Declaración de originalidad

Declaro bajo mi responsabilidad que el Proyecto presentado con el título **Analizando el Mercado: Matemáticas de un Algoritmo Previsor** e la ETS de Ingeniería – ICAI de la Universidad Pontificia Comillas en el curso académico 2025/26 es de mi autoría 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.

Uso de Inteligencia Artificial[1]

Declaro bajo mi responsabilidad que (indicar la opción correcta):

☐ No he utilizado Inteligencia Artificial en la elaboración del presente documento.

■ He utilizado Inteligencia Artificial en la elaboración del presente documento y/o del Anexo B siempre en las condiciones permitidas por la Universidad Pontificia Comillas, es decir, aplicando el Nivel 2 de la Escala de Evaluación de Perkins et al. (2024): "*La IA puede utilizarse para actividades previas a la tarea, como la lluvia de ideas, la descripción y la investigación inicial. Este nivel se centra en el uso de la IA para la planificación, las síntesis y la generación de ideas, pero las evaluaciones deben hacer hincapié en la capacidad de desarrollar y refinar estas ideas de forma independiente*". En concreto, las Inteligencia Artificial ha sido empleada para:

Lluvia de ideas y estructuración inicial del enfoque y los objetivos del proyecto.
Búsqueda y síntesis preliminar de literatura y conceptos de referencia.
Apoyo en la organización y esquema de los apartados del documento.
Aclaración de conceptos técnicos para facilitar mi propia comprensión.
Revisión ortográfica y de estilo de textos redactados por mí.

Álvaro Guibelalde Rodríguez
Firmado (alumno): 
Fecha: 23/07/2026

Autorización para la entrega del Proyecto

El Director del Proyecto	El co-Director del Proyecto (si aplica)
Miguel Zaballa	
Fdo: 	Fdo:
Fecha: 23/07/2026	Fecha:

Esta declaración se refiere al uso de la Inteligencia Artificial generativa para realizar los documentos del Proyecto (Anexo B y Memoria). No aplica a Proyectos donde, por su naturaleza, deban emplear inteligencia artificial como parte de los mismos (aplicación de técnicas de aprendizaje automático, redes neuronales, análisis de datos…)

Anticipando el mercado: matemáticas de un algoritmo previsor

Estimación online de *drift* en un market maker de Avellaneda–Stoikov
y su valor económico tras ejecución

Álvaro Guibelalde Rodríguez[1] and Director: Miguel Zaballa Pardo[1]

[1]ETS de Ingeniería ICAI, Universidad Pontificia Comillas. Máster en Ingeniería Industrial

Julio de 2026

Abstract

Este trabajo estudia cuándo una señal estadística de *drift* puede monetizarse dentro de un algoritmo de *market making* basado en Avellaneda–Stoikov, una vez descontados ejecución, inventario, costes y control de cotizaciones obsoletas. Se construye un banco de pruebas sintético y controlado con *drift* latente conocido, y se comparan seis modelos de estimación (sin *drift*, EMA, Kalman de caminata aleatoria, Kalman con reversión a la media, IMM de cambio de régimen y una extensión con *Order Flow Imbalance*) sobre cinco escalas temporales, con 50 semillas reproducibles y controles de señal invertida, ausencia de comisiones, sensibilidad de Q y τ, ablación del 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 cuando el motor de cotización genera *quotes* cruzadas, *stale quotes* o *fills* adversos. El cuello de botella del sistema no está en elegir entre RW, OU, IMM u OFI, sino en controlar el cruce de *quotes*, el horizonte τ, la calibración de Q, el inventario y el realismo de la ejecución.

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

1 Introducción y estado de la cuestión

Un *market maker* proporciona liquidez publicando de forma continua precios de compra y de 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 (Harris, 2003; Hasbrouck, 2007). La hipótesis natural es que una estimación del *drift* del precio permita 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, el rebote *bid-ask* y los cambios discretos del libro, de modo que un estimador sofisticado puede empeorar el resultado si desplaza las *quotes* con confianza excesiva.

El título 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. Ello obliga a separar tres planos que suelen confundirse: predictibilidad estadística, mejora de las *quotes* y resultado neto. La descomposición contable de referencia es

$$\mathrm{PnL}_k^{\mathrm{neto}} = C_k^{\mathrm{neto}} + q_k S_k, \qquad C_k^{\mathrm{neto}} = C_k^{\mathrm{bruto}} - \sum_{j \le k} \mathrm{fee}_j, \tag{1}$$

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

1.1 Modelo de Avellaneda–Stoikov

El precio eficiente se modela localmente como un movimiento browniano con *drift* instantáneo, $dS_t = \alpha_t\,dt + \sigma_t\,dW_t$. Bajo utilidad exponencial e intensidades de llegada $\lambda(\delta) = Ae^{-k\delta}$, el modelo (Avellaneda y Stoikov, 2008) conduce a un precio de reserva y a un *spread* óptimo,

$$r_t = S_t + \hat{\alpha}_t\,\tau - q_t\,\gamma\,\sigma_t^2\,\tau, \tag{2}$$

$$\delta_t^* = \gamma\,\sigma_t^2\,\tau + \tfrac{2}{\gamma}\ln\Big(1+\tfrac{\gamma}{k}\Big), \qquad p_t^{\mathrm{bid}} = r_t - \tfrac{\delta_t^*}{2},\ p_t^{\mathrm{ask}} = r_t + \tfrac{\delta_t^*}{2}. \tag{3}$$

El *drift* no cambia la anchura del *spread*: mueve el centro alrededor del cual se colocan *bid* y *ask*. La tensión entre el término direccional $\hat{\alpha}_t\tau$ y la penalización de inventario $-q_t\gamma\sigma_t^2\tau$ es el núcleo del sistema.

1.2 Estimación del *drift* con filtros de Kalman

La observación que entra en el filtro no es el precio bruto, sino el retorno por unidad de tiempo a la escala de muestreo, $z_k(\Delta t) = (S_k - S_{k-1})/\Delta t$. El modelo de caminata aleatoria (M2, RW) toma $\alpha_k = \alpha_{k-1} + w_k$ con $w_k \sim \mathcal{N}(0, Q\Delta t)$ y observación $z_k = \alpha_k + v_k$, $v_k \sim \mathcal{N}(0, R)$. La actualización estándar

$$\nu_k = z_k - \hat{\alpha}_{k|k-1}, \quad K_k = P_{k|k-1}\,\Omega_k^{-1}, \quad \hat{\alpha}_{k|k} = \hat{\alpha}_{k|k-1} + K_k\,\nu_k \tag{4}$$

produce el *drift* estimado que alimenta el precio de reserva. La variante OU (M3) sustituye la caminata aleatoria por una dinámica con reversión a la media, $F_{\mathrm{OU}} = e^{-\kappa\Delta t}$, que disipa la predicción anterior y regulariza la agresividad de la señal; el modelo IMM (M4, Blom y Bar-Shalom, 1988) mantiene tres filtros en paralelo (tendencia, reversión y alta volatilidad) y combina sus estimaciones ponderando por la verosimilitud de cada régimen. La calibración de Q por máxima verosimilitud, $\hat{Q}_{\mathrm{MLE}} = \arg\max_Q \ell(Q)$, ajusta el modelo estadístico del filtro, no el PnL; en escenarios de *drift* casi constante su perfil resulta monótono y el máximo cae en la frontera inferior del *grid*, por lo que se trata como diagnóstico *in-sample* degenerado y no como calibración recomendada. La extensión OFI (M5; Cont, Kukanov y Stoikov, 2014) añade una segunda observación, un proxy sintético de desequilibrio de flujo, como actualización escalar sucesiva.

1.3 Posición frente a la literatura

Avellaneda y Stoikov (2008) formulan el modelo de referencia para *market making* óptimo; Guéant, Lehalle y Fernandez-Tapia (2013) y Guéant (2016) desarrollan las extensiones prácticas de inventario, y Cartea, Jaimungal y Penalva (2015) ofrecen marcos de control óptimo donde las señales predictivas entran dentro de la propia optimización. Este trabajo adopta en cambio una aproximación de *separación*: primero estima $\hat{\alpha}$ con un filtro de Kalman y después introduce esa estimación en la fórmula del precio de reserva, $r_t = S_t + \hat{\alpha}_t\tau - q_t\gamma\sigma_t^2\tau$. No se resuelve una nueva ecuación HJB acoplada con cambio de régimen; ésta se mantiene como motivación teórica y línea futura, no como resultado demostrado. La decisión reduce la ambición teórica pero aumenta la transparencia empírica, y conecta con la línea de Fodra y Labadie (2012) sobre *market making* con apuestas direccionales. El filtrado de estados latentes tiene tradición consolidada en finanzas (Kalman, 1960; Wells, 1996; Durbin y Koopman, 2012), y el rebote *bid-ask* que el generador introduce de forma controlada es el mecanismo clásico de Roll (1984). El hueco que cubre el trabajo no está en proponer una fórmula nueva, sino en construir una evaluación reproducible que separe escala temporal, calidad de señal y rentabilidad neta.

1.4 Diseño experimental y sistema

El banco de pruebas se implementa íntegramente en Python con bibliotecas de código abierto y sigue cuatro bloques: generación de datos sintéticos con *drift* conocido, estimación online, cálculo de *quotes* con Avellaneda–Stoikov y simulación de *fills*, y evaluación (Fig. 1). El precio observado se genera como $S_k^{\mathrm{obs}} =$

$S_k^{\text{eff}} + b(-1)^k + \xi_k$, donde el término alternante $b(-1)^k$ introduce un rebote *bid-ask* determinista que produce autocorrelación negativa de corto plazo. Se emplean seis escenarios (tendencia alcista limpia, tendencia bajista ruidosa, mercado lateral, cambio de régimen, microestructura *bid-ask* y alta volatilidad sin *drift*) que cubren el espacio de situaciones que un estimador debe distinguir, con 50 semillas por configuración y cinco escalas $\Delta t \in \{1, 2, 5, 10, 30\}$ s. La simulación de ejecución usa la probabilidad de *fill* $\varphi = 1 - \exp(-\lambda \Delta t)$, con $\lambda = Ae^{-k\delta}$. El motor de ejecución corregido no contabiliza *quotes* cruzadas como órdenes pasivas ni permite *fills* simultáneos de *bid* y *ask* en el mismo paso; esta validación del instrumento de medida precede al análisis de resultados. El PnL se expresa en unidades monetarias sintéticas por simulación de 3600 s: son magnitudes para comparar mecanismos dentro del experimento, no euros de un mercado real.



Figura 1: Arquitectura del *pipeline* de experimentación: datos sintéticos, estimadores, *market maker*, ejecución, validación y evidencia. El sistema es agnóstico al estimador.

Tabla 1: 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	$\alpha_k = e^{-\kappa \Delta t} \alpha_{k-1} + w_k$	Reversión a cero
M4 IMM	Mezcla de filtros por régimen	Cambio de régimen
M5 Kalman OFI	Precio + proxy OFI sintético	Vector de observación enriquecido

2 Resultados y discusión

2.1 Escala temporal y relación señal–ruido

La SNR estructural de bloque compara el *drift* acumulado esperado con la volatilidad del retorno de bloque, $\text{SNR}_{\text{bloque}}(\Delta t) = |\alpha| \Delta t / \sigma_{\Delta t}$. En microestructura, la SNR limpia pasa de 0.030 a $\Delta t = 1$ s a 0.581 a $\Delta t = 30$ s: la señal queda menos enterrada en ruido, pero sigue por debajo de 1. El detalle intermedio tiene explicación mecánica (Fig. 2): 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 2 s y 10 s y vuelve a ser negativo a 5 s. Un control con rebote estocástico

tipo Roll confirma que la mejora por agregación no depende del artefacto determinista: ρ_1 pasa de -0.425 a 1 s a -0.073 a 30 s y la SNR limpia crece de forma monótona de 0.041 a 0.533.

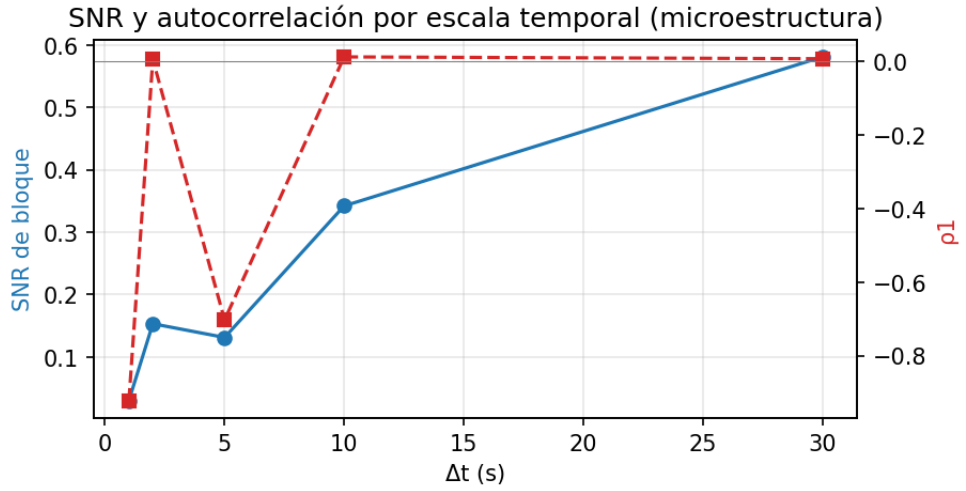


Figura 2: SNR de bloque (azul) y autocorrelación ρ_1 (rojo) por escala temporal en microestructura. La autocorrelación negativa a 1 s procede de la alternancia *bid-ask* incorporada al generador; el patrón de paridad se hace visible al agregar.

2.2 Sensibilidad a Δt: la señal se limpia pero no se monetiza

El aumento de Δt mejora la SNR pero no el PnL neto corregido. En agregado sobre los seis escenarios, Kalman RW pasa de 142.2 a 1 s a -35.0 a 30 s; en microestructura, de 191.8 a 80.8 (Fig. 3). La lectura correcta es un *deterioro de monetización*, no una transición de pérdidas a beneficios. Un control que fija la volatilidad por segundo en la σ del generador reproduce el mismo patrón (73.8 frente a 80.8 a 30 s), de modo que el canal dominante es la exposición de ejecución y no la penalización mecánica de inventario $\gamma\sigma^2\tau$. La Tabla 2 recoge los extremos: a 30 s todos los modelos con *drift* caen a terreno negativo mientras el *baseline* agregado mantiene 85.9; proveer liquidez sin predicción puede superar a modelos con *drift* mal monetizado.

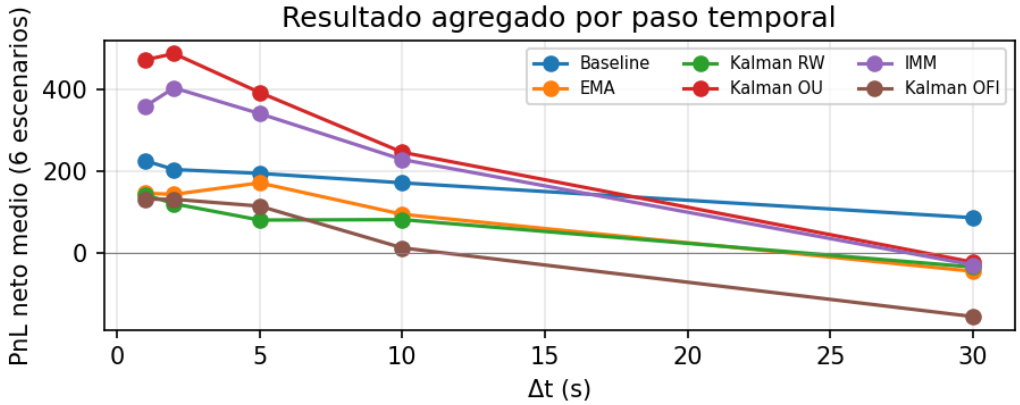


Figura 3: Resultado agregado (PnL neto medio sobre los seis escenarios) por paso temporal Δt y modelo. La mejora de SNR al agregar no se traslada al PnL neto tras ejecución corregida.

Tabla 2: Sensibilidad agregada a Δt con IC95 (extremos $\Delta t = 1$ s y 30 s, todos los modelos).

Δt	Modelo	PnL neto (IC95)	Fill	$\lvert q \rvert$ 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 es que la precisión direccional de Kalman RW puede subir mientras el PnL cae. La precisión, además, no ordena los modelos: EMA supera a Kalman RW en acierto de signo (76.1% frente a 68.5% a 1 s) y aun así no domina en PnL, 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. El contraste RW–OU ilustra el mecanismo: a 1 s Kalman OU alcanza 472.8 en el agregado con el menor cruce de *quotes* de los modelos con *drift* (4.7% frente al 28.6% de RW en microestructura), porque la disipación $F = e^{-\kappa \Delta t}$ encoge $\hat{\alpha}$ y con ella el desplazamiento $\hat{\alpha}\tau$ del precio de reserva. 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.

2.3 Comisiones, controles y sensibilidad de especificación

Separar PnL bruto y neto (Fig. 4) responde a una duda clave: una estrategia puede tener predictibilidad y no ser rentable tras costes. La evidencia sobre el peso de los costes está en la sensibilidad de parámetros: para Kalman RW en microestructura a 1 s, el PnL neto pasa de 215.4 sin comisiones a 211.7 con 2 pb y 206.3 con 5 pb, una variación pequeña frente al efecto de τ, de Q o del propio motor de ejecución. El horizonte τ no es neutro: a 30 s, Kalman RW obtiene 316.7 con $\tau = 10$ s, 301.3 con $\tau = 30$ s y solo 80.8 con $\tau = 60$ s. El Q_{MLE} es un diagnóstico *in-sample*: a 1 s el PnL pasa de 191.8 a 455.2 y la precisión sube a 96.5%, pero calibra y evalúa sobre la misma ruta y su óptimo cae en la frontera inferior del *grid*. Frente a su ablación limpia (mismo filtro de precio sin la segunda actualización), el proxy OFI no domina: a 1 s obtiene 135.5 frente a 194.2 del filtro solo-precio, y aunque a 30 s recupera terreno con mayor precisión, la precisión adicional no ordena el PnL. Estas sensibilidades son fragilidades de especificación, no anexos menores: A, k y la escala del *drift* alteran *fill rate*, cruce de *quotes* y signo del PnL con más fuerza que un cambio de comisión.

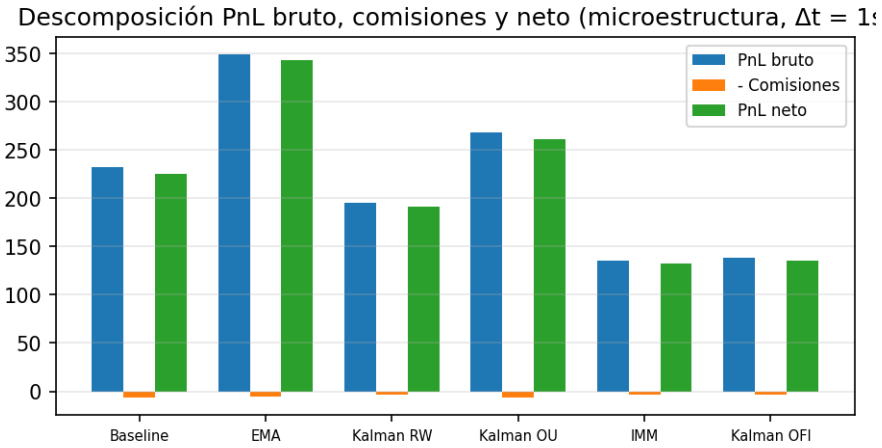


Figura 4: Descomposición entre PnL bruto, comisiones y PnL neto (microestructura, $\Delta t = 1$ s). Con comisión proporcional al *notional* y *fills* que no dependen de ella, el ranking depende del desplazamiento de *quotes*, inventario y exposición temporal más que del coste.

El control de señal invertida es revelador. Con $\tau = 60$ s el término $\hat{\alpha}\tau$ desplaza el precio de reserva más de media anchura de *spread* con frecuencia estructural (cruce 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. No descubre una estrategia — heredaría los mismos riesgos de especificación — sino que diagnostica la desalineación entre señal y ejecución. El caso más ilustrativo es el proxy OFI a 30 s: el PnL medio por paso cuando *acierta* la dirección es 0.751, mientras que cuando *falla* es 0.886; el modelo gana más por paso cuando se equivoca. El mecanismo es que la variación de PnL por paso está dominada por la revalorización *mark-to-market* del inventario heredado, no por los *fills* de ese paso: acertar el signo hoy no compensa haber llegado posicionado en contra durante la caída que originó la señal. La condición de cruce

$$p_t^{\text{bid}} > S_t \iff \hat{\alpha}_t\tau - q_t\gamma\sigma_t^2\tau > \frac{\delta_t^*}{2} \tag{5}$$

formaliza por qué τ, Q, el inventario y el *spread* afectan directamente al cruce de *quotes*.

2.4 Validación *walk-forward*

La validación *walk-forward* (Fig. 5) suma cinco ventanas de 600 s con inventario a cero y estimador reiniciado al inicio de cada una. Solo M2 recalibra Q en la ventana anterior; para el resto la comparación mide estabilidad por tramos y sensibilidad a los reinicios, no validación fuera de muestra en sentido estricto. Con esa lectura, Kalman RW en microestructura pasa de 191.8 a 261.3 a 1 s, 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 30 s 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.

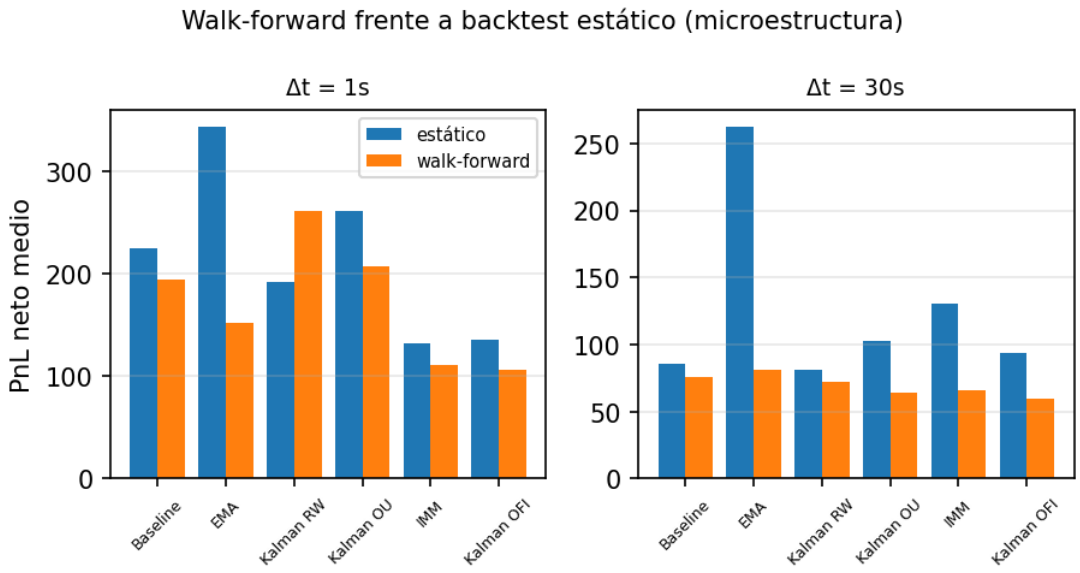


Figura 5: Validación *walk-forward* frente a *backtest* estático (microestructura, $\Delta t = 1$ s y 30 s). Los reinicios de estado mejoran el caso base de Kalman RW a 1 s y el efecto se diluye a 30 s.

Las diferencias pareadas por semilla confirman la sobriedad de las afirmaciones: cuando el intervalo pareado cruza el cero, la comparación se describe como indistinguible y no como *ranking*. Las dos únicas diferencias que excluyen el cero — Kalman OU frente a *baseline* ($+36.2 \pm 14.9$, 76% de semillas positivas) y la variante multiescala OFI ($+93.7 \pm 62.6$, 68%) — sobreviven además a una corrección de Bonferroni. El control multiescala (estimar con retornos agregados de 30 s pero recotizar cada segundo) mantiene las oportunidades de ejecución del caso base y sube Kalman RW de 191.8 a 247.1; la ganancia no viene de predecir mejor, sino de dejar de convertir ruido en desplazamientos agresivos de *quote*.

3 Conclusiones

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 30 s la monetización se deteriora y el resultado queda dominado por *fills* adversos, órdenes que envejecen expuestas y acumulación de inventario. 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 precio de reserva, y si ese desplazamiento genera *quotes* demasiado agresivas o deja órdenes vivas demasiado tiempo, acertar dirección no basta. El proxy OFI a 30 s, que gana más por paso cuando falla que cuando acierta, resume esa desconexión entre señal y ejecución.

La aportación propia es, por tanto, una evaluación reproducible de la estimación online del *drift*, sus límites empíricos y su dependencia de la capa de ejecución, no una fórmula nueva de *market making*. El alcance termina en el simulador: no se añade contraste con datos reales, por lo que las magnitudes se leen en la moneda interna del banco de pruebas y no como euros de un *venue* concreto. Las líneas futuras naturales son un simulador de libro de órdenes con cancelaciones, latencia y control *ex ante* de cruces; el refinamiento de la estrategia multiescala esbozada como control; la calibración de Q, R y τ genuinamente fuera de muestra con óptimos interiores; y la resolución numérica de formulaciones HJB con régimen que incorporen el estado del filtro al control. Ninguna de estas extensiones cambia la tesis final: la predicción de *drift* solo tiene valor si la capa de ejecución conserva ese valor hasta el PnL neto.

Referencias

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* (2.ª 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*. 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.