} v \quad (33)$$

El inventario aumenta si se ejecuta el bid y disminuye si se ejecuta el ask; v es el tamaño de orden u `order_size`.

$$C_{k+1} = C_k - \mathbf{1}_{bid,k} v p_k^{bid} + \mathbf{1}_{ask,k} v p_k^{ask} - fee_k \quad (34)$$

El cash neto se actualiza con compras, ventas y comisiones de ejecución.

$$fee_k = c(\mathbf{1}_{bid,k} v p_k^{bid} + \mathbf{1}_{ask,k} v p_k^{ask}) \quad (35)$$

La comisión es proporcional al notional ejecutado; por eso más fills pueden empeorar el PnL neto aunque haya señal.

$$PnL_k = C_k + q_k S_k, PnL_{neto,k} = PnL_{bruto,k} - \sum_{j \leq k} fee_j \quad (36)$$

El mark-to-market valora el inventario pendiente al midprice actual y resta las fricciones acumuladas, en coherencia con la definición introducida en la ecuación (1).

5.4 MÉTRICAS

- PnL bruto: resultado antes de comisiones.
- Comisiones: fricción proporcional al notional ejecutado.
- PnL neto: PnL bruto menos comisiones (las unidades del simulador quedaron definidas en el capítulo 2).
- Precisión direccional: porcentaje de veces que $\text{signo}(\hat{\alpha})$ coincide con $\text{signo}(\alpha \text{ verdadero})$; no aplica al baseline sin drift estimado.
- Tasa de silencio: porcentaje de pasos con $|\hat{\alpha}|$ por debajo del umbral, sin condicionar al drift verdadero.
- Silencio correcto: la misma fracción condicionada a que el drift verdadero sea nulo o casi nulo; solo es informativa en escenarios laterales y se reporta junto a la precisión.
- SNR efectivo: varianza de $\hat{\alpha}$ respecto a la incertidumbre media del filtro.
- Inventario medio absoluto: exposición acumulada del market maker.
- Drawdown: caída máxima de la curva de PnL mark-to-market respecto a su máximo previo dentro de cada simulación; se reporta la media por semilla y es, por construcción, un valor no positivo.

El umbral de silencio (0.01 en unidades de α) se fija justo por debajo del drift verdadero más débil de la Tabla 1 (0.012 en microestructura), de modo que una estimación correcta de la señal más tenue no compute como silencio.

$$\text{FillRate} = \frac{(\sum_k \mathbf{1}_{bid,k}) + (\sum_k \mathbf{1}_{ask,k})}{2N} \quad (37)$$

El denominador $2N$ aparece porque en cada instante hay dos oportunidades de ejecución, bid y ask.

$$\text{FillRate}_{valida} = \frac{(\sum_k \mathbf{1}_{bid,k}) + (\sum_k \mathbf{1}_{ask,k})}{2N - (\sum_k \mathbf{1}_{bidcruzado,k}) - (\sum_k \mathbf{1}_{askcruzado,k})} \quad (38)$$

El fill rate condicionado a quotes válidas separa la menor ejecución real de las cancelaciones provocadas por quotes cruzadas.

$$\text{Acc}_{dir} = \frac{1}{|\mathcal{K}|} \sum_{k \in \mathcal{K}} \mathbf{1}\{\text{sign}(\hat{\alpha}_k) = \text{sign}(\alpha_k)\} \quad (39)$$

La precisión direccional mide si el filtro acierta el signo del drift verdadero en escenarios sintéticos.

$$\text{SNR}_{eff} = \frac{\text{Var}(\hat{\alpha}_k)}{\mathbb{E}[P_k]} \quad (40)$$

El SNR efectivo compara variabilidad de la señal estimada con la incertidumbre posterior media del filtro.

$$\text{SNR}_{bloque}(\Delta t) = \frac{|\alpha| \Delta t}{\sigma_{\Delta t}} \quad (41)$$

Esta SNR estructural usa el drift verdadero del generador y la volatilidad del bloque; es la medida que sostiene la lectura de escala temporal.

Por tanto, SNR_{eff} diagnostica la confianza interna del filtro, mientras que SNR_{bloque} mide si el experimento sintético contiene suficiente drift acumulado frente al ruido observado. El análisis de Δt se apoya en SNR_{bloque} ; SNR_{eff} queda como métrica auxiliar del estimador.

5.5 DETALLES DE IMPLEMENTACIÓN Y FLUJO DE DATOS

5.5.1 GENERACIÓN DE DATOS Y RESAMPLING

El generador produce a la vez precio observado, precio eficiente, drift verdadero y OFI; separar el precio observado del eficiente permite introducir rebote bid-ask sin confundirlo con tendencia real y evaluar la precisión direccional contra una señal latente conocida, aunque esa comodidad simplifica la profundidad del libro y la heterogeneidad de agentes. El resampling a Δt toma el último precio de cada bloque y promedia el drift latente, lo que mantiene una relación coherente entre observación agregada y señal verdadera media y hace comparables los cinco pasos temporales; la agregación por bloques, en cambio, no reproduce la decisión continua de cancelar y recolocar órdenes.

5.5.2 ESTADO FINANCIERO, INVENTARIO Y VOLATILIDAD

El backtest mantiene cash neto, cash bruto, inventario y comisiones acumuladas; registrar el cash bruto por separado permite atribuir cuánto valor procede de la estrategia antes de fricciones, aunque un

backtest sin impacto de mercado siga siendo una aproximación parcial. El límite duro de inventario impide compensar mala predicción acumulando exposición sin freno: cuando una ejecución lo excedería, la orden se rechaza; es una versión simplificada de la disciplina de riesgo real, sin liquidación gradual ni skew dinámico. La volatilidad se estima como desviación típica rolling de los retornos por segundo del bloque, sobre una ventana fija en segundos, de modo que los modelos comparten memoria efectiva al cambiar de frecuencia. Esa $\hat{\sigma}$ equivale a la del bloque dividida por Δt : decrece al agregar y, con ella, la penalización de inventario $\gamma\sigma^2\tau$. El efecto forma parte del mecanismo de la escala temporal y debe tenerse presente al leer los resultados. Una rolling std tampoco captura cambios bruscos de régimen tan bien como un GARCH.

5.5.3 REPRODUCIBILIDAD Y TRAZABILIDAD

Cada experimento fija sus semillas. El generador de trayectorias y el de ejecuciones Poisson usan generadores desacoplados (semilla más desplazamiento fijo), de modo que la aleatoriedad de los fills no replica el mismo bit-stream que la del precio. El pipeline guarda CSV intermedios y figuras con nombres estables: cada tabla y cifra del documento tiene una fuente regenerable, y las tablas, cifras y figuras del documento se regeneran desde esos CSV con python-docx (update_memory.py), ligadas al código que produce su evidencia. Si se cambian parámetros hay que regenerar resultados y documento a la vez. Cincuenta semillas dan intervalos de confianza útiles, sin sustituir una validación industrial con datos reales.

5.6 VALIDACIÓN DEL MOTOR DE EJECUCIÓN

La revisión de resultados parte de un cambio metodológico importante: el backtest principal ya no permite que una quote cruzada se contabilice como orden pasiva, ni permite fills simultáneos de bid y ask dentro del mismo paso. Si el bid queda por encima del midprice o el ask por debajo, ese lado se cancela para el cálculo de fill. Si ambos lados tienen probabilidad de ejecución, el simulador permite como máximo un fill y elige el lado de forma ponderada por las probabilidades Poisson. Ese tope de un fill por paso es un supuesto, conservador a 1s y restrictivo a 30s, así que la comparación incluye además un modo dual fill que cancela cruces pero permite ejecutar ambos lados en el mismo paso.

Tabla 5. Comparación de motores de ejecución (legacy, corregida y dual fill) en microestructura (12 semillas).

Δt	Modelo	Ejecución	n	PnL IC95 neto	Fill	Quotes cruzadas	Simult. suprimida
1s	M0 Baseline	legacy	12	230.8 ± 21.6	3.9%	0.0%	0.0%
1s	M0 Baseline	dual fill	12	230.8 ± 21.6	3.9%	0.0%	0.0%
1s	M0 Baseline	corregida	12	227.6 ± 21.7	3.8%	0.0%	0.1%
1s	M2 Kalman RW	legacy	12	-180.1 ± 71.1	7.9%	25.0%	0.0%
1s	M2 Kalman RW	dual fill	12	194.9 ± 102.4	2.1%	28.4%	0.0%
1s	M2 Kalman RW	corregida	12	211.7 ± 122.0	2.1%	28.3%	0.1%
1s	M5 Kalman OFI	legacy	12	-412.1 ± 70.9	9.6%	27.4%	0.0%
1s	M5 Kalman OFI	dual fill	12	124.4 ± 165.0	1.9%	30.5%	0.0%

1s	M5 Kalman OFI	corregida	12	127.4 ± 166.8	1.9%	30.5%	0.0%
30s	M0 Baseline	legacy	12	184.5 ± 102.6	71.1%	0.0%	0.0%
30s	M0 Baseline	dual fill	12	184.5 ± 102.6	71.1%	0.0%	0.0%
30s	M0 Baseline	corregida	12	161.8 ± 130.7	45.4%	0.0%	48.3%
30s	M2 Kalman RW	legacy	12	473.7 ± 57.2	48.9%	25.1%	0.0%
30s	M2 Kalman RW	dual fill	12	114.3 ± 70.5	38.8%	25.1%	0.0%
30s	M2 Kalman RW	corregida	12	157.3 ± 108.1	27.7%	25.1%	21.7%
30s	M5 Kalman OFI	legacy	12	490.1 ± 56.7	48.6%	24.7%	0.0%
30s	M5 Kalman OFI	dual fill	12	117.3 ± 84.6	39.6%	24.8%	0.0%
30s	M5 Kalman OFI	corregida	12	186.8 ± 95.7	28.6%	24.7%	21.7%

La Tabla 5 es un diagnóstico metodológico con 12 semillas, pensado para medir el efecto de cambiar el motor de ejecución; sus cifras no son comparables una a una con las tablas principales, que usan 50 semillas por escenario o 300 observaciones cuando agregan seis escenarios. El modo dual fill acota el peso del supuesto de un solo fill por paso: la distancia entre corregida y dual fill a 30s mide cuánta parte del deterioro a Δt alto procede de ese supuesto y no de la señal. Dos detalles de la tabla merecen aclaración: las filas legacy y dual fill del baseline son idénticas porque ese modelo nunca cruza quotes y el motor legacy ya permitía ejecutar ambos lados, de modo que ambos modos coinciden exactamente; y a 30s el PnL del baseline corregido queda por debajo del legacy (161.8 frente a 184.5) al suprimirse cerca de la mitad de los fills simultáneos, una diferencia que sigue dentro de los IC95 (± 131 frente a ± 103) y que no debe sobreinterpretarse.

Tabla 6. Alcance estadístico de las evidencias usadas en resultados.

Bloque	CSV	n	Lectura
Comparación de motores de ejecución (legacy/corregida/dual)	legacy_vs_corrected_execution.csv	12	Diagnóstico metodológico de ejecución; no comparable directamente con estimaciones principales.
Resultados escenario-modelo- Δt	summary_with_ci.csv	50	Estimación principal por escenario, Δt y modelo.
Sensibilidad agregada a Δt	dt_sensitivity_table.csv	300	Media de diseño experimental sobre escenarios; no distribución de mercado.
Sensibilidad de parámetros	parameter_sensitivity.csv	12	Diagnóstico one-at-a-time de especificación del simulador.
Q fijo frente a Q MLE	q_sensitivity.csv	50	Sensibilidad estadística in-sample, no validación económica robusta.
τ , OFI y controles	tau_sensitivity.csv / ofi_leakage_controls.csv / controls_no_fee_inverted_alpha.csv	50	Controles específicos para separar señal, costes y especificación.
Separación estimación/exposición y control multiescala	execution_dt_decomposition.csv / multiscale_control.csv	50	Aísla escala de estimación, vida de quote y frecuencia de recotización.

Diagnóstico SNR y autocorrelación	diagnostics_snr_autocorr.csv	50	Promedio sobre las 50 semillas del generador; sin backtest.
Walk-forward	walkforward_summary.csv	50	Transferencia temporal en microestructura y cambio de régimen.

Este cambio reduce el sesgo contable de la ejecución, pero no elimina la fragilidad operativa. En Kalman RW microestructura la tasa de quote crossing sigue alrededor de 28.6% a 1s y 25.4% a 30s (50 semillas; la tabla anterior usa 12), por lo que el problema no está solo en cómo se contabilizan los fills: el reservation price genera quotes demasiado agresivas con frecuencia estructural.

La comparación legacy/corregida se trata como riesgo de modelo. Cuando una corrección de ejecución cambia signo o magnitud, el motor de fills pesa tanto como el filtro en la conclusión económica.

Capítulo 6. ANÁLISIS DE RESULTADOS

Validado el motor de ejecución en el capítulo anterior, los resultados siguen la cadena causal del trabajo: primero la calidad estadística de la señal por escala temporal, después su traducción a PnL bajo el simulador corregido y, por último, los controles que separan señal, costes y especificación.

6.1 ESCALA TEMPORAL Y RELACIÓN SEÑAL-RUIDO

La SNR de bloque de la ecuación (41) se recalcula con unidades temporales consistentes. Para cada bloque se compara el drift acumulado esperado, $|\alpha|\Delta t$, con la volatilidad observada del retorno de bloque. En microestructura, la SNR limpia pasa de 0.030 a $\Delta t = 1s$ a 0.581 a $\Delta t = 30s$. El detalle intermedio tiene una explicación mecánica: el rebote sintético es una alternancia determinista de período 2, de modo que al muestrear el último precio de cada bloque desaparece por completo con Δt par y persiste con Δt impar; por eso ρ_1 es casi nulo a 2s y 10s, vuelve a ser negativo a 5s, y la comparación limpia de la agregación es 1s frente a los Δt pares. Un rebote estocástico tipo Roll, con signos aleatorios en lugar de alternancia determinista, atenúa el rebote como $1/\sqrt{n}$ al agregar en vez de anularlo exactamente en los Δt pares; el control adicional con ese rebote (stochastic_bounce_control.csv) lo confirma: ρ_1 pasa de -0.425 a 1s a -0.073 a 30s sin artefacto de paridad y la SNR limpia crece de forma monótona de 0.041 a 0.533, de modo que la mejora por agregación no depende del rebote determinista. Aunque la señal queda menos enterrada en ruido, 0.581 sigue por debajo de 1; la métrica anterior habría dado 3.180 a 30s, por lo que se mantiene solo como referencia de trazabilidad y no como argumento principal.

En la definición (41), $\sigma_{\{\Delta t\}}$ es la desviación típica del cambio de precio observado entre bloques. Esta convención evita multiplicar de nuevo por $\sqrt{\Delta t}$ cuando la volatilidad ya ha sido medida después del resampling.

Tabla 7. Diagnóstico SNR y autocorrelación en microestructura (media de 50 semillas).

Δt	$ \alpha $ medio	σ /seg	σ bloque	SNR limpia	SNR anterior	ρ_1
1s	0.0119	0.3962	0.3962	0.030	0.030	-0.922
2s	0.0119	0.0778	0.1556	0.153	0.217	0.006
5s	0.0119	0.0908	0.4539	0.131	0.294	-0.703
10s	0.0119	0.0349	0.3485	0.342	1.082	0.013
30s	0.0119	0.0205	0.6163	0.581	3.180	0.008

Tabla 8. Descomposición del rebote bid-ask observado frente al precio eficiente (media de 50 semillas).

Δt	ρ_1 observado	ρ_1 eficiente	σ bloque obs.	σ bloque eficiente
1s	-0.922	0.004	0.3962	0.1099
2s	0.006	0.006	0.1556	0.1556
5s	-0.703	-0.004	0.4539	0.2473
10s	0.013	0.013	0.3485	0.3485
30s	0.008	0.008	0.6163	0.6163

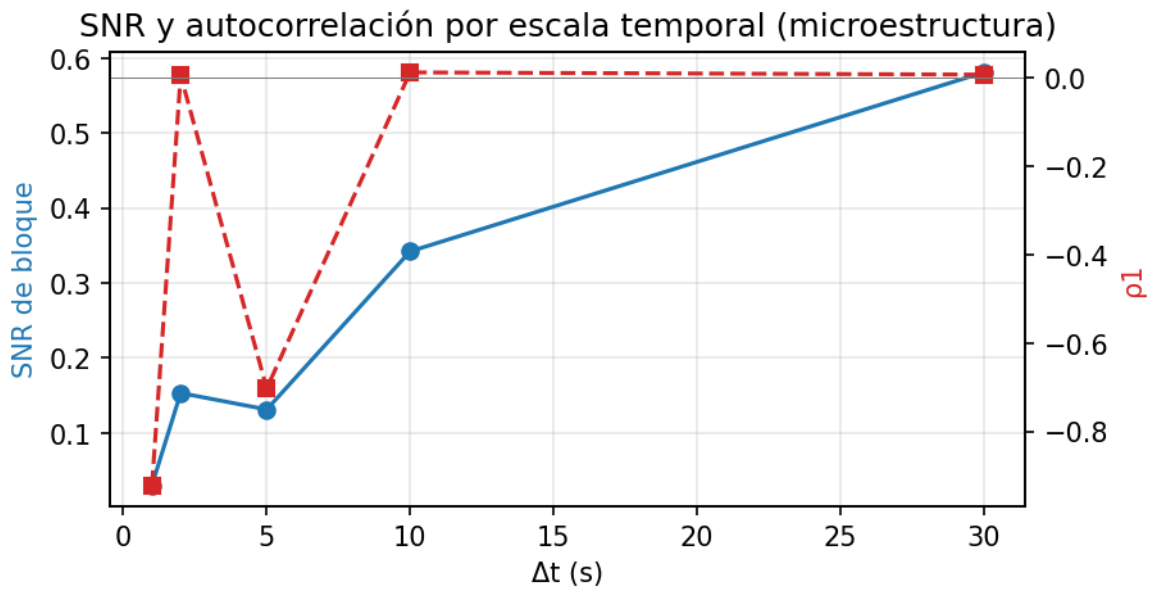


Figura 3. SNR y autocorrelación por escala temporal.

La Figura 3 superpone ambas series y hace visible el patrón de paridad. La autocorrelación a un segundo es negativa por la alternancia bid-ask incorporada al generador. Al comparar precio observado y precio eficiente se evita atribuir todo el patrón al drift latente: el diagnóstico muestra qué parte procede del diseño microestructural sintético.

$$\hat{\rho}_1 = \frac{\sum_{k=2}^N (r_{k-r}^-)(r_{k-1-r}^-)}{\sum_{k=1}^N (r_{k-r}^-)^2} \quad (42)$$

La autocorrelación estimada cuantifica el rebote bid-ask en vez de describirlo solo de forma cualitativa.

6.2 SENSIBILIDAD A ΔT

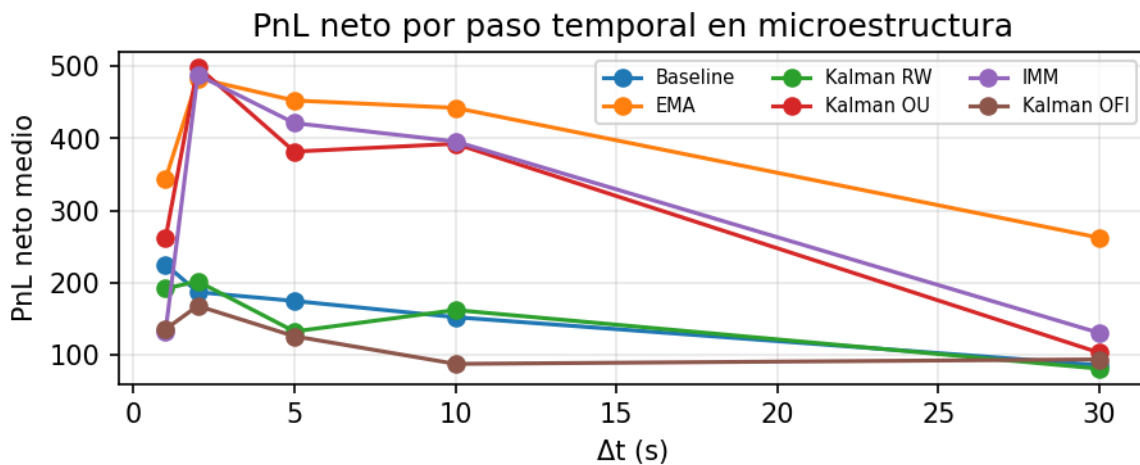


Figura 4. Sensibilidad del PnL neto al paso temporal en microestructura.

El aumento de Δt mejora la SNR, pero no el PnL neto corregido (Figura 4). En agregado, Kalman RW pasa de 142.2 a 1s a -35.0 a 30s; en microestructura, de 191.8 a 80.8. La escala sigue importando, pero la lectura correcta es deterioro de monetización, no transición de pérdidas a beneficios.

Parte del efecto de Δt opera además por un canal de especificación: la volatilidad rolling se mide sobre retornos por segundo del bloque, de modo que $\hat{\sigma}$ decrece mecánicamente al agregar y arrastra consigo la penalización de inventario $\gamma\sigma^2\tau$ y el spread (capítulo 5). El control que repite esta sensibilidad con la volatilidad por segundo fijada en la σ del generador (fixed_sigma_control.csv) reproduce el mismo patrón, con 73.8 a 30s frente a 80.8 con $\hat{\sigma}$ rolling y el resto de escalas comparables: el deterioro no desaparece al fijar $\hat{\sigma}$, así que el canal dominante es la exposición de ejecución, no la penalización mecánica de inventario.




Figura 5. Resultado agregado por paso temporal en todos los escenarios.

La Figura 5 extiende la lectura a los seis escenarios y a las cinco escalas; la tabla siguiente condensa los extremos.

Tabla 9. Sensibilidad agregada a Δt con IC95 para todos los modelos.

Δt	Modelo	PnL neto IC95	Fill	q medio	DD medio	Precisión
1s	M0 Baseline	225.2 ± 19.8	3.8%	2.90	-61.1	No aplica
1s	M1 EMA	145.9 ± 40.1	1.8%	5.00	-132.0	76.1%
1s	M2 Kalman RW	142.2 ± 37.7	1.3%	4.80	-117.1	68.5%
1s	M3 Kalman OU	472.8 ± 52.4	3.1%	5.73	-67.8	67.1%
1s	M4 IMM	359.3 ± 50.4	2.2%	5.63	-85.7	68.8%
1s	M5 Kalman OFI	131.3 ± 38.4	1.4%	4.72	-122.4	74.0%
30s	M0 Baseline	85.9 ± 38.6	45.2%	4.78	-135.2	No aplica
30s	M1 EMA	-45.4 ± 36.9	21.4%	4.30	-177.2	78.0%
30s	M2 Kalman RW	-35.0 ± 27.6	17.9%	3.36	-137.0	71.5%
30s	M3 Kalman OU	-23.0 ± 33.4	21.1%	3.74	-147.0	69.7%
30s	M4 IMM	-29.8 ± 33.3	20.0%	3.92	-154.9	73.1%
30s	M5 Kalman OFI	-156.3 ± 42.8	20.2%	4.68	-255.0	78.9%

El resultado menos cómodo de la sensibilidad es que la precisión direccional de Kalman RW puede subir mientras el PnL cae: la tabla no respalda una regla simple de aumentar Δt , sino una separación entre limpieza estadística de la señal y calidad económica de la ejecución. La columna de precisión exige además una salvedad: agrega escenarios con drift real y escenarios laterales donde el drift verdadero es solo la componente lenta del ruido, de modo que no mide una única habilidad direccional homogénea; por esa razón no se usa para ordenar modelos y el desglose por escenario queda disponible en `summary_with_ci.csv`.

El silencio correcto completa esa lectura: en el mercado lateral, con drift verdadero casi nulo, Kalman RW mantiene la señal por debajo del umbral solo el 21.6% de los pasos a 1s. Dicho de otro modo, el filtro casi nunca enmudece: emite dirección sobre ruido la mayor parte del tiempo, y esa es la vía por la que un estimador reactivo convierte ruido en desplazamientos de quote.

Tabla 10. Separación entre escala de estimación y exposición de ejecución en microestructura.

Δt estimación	Vida quote	Modelo	PnL neto IC95	Fill
1s	1s	M0 Baseline	225.4 ± 9.8	3.8%
1s	1s	M2 Kalman RW	191.8 ± 53.6	2.0%
1s	1s	M5 Kalman OFI	135.5 ± 65.9	1.8%
30s	1s	M0 Baseline	17.6 ± 21.5	3.7%
30s	1s	M2 Kalman RW	16.4 ± 15.0	2.2%
30s	1s	M5 Kalman OFI	17.8 ± 15.0	2.3%
30s	30s	M0 Baseline	85.8 ± 63.5	45.2%
30s	30s	M2 Kalman RW	80.8 ± 54.9	27.8%
30s	30s	M5 Kalman OFI	93.7 ± 60.4	28.4%

La fila del baseline desmonta una lectura tentadora de la Tabla 10. Con vida de quote de 1s, estimar a 30s también implica recotizar 30 veces menos, y el propio baseline, que no usa señal alguna, cae de 225.4 a 17.6. El colapso de los modelos con drift en esa configuración es por tanto mayoritariamente mecánico, menos oportunidades de cotizar, y no una medida de la calidad informacional de la señal agregada. Para aislar la estrategia multiescala hace falta recotizar cada segundo con la señal lenta, que es exactamente el control siguiente.

Tabla 11. Control multiescala: estimación lenta con recotización a 1s.

Δt estimación	Recotización	Modelo	PnL neto IC95	Fill	Quote cruzada
30s	1s	M2 Kalman RW	247.1 ± 59.8	2.3%	23.4%
30s	1s	M5 Kalman OFI	229.1 ± 58.2	2.3%	22.9%

El control multiescala de la Tabla 11 mantiene las oportunidades de cotización del caso base (recotiza y cancela cada segundo) y solo cambia la escala de la señal: el filtro se actualiza con retornos agregados de 30s y mantiene $\hat{\alpha}$ constante dentro del bloque. Kalman RW obtiene 247.1 frente a 191.8 del caso base a 1s; como los intervalos marginales se solapan, la comparación honesta es pareada por semilla y aparece en la tabla siguiente. Esta es la versión operativa de la idea multiescala que las conclusiones proponen refinar.

El salto de la variante OFI merece explicación propia: al promediar el proxy en bloques de 30 segundos, su ruido independiente se reduce aproximadamente en un factor raíz de 30, así que la segunda observación entra mucho más limpia; con una señal menos errática, el reservation price se desplaza menos y el quote crossing cae de 30.7% en el caso base a 22.9% en el control multiescala. La ganancia

no viene de predecir mejor, sino de dejar de convertir ruido del proxy en desplazamientos agresivos de quote; la comparación pareada de la tabla siguiente confirma si esa mejora es sistemática entre semillas.

Tabla 12. Diferencias pareadas por semilla en las comparaciones afirmadas.

Comparación (microestructura)	Dif. media	IC95 pareado	% semillas +
Multiescala RW (señal 30s, quotes 1s) - RW 1s	+55.3	± 61.7	66%
Multiescala OFI - OFI 1s	+93.7	± 62.6	68%
Kalman OU 1s - Baseline 1s	+36.2	± 14.9	76%
Walk-forward RW 30s - estático 30s	-8.6	± 55.9	44%
Proxy OFI 1s - ablación sin OFI 1s	-58.7	± 60.7	38%

La Tabla 12 responde a una objeción estadística legítima: los IC95 marginales de varias comparaciones se solapan, pero las 50 semillas son compartidas y la diferencia pareada tiene más potencia. La lectura es sobria: cuando el intervalo pareado cruza el cero, la comparación se describe como indistinguible y no como ranking; cuando no lo cruza, la afirmación queda blindada. Ninguna afirmación de este capítulo se apoya ya en comparar medias marginales con intervalos solapados. El IC95 pareado equivale a un contraste t bilateral al 5% con 49 grados de libertad; las dos diferencias que excluyen el cero, OU frente a baseline y la multiescala OFI, sobreviven además una corrección de Bonferroni para las cinco comparaciones de la tabla (p inferior a 0.01); el resto de comparaciones se describe como indistinguible.

6.3 COMISIONES Y PnL BRUTO

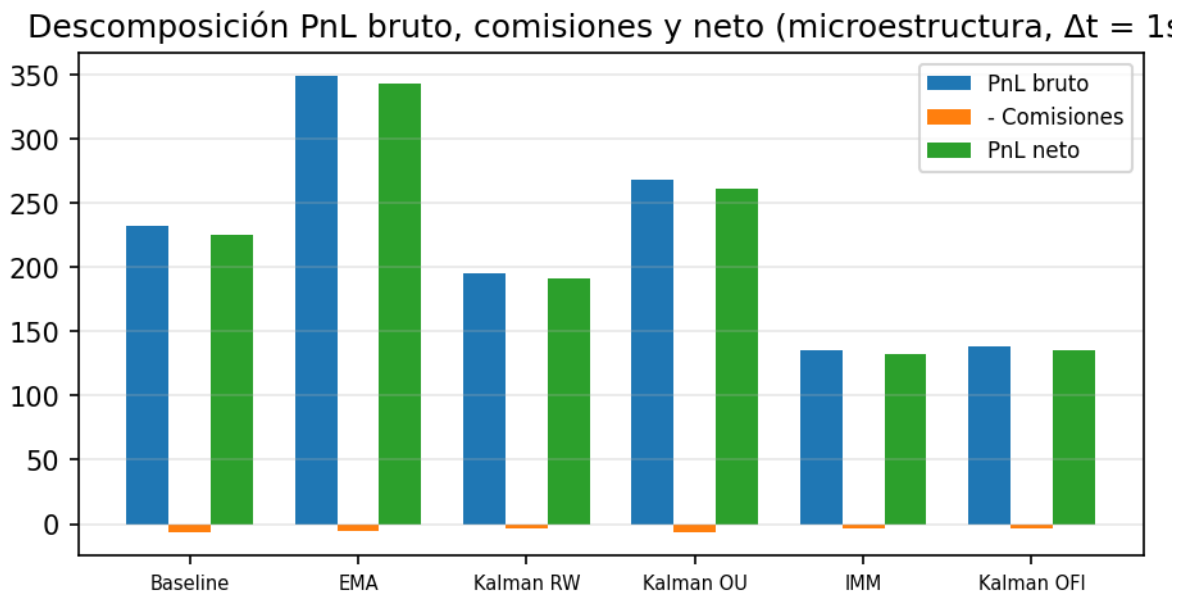


Figura 6. Descomposición entre PnL bruto, comisiones y PnL neto.

Separar PnL bruto y neto (Figura 6) permite responder a una duda clave: una estrategia puede tener predictibilidad y aun así no ser rentable después de costes. Tras corregir la ejecución, las comisiones siguen siendo una fricción visible, pero el ranking depende también del desplazamiento de quotes, inventario, fills cancelados y exposición temporal.

Una aclaración evita sobrevender el control de costes: con comisión proporcional al notional y fills que no dependen de ella, el PnL con $c = 0$ coincide con el PnL bruto por construcción, así que esa curva no es evidencia independiente. La evidencia real sobre el peso de los costes está en la sensibilidad de parámetros: para Kalman RW en microestructura a 1s (12 semillas), el PnL neto pasa de 215.4 sin comisiones a 211.7 con 2 puntos básicos y 206.3 con 5, una variación pequeña frente al efecto de τ , de Q o del propio motor de ejecución.

$$\Delta \text{PnL}_{\text{coste}} = \text{PnL}_{\text{bruto}} - \text{PnL}_{\text{neto}} = \sum_k f e e_k \quad (43)$$

En la figura las comisiones se dibujan como barra negativa (- Comisiones) para visualizar la identidad $\text{PnL neto} = \text{PnL bruto} - \text{comisiones}$.

6.4 DRIFT INVERTIDO Y AUSENCIA DE COMISIONES

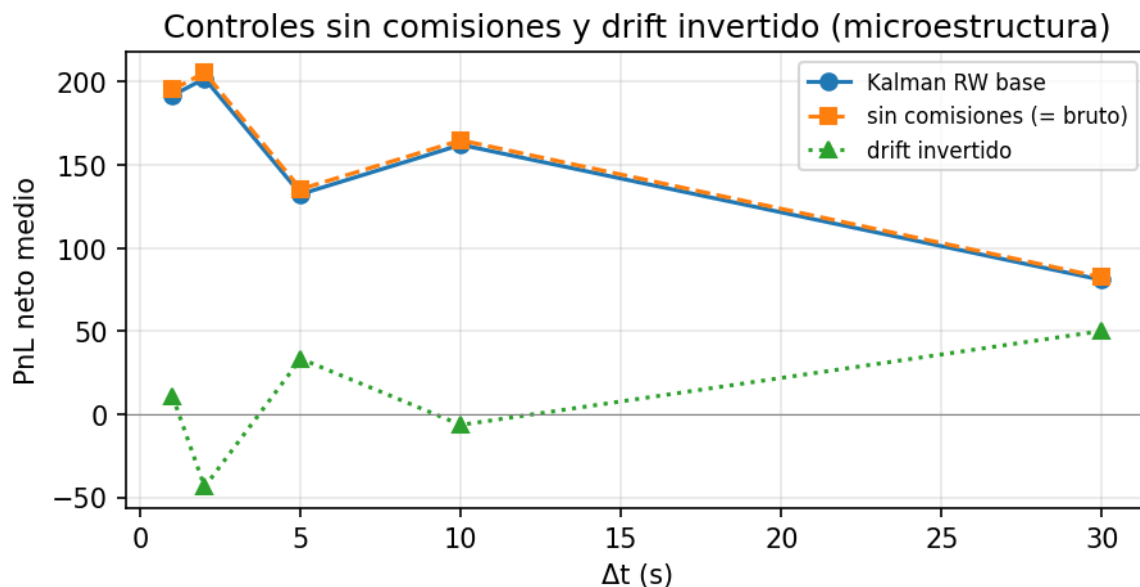


Figura 7. Controles sin comisiones y drift invertido.

La Figura 7 recorre las cinco escalas de ambos controles. El control de inversión de señal registra +10.8 a 1s, -43.7 a 2s, +33.4 a 5s, -6.4 a 10s, +50.1 a 30s en microestructura para Kalman RW. El patrón a Δt alto merece explicación en lugar de despacharse: con $\tau = 60s$ el término $\hat{\alpha}\tau$ desplaza el reservation price más de media anchura de spread con frecuencia estructural (quote crossing en torno al 25%), de modo que operar con el signo contrario coloca la quote en el lado que el flujo simulado tiende a llenar a mejor precio, con un fill rate casi idéntico (27.7% frente a 27.8% a 30s). Es un resultado in-sample de un único escenario: una estrategia con signo invertido heredaría los mismos riesgos de especificación en τ , Q y motor de ejecución, así que el control diagnostica la desalineación entre señal y ejecución, no descubre una estrategia. La lectura general del control es que, cuando ambos signos de la señal producen PnL positivo, la mayor parte del resultado procede de la provisión pasiva de spread y no de la información direccional.

El control $c = 0$ se mantiene por trazabilidad, pero hay que decirlo sin rodeos: en este simulador coincide exactamente con el PnL bruto (50 semillas: $195.3 = 195.3$ a 1s y $82.4 = 82.4$ a 30s para Kalman RW), porque la comisión no altera qué órdenes se ejecutan. La comparación informativa es neto frente a bruto (191.8 frente a 195.3 a 1s; 80.8 frente a 82.4 a 30s; en el baseline a 1s, 225.4 frente a 232.0) junto con la sensibilidad de 0 a 5 puntos básicos del apartado de parámetros: los costes existen, pero no gobiernan el ranking.

$$\text{Control}_{nofee}: c = 0, \text{Control}_{inv}: \hat{\alpha}_k \leftarrow -\hat{\alpha}_k \quad (44)$$

Los controles separan el efecto de las comisiones del efecto de invertir la dirección estimada.

6.5 FILL RATE Y SATURACIÓN

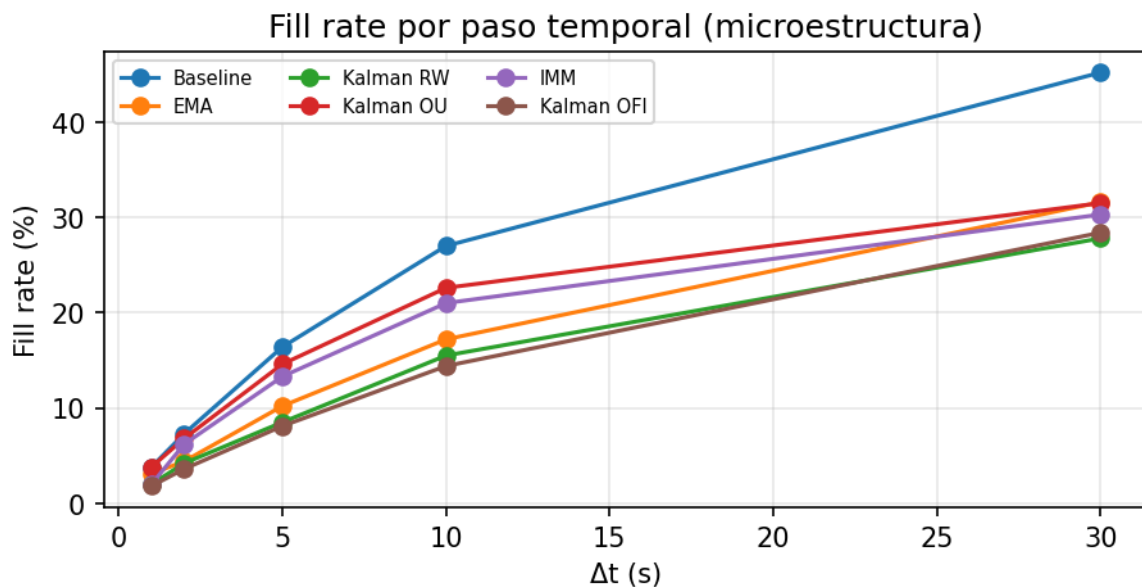


Figura 8. Fill rate por paso temporal.

El fill rate aumenta con Δt (Figura 8) porque $p = 1 - \exp(-\lambda\Delta t)$. En un simulador Poisson sin cancelaciones, mantener la quote durante más tiempo aumenta mecánicamente la probabilidad de ejecución. Las implicaciones operativas de esa exposición prolongada se desarrollan en la sección siguiente.

$$\lim_{\Delta t \rightarrow \infty} (1 - e^{-\lambda\Delta t}) = 1 \quad (45)$$

La saturación del fill rate a Δt altos es una propiedad matemática del simulador, no una garantía operativa real.

6.6 LECTURA OPERATIVA DE LA SIMULACIÓN

Cancelar una quote cruzada ex post corrige el backtest, pero no equivale a una regla realista de trading. Un motor de ejecución real debería impedir el cruce antes de enviar la orden, respetar tick size, decidir cuándo una quote pasa a ser agresiva y cancelar o recolocar si el libro cambia.

Una quote viva durante 30 segundos es, ante todo, exposición a stale quotes y selección adversa, no una recomendación operativa. La lectura práctica es multi-escala: estimar una componente lenta de drift y cotizar/cancelar en escala rápida, separando el horizonte estadístico del horizonte de ejecución.

El modelo Poisson captura una intuición útil, pero parcial: al aumentar Δt , $p = 1 - \exp(-\lambda\Delta t)$ incrementa fills de forma mecánica. Sin cola, prioridad, cancelaciones, latencia ni agentes informados, el simulador sirve para explicar mecanismos, no para extraer conclusiones de producción.

- Δt es la escala de observación y estimación: decide qué retornos ve el filtro.
- T es la vida efectiva de la quote dentro del modelo Poisson: decide durante cuánto tiempo puede ejecutarse.
- τ es el horizonte de riesgo del reservation price: decide cuánto pesa el drift estimado y la penalización de inventario.

$$b_t > S_t \Leftrightarrow \hat{\alpha}_t \tau - q_t \gamma \sigma_t^2 \tau > \frac{\delta_t^*}{2}, a_t < S_t \Leftrightarrow \hat{\alpha}_t \tau - q_t \gamma \sigma_t^2 \tau < -\frac{\delta_t^*}{2} \quad (46)$$

Una quote se cruza cuando el desplazamiento del reservation price por drift e inventario supera media distancia óptima de cotización. b_t y a_t abrevian aquí las quotes p_t^{bid} y p_t^{ask} de la ecuación (11). Por eso τ , Q de Kalman, inventario y spread afectan directamente a quote crossing.

6.7 SENSIBILIDAD DE Q, T Y PROXY OFI

Tabla 13. Sensibilidad Q fijo frente a Q MLE en microestructura.

Δt	Q	PnL neto IC95	Q usado	Precisión
1s	fixed Q default	191.8 \pm 53.6	0.000200	69.2%
1s	mle Q same path	455.2 \pm 61.4	0.000001	96.5%
30s	fixed Q default	80.8 \pm 54.9	0.000200	75.8%
30s	mle Q same path	188.9 \pm 58.9	0.000025	84.2%

Tabla 14. Sensibilidad del horizonte τ para Kalman RW.

Δt	τ	PnL neto IC95	Fill	$ q $
1s	10s	417.2 \pm 36.0	3.9%	5.64
1s	30s	325.5 \pm 42.9	3.3%	5.40
1s	60s	191.8 \pm 53.6	2.0%	4.71
30s	10s	316.7 \pm 53.1	44.8%	6.50
30s	30s	301.3 \pm 50.0	39.7%	6.51
30s	60s	80.8 \pm 54.9	27.8%	4.05

Tabla 15. Controles de fuga del proxy OFI sintético.

Δt	Variante OFI	PnL neto IC95	Precisión	Fill
1s	sin OFI (solo precio)	194.2 \pm 54.9	70.3%	2.0%
1s	proxy OFI actual	135.5 \pm 65.9	67.8%	1.8%
1s	proxy OFI retardado	162.8 \pm 62.4	67.8%	1.8%
1s	proxy OFI barajado	149.6 \pm 58.0	67.9%	1.8%

30s	sin OFI (solo precio)	72.1 ± 56.6	76.1%	28.1%
30s	proxy OFI actual	93.7 ± 60.4	77.8%	28.4%
30s	proxy OFI retardado	105.0 ± 50.5	77.9%	28.7%
30s	proxy OFI barajado	83.8 ± 59.1	77.7%	28.7%

Estas sensibilidades son fragilidades de especificación, no anexos menores. Q MLE se interpreta como diagnóstico in-sample: a 1s pasa de 191.8 a 455.2 y la precisión sube hasta 96.5%, pero ese ajuste usa la misma ruta para calibrar y evaluar. τ tampoco es neutro: a 30s, Kalman RW obtiene 316.7 con $\tau = 10s$, 301.3 con $\tau = 30s$ y 80.8 con $\tau = 60s$. El valor base de 60s es conservador y comparable, pero la conclusión económica cambia con τ . Hay además un detalle estadístico que no debe pasar desapercibido: el Q seleccionado por MLE a 1s cae en la frontera inferior del grid explorado (10^{-6}), con verosimilitud monótona decreciente en Q, así que el supuesto óptimo no es un máximo interior sino la firma de un drift casi constante en el generador.

La variante sin OFI es una ablación limpia: el mismo filtro de precio sin la segunda actualización. Una anotación necesaria: el filtro de precio de M5 usa $R = 0.06$ y $P0 = 0.04$ frente a los 0.05/0.05 de M2, así que la comparación directa M2-M5 mezcla el efecto del OFI con ese cambio de parámetros. La comparación limpia del OFI es siempre interna a M5, contra su propia ablación. En una versión anterior se fijaba $OFI = 0$ manteniendo la actualización, lo que encogía $\hat{\alpha}$ hacia cero en cada paso y convertía el control en otro estimador; ese defecto está corregido.

Con la ablación como referencia, el proxy OFI no domina: a 1s obtiene 135.5 frente a 194.2 del filtro solo-precio, aunque la diferencia pareada cruza el cero; a 30s recupera terreno (93.7 frente a 72.1) con una precisión mayor (77.8% frente a 76.1%). En ninguno de los dos cortes la precisión adicional ordena el PnL: acertar más el signo no se traduce mecánicamente en monetizar mejor.

Una peculiaridad de la tabla exige explicación para que no parezca un error: el barajado apenas mueve la precisión respecto al proxy en vivo. En microestructura el drift es casi constante y el OFI es α más ruido independiente, es decir, una serie casi intercambiable: permutarla no cambia su distribución, de modo que el control solo puede detectar fuga temporal, que aquí no existe. El barajado sí afecta al PnL, donde importan los valores paso a paso. Por eso el control se ejecuta también en el escenario de cambio de régimen, donde el orden temporal sí lleva información direccional; allí el barajado degrada la precisión (87.1% en vivo frente a 54.9% barajado a 30s), confirmando que el control funciona cuando hay estructura que destruir.

Como el proxy nace del mismo generador que el drift latente, su cercanía informativa está exagerada frente a un libro real; defender una señal operativa exigiría OFI de libro L2/L3.

6.8 RIESGO, INVENTARIO Y VALOR ECONÓMICO DE LA SEÑAL

Tabla 16. Métricas de riesgo y ejecución en microestructura.

At	Modelo	DD	$ q _{max}$	Rechazo inv.	Quote cruzado	Simult. supr.	PnL/acierto	PnL/error	n acierto	n error	n señal
1s	M0 Baseline	-9.6	6.12	0.0%	0.0%	0.1%	N/A	N/A	N/A	N/A	0

1s	M1 EMA	- 36. 4	11.94	3.3%	12.8%	0.1%	0.202	-0.390	14756 8	3243 2	10897 8
1s	M2 Kalman RW	- 47. 1	10.60	1.6%	28.6%	0.1%	0.281	-0.459	12460 1	5539 9	12779 5
1s	M3 Kalman OU	- 15. 3	9.04	0.0%	4.7%	0.1%	0.334	-0.456	12045 3	5954 7	46365
1s	M4 IMM	- 70. 5	10.60	1.8%	28.6%	0.1%	0.153	-0.194	11963 8	6036 2	12562 2
1s	M5 Kalman OFI	- 75. 4	10.70	2.1%	30.7%	0.1%	0.060	-0.010	12199 4	5800 6	13197 2
30 s	M0 Baselin e	- 79. 2	10.58	1.7%	0.0%	48.1%	N/A	N/A	N/A	N/A	0
30 s	M1 EMA	- 30. 2	10.96	2.6%	20.5%	22.5%	2.670	-1.443	5294	706	3582
30 s	M2 Kalman RW	- 62. 4	8.62	0.9%	25.4%	20.4%	0.787	0.317	4550	1450	3870
30 s	M3 Kalman OU	- 55. 9	9.12	1.2%	21.0%	24.8%	1.079	0.248	4402	1598	3467
30 s	M4 IMM	- 63. 2	9.80	1.8%	21.9%	23.1%	1.393	-0.082	4750	1250	3592
30 s	M5 Kalman OFI	- 68. 5	9.46	0.8%	24.7%	21.0%	0.751	0.886	4666	1334	3815

La precisión direccional se mantiene como diagnóstico estadístico, pero no se usa como criterio económico suficiente. Las métricas disponibles combinan drawdown, inventario, rechazo por límite, turnover implícito en fills, quote crossing, fills simultáneos suprimidos, PnL/acierto y PnL/error. En el baseline no se informa acierto/error porque no emite una señal direccional. Las columnas PnL/acierto y PnL/error son medias pooled por paso: multiplicadas por sus conteos reconstruyen exactamente el PnL total de cada configuración. El límite max_inventory = 12 está además activo en las colas: los |q| máximos observados alcanzan entre 8.6 y 11.9, de modo que las pérdidas de los peores modelos están parcialmente acotadas por esa regla y serían mayores sin ella. Los percentiles 10 y 90 del PnL por configuración están calculados en summary_with_ci.csv y se reportan en el anexo; para producción faltarían hit ratio por lado y PnL condicionado a inventario.

6.8.1 CUANDO ACERTAR DIRECCIÓN NO BASTA

El caso más ilustrativo aparece en el proxy OFI a 30s: el PnL medio por paso cuando acierta la dirección es 0.751, calculado sobre 4666 pasos correctos, mientras que cuando falla es 0.886, sobre 1334 pasos incorrectos: el modelo gana más por paso cuando se equivoca que cuando acierta. La métrica se condiciona al signo del drift verdadero, no a que la señal supere el umbral de silencio, y en este escenario de drift casi constante cubre todos los pasos; las medias son pooled (suma del PnL condicionado dividida por el número total de pasos de cada grupo), de modo que multiplicadas por sus conteos reconstruyen exactamente el PnL total de la Tabla 20 ($0.751 \cdot 4666 + 0.886 \cdot 1334 = 50 \cdot 93.7$). Kalman RW a 30s no invierte el orden (0.787 al acertar frente a 0.317 al fallar), lo que subraya que la

desalineación entre señal y ejecución depende de la especificación del modelo y no es una regla del simulador. La señal direccional está desalineada con la ejecución: acierta el signo, pero lo traduce en quotes que se llenan en momentos o lados económicamente desfavorables.

El mecanismo detrás de esa inversión merece hacerse explícito. La variación de PnL por paso está dominada por la revalorización mark-to-market del inventario acumulado, no por los fills de ese paso: cuando el filtro acierta el signo del drift, el market maker puede llegar posicionado en contra (compró durante la caída anterior que originó la señal) y la revalorización le drena; cuando falla, la posición heredada juega a favor. Es la misma desalineación entre señal y ejecución que formaliza la condición de cruce de la ecuación (46): el desplazamiento $\hat{\alpha}\tau$ decide dónde se colocan las quotes hoy, pero el PnL del paso lo decide el inventario de ayer.

Tabla 17. Métricas normalizadas por fill y notional en microestructura.

Δt	Modelo	PnL	PnL/fill	PnL/1000 not.	Comisiones	Fill bruto	Fill válido	Fills
1s	M0 Baseline	225.4	0.833	6.871	6.6	3.8%	3.8%	270.3
30s	M0 Baseline	85.8	0.782	6.400	2.6	45.2%	45.2%	108.5
1s	M1 EMA	343.8	1.481	12.116	5.4	3.1%	3.5%	220.4
30s	M1 EMA	262.3	3.535	29.009	1.8	31.6%	39.7%	75.8
1s	M2 Kalman RW	191.8	1.267	10.391	3.5	2.0%	2.8%	143.9
30s	M2 Kalman RW	80.8	1.190	9.842	1.6	27.8%	37.3%	66.8
1s	M3 Kalman OU	261.5	0.963	7.917	6.6	3.8%	3.9%	270.6
30s	M3 Kalman OU	102.9	1.311	10.824	1.8	31.5%	39.9%	75.7
1s	M4 IMM	132.3	0.815	6.747	3.5	2.0%	2.8%	143.8
30s	M4 IMM	130.3	1.736	14.274	1.8	30.3%	38.8%	72.8
1s	M5 Kalman OFI	135.5	0.858	7.011	3.2	1.8%	2.6%	131.7
30s	M5 Kalman OFI	93.7	1.384	11.379	1.7	28.4%	37.7%	68.2

La normalización evita leer el PnL como calidad pura de predicción. Un modelo puede obtener más PnL porque opera más, porque sus fills válidos son más rentables o porque soporta menor coste por unidad de notional. La comparación entre fill bruto y fill válido separa además la caída provocada por cancelaciones de quotes cruzadas de la probabilidad de ejecución de las quotes que sí permanecen activas. Las columnas PnL/fill y PnL/1000 notional se calculan por semilla y después se promedian (media de ratios); por eso no coinciden en general con el cociente de las medias de las columnas PnL y Fills, especialmente en los modelos con mayor dispersión entre semillas.

6.9 SENSIBILIDAD DE PARÁMETROS DE MERCADO

Tabla 18. Sensibilidad one-at-a-time de parámetros de mercado para Kalman RW en microestructura (12 semillas).

Parámetro	Valor	Δt	PnL neto IC95	Fill	DD	Quote cruzada
A	0.07000	1s	116.7 ± 118.8	1.3%	-55.5	28.4%
A	0.07000	30s	222.0 ± 82.7	23.3%	-14.5	25.1%
A	0.11000	1s	211.7 ± 122.0	2.1%	-35.4	28.3%
A	0.11000	30s	157.3 ± 108.1	27.7%	-35.1	25.1%
A	0.16000	1s	188.7 ± 133.4	2.9%	-51.8	29.0%
A	0.16000	30s	30.4 ± 148.5	30.2%	-80.6	25.1%
alpha scale	0.50000	1s	105.1 ± 69.1	2.1%	-42.5	27.9%
alpha scale	0.50000	30s	78.2 ± 45.8	31.5%	-20.7	21.4%
alpha scale	1.00000	1s	211.7 ± 122.0	2.1%	-35.4	28.3%
alpha scale	1.00000	30s	157.3 ± 108.1	27.7%	-35.1	25.1%
alpha scale	1.50000	1s	318.2 ± 139.7	1.9%	-32.0	29.5%
alpha scale	1.50000	30s	8.8 ± 122.0	22.9%	-88.7	30.9%
commission rate	0.00000	1s	215.4 ± 122.0	2.1%	-35.0	28.3%
commission rate	0.00000	30s	158.9 ± 108.1	27.7%	-34.8	25.1%
commission rate	0.00020	1s	211.7 ± 122.0	2.1%	-35.4	28.3%
commission rate	0.00020	30s	157.3 ± 108.1	27.7%	-35.1	25.1%
commission rate	0.00050	1s	206.3 ± 121.8	2.1%	-35.9	28.3%
commission rate	0.00050	30s	154.9 ± 108.2	27.7%	-35.5	25.1%
k	0.85000	1s	290.5 ± 102.3	2.6%	-24.1	21.8%
k	0.85000	30s	297.5 ± 57.6	33.8%	-10.5	18.2%
k	1.15000	1s	211.7 ± 122.0	2.1%	-35.4	28.3%
k	1.15000	30s	157.3 ± 108.1	27.7%	-35.1	25.1%
k	1.45000	1s	137.4 ± 139.5	1.6%	-59.3	32.5%
k	1.45000	30s	73.6 ± 119.7	23.9%	-52.8	29.9%
micro bounce	0.10000	1s	176.0 ± 134.1	2.2%	-56.2	27.2%
micro bounce	0.10000	30s	157.3 ± 108.1	27.7%	-35.1	25.1%
micro bounce	0.19000	1s	211.7 ± 122.0	2.1%	-35.4	28.3%
micro bounce	0.19000	30s	157.3 ± 108.1	27.7%	-35.1	25.1%
micro bounce	0.28000	1s	80.9 ± 132.3	1.5%	-78.5	32.4%
micro bounce	0.28000	30s	157.3 ± 108.1	27.7%	-35.1	25.1%

Esta sensibilidad es un diagnóstico one-at-a-time con 12 semillas, complementario a los resultados principales de 50 semillas. Los intervalos de confianza miden variación Monte Carlo bajo un generador fijo, mientras que A, k, costes, rebote bid-ask y escala de drift miden riesgo de especificación del simulador. En particular, A, k y alpha_scale alteran fill rate, quote crossing y signo del PnL con mucha más fuerza que un simple cambio de comisión; las comisiones importan, pero no son el cuello de botella dominante frente a ejecución, τ , Q de Kalman y agresividad de quotes. Con 12 semillas varios intervalos se solapan, de modo que esta lectura es cualitativa y direccional, no un contraste formal.

6.10 VALIDACIÓN WALK-FORWARD

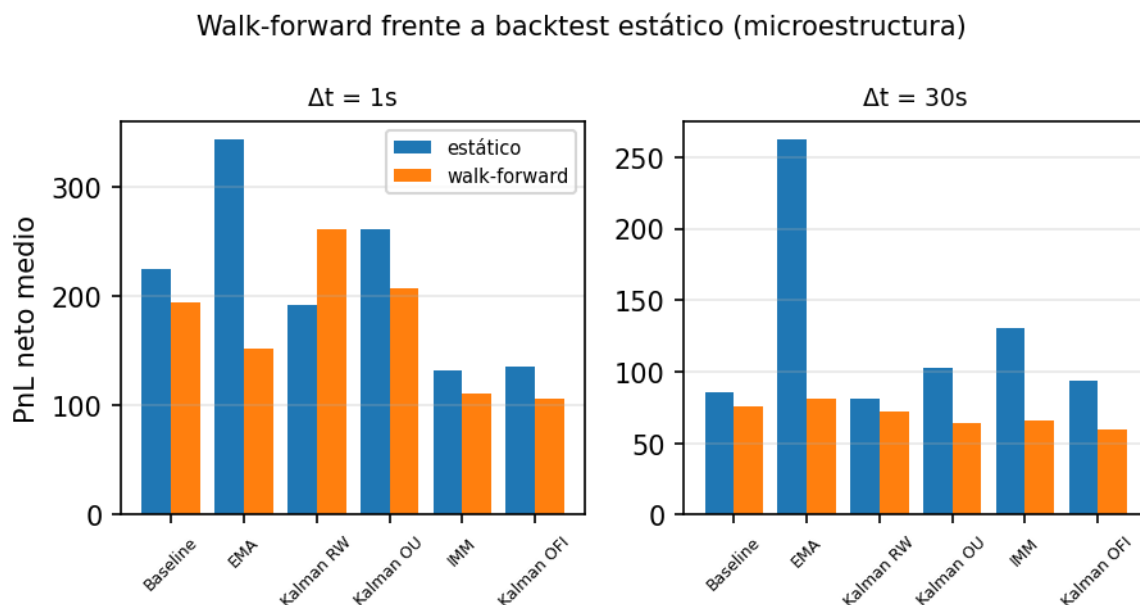


Figura 9. Validación walk-forward frente a backtest estático.

La validación walk-forward (Figura 9) se amplía a microestructura y cambio de régimen, a $\Delta t = 1s$ y $30s$, con las 50 semillas reproducibles. Importa precisar qué se compara: el backtest estático recorre 3600 segundos continuos, mientras que la columna walk-forward suma cinco ventanas de 600 segundos con inventario a cero y estimador reiniciado al inicio de cada una, y con una semilla de ejecución distinta por ventana; solo M2 recalibra Q en la ventana de entrenamiento anterior, mientras que el resto opera con hiperparámetros fijos (la semivida del EMA, κ del OU, la matriz Π del IMM), cuya calibración fuera de muestra queda como línea futura. Para esos modelos la comparación mide estabilidad por tramos y sensibilidad a los reinicios de estado, no una validación fuera de muestra en sentido estricto. Con esa lectura, Kalman RW en microestructura pasa de 191.8 a 261.3 a 1s, con el 89% de las ventanas en positivo: los reinicios truncan las rachas adversas largas, lo que apunta a la acumulación de exposición, más que al signo de la señal, como origen de parte de la fragilidad del caso base. A 30s, en cambio, la diferencia pareada es indistinguible de cero (-8.6 ± 55.9), de modo que el efecto de los reinicios se concentra en la escala rápida.

$$\text{PnL}_{WF} = \sum_{m=1}^M \text{PnL}(\theta_m; \mathcal{D}_m^{\text{test}}), \theta_m = \text{fit}(\mathcal{D}_m^{\text{train}}) \quad (47)$$

Cada ventana usa parámetros fijados con datos anteriores y evalúa en un tramo posterior.

6.11 RESUMEN DE MÉTRICAS Y TRAZABILIDAD




Figura 10. Métricas principales a $\Delta t = 1s$.

La Figura 10 y la tabla siguiente condensan la foto a 1s para los seis modelos.

Tabla 19. Métricas agregadas a $\Delta t = 1s$ para todos los modelos.

Modelo	PnL neto	Comisiones	Precisión	Fill rate
M0 Baseline	225.2	5.8	No aplica	3.8%
M1 EMA	145.9	2.7	76.1%	1.8%
M2 Kalman RW	142.2	2.0	68.5%	1.3%
M3 Kalman OU	472.8	4.7	67.1%	3.1%
M4 IMM	359.3	3.3	68.8%	2.2%
M5 Kalman OFI	131.3	2.0	74.0%	1.4%

Tabla 20. PnL neto medio por escenario, modelo y Δt .

Escenario	Δt	Baseline	EMA	Kalman RW	Kalman OU	IMM	Kalman OFI
Alta volatilidad sin drift	1s	219.2	69.8	55.7	99.1	62.5	76.6
Alta volatilidad sin drift	30s	88.4	51.1	17.6	42.0	23.3	60.3
Cambio de régimen	1s	234.7	106.5	90.7	205.3	134.8	110.9
Cambio de régimen	30s	69.4	41.9	38.4	34.7	56.8	26.9
Mercado lateral	1s	229.2	115.1	88.6	171.6	137.3	89.3
Mercado lateral	30s	88.6	70.0	39.4	56.3	36.5	54.5
Microestructura bid-ask	1s	225.4	343.8	191.8	261.5	132.3	135.5
Microestructura bid-ask	30s	85.8	262.3	80.8	102.9	130.3	93.7
Tendencia alcista limpia	1s	201.1	-127.0	229.2	1264.5	1062.4	-30.3
Tendencia alcista limpia	30s	74.4	-466.3	-236.8	-249.0	-308.9	-753.4
Tendencia bajista ruidosa	1s	241.7	367.4	197.1	834.7	626.6	405.9
Tendencia bajista ruidosa	30s	108.7	-231.7	-149.2	-124.6	-116.6	-419.7

La tabla de escenarios es una media de diseño experimental, no una distribución de mercado. Tendencia alcista limpia y tendencia bajista ruidosa son pruebas de mecanismo: a 1s, Kalman OU alcanza 1264.5 y 834.7 respectivamente, pero ese dominio puede depender del generador, del turnover, del inventario y del régimen impuesto.

El extremo negativo de la tabla también tiene lectura mecánica: EMA a 30s en tendencia alcista limpia cae hasta -466.3. Con bloques de 30 segundos y semivida de 45, la media exponencial reacciona con uno o dos bloques de retraso; en una tendencia persistente eso deja el centro de quotes por detrás del precio, concentra las ejecuciones en el lado adverso y acumula inventario en contra. El mismo suavizado que protege en mercados laterales se convierte en un sesgo sistemático cuando el drift no revierte.

El baseline tampoco es 'no hacer nada': es un market maker activo sin drift, que cotiza y captura spread bajo las reglas del simulador. En el agregado a 30s obtiene 85.9 mientras todos los modelos con drift quedan en negativo. Bajo estos supuestos, proveer liquidez sin predicción puede superar a modelos con drift mal monetizado.

Tabla 21. Validación walk-forward ampliada.

Escenario	Δt	Modelo	Estático IC95	Walk-forward IC95	Ventanas +
Microestructura bid-ask	1s	M0 Baseline	225.4 ± 9.8	194.2 ± 7.5	100%
Microestructura bid-ask	1s	M1 EMA	343.8 ± 45.2	151.7 ± 17.0	94%
Microestructura bid-ask	1s	M2 Kalman RW	191.8 ± 53.6	261.3 ± 17.6	89%
Microestructura bid-ask	1s	M3 Kalman OU	261.5 ± 20.2	207.9 ± 14.8	99%
Microestructura bid-ask	1s	M4 IMM	132.3 ± 58.7	110.9 ± 13.4	84%
Microestructura bid-ask	1s	M5 Kalman OFI	135.5 ± 65.9	106.0 ± 13.8	83%
Microestructura bid-ask	30s	M0 Baseline	85.8 ± 63.5	75.4 ± 10.2	82%
Microestructura bid-ask	30s	M1 EMA	262.3 ± 52.0	81.1 ± 10.6	88%
Microestructura bid-ask	30s	M2 Kalman RW	80.8 ± 54.9	72.2 ± 10.6	84%
Microestructura bid-ask	30s	M3 Kalman OU	102.9 ± 54.3	64.2 ± 10.8	80%
Microestructura bid-ask	30s	M4 IMM	130.3 ± 66.1	66.3 ± 9.9	86%
Microestructura bid-ask	30s	M5 Kalman OFI	93.7 ± 60.4	59.6 ± 8.8	81%
Cambio de régimen	1s	M0 Baseline	234.7 ± 32.8	194.6 ± 19.5	88%
Cambio de régimen	1s	M1 EMA	106.5 ± 35.6	85.8 ± 21.1	78%
Cambio de régimen	1s	M2 Kalman RW	90.7 ± 34.4	137.8 ± 24.5	82%
Cambio de régimen	1s	M3 Kalman OU	205.3 ± 42.6	169.7 ± 26.2	88%
Cambio de régimen	1s	M4 IMM	134.8 ± 36.1	119.7 ± 21.1	81%
Cambio de régimen	1s	M5 Kalman OFI	110.9 ± 30.4	94.7 ± 14.5	87%
Cambio de régimen	30s	M0 Baseline	69.4 ± 31.6	68.2 ± 16.9	78%
Cambio de régimen	30s	M1 EMA	41.9 ± 21.7	41.3 ± 11.8	75%
Cambio de régimen	30s	M2 Kalman RW	38.4 ± 22.8	35.7 ± 10.1	78%
Cambio de régimen	30s	M3 Kalman OU	34.7 ± 21.2	37.9 ± 10.7	73%

Cambio de régimen	de	30s	M4 IMM	56.8 ± 23.4	37.2 ± 9.4	77%
Cambio de régimen	de	30s	M5 Kalman OFI	26.9 ± 23.3	41.8 ± 9.7	74%

En la lectura de la Tabla 21 debe recordarse la asimetría señalada al inicio de la sección: solo M2 recalibra Q por ventana, de modo que las columnas walk-forward del resto de modelos miden estabilidad por tramos con hiperparámetros fijos y no son directamente comparables entre modelos como validación fuera de muestra.

Todas las cifras citadas en esta sección proceden de CSV generados por el pipeline: dt_sensitivity_table.csv, escenario_model_dt_heatmap.csv, controls_no_fee_inverted_alpha.csv, q_sensitivity.csv, tau_sensitivity.csv, ofi_leakage_controls.csv, execution_dt_decomposition.csv, multiscale_control.csv, risk_execution_summary.csv y walkforward_summary.csv.

6.12 INTERPRETACIÓN DE LOS MECANISMOS

6.12.1 BASELINE Y BENCHMARKS SIMPLES

El baseline es un market maker activo sin drift, no una cartera inmóvil. Su fortaleza obliga a interpretar el TFM desde una pregunta más exigente: una señal predictiva solo aporta valor si mejora el precio medio de ejecución frente a proveer liquidez de forma disciplinada. EMA cumple otra función de control: suaviza retornos sin introducir toda la maquinaria bayesiana, por lo que sirve para detectar si Kalman gana por información o solo por regularización. Ese círculo se cierra con un dato incómodo y útil: EMA supera a Kalman RW en precisión direccional (76.1% frente a 68.5% a 1s en el agregado), lo que confirma que el valor del filtrado bayesiano en este banco no está en acertar más el signo, sino en la gestión explícita de la incertidumbre, y que la precisión por sí sola no ordena los modelos por PnL.

- A 1s Kalman RW es positivo, pero no domina al baseline ni a OU en todos los escenarios.
- A 30s la media agregada de Kalman RW cae de 142.2 a -35.0, aunque la SNR mejore.
- El ranking por PnL solo tiene sentido junto a inventario, drawdown, fill rate y quote crossing.

6.12.2 MODELOS KALMAN, OU E IMM

Kalman RW representa la hipótesis más directa de drift persistente. Bajo ejecución corregida no hay una mejora monetaria al aumentar Δt : hay una señal menos ruidosa que se traduce peor en quotes. En microestructura pasa de 191.8 a 1s a 80.8 a 30s; en agregado, de 142.2 a -35.0.

Kalman OU aporta una lectura distinta: domina en pruebas de tendencia alcista limpia y bajista ruidosa, pero esos escenarios son mecanismos controlados, no mercados típicos. Su buen comportamiento puede venir de la forma del generador, del turnover y del régimen de drift impuesto. IMM, por su parte, no debe venderse como detector perfecto de regímenes; su valor está en promediar hipótesis cuando el filtro no sabe si el drift persiste, revierte o se degrada.

6.12.3 EL CONTRASTE RW-OU COMO MECANISMO

El contraste entre RW y OU no es una curiosidad de ranking, sino el mismo mecanismo de ejecución visto desde la elección de modelo. A 1s, Kalman OU alcanza 472.8 en el agregado frente a 225.2 del baseline, con el menor quote crossing de los modelos con drift (4.7% frente a 28.6% de RW en microestructura): la disipación $F = \exp(-\kappa\Delta t)$ encoge sistemáticamente $\hat{\alpha}$, y con ella el desplazamiento $\hat{\alpha}\tau$ del reservation price, así que OU monetiza mejor no porque prediga más, sino porque su prior de reversión regulariza la agresividad de las quotes, exactamente el cuello de botella que este trabajo identifica. La cautela sigue siendo obligada porque su dominio en los escenarios de tendencia depende del generador, pero la lección de diseño es transferible: en este simulador, un prior que disipa la señal protege más que un prior que la persigue.

6.12.4 OFI Y ACCURACY

OFI mejora la precisión direccional a Δt altos (a 1s llega a empeorarla frente a la ablación sin OFI), sin que eso pruebe valor económico: la comparación relevante es contra la ablación, no contra el baseline, y la tabla de controles muestra que la ventaja de precisión no se traduce de forma estable en PnL. Su proximidad informativa frente a un libro real quedó acotada en los controles de fuga.

6.12.5 EJECUCIÓN, INVENTARIO Y COSTE ECONÓMICO

La capa de ejecución es el cuello de botella. Cancelar quotes cruzadas ex post evita contabilizar fills imposibles como pasivos, pero un sistema real tendría que impedir el cruce ex ante, respetar tick size, decidir si una orden se vuelve agresiva y cancelar quotes obsoletas antes de que acumulen selección adversa. El modelo Poisson aumenta fills por construcción cuando sube Δt ; las limitaciones del motor quedaron acotadas en la lectura operativa del capítulo anterior y en la matriz de riesgos.

El PnL condicionado a aciertos y errores resume la tesis operativa: acertar dirección no basta si la quote se desplaza hacia ejecuciones adversas. Por eso las comisiones se mantienen como fricción, pero el análisis da más peso a τ , a la calibración de Q y a la vida de las quotes: dónde se colocan, cuánto tiempo quedan expuestas y qué inventario dejan detrás.

Tabla 22. Síntesis causal del hallazgo de Δt .

Mecanismo	Evidencia	Efecto sobre PnL	Riesgo de interpretación
SNR de bloque	Microestructura pasa de 0.030 a 1s a 0.581 a 30s.	Hace la señal menos ruidosa.	No implica PnL positivo; SNR 30s sigue por debajo de 1.
PnL Kalman RW	Agregado 142.2 a -35.0; microestructura 191.8 a 80.8.1 -> 9.1.	Se deteriora en el backtest estático base.	Walk-forward mejora algunos cortes; no invalida la fragilidad de ejecución.
Fill rate Poisson	$p = 1 - \exp(-\lambda\Delta t)$.	Aumenta fills al subir vida de quote.	El aumento puede venir de exposición, no de mejor señal.
Quote crossing	Kalman RW mantiene crossing de 25.4% a 30s.	Desplaza quotes hacia zonas agresivas.	Debe controlarse ex ante en un motor realista.
τ y Q de Kalman	τ altera fuertemente el PnL a 30s y el Q MLE degenera a la frontera del grid.	Condicionan la agresividad del reservation price.	Son riesgo de especificación, no detalle menor.

OFI y accuracy	proxy_ofi_current mejora precisión pero no siempre PnL.	Muestra separación entre acertar y monetizar.	El proxy OFI es sintético y cercano al generador.
Baseline/EMA	Baseline y EMA compiten o dominan en cortes centrales.	La provisión de liquidez simple es un benchmark exigente.	Puede reflejar generosidad del simulador de fills.
Multiescala	Recotizar a 1s con señal de 30s mantiene las oportunidades de ejecución.	Separa la información de la señal del número de oportunidades.	Sigue siendo un simulador sin colas ni cancelaciones.

6.13 MATRIZ DE RIESGOS INTERPRETATIVOS

Tabla 23. Matriz de riesgos interpretativos.

Riesgo	Evidencia observada	Decisión narrativa	Límite que permanece
Datos sintéticos	Drift verdadero y escenarios controlados.	Leer los resultados como prueba de mecanismo.	No hay contraste real; el TFM se mantiene como simulación controlada.
Ejecución Poisson	$p = 1 - \exp(-\lambda\Delta t)$ aumenta fills mecánicamente.	Separar estimación de exposición y advertir saturación.	No hay cola, cancelaciones ni agentes informados.
Quote crossing	Kalman RW mantiene crossing cercano al 25% a 30s.	Tratar ejecución como fuente de riesgo de modelo.	La regla ex post no sustituye control ex ante.
Stale quotes	Una quote viva 30s puede quedarse desalineada del libro.	Proponer estimación lenta y cotización/cancelación rápida.	No se modela latencia ni actualización intrabloque.
Calibración in-sample	Q MLE alcanza 455.2 a 1s en la misma ruta y su óptimo cae en la frontera del grid.	Presentarlo como diagnóstico, no como mejora robusta.	Hace falta calibración fuera de muestra con un óptimo interior.
OFI sintético	La referencia es la ablación sin OFI (solo precio); la mejora de precisión del proxy no implica mejora económica.	Separar accuracy de valor económico.	OFI real requiere eventos o snapshots de libro.
Parámetros A, k y τ	τ cambia el signo a 30s y A/k alteran fills.	Elevarlos a riesgo de especificación.	No hay calibración a un venue real.
HJB no resuelta	Se usa estimador + reservation price, no control acoplado.	Mantener la HJB como motivación y trabajo futuro.	Una solución numérica completa queda fuera del alcance.

A los riesgos de la matriz se añaden dos advertencias de especificación identificadas en la revisión final: la dependencia mecánica de $\hat{\sigma}$ respecto a Δt , que arrastra la penalización $\gamma\sigma^2\tau$ y confunde parcialmente el canal de la escala temporal, y el carácter determinista del rebote sintético, que convierte parte de la mejora de SNR al agregar en un artefacto de paridad. Ambas se han cerrado con controles específicos: con la volatilidad por segundo fija el deterioro a Δt alto persiste (`fixed_sigma_control.csv`) y con rebote estocástico la mejora de SNR sobrevive sin el artefacto de paridad (`stochastic_bounce_control.csv`), de modo que ninguno de los dos artefactos gobierna el hallazgo.

Capítulo 7. CONCLUSIONES Y TRABAJOS FUTUROS

La conclusión principal es que la señal puede existir estadísticamente y, aun así, fallar al monetizarse. La agregación temporal reduce parte del ruido microestructural, pero en el backtest estático base Kalman RW no convierte esa mejora de SNR en PnL robusto: a 30s la monetización se deteriora y el resultado queda dominado por fills adversos, órdenes que envejecen expuestas y acumulación de inventario. El ejercicio walk-forward matiza el cuadro: a 1s los tramos con estado reiniciado mejoran el caso base de Kalman RW, mientras que a 30s el efecto desaparece; como solo el filtro RW recalibra Q por ventana, esa lectura habla sobre todo de acumulación de exposición, no de robustez de calibración.

El resultado más relevante para un trader no es elegir un modelo ganador, sino identificar dónde se rompe la cadena de valor. Un filtro con drift desplaza el reservation price; si ese desplazamiento genera quotes demasiado agresivas o deja órdenes vivas demasiado tiempo, acertar dirección no basta. El proxy OFI a 30s, que gana más por paso cuando falla que cuando acierta, resume esa desconexión entre señal y ejecución.

Con ello quedan cubiertos los cinco objetivos fijados en el primer capítulo: el pipeline reproducible existe y regenera todas las evidencias (Anexo I); la comparación homogénea separa PnL bruto, comisiones y PnL neto (Tablas 10, 20 y 21); el efecto de Δt sobre SNR, autocorrelación, fill rate e inventario está medido (Tablas 8 a 11); los controles de señal invertida, coste cero y sensibilidad separan predictibilidad de rentabilidad neta (Figura 7 y Tablas 14 a 16); y la defensa del hallazgo como diagnóstico sintético queda formalizada en la matriz de riesgos (Tabla 23). La contribución académica queda acotada con más precisión. Avellaneda-Stoikov proporciona el motor de quotes; Guéant y otros autores ya desarrollan variantes con inventario; Cartea-Jaimungal ofrecen marcos de control más generales. La aportación propia es una evaluación reproducible de la estimación online del drift, sus límites empíricos y su dependencia de la capa de ejecución.

7.1 DISCUSIÓN DE ALCANCE

7.1.1 SIMULACIÓN FRENTE A PRODUCCIÓN

Los escenarios sintéticos reducen ambigüedad causal porque se conoce el drift verdadero. El alcance del TFM termina ahí: no se añade sanity check con datos reales y, por tanto, no se presentan las cifras como evidencia empírica de mercado. En producción no se observa α , el libro cambia dentro del intervalo y la ejecución depende de cola, latencia, cancelaciones, tick size y competencia informada. Por eso las magnitudes del documento se leen en la moneda interna del simulador, no como euros esperados en un venue concreto.

7.2 LÍNEAS FUTURAS

7.2.1 OPERATIVAS

- Simulador de libro de órdenes con cancelaciones, latencia y prioridad de cola, con control ex ante de cruces y medición de PnL por lado.
- Refinar la estrategia multiescala que aquí se esboza como control (señal a 30s, recotización a 1s): decidir el sesgo con la señal lenta y gestionar colas y cancelaciones en la escala rápida.
- Regularización explícita de estimadores adaptativos y límites dinámicos de inventario para evitar exceso de confianza.

7.2.2 ACADÉMICAS

- Calibración de Q , R y τ genuinamente fuera de muestra, con óptimos interiores del grid.
- Extender la simulación controlada a más regímenes, colas de distribución, shocks de liquidez, cambios graduales de drift y proxies de flujo menos cercanos al drift latente.
- Resolución numérica, no analítica, de formulaciones HJB con régimen, incorporando el estado del filtro al control.

Estas extensiones no cambian la tesis final: la predicción de drift solo tiene valor si la capa de ejecución conserva ese valor hasta el PnL neto.

BIBLIOGRAFÍA

- [1] Avellaneda, M. y Stoikov, S. (2008). High-frequency trading in a limit order book. *Quantitative Finance*, 8(3), 217-224.
- [2] Blom, H. A. P. y Bar-Shalom, Y. (1988). The interacting multiple model algorithm for systems with Markovian switching coefficients. *IEEE Transactions on Automatic Control*, 33(8), 780-783.
- [3] Cartea, Á. y Jaimungal, S. (2015). Risk metrics and fine tuning of high-frequency trading strategies. *Mathematical Finance*, 25(3), 576-611.
- [4] Cartea, Á., Jaimungal, S. y Penalva, J. (2015). *Algorithmic and High-Frequency Trading*. Cambridge University Press.
- [5] Cont, R., Kukanov, A. y Stoikov, S. (2014). The price impact of order book events. *Journal of Financial Econometrics*, 12(1), 47-88.
- [6] Cont, R., Stoikov, S. y Talreja, R. (2010). A stochastic model for order book dynamics. *Operations Research*, 58(3), 549-563.
- [7] Durbin, J. y Koopman, S. J. (2012). *Time Series Analysis by State Space Methods (2ª ed.)*. Oxford University Press.
- [8] Easley, D., López de Prado, M. M. y O'Hara, M. (2012). Flow toxicity and liquidity in a high-frequency world. *Review of Financial Studies*, 25(5), 1457-1493.
- [9] Fodra, P. y Labadie, M. (2012). High-frequency market-making with inventory constraints and directional bets. arXiv:1206.4810.
- [10] Gould, M. D., Porter, M. A., Williams, S., McDonald, M., Fenn, D. J. y Howison, S. D. (2013). Limit order books. *Quantitative Finance*, 13(11), 1709-1742.
- [11] Guéant, O. (2016). *The Financial Mathematics of Market Liquidity: From Optimal Execution to Market Making*. Chapman and Hall/CRC.
- [12] Guéant, O., Lehalle, C. A. y Fernandez-Tapia, J. (2013). Dealing with the inventory risk: a solution to the market making problem. *Mathematics and Financial Economics*, 7(4), 477-507.
- [13] Harris, L. (2003). *Trading and Exchanges: Market Microstructure for Practitioners*. Oxford University Press.
- [14] Hasbrouck, J. (2007). *Empirical Market Microstructure*. Oxford University Press.
- [15] Kalman, R. E. (1960). A new approach to linear filtering and prediction problems. *Journal of Basic Engineering*, 82(1), 35-45.
- [16] Roll, R. (1984). A simple implicit measure of the effective bid-ask spread in an efficient market. *The Journal of Finance*, 39(4), 1127-1139.
- [17] Wells, C. (1996). *The Kalman Filter in Finance*. Kluwer Academic Publishers.