Facsímil 10

Aprendizaje por refuerzo

Capítulo 07

Serving de políticas: monitorización, drift y cambios controlados

686f6c61 · 2026

Capítulo 07: Serving de políticas: monitorización, drift y cambios controlados

La política no termina cuando pasa evaluación

Una política puede pasar evaluación offline, tener una reward card razonable y aun así comportarse mal al vivir en producción. No porque el algoritmo sea misterioso. Porque producción no es el notebook. Producción trae tráfico cambiante, latencia, herramientas que fallan, usuarios con patrones nuevos, documentos actualizados, costes, trazas incompletas y decisiones que hay que poder deshacer.

En este capítulo dejamos de mirar la política como una fórmula aislada y la miramos como un componente operativo. Una política servida no es solo $\pi(a \mid x)$. Es $\pi(a \mid x)$ más versión, traza, SLO, gate, feature flag, política de reserva, ventana de referencia, monitorización por slice y runbook.

Fecha de corte: 9 de junio de 2026. Para la parte de herramientas y operación hemos revisado documentación oficial de OpenTelemetry, LaunchDarkly y Evidently, y la conectamos con literatura estable sobre deuda técnica de ML, producción de modelos, SRE y drift.[1][2][3]

La idea central:

> Una política no se publica: se sirve, se mide, se limita y se puede retirar.

Qué no es servir una política

Servir una política no es desplegar un endpoint y mirar si responde. Eso solo comprueba que hay una ruta técnica. No comprueba si la política está tomando buenas decisiones.

Tampoco es activar una feature flag sin contrato. Una flag controla exposición; la política decide acciones. Si mezclas ambas cosas, acabas sin saber si el problema viene del rollout, del modelo, de la recompensa, del contexto, de la herramienta o de la población que recibió la variante.

Y no es monitorizar una media global. Si `reward_mean` sube pero `privacidad` baja, el sistema no está sano. Si baja la latencia porque deja de llamar a una herramienta necesaria, tampoco. Si mejora la aceptación inmediata pero aumenta fallback, quizá has movido el coste a soporte, revisión o reintentos.

Sculley y otros describieron que los sistemas de ML acumulan deuda técnica por dependencias ocultas, configuración, bucles de feedback y cambios del mundo externo.[4] Breck y otros propusieron el ML Test Score como una rúbrica de preparación productiva donde las pruebas y la monitorización son parte del sistema, no un adorno final.[5]

La lección práctica para este capítulo: una política que no deja evidencia operativa no está lista para producción.

Qué sí es el serving de políticas

Serving de políticas es la capa que recibe una petición, construye el contexto, elige una acción según una política versionada, ejecuta o propone esa acción, registra la decisión y aplica gates antes de aumentar exposición.

En un sistema de IA puede aparecer en muchos sitios:

SISTEMA	POLÍTICA	ACCIÓN
Routing de modelos	Elegir modelo según tarea y coste.	`small_rag_model`, `large_reasoning_model`, `local_model`.
RAG	Elegir estrategia de recuperación.	`top_k=4`, `top_k=12`, reranker, abstención.
Agente con herramientas	Elegir siguiente herramienta o parada.	Buscar, consultar base de datos, pedir aprobación.
Post-training	Elegir variante candidata.	Política estable o política ajustada.
Producto	Elegir experiencia controlada.	Mostrar respuesta directa, pedir aclaración, derivar a humano.

El serving correcto separa cinco planos:

PLANO	PREGUNTA
Política	¿Qué acción elige π?
Exposición	¿Quién recibe la candidata y cuánto tráfico se mueve?
Observabilidad	¿Qué traza, métrica y log se guardan?
Gate	¿Qué condiciones permiten avanzar?
Recuperación	¿Cómo volvemos a la política de reserva?

OpenTelemetry define señales como trazas, métricas y logs para instrumentar sistemas distribuidos.[6][7][8] En IA generativa, además, la semántica de GenAI ayuda a nombrar atributos de peticiones, modelos y operaciones de generación.[9]

El contrato matemático del serving

Una política servida se escribe con la notación estándar de RL, anotando además la versión, para separar decisión, versión y restricciones. No es una API ni una especificación de producto, sino una forma compacta de recordar qué debe viajar junto a una decisión operativa:

$$a_t \sim \pi_{\theta,v}(a \mid x_t, c_t)$$

SÍMBOLO	SIGNIFICADO	EJEMPLO
t	Instante o petición.	Petición 1523 de la ventana actual.
x_t	Contexto de decisión.	Pregunta, usuario agregado, documentos, tarea.
c_t	Restricciones operativas.	Slice permitido, coste máximo, permisos, flag.
a_t	Acción elegida.	`large_reasoning_model`.
$\pi_{\theta,v}$	Política con parámetros θ y versión v.	`policy_candidate_v4`.

La decisión no se guarda solo como acción. Se guarda como evento:

$$e_t = (x_t, a_t, p_t, r_t, g_t, v_\pi, v_R, s_t)$$

SÍMBOLO	SIGNIFICADO	EJEMPLO
p_t	Probabilidad o razón de selección.	0,05 en un piloto al 5 %.
r_t	Recompensa observada o estimada.	0,73.
g_t	Resultado de gates duros.	JSON válido, evidencia soportada.
v_π	Versión de política.	`policy_candidate_v4`.
v_R	Versión de reward card.	`1.0.0`.
s_t	Slice operativo.	`rag`, `sql`, `herramientas`.

Después agregamos por ventana:

$$\mathrm{SLI}_m(W) = \frac{1}{|W|} \sum_{e_t \in W} h_m(e_t)$$

SÍMBOLO	SIGNIFICADO	EJEMPLO
W	Ventana de observación.	Últimas 12 horas.
m	Métrica o indicador.	`reward_mean`, `p95_latency_ms`.
$h_m(e_t)$	Función que extrae una medición del evento.	Latencia de la petición.
$\mathrm{SLI}_m(W)$	Indicador medido en la ventana.	Reward medio 0,73.

Un SLO convierte ese indicador en objetivo:

$$\mathrm{SLI}_m(W) \geq \mathrm{SLO}_m$$

o, si menor es mejor:

$$\mathrm{SLI}_m(W) \leq \mathrm{SLO}_m$$

Google SRE insiste en separar monitorización útil, SLOs y alertas: no medimos por llenar gráficos, medimos para decidir y actuar.[101112]

En serving de políticas, el SLO no es solo disponibilidad. También hay SLOs de calidad: evidencia, reward, fallback, coste, latencia y slices.

Drift: cuando la ventana actual ya no se parece a la referencia

Drift significa que algo relevante cambió. Puede cambiar la distribución de entradas, la mezcla de slices, la acción elegida, la recompensa, el coste, el comportamiento de herramientas o el propio verificador.

Gama y otros revisan el problema de concept drift como cambio en flujos de datos donde la relación entre entrada y objetivo evoluciona con el tiempo.[13] Sugiyama y otros trataron el covariate shift como el caso donde cambia la distribución de entradas aunque la relación condicional se mantenga.[14]

En este capítulo no queremos convertir al lector en especialista de detección de drift. Queremos que pueda mirar producción y hacerse estas preguntas:

TIPO DE DRIFT	QUÉ CAMBIA	EJEMPLO
Drift de contexto	Cambia $P(x)$.	Llegan más preguntas SQL que RAG.
Drift de acción	Cambia la mezcla de acciones.	La política llama mucho más al modelo caro.
Drift de recompensa	Cambia la relación entre reward y resultado real.	Sube reward, baja evidencia revisada.
Drift de coste	Cambia latencia, tokens o herramientas.	P95 pasa de 1900 ms a 3100 ms.
Drift de verificador	Cambia cómo puntúa un grader.	El verificador de citas acepta peor un nuevo formato.
Drift de slice	Un segmento pequeño se degrada.	`privacidad` cae mientras el global parece bien.

Evidently documenta drift comparando una ventana de referencia con una ventana actual y aplicando métodos distintos según tipo de columna, tamaño y cardinalidad.[15] La herramienta concreta puede cambiar; la idea estable no: siempre necesitas referencia, actual, métrica y criterio de decisión.

PSI: una medida sencilla para empezar

Una métrica frecuente para comparar distribuciones discretizadas es el Population Stability Index:

$$\mathrm{PSI}(P, Q) = \sum_{b=1}^{B} (q_b - p_b) \log\left(\frac{q_b}{p_b}\right)$$

SÍMBOLO	SIGNIFICADO	EJEMPLO
P	Distribución de referencia.	Acciones de la política estable.
Q	Distribución actual.	Acciones de la candidata.
b	Bin o categoría.	`rag`, `sql`, `herramientas`.
p_b	Proporción de referencia en el bin.	0,55.
q_b	Proporción actual en el bin.	0,32.
B	Número de bins.	4 slices.

El PSI no es una verdad universal. Es una alarma. Si Q se separa mucho de P, toca mirar. Aquí usamos un umbral conservador de 0,20:

PSI	LECTURA PRÁCTICA
0,00-0,10	Cambio pequeño.
0,10-0,20	Revisar con cuidado.
> 0,20	No aumentar exposición sin explicación.

Ejemplo: si la distribución de acciones cambia de `small_rag_model` a `large_reasoning_model`, quizá el reward sube un poco, pero el coste y la latencia también. Una política candidata no puede avanzar solo porque una métrica mejore si está cambiando la forma de usar el sistema.

El gate de rollout

Un gate de serving combina SLOs, drift, trazas y preparación de rollback:

$$G_k = 1[\mathrm{SLI}_{\mathrm{reward}} \geq \tau_R] \cdot 1[\mathrm{SLI}_{\mathrm{evidencia}} \geq \tau_E] \cdot 1[\mathrm{p95}_{\mathrm{latencia}} \leq \tau_L] \cdot 1[\mathrm{PSI} \leq \tau_D] \cdot 1[\text{rollback listo}]$$

SÍMBOLO	SIGNIFICADO	EJEMPLO
G_k	Gate de la etapa k.	Gate para `pilot_5`.
τ_R	Umbral mínimo de reward.	0,62.
τ_E	Umbral mínimo de evidencia.	0,90.
τ_L	Máximo p95 de latencia.	2500 ms.
τ_D	Máximo drift aceptable.	PSI 0,20.

Si cualquier factor vale 0, el producto vale 0. Esa es la gracia: el rollout no avanza porque una media compense un fallo operativo. No compensamos rollback no preparado con reward alto. No compensamos evidencia baja con latencia buena. No compensamos drift fuerte con una media global bonita.

Una secuencia razonable:

ETAPA	TRÁFICO REAL	QUÉ EXIGE
Shadow	0 %	Trazas completas, paridad razonable, latencia medida.
Piloto 5 %	5 %	SLOs por slice y política de reserva lista.
Piloto 25 %	25 %	Drift bajo, coste dentro de presupuesto, revisión de soporte.
Piloto 50 %	50 %	Estabilidad en varias ventanas.
General	100 %	Runbook, alertas y deuda de flags revisada.

LaunchDarkly documenta rollouts porcentuales y progresivos como forma de liberar cambios gradualmente.[16] También advierte sobre deuda técnica de flags: una flag que controla un rollout no debe quedarse indefinidamente como residuo operativo.[17]

La anatomía de un serving defendible

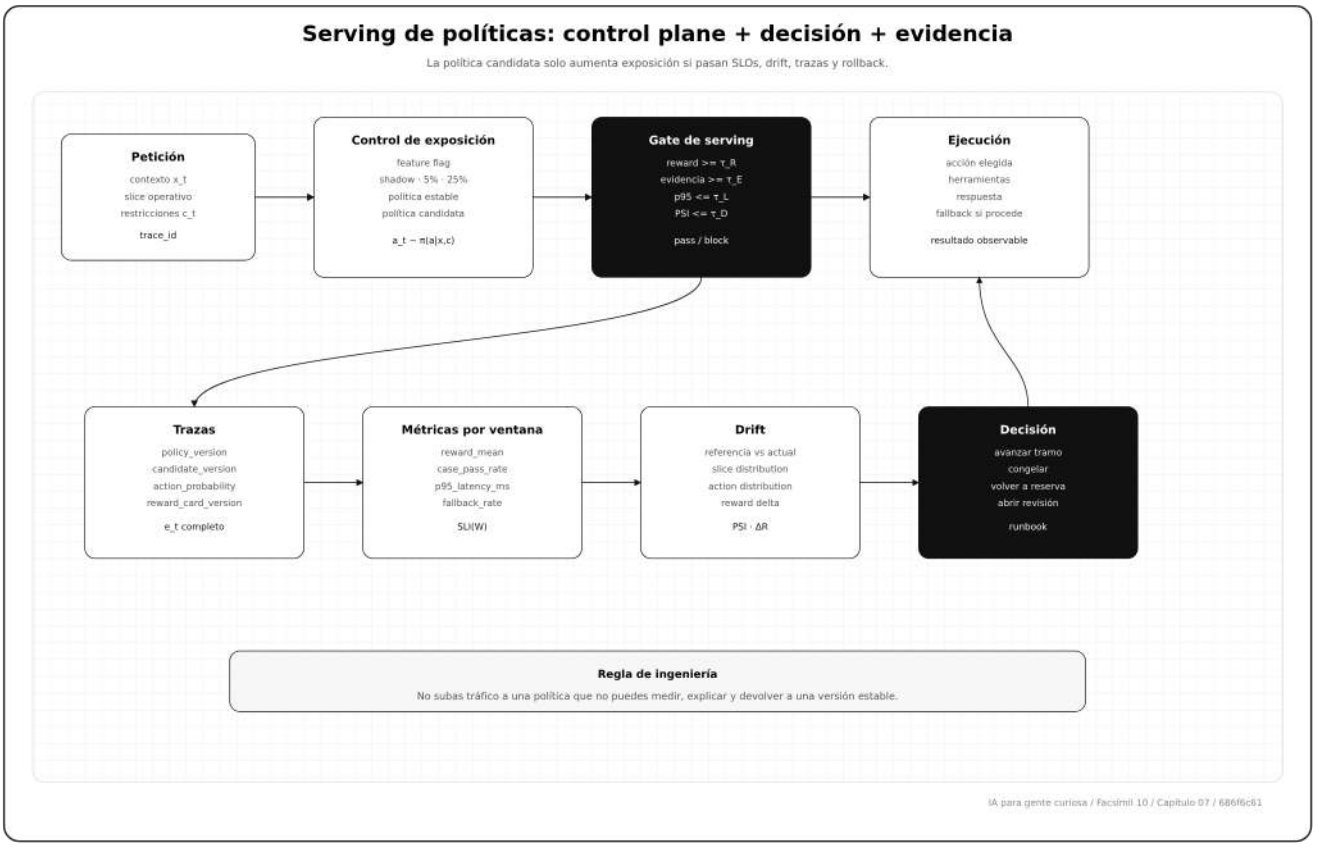

Cómo encaja todo

Lee este mapa como el cierre operativo del facsímil antes de la recapitulación final. Heredamos eventos y linaje del capítulo 02, exploración y rollout del 03, evaluación offline del 04 y reward cards del 06. Aquí juntamos todo en una decisión de serving: shadow, piloto, drift, SLOs, rollback y runbook.

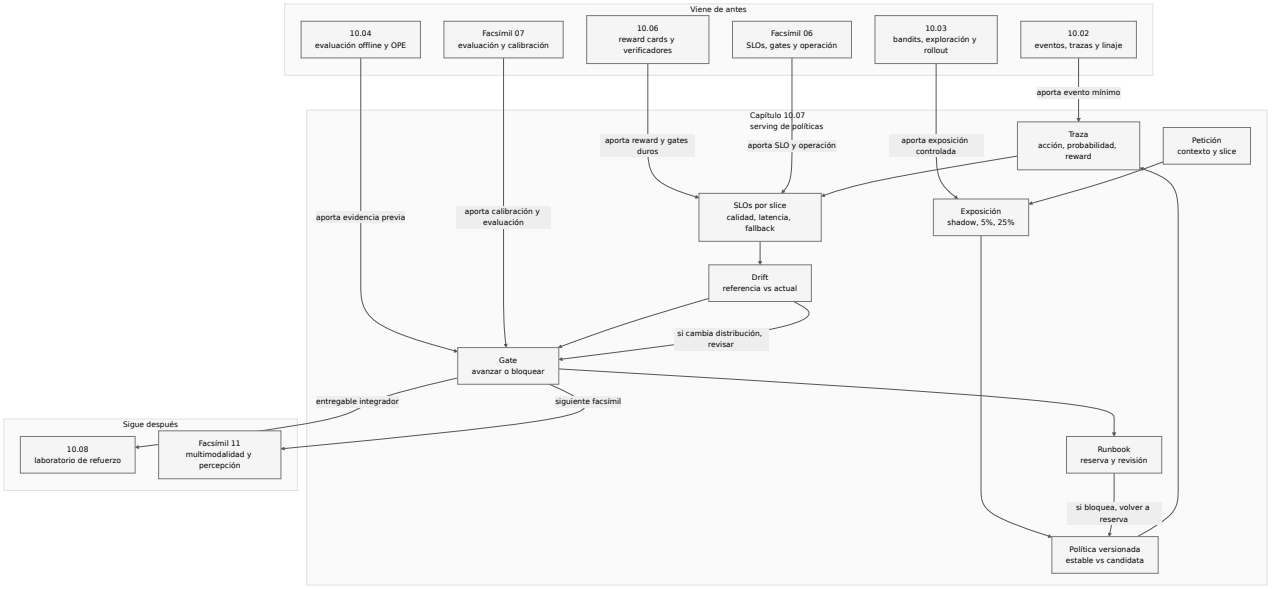

Vocabulario aprendido

TÉRMINO	QUÉ SIGNIFICA	CÓMO LO USARÍA
Serving de políticas	Capa que ejecuta una política versionada con gates y trazas.	No confundir con un endpoint sin control operativo.
Política candidata	Versión que queremos probar.	`policy_candidate_v4`.
Política de reserva	Versión estable a la que podemos volver.	`policy_stable_v3`.
Shadow	Fase sin tráfico real de decisión.	La candidata recomienda, pero no decide.
Rollout	Aumento gradual de exposición.	5 %, 25 %, 50 %.
Drift	Cambio entre referencia y actual.	Cambio de slices, acciones o reward.
PSI	Métrica para comparar distribuciones.	Detectar cambio de mezcla de acciones.
SLI	Indicador medido.	`p95_latency_ms`.
SLO	Objetivo del indicador.	P95 menor o igual que 2500 ms.
Runbook	Guía operativa de actuación.	Qué mirar y qué hacer si bloquea.

Dónde solía tropezar yo

TROPIEZO	POR QUÉ OCURRE	ANTÍDOTO
Pensar que servir es desplegar un endpoint.	La infraestructura responde.	Exigir política versionada, trazas y gate.
Mirar solo una media global.	Es cómoda y fácil de enseñar.	Revisar slices y casos pequeños.
Aumentar tráfico sin shadow.	La evaluación offline salió bien.	Pasar primero por shadow con trazas completas.
No tener política de reserva.	Nadie piensa en volver hasta que hace falta.	Declararla antes de abrir piloto.
Confundir feature flag con política.	Ambas controlan comportamiento.	La flag controla exposición; la política decide acción.
Medir drift sin decisión asociada.	El gráfico parece suficiente.	Definir umbral, gate y runbook.

Antes de pasar página

- ¿Por qué una política no termina cuando pasa evaluación offline?
- ¿Qué diferencia hay entre política, endpoint y feature flag?
- ¿Qué campos guardarías en una traza de decisión?
- ¿Qué SLOs pondrías para un router de modelos?
- ¿Por qué el drift debe mirarse por slice?
- ¿Qué mide el PSI?
- ¿Qué debería ocurrir en shadow?
- ¿Qué condiciones bloquearían un piloto al 5 %?
- ¿Qué debe contener una política de reserva?
- ¿Qué hace el runbook si el gate bloquea?

Para saber más

Breck, E., Cai, S., Nielsen, E., Salib, M., & Sculley, D. (2017). The ML Test Score: A rubric for ML production readiness and technical debt reduction. *2017 IEEE International Conference on Big Data*, 1123-1132. https://doi.org/10.1109/BigData.2017.8258038

Evidently AI. (2026). *Data drift*. https://docs.evidentlyai.com/metrics/explainer_drift

Ewaschuk, R. (2016). *Monitoring Distributed Systems*. En B. Beyer, C. Jones, J. Petoff y N. R. Murphy (eds.), *Site Reliability Engineering*. https://sre.google/sre-book/monitoring-distributed-systems/

Gama, J., Žliobaitė, I., Bifet, A., Pechenizkiy, M., & Bouchachia, A. (2014). A survey on concept drift adaptation. *ACM Computing Surveys, 46*(4), 1-37. https://doi.org/10.1145/2523813

Jones, C., Wilkes, J., Murphy, N., & Smith, C. (2016). *Service Level Objectives*. En B. Beyer, C. Jones, J. Petoff y N. R. Murphy (eds.), *Site Reliability Engineering*. https://sre.google/sre-book/service-level-objectives/

LaunchDarkly. (2026). *Releasing features with LaunchDarkly*. https://launchdarkly.com/docs/home/releases/releasing

OpenTelemetry. (2026). *Traces*. https://opentelemetry.io/docs/concepts/signals/traces/

OpenTelemetry. (2026). *Metrics*. https://opentelemetry.io/docs/concepts/signals/metrics/

Sculley, D., Holt, G., Golovin, D., Davydov, E., Phillips, T., Ebner, D., Chaudhary, V., Young, M., Crespo, J.-F., & Dennison, D. (2015). Hidden Technical Debt in Machine Learning Systems. *Advances in Neural Information Processing Systems, 28*. https://papers.nips.cc/paper_files/paper/2015/hash/86df7dcfd896fcaf2674f757a2463eba-Abstract.html

Sugiyama, M., Krauledat, M., & Müller, K.-R. (2007). Covariate Shift Adaptation by Importance Weighted Cross Validation. *Journal of Machine Learning Research, 8*, 985-1005. https://jmlr.csail.mit.edu/papers/v8/sugiyama07a.html

En resumen

IDEA	QUÉ DEBES RECORDAR
Una política servida es un sistema operativo, no solo una función.	Necesita versión, trazas, SLOs, gates, exposición controlada y política de reserva.
El drift es una señal para decidir, no un gráfico decorativo.	Compara referencia y actual por slice, acciones y reward antes de aumentar tráfico.
El rollout debe ser reversible.	Shadow, pilotos y runbook importan tanto como la métrica de calidad.
El cierre del facsímil ya puede integrar todo.	Datos, reward card, política, serving y gates quedan listos para practicarse juntos.

Notas

1. OpenTelemetry. (2026). *Documentation*. https://opentelemetry.io/docs/. Consultado el 9 de junio de 2026. ↩

2. LaunchDarkly. (2026). *Releasing features with LaunchDarkly*. https://launchdarkly.com/docs/home/releases/releasing. Consultado el 9 de junio de 2026. ↩

3. Evidently AI. (2026). *Data drift*. https://docs.evidentlyai.com/metrics/explainer_drift. Consultado el 9 de junio de 2026. ↩

4. Sculley, D. y otros (2015). *Hidden Technical Debt in Machine Learning Systems*. *Advances in Neural Information Processing Systems, 28*. https://papers.nips.cc/paper_files/paper/2015/hash/86df7dcfd896fcaf2674f757a2463eba-Abstract.html ↩

5. Breck, E., Cai, S., Nielsen, E., Salib, M. y Sculley, D. (2017). The ML Test Score: A rubric for ML production readiness and technical debt reduction. *2017 IEEE International Conference on Big Data*, 1123-1132. https://doi.org/10.1109/BigData.2017.8258038 ↩

6. OpenTelemetry. (2026). *Traces*. https://opentelemetry.io/docs/concepts/signals/traces/. Consultado el 9 de junio de 2026. ↩

7. OpenTelemetry. (2026). *Metrics*. https://opentelemetry.io/docs/concepts/signals/metrics/. Consultado el 9 de junio de 2026. ↩

8. OpenTelemetry. (2026). *Logs*. https://opentelemetry.io/docs/concepts/signals/logs/. Consultado el 9 de junio de 2026. ↩

9. OpenTelemetry. (2026). *Semantic conventions for generative AI systems*. https://opentelemetry.io/docs/specs/semconv/gen-ai/. Consultado el 9 de junio de 2026. ↩

10. Ewaschuk, R. (2016). *Monitoring Distributed Systems*. En B. Beyer, C. Jones, J. Petoff y N. R. Murphy (eds.), *Site Reliability Engineering*. https://sre.google/sre-book/monitoring-distributed-systems/. Consultado el 9 de junio de 2026. ↩

11. Jones, C., Wilkes, J., Murphy, N. y Smith, C. (2016). *Service Level Objectives*. En B. Beyer, C. Jones, J. Petoff y N. R. Murphy (eds.), *Site Reliability Engineering*. https://sre.google/sre-book/service-level-objectives/. Consultado el 9 de junio de 2026. ↩

12. Wilkinson, J. (2018). *Alerting on SLOs*. En B. Beyer, N. R. Murphy, D. Rensin, K. Kawahara y S. Thorne (eds.), *The Site Reliability Workbook*. https://sre.google/workbook/alerting-on-slos/. Consultado el 9 de junio de 2026. ↩

13. Gama, J., Žliobaitė, I., Bifet, A., Pechenizkiy, M. y Bouchachia, A. (2014). A survey on concept drift adaptation. *ACM Computing Surveys, 46*(4), 1-37. https://doi.org/10.1145/2523813 ↩

4. Sugiyama, M., Krauledat, M. y Müller, K.-R. (2007). Covariate Shift Adaptation by Importance Weighted Cross Validation. *Journal of Machine Learning Research, 8*, 985-1005. https://jmlr.csail.mit.edu/papers/v8/sugiyama07a.html ↩

5. Evidently AI, 2026. ↩

6. LaunchDarkly, 2026. ↩

7. LaunchDarkly. (2026). *Reducing technical debt from feature flags*. https://launchdarkly.com/docs/guides/flags/technical-debt. Consultado el 9 de junio de 2026. ↩