

# Multi-Cloud Engineering Program

Parte 18 — Azure: arquitectura empresarial y operación en producción

12 clases · 52 horas

Cuaderno de una sola parte: su introducción, sus clases completas y sus evaluaciones.

Extracto del manual integral, generado desde las mismas fuentes versionadas.

## Alcance de este cuaderno

| Componente      | Cobertura |
|-----------------|-----------|
| Parte           | 18 de 23  |
| Clases          | 217–228   |
| Evaluaciones    | 12        |
| Horas estimadas | 52        |

# Índice

|                                                                             |          |
|-----------------------------------------------------------------------------|----------|
| <b>Alcance de este cuaderno</b>                                             | <b>2</b> |
| <b>Índice</b>                                                               | <b>3</b> |
| <b>Parte 18 — Azure: arquitectura empresarial y operación en producción</b> | <b>4</b> |
| 217 — Enterprise-scale landing zones y management groups . . . . .          | 6        |
| 218 — Entra ID, workload identity, PIM y Conditional Access . . . . .       | 16       |
| 219 — Hub-spoke, Virtual WAN, Private Link y DNS privado . . . . .          | 26       |
| 220 — Bicep, deployment stacks y Azure Verified Modules . . . . .           | 37       |
| 221 — App Service, Functions y Container Apps en producción . . . . .       | 47       |
| 222 — AKS, workload identity, ingress y GitOps . . . . .                    | 57       |
| 223 — Azure SQL, Cosmos DB y consistencia distribuida . . . . .             | 68       |
| 224 — Service Bus, Event Grid y Event Hubs . . . . .                        | 79       |
| 225 — Azure Monitor, Application Insights y OpenTelemetry . . . . .         | 89       |
| 226 — Defender for Cloud, Policy y Sentinel . . . . .                       | 100      |
| 227 — Cost Management, Advisor, resiliencia y Chaos Studio . . . . .        | 111      |
| 228 — Proyecto: CloudShop productivo en Azure . . . . .                     | 122      |

# Parte 18 — Azure: arquitectura empresarial y operación en producción

← Parte 17 · Índice completo · Parte 19 →

Descargar: Esta parte en PDF · Recorrido de Azure en PDF · Manual integral

Nivel: avanzado · Clases: 12 · Duración sugerida: 6–8 semanas

Operar CloudShop sobre landing zones, PaaS, datos, identidad y observabilidad de Azure.


## Resultados de la parte

Al completar esta parte podrás explicar el dominio con lenguaje independiente del proveedor, implementar sus mecanismos esenciales, diagnosticar fallos y defender decisiones mediante evidencia, costo, seguridad y objetivos de confiabilidad.

## Modelo mental

La arquitectura Azure nace del tenant y las políticas heredables, y llega al workload mediante identidades administradas y redes privadas.

## Secuencia



## Clases

| ID  | Clase                                                 | Laboratorio   | Horas |
|-----|-------------------------------------------------------|---------------|-------|
| 217 | Enterprise-scale landing zones y management groups    | governance    | 4     |
| 218 | Entra ID, workload identity, PIM y Conditional Access | iam           | 4     |
| 219 | Hub-spoke, Virtual WAN, Private Link y DNS privado    | network       | 4     |
| 220 | Bicep, deployment stacks y Azure Verified Modules     | iac           | 4     |
| 221 | App Service, Functions y Container Apps en producción | serverless    | 4     |
| 222 | AKS, workload identity, ingress y GitOps              | kubernetes    | 4     |
| 223 | Azure SQL, Cosmos DB y consistencia distribuida       | data          | 4     |
| 224 | Service Bus, Event Grid y Event Hubs                  | messaging     | 4     |
| 225 | Azure Monitor, Application Insights y OpenTelemetry   | observability | 4     |
| 226 | Defender for Cloud, Policy y Sentinel                 | security      | 4     |
| 227 | Cost Management, Advisor, resiliencia y Chaos Studio  | finops        | 4     |
| 228 | Proyecto: CloudShop productivo en Azure               | capstone      | 8     |

## Evaluación de la parte

- 35 % laboratorios y evidencia reproducible.
- 25 % retos verificables.
- 20 % decisiones y ADR.
- 10 % seguridad, confiabilidad y costo.

- 10 % proyecto integrador de la parte.

Se aprueba con 80 % de clases en nivel B o superior y el proyecto integrador reproducible.

## **Pauta bibliográfica**

- Azure Architecture Center — Microsoft.
- Exam Ref AZ-305 — Microsoft Press.
- Designing Distributed Systems — Brendan Burns.

# 217 — Enterprise-scale landing zones y management groups

Parte: 18 — Azure: arquitectura empresarial y operación en producción Nivel: avanzado · Horas estimadas: 4  
Laboratorio: governance · Estado: EXECUTABLECORE

## Propósito

Diseñar la jerarquía de Azure —grupos de administración, suscripciones y grupos de recursos— que es a esta nube lo que el plan de direcciones a la red: se decide en una tarde y condiciona una década. La clase da el criterio de reparto, explica dónde se aplican los controles para que no se puedan quitar desde abajo, y desarrolla la parte que más cuesta corregir después: mover una suscripción de sitio no mueve lo que ya se creó con la política antigua.

## Resultados de aprendizaje

Al finalizar podrás:

1. Repartir cargas entre grupos de administración y suscripciones con criterio.
2. Aplicar controles en el nivel correcto, sin que se puedan quitar desde abajo.
3. Distinguir política, iniciativa y bloqueo, y saber qué resuelve cada uno.
4. Desplegar políticas en modo auditoría antes de denegar.
5. Corregir una jerarquía mal repartida sin romper lo existente.

## Conceptos centrales


| Concepto                | Comprensión verificable                                                                                        |
|-------------------------|----------------------------------------------------------------------------------------------------------------|
| grupo de administración | Contenedor de suscripciones donde se aplican políticas y permisos heredados. Es el nivel que fija el gobierno. |
| suscripción             | Unidad de facturación, de cuota y de aislamiento. Equivale funcionalmente a una cuenta.                        |
| grupo de recursos       | Agrupación dentro de una suscripción, con ciclo de vida común. Se borra entero.                                |
| política                | Regla que audita, deniega, modifica o despliega. Se hereda hacia abajo y no se puede quitar desde abajo.       |
| iniciativa              | Conjunto de políticas asignado como una unidad, con parámetros. Es la forma práctica de gobernar.              |
| zona de aterrizaje      | Suscripción preparada con red, identidad, controles y observabilidad, lista para recibir cargas.               |

## Modelo mental

La arquitectura Azure nace del tenant y las políticas heredables, y llega al workload mediante identidades administradas y redes privadas.

Aplicado a esta clase, separa siempre cuatro planos: intención (qué necesita el usuario), configuración (qué declaramos), estado observado (qué existe de verdad) y evidencia (cómo sabemos que cumple). Confundirlos produce diseños que se ven correctos en un diagrama pero fallan al operar.

## ■ Flujo de razonamiento



## Desarrollo

### 1. La jerarquía, y por qué se decide pronto

Azure tiene tres niveles y cada uno resuelve algo distinto. Confundirlos es el error inicial.

#### GRUPO DE ADMINISTRACIÓN

contenedor de suscripciones  
aquí van las POLÍTICAS y las asignaciones de permisos que se heredan  
→ es el nivel del gobierno

#### SUSCRIPCIÓN

unidad de facturación, de CUOTA y de aislamiento  
→ los límites de recursos son por suscripción, y ese es el motivo práctico más frecuente para separar

#### GRUPO DE RECURSOS

agrupación con ciclo de vida común  
→ se borra entero; los recursos de un grupo deberían nacer y morir juntos  
→ no es un mecanismo de aislamiento de seguridad fuerte

Y el reparto que funciona, que conviene copiar salvo buena razón:

#### raíz

|                    |                                                             |
|--------------------|-------------------------------------------------------------|
| ■■■ PLATAFORMA     |                                                             |
| ■ ■■■ identidad    | directorio, servidores heredados                            |
| ■ ■■■ conectividad | red central, cortafuegos, DNS                               |
| ■ ■■■ gestión      | registros, copias, herramientas                             |
| ■■■ CARGAS         |                                                             |
| ■ ■■■ corporativo  | necesita red interna                                        |
| ■ ■■■ en línea     | público, sin red interna                                    |
| ■■■ SANDBOX        | experimentación, con caducidad                              |
| ■■■ DESAPROBADO    | lo que se retira, con controles más duros y sin crecimiento |

Y las tres decisiones que hay que tomar y que cuestan corregir:

- 1 ¿UNA SUSCRIPCIÓN POR ENTORNO O POR CARGA?  
por entorno y por carga: producción de pedidos, una; preproducción de pedidos, otra  
→ aísla cuota, facturación y permisos a la vez  
→ y es lo que permite dar acceso de administrador a un equipo sobre SU entorno sin exponer los demás
- 2 ¿DÓNDE VAN LOS CONTROLES?  
en el grupo de administración, nunca en la suscripción  
→ una política asignada en la suscripción la puede quitar quien administre esa suscripción  
→ una asignada arriba, no

clase 169

- 3 ¿QUÉ SE HEREDA Y QUÉ SE PARAMETRIZA?  
la misma iniciativa arriba, con parámetros distintos por rama  
→ «regiones permitidas» puede ser más estricto en corporativo que en sandbox

Y la advertencia que da nombre a la clase:

- MOVER UNA SUSCRIPCIÓN DE SITIO NO ARREGLA LO YA CREADO  
las políticas de denegación solo actúan sobre CREACIONES y MODIFICACIONES  
→ los recursos que ya existen siguen incumpliendo  
→ aparecen como no conformes, y hay que corregirlos uno a uno o con tareas de remediación
- y por eso la jerarquía se decide antes de crear nada  
ley 14

## 2. Políticas: auditar antes de denegar

Las políticas son el mecanismo de gobierno de Azure y tienen cuatro efectos, con usos distintos.

- |                        |                                                                                                                                   |
|------------------------|-----------------------------------------------------------------------------------------------------------------------------------|
| AUDITAR                | registra el incumplimiento, no impide nada<br>→ siempre el primer paso                                                            |
| DENEGAR                | impide crear o modificar<br>→ el control real                                                                                     |
| MODIFICAR              | corrige el recurso al crearlo (añade etiquetas, activa cifrado)<br>→ mejor que denegar cuando se puede arreglar solo<br>clase 214 |
| DESPLEGAR SI NO EXISTE | crea lo que falta (diagnóstico, agente)<br>→ potente y peligroso: despliega cosas que nadie pidió y que facturan                  |

Y el orden de implantación, que es el mismo de la clase 200:

- 1 ASIGNAR EN MODO AUDITORÍA, en el grupo de administración
- 2 MEDIR 2-4 semanas: cuántos recursos incumplen y cuáles
- 3 CLASIFICAR: incumplimientos reales frente a excepciones legítimas
- 4 CORREGIR o EXCEPTUAR, con dueño y fecha
- 5 CAMBIAR A DENEGAR
- 6 VIGILAR el cumplimiento como una señal más  
clase 211

- asignar en denegar el primer día bloquea despliegues legítimos y el gobierno pierde credibilidad  
ley 16

Las iniciativas, que es como se gobierna de verdad:

- una política suelta es difícil de mantener  
una INICIATIVA agrupa decenas con parámetros  
→ se asigna una vez por rama, con sus parámetros  
→ y el cumplimiento se mide por iniciativa, no política a política

- las iniciativas mínimas de una organización  
etiquetas obligatorias y sus valores  
regiones permitidas  
tipos de recurso permitidos o prohibidos  
cifrado obligatorio y versión mínima de TLS  
sin acceso público en almacenamiento ni en bases  
diagnóstico enviado al destino central  
y las de cumplimiento normativo, si aplican  
clase 214

Y una advertencia sobre el modo de despliegue automático:

- una política que despliega el agente de diagnóstico en cada recurso nuevo  
→ resuelve el problema de la observabilidad ausente  
→ y crea coste que nadie pidió  
clase 214  
→ hay que estimar el coste de lo que la política despliega ANTES de asignarla

Los bloqueos, que son otra cosa y se confunden con las políticas:

- |                    |                            |
|--------------------|----------------------------|
| BLOQUEO DE BORRADO | impide eliminar el recurso |
|--------------------|----------------------------|

BLOQUEO DE SOLO LECTURA impide modificarlo

- se aplican al recurso o al grupo, y los hereda lo de dentro
- útiles para lo que nunca debe borrarse: bases de datos de producción, red central, copias
- y son un incordio si se ponen de más: bloquean el despliegue declarativo
  - ← y entonces se quitan y nadie los repone
  - ley 25

### 3. Suscripciones: cuotas, facturación y aislamiento

La suscripción es el nivel donde se topan los límites, y ese es el motivo práctico que más veces obliga a separar.

#### LO QUE ES POR SUSCRIPCIÓN

- cuotas de cómputo por familia y por región
- límites de recursos por tipo
- la factura y su desglose
- y el ámbito natural de muchos permisos

#### CONSECUENCIAS PRÁCTICAS

- una carga que consume mucha cuota puede impedir crecer a otra de la misma suscripción
- separar por carga aísla ese riesgo

- las cuotas NO son automáticas: hay que pedir las con antelación
- y en un incidente que requiera escalar mucho, la cuota es el límite real, no la capacidad de Azure
- por eso se pide margen antes, y se vigila el consumo frente al límite
- clase 262

Las zonas de aterrizaje, que es la forma de que una suscripción nueva nazca lista:

#### QUÉ TRAE UNA SUSCRIPCIÓN ENTREGADA

- colocada en el grupo de administración correcto
- red conectada al centro, con sus rangos del plan
- clase 219
- identidad y permisos base asignados
- diagnóstico enrutado al destino central
- presupuesto y etiquetas obligatorias
- clase 214
- y las políticas heredadas ya aplicando

#### Y EL PLAZO IMPORTA

- si entregar una suscripción tarda tres semanas, los equipos usarán la suya, o crearán recursos donde puedan
- ley 16
- automatizar la entrega es lo que hace que el gobierno se cumpla
- clase 171

Y la decisión sobre quién administra qué:

#### EL EQUIPO DE PLATAFORMA administra

- grupos de administración, políticas, red central, identidad, destinos de diagnóstico

#### EL EQUIPO DE LA CARGA administra

- su suscripción: crea, despliega y opera dentro de las reglas heredadas

#### Y LO QUE NADIE DEBE PODER HACER

- quitar una política heredada
- cambiar el enrutamiento del diagnóstico
- crear emparejamientos de red por su cuenta
- estas son las que van arriba, denegadas

### 4. Corregir una jerarquía mal repartida

Casi ninguna organización empieza con la jerarquía correcta. Corregirla se puede, y hay un orden.

#### LO QUE SE PUEDE MOVER

- una suscripción puede cambiar de grupo de administración
- un recurso puede cambiar de grupo de recursos (a veces)
- y en algunos casos, de suscripción

## LO QUE NO SE MUEVE FÁCIL

recursos con dependencias de red  
recursos con identidad administrada asignada  
claves y secretos con referencias  
y todo lo que tenga la suscripción escrita en su  
identificador en otro sitio

Y el procedimiento:

- 1 DEFINIR la jerarquía objetivo y las iniciativas
- 2 ASIGNARLAS EN AUDITORÍA en el nivel correcto
- 3 MEDIR el incumplimiento actual  
→ esta es la fotografía que dice cuánto trabajo hay
- 4 MOVER las suscripciones al grupo que les corresponde  
→ recordando que lo ya creado sigue incumpliendo
- 5 REMEDIAR lo existente, por lotes y por prioridad  
→ primero lo que afecta a seguridad y a datos
- 6 PASAR A DENEGAR cuando el incumplimiento sea residual
- 7 DEJAR el cumplimiento como señal vigilada

Y lo que hay que medir mientras tanto:

recursos conformes frente a totales, por iniciativa  
y su TENDENCIA  
→ si no baja, la remediación no está ocurriendo  
excepciones vivas y su antigüedad clase 190  
→ si crecen siempre, la política está mal calibrada

Y una advertencia sobre las exenciones:

una exención sin fecha es una política que no existe ley 25  
→ toda exención con dueño, motivo y caducidad  
→ y un panel con las que vencen este mes

Y la lista de comprobación de la clase:

- hay grupos separados para plataforma, cargas, sandbox y desaprobado
- las suscripciones se separan por carga Y por entorno
- todas las políticas se asignan en grupos de administración, no en suscripciones
- las políticas se asignaron primero en auditoría
- se midió el incumplimiento antes de denegar
- las iniciativas están parametrizadas por rama
- está estimado el coste de lo que despliegan las políticas
- los bloqueos están solo donde hacen falta y no estorban al despliegue declarativo
- las cuotas están pedidas con margen y se vigilan
- entregar una suscripción nueva está automatizado y tarda minutos
- ningún equipo de carga puede quitar una política heredada
- toda exención tiene dueño, motivo y caducidad
- el cumplimiento por iniciativa se vigila como una señal

Y el cierre que enlaza con la clase siguiente: con la jerarquía puesta, el control que de verdad decide el alcance en Azure no es la política sino quién puede hacer qué y desde dónde. Identidad, identidades de carga, elevación temporal y acceso condicional es la materia de la clase 218.

## Ejemplo trabajado

CloudShop lleva cuatro años en Azure con 61 suscripciones creadas sin criterio. Lo que sigue es la fotografía del incumplimiento, la jerarquía nueva, y el hallazgo de que mover las suscripciones no arregló casi nada.

El punto de partida:

|                                              |     |
|----------------------------------------------|-----|
| suscripciones                                | 61  |
| bajo la raíz, sin grupo de administración    | 47  |
| en un grupo llamado «Producción»             | 9   |
| en un grupo llamado «Test»                   | 5   |
| políticas asignadas                          | 12  |
| en grupos de administración                  | 3   |
| EN SUSCRIPCIONES                             | 9 ← |
| de las 9, quitadas por el equipo de la carga | 4   |

y la consecuencia  
 4 equipos habían quitado las políticas de su propia suscripción porque «bloqueaban el despliegue»  
 → y nadie se enteró: no había alerta de cambio de asignación  
 ley 15

Y el detalle de por qué las quitaron:

la política denegaba crear cuentas de almacenamiento sin cifrado con clave propia  
 la plantilla del equipo no lo declaraba  
 y el mensaje de error decía solo «denegado por política»  
 → nadie sabía qué faltaba  
 → y quitar la política era más rápido que averiguarlo  
 ley 16

La jerarquía nueva:

```

raíz
■ ■ ■ ■ plataforma
■ ■ ■ ■ ■ ■ ■ ■ identidad          1 suscripción
■ ■ ■ ■ ■ ■ ■ ■ conectividad      2 (una por región)
■ ■ ■ ■ ■ ■ ■ ■ gestión           1
■ ■ ■ ■ ■ ■ ■ ■ cargas
■ ■ ■ ■ ■ ■ ■ ■ ■ ■ corporativo    34 suscripciones
■ ■ ■ ■ ■ ■ ■ ■ ■ ■ ■ ■ pedidos-prod, pedidos-pre, pedidos-dev,
■ ■ ■ ■ ■ ■ ■ ■ ■ ■ ■ ■ ■ ■ catalogo-prod, ... (una por carga y entorno)
■ ■ ■ ■ ■ ■ ■ ■ ■ ■ ■ ■ en línea   9
■ ■ ■ ■ ■ ■ ■ ■ ■ ■ ■ ■ sandbox    12 ← con caducidad de 90 días
■ ■ ■ ■ ■ ■ ■ ■ ■ ■ ■ ■ desaprobad 2
  
```

y el criterio escrito  
 una suscripción por CARGA y por ENTORNO  
 motivo aísla cuota, factura y permisos a la vez  
 coste de cambio si nos equivocamos alto

Las iniciativas, con sus parámetros por rama:

| iniciativa                     | corporativo | en línea  | sandbox |
|--------------------------------|-------------|-----------|---------|
| etiquetas obligatorias         | denegar     | denegar   | auditar |
| regiones permitidas            | 2 (UE)      | 2 (UE)    | 2 (UE)  |
| sin acceso público             | denegar     | denegar   | denegar |
| cifrado en reposo              | denegar     | denegar   | auditar |
| TLS mínimo 1.2                 | denegar     | denegar   | denegar |
| diagnóstico al destino central | desplegar   | desplegar | auditar |
| tipos de recurso permitidos    | restringido | amplio    | amplio  |
| sin IP pública en máquinas     | denegar     | auditar   | auditar |

Y el coste que se estimó antes de asignar:

la política que despliega el diagnóstico crearía  
 un ajuste de diagnóstico por recurso  
 ingesta estimada a partir del inventario ~1.900 €/mes  
 → se ajustó qué categorías se envían y con qué caducidad  
 → ingesta real 640 €/mes  
 → sin esta estimación previa, habría sido una sorpresa en  
 la factura del mes siguiente clase 214

La fase de auditoría, cuatro semanas.

|                                |        |       |
|--------------------------------|--------|-------|
| recursos totales               | 14.200 |       |
| incumplimientos por iniciativa |        |       |
| etiquetas obligatorias         | 9.140  | 64 %  |
| cifrado en reposo              | 1.870  | 13 %  |
| sin acceso público             | 340    | 2,4 % |
| TLS mínimo                     | 620    | 4,4 % |
| regiones permitidas            | 112    | 0,8 % |
| tipos de recurso               | 88     | 0,6 % |
| sin IP pública                 | 210    | 1,5 % |

y los que preocupaban de verdad  
 340 recursos con acceso público  
 de ellos, cuentas de almacenamiento 214  
 de ellas, con datos de clientes 19 ←  
 112 recursos fuera de las regiones permitidas



|                                             |           |        |
|---------------------------------------------|-----------|--------|
| recursos conformes (etiquetas)              | 36 %      | 98 %   |
| almacenes públicos con datos                | 19        | 0      |
| recursos fuera de región permitida          | 112       | 0      |
| exenciones vivas                            | 0         | 22     |
| con dueño, motivo y caducidad               | —         | 22     |
| vencidas y sin renovar                      | —         | 1      |
| plazo de entrega de una suscripción         | 3 semanas | 22 min |
| suscripciones creadas por fuera del proceso | 12        | 0      |

La lección que esta clase deja: mover sesenta y una suscripciones al grupo correcto no corrigió ni un solo recurso existente, porque las políticas de denegación solo actúan al crear o modificar; lo que corrigió catorce mil recursos fue una combinación de políticas de tipo modificar, tareas de remediación y cuatro meses de recrear cosas. Y las cuatro políticas que los equipos habían quitado no las quitaron por mala fe: las quitaron porque el mensaje de error decía «denegado por política» y no decía qué faltaba.

## Laboratorio guiado

Ejecuta desde la raíz:

```
python classes/part-18-azure-production-architecture/217-enterprise-scale-landing-zones-y-management-groups/lab.py
```

El laboratorio selecciona el motor de práctica governance y produce labresult.json. El escenario, sus comprobaciones y el artefacto esperado corresponden a esta clase; no requiere credenciales y deja explícito qué debe revalidarse en un sandbox real.

1. Lee exercise.steps y formula una predicción antes de ejecutar.
2. Ejecuta la práctica y verifica todos los elementos de checks.
3. Provoca el caso de negativetest y explica la señal observada.
4. Materializa azure-landing-zone en evidence/ usando la plantilla indicada.
5. Para proveedor real, sigue sandbox.requires, registra costo y ejecuta destroy.

## Evidencia esperada

El artefacto principal es una jerarquía de política, ownership y evidencia. Además, la entrega debe incluir el comando ejecutado, la salida estructurada y una conclusión que no exceda lo observado.

## Reto verificable

Construye azure-landing-zone para el caso CloudShop. Incluye una alternativa descartada, un supuesto que pueda falsarse, una prueba de fallo y una decisión de rollback.

## ■ Criterio de aceptación

- [ ] lab.py termina con código 0 y genera JSON válido.
- [ ] La entrega conecta al menos tres requisitos con mecanismos verificables.
- [ ] Existe una prueba positiva y una prueba negativa con evidencia.
- [ ] Seguridad, costo y operación aparecen como decisiones, no como anexos.
- [ ] Se declara una limitación y una condición que obligaría a revisar el diseño.
- [ ] Otra persona puede repetir el recorrido sin conocimiento tácito.

## ■ Errores frecuentes

| Síntoma                                                                             | Causa probable                                                                | Corrección                                                                                                                    |
|-------------------------------------------------------------------------------------|-------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------|
| Un equipo quita la política que le estorba y nadie se entera                        | La política estaba asignada en la suscripción, que ese equipo administra      | Asigna siempre en el grupo de administración y alerta sobre cambios de asignación.                                            |
| Mover las suscripciones no corrige ningún recurso                                   | Las políticas de denegación solo actúan sobre creaciones y modificaciones     | Usa políticas de tipo modificar con tareas de remediación para lo existente, y planifica recrear lo que no se pueda corregir. |
| Al activar el modo denegar se bloquean despliegues legítimos y llueven los tiquetes | Se pasó de cero a denegar sin auditar y sin mensajes útiles                   | Audita semanas, corrige lo real, añade mensajes que digan qué falta y actualiza la plantilla por defecto antes de denegar.    |
| Una carga impide crecer a otra sin relación con ella                                | Comparten suscripción y por tanto cuota                                       | Separa por carga y por entorno, y pide cuota con margen antes de necesitarla.                                                 |
| Aparecen recursos creados fuera del proceso                                         | Conseguir una suscripción tarda semanas                                       | Automatiza la entrega de suscripciones preparadas; si tarda minutos, nadie busca atajos.                                      |
| La factura crece tras aplicar el gobierno                                           | Una política despliega agentes o ajustes de diagnóstico en cada recurso nuevo | Estima el coste de lo que la política despliega antes de asignarla y ajusta categorías y caducidad.                           |

## ■ Seguridad, ética y costo

Trabaja con cuentas propias o sandboxes autorizados. No publiques secretos, identificadores reales ni datos personales. Antes de crear recursos pagos define presupuesto, etiquetas y comando de destrucción; después verifica que no queden recursos huérfanos. Los ejemplos locales enseñan contratos, pero no certifican cumplimiento ni disponibilidad de producción.

## ■ Preguntas de comprobación

1. ¿Qué resuelve cada uno de los tres niveles de la jerarquía?
2. ¿Por qué las políticas se asignan en grupos de administración y no en suscripciones?
3. ¿Qué corrige mover una suscripción de grupo y qué no?
4. ¿Cuál es el orden correcto para implantar una política y por qué?
5. ¿Qué debe llevar una exención para ser útil?

## Referencias

- Microsoft (2025). Cloud Adoption Framework: Azure landing zone design areas. <<https://learn.microsoft.com/en-us/azure/cloud-adoption-framework/ready/landing-zone/>>
- Microsoft (2025). Management groups and organizing resources. <<https://learn.microsoft.com/en-us/azure/governance/management-groups/overview>>
- Microsoft (2025). Azure Policy effects and remediation. <<https://learn.microsoft.com/en-us/azure/governance/policy/concepts/effects>>
- Microsoft (2025). Azure Policy exemptions. <<https://learn.microsoft.com/en-us/azure/governance/policy/concepts/exemption-structure>>
- Microsoft (2025). Subscription vending and landing zone automation. <<https://learn.microsoft.com/en-us/azure/cloud-adoption-framework/ready/landing-zone/design-area/subscription-vending>>
- Documentación oficial vigente del servicio implementado; registra URL y fecha de consulta.

Descargar: Parte 18 en PDF · Recorrido de Azure en PDF · Manual integral

| Anterior                                      | Índice              | Siguiente                                                        |
|-----------------------------------------------|---------------------|------------------------------------------------------------------|
| ← 216 · Proyecto: CloudShop productivo en AWS | Parte 18 · Programa | 218 · Entra ID, workload identity, PIM y Conditional Access<br>→ |

## Evaluación — 217 Enterprise-scale landing zones y management groups

### Preguntas

1. Explica el problema que resuelve esta capacidad sin mencionar un proveedor.
2. Identifica una frontera de responsabilidad y su propietario.
3. Compara dos alternativas mediante confiabilidad, seguridad, costo y operación.
4. ¿Qué demuestra el laboratorio y qué no puede demostrar?
5. Propón un caso límite o una prueba de fallo.

### Reto verificable

Entrega azure-landing-zone con diagrama o configuración, evidencia de ejecución, alternativa descartada, riesgo residual y criterio de rollback.

### Criterio de aceptación

- ☐ Resultado reproducible por una segunda persona.
- ☐ Evidencia vinculada a cada afirmación técnica.
- ☐ Prueba negativa o de fallo incluida.
- ☐ Costos y permisos expresados con unidades y alcance.
- ☐ Limitaciones declaradas sin presentar la simulación como producción.

### Escala

| Nivel             | Evidencia                                                |
|-------------------|----------------------------------------------------------|
| A — competente    | Cumple todo y defiende trade-offs con datos.             |
| B — en desarrollo | Cumple lo esencial; falta profundidad en una dimensión.  |
| C — inicial       | Artefacto parcial o conclusión sin evidencia suficiente. |
| 0                 | Sin entrega reproducible.                                |

# 218 — Entra ID, workload identity, PIM y Conditional Access

Parte: 18 — Azure: arquitectura empresarial y operación en producción Nivel: avanzado · Horas estimadas: 4  
Laboratorio: iam · Estado: EXECUTABLECORE

## Propósito

Resolver la identidad en Azure, que es donde se decide el alcance real de todo lo demás. La clase cubre las identidades de carga sin secretos, el modelo de asignación de permisos con su error característico —un ámbito demasiado amplio, que es el equivalente exacto del comodín de la clase 206—, la elevación temporal para el acceso administrativo y el acceso condicional como control de contexto que se aplica a personas y a cargas.

## Resultados de aprendizaje

Al finalizar podrás:

1. Eliminar secretos de aplicación usando identidades administradas y federación.
2. Asignar permisos en el ámbito mínimo y detectar los amplios.
3. Configurar elevación temporal con aprobación para el acceso administrativo.
4. Aplicar acceso condicional sin quedarse fuera del propio inquilino.
5. Revisar accesos periódicamente y retirar lo que no se usa.

## Conceptos centrales


| Concepto               | Comprensión verificable                                                                                           |
|------------------------|-------------------------------------------------------------------------------------------------------------------|
| identidad administrada | Identidad ligada a un recurso de Azure, sin credenciales que gestionar. Asignada por el sistema o por el usuario. |
| credencial federada    | Confianza declarada en un emisor externo para que sus testigos obtengan credenciales sin secreto.                 |
| ámbito de asignación   | Nivel al que se concede un permiso: grupo de administración, suscripción, grupo de recursos o recurso.            |
| elevación temporal     | Activación de un permiso administrativo por tiempo limitado, con justificación y aprobación.                      |
| acceso condicional     | Regla que decide si una autenticación se permite según usuario, aplicación, dispositivo, red y riesgo.            |
| acceso de emergencia   | Cuentas excluidas de las políticas, para no quedarse fuera. Vigiladas y probadas.                                 |

## Modelo mental

La arquitectura Azure nace del tenant y las políticas heredables, y llega al workload mediante identidades administradas y redes privadas.

Aplicado a esta clase, separa siempre cuatro planos: intención (qué necesita el usuario), configuración (qué declaramos), estado observado (qué existe de verdad) y evidencia (cómo sabemos que cumple). Confundirlos produce diseños que se ven correctos en un diagrama pero fallan al operar.

## ■ Flujo de razonamiento



## Desarrollo

### 1. Identidad de carga sin secretos

El objetivo es el mismo de la clase 206: que ninguna aplicación tenga una credencial guardada.

**IDENTIDAD ADMINISTRADA** – para lo que corre EN Azure  
el recurso tiene identidad propia; la plataforma le entrega testigos  
sin secretos, sin rotación, sin nada que robar

**ASIGNADA POR EL SISTEMA**  
nace y muere con el recurso  
+ no queda huérfana  
– no se puede preasignar permisos antes de crearlo

**ASIGNADA POR EL USUARIO**  
recurso independiente, reutilizable por varios  
+ permisos preparados antes; sirve para conjuntos  
– sobrevive al recurso ley 25  
→ y hay que retirarla cuando ya no la use nadie

**CREDECIAL FEDERADA** – para lo que corre FUERA  
canalizaciones, cargas en otro clúster, otra nube  
se declara confianza en el emisor y en el sujeto  
→ mismo mecanismo y mismos errores que en la clase 206

**SECRETO DE CLIENTE** – último recurso  
con caducidad corta, rotación automatizada y una excepción registrada con fecha ley 25

Y la regla que ordena la elección:

|                      |                                |
|----------------------|--------------------------------|
| ¿corre en Azure?     | identidad administrada         |
| ¿corre fuera?        | credencial federada            |
| ¿ninguna de las dos? | secreto, con fecha de revisión |

→ y una función de aptitud: cero secretos de cliente sin excepción registrada clase 190

Y el detalle de configuración donde se falla, igual que en AWS:

LA CREDENCIAL FEDERADA SE ATA A  
emisor, sujeto y audiencia

✗ sujeto con comodín, o sin comprobar audiencia  
→ cualquier repositorio u organización puede obtener el testigo

✓ sujeto exacto: organización, repositorio y entorno

→ es el mismo fallo de la clase 206 con otro nombre, y por eso la prueba negativa es idéntica: intentarlo desde otro

## 2. El ámbito de asignación: el error característico

En Azure los permisos se conceden asignando un papel a una identidad en un ámbito, y el ámbito se hereda hacia abajo. Ahí está el error.

LOS CUATRO ÁMBITOS, de mayor a menor

|                         |                               |
|-------------------------|-------------------------------|
| grupo de administración | → todas sus suscripciones     |
| suscripción             | → todos sus grupos y recursos |
| grupo de recursos       | → todo lo de dentro           |
| recurso                 | → solo ese                    |

Y LA COSTUMBRE

asignar «Colaborador» en la suscripción, porque es cómodo y funciona

→ esa identidad puede crear, modificar y borrar

CUALQUIER cosa de la suscripción

→ incluida la base de datos de producción

Y el equivalente exacto de la clase 206:

en AWS una condición de sujeto con comodín permite que cualquiera asuma el rol

en Azure una asignación en un ámbito amplio permite que la identidad toque cualquier cosa de ese ámbito

→ el mecanismo es distinto; el resultado, el mismo:

alcance enorme desde un punto comprometido clase 189

Cómo se hace bien, con el coste que tiene:

asignar en el ÁMBITO DEL RECURSO o del grupo de recursos con el papel MÁS ESPECÍFICO que exista

no «Colaborador» sino «Colaborador de datos de blob»

no «Propietario» nunca, salvo casos contados

y cuando no existe un papel adecuado

papel personalizado, con las acciones justas

→ cuesta mantenerlo, y compensa en los casos de mucho alcance

Y los papeles que hay que tratar como excepcionales:

|                            |                                 |
|----------------------------|---------------------------------|
| Propietario                | puede conceder permisos         |
|                            | → quien lo tiene, lo tiene todo |
| Administrador de acceso    | puede conceder permisos         |
|                            | → equivalente en la práctica    |
| Colaborador en suscripción | puede borrar casi todo          |

→ estos tres se conceden con elevación temporal, nunca de forma permanente

Cómo detectar los ámbitos amplios, que es el trabajo continuo:

inventario de asignaciones, por ámbito

¿cuántas hay en grupo de administración?

¿cuántas en suscripción?

¿cuántas identidades tienen Propietario?

y la medida que importa

ALCANCE desde cada identidad: a cuántos recursos llega

→ se mide, y es la cifra que ordena el trabajo  
clases 133, 189

y las asignaciones que no se usan

→ los registros de actividad dicen qué permisos se ejercen de verdad

→ lo concedido y no usado se retira clase 134

Y una fuente de alcance que se olvida:

LOS GRUPOS ANIDADOS

un grupo dentro de otro hereda sus asignaciones

→ alguien añadido a un grupo «de proyecto» acaba con permisos de producción sin que nadie lo decida

→ hay que revisar la pertenencia efectiva, no la directa

### 3. Elevación temporal y revisión de accesos

Para las personas, el objetivo es que nadie tenga permisos administrativos permanentes.

#### EL MODELO

la persona es ELEGIBLE para un papel, no lo tiene  
cuando lo necesita, lo activa  
con justificación escrita  
con aprobación de otra persona, si el papel es sensible  
con segundo factor en el momento de activar  
y con CADUCIDAD: 1, 4 u 8 horas

#### QUÉ RESUELVE

el permiso permanente que nadie revisa  
el administrador que se va y conserva accesos  
el compromiso de una cuenta con permisos totales  
y deja registro de POR QUÉ se usó, no solo de que se usó  
clase 141

Y los detalles que hacen que funcione o que se rodee:

SI ACTIVAR TARDA MUCHO, la gente pedirá permanente  
→ activación en segundos cuando no requiere aprobación  
→ y aprobadores suficientes, con turnos, cuando sí  
ley 16

#### SI NO HAY APROBADOR DISPONIBLE DE MADRUGADA

→ un incidente se atasca esperando  
→ por eso los papeles de emergencia se activan sin aprobación, con alerta inmediata y revisión posterior

#### Y LA PRUEBA QUE HAY QUE HACER

activar el papel de emergencia y cronometrar  
→ en la clase 179, el acceso de emergencia estaba creado, documentado y NO funcionaba  
ley 22

Las revisiones de acceso, que es lo que impide la acumulación:

cada trimestre, quien es dueño revisa  
quién es elegible para cada papel  
qué identidades tienen asignaciones amplias  
qué invitados externos siguen teniendo acceso

y la regla que las hace útiles  
quien no responde a la revisión → se retira el acceso  
→ si la falta de respuesta lo conserva, la revisión no sirve de nada

Y la señal que dice si el modelo está funcionando:

número de asignaciones PERMANENTES de papeles sensibles  
objetivo: cero, salvo cuentas de emergencia  
y número de activaciones al mes, con su justificación  
→ si nadie activa nunca, o sobran los papeles o la gente tiene permisos por otra vía

### 4. Acceso condicional, sin quedarse fuera

El acceso condicional decide si una autenticación se permite según el contexto, y es el control más potente del directorio.

#### LO QUE PUEDE EVALUAR

quién: usuario, grupo, papel  
qué: aplicación o recurso  
desde dónde: red, país, dispositivo  
con qué: dispositivo conforme o unido al directorio  
y el riesgo: de la sesión y del usuario

#### LO QUE PUEDE EXIGIR

segundo factor  
dispositivo conforme  
aplicación cliente aprobada

frecuencia de reautenticación  
o directamente bloquear

Las políticas mínimas de una organización:

- 1 segundo factor para TODOS los usuarios  
→ y resistente a suplantación (llave física o similar)  
para los papeles administrativos
- 2 bloquear protocolos de autenticación antiguos  
→ son los que se saltan el segundo factor
- 3 exigir dispositivo conforme para el acceso  
administrativo
- 4 bloquear países donde no se opera  
→ medida sencilla que reduce mucho el ruido
- 5 exigir reautenticación al elevar privilegios
- 6 y proteger los flujos de registro de credenciales  
→ registrar un segundo factor es un momento crítico

Y el error que deja a la organización fuera de su propio inquilino:

UNA POLÍTICA QUE EXIGE DISPOSITIVO CONFORME A TODOS  
incluidas las cuentas administrativas  
y el día que falla el sistema de conformidad, o el  
dispositivo del administrador se rompe  
→ nadie puede entrar a arreglarlo

LA PROTECCIÓN

cuentas de acceso de emergencia  
excluidas de todas las políticas condicionales  
con credenciales largas guardadas físicamente  
con alerta INMEDIATA en cada uso  
y probadas cada trimestre ley 22  
y siempre DOS, por si una falla

Y la disciplina de despliegue, que es la misma de siempre:

- 1 crear la política en modo SOLO INFORME
  - 2 medir a quién afectaría, durante semanas
  - 3 excluir lo que haya que excluir, con registro
  - 4 activar para un grupo piloto
  - 5 activar para todos
- activar una política condicional para todos el primer día  
es la forma más rápida de dejar a la empresa sin acceso  
clase 200

Y la lista de comprobación de la clase:

- ninguna aplicación tiene secretos de cliente sin excepción registrada
- lo que corre en Azure usa identidad administrada
- las credenciales federadas atan emisor, sujeto y audiencia
- no hay asignaciones de Propietario permanentes
- las asignaciones se hacen en el ámbito del recurso o del grupo
- se usa el papel más específico disponible
- está medido el alcance desde cada identidad
- se revisan los permisos concedidos y no usados
- se revisa la pertenencia efectiva a grupos, no la directa
- los papeles sensibles requieren elevación temporal
- hay aprobadores suficientes y activación rápida
- el acceso de emergencia se ha probado este trimestre
- hay dos cuentas de emergencia excluidas de las políticas
- cada uso de emergencia dispara alerta inmediata
- las políticas condicionales se desplegaron en solo informe
- los protocolos de autenticación antiguos están bloqueados

Y el cierre que enlaza con la clase siguiente: con la jerarquía y la identidad resueltas, queda conectar las suscripciones entre sí y con el centro de datos, y decidir por dónde entra y sale el tráfico. Red en Azure es la materia de la clase 219.

## Ejemplo trabajado

CloudShop revisa la identidad de su inquilino de Azure. Lo que sigue es el inventario de asignaciones, las tres identidades que podían tocar toda la producción, y la política condicional que dejó al equipo fuera durante cuarenta minutos.

#### El inventario:

|                                         |       |   |
|-----------------------------------------|-------|---|
| identidades de aplicación               | 184   |   |
| con identidad administrada              | 61    |   |
| con credencial federada                 | 9     |   |
| CON SECRETO DE CLIENTE                  | 114   | ← |
| de ellos, caducados y aún referenciados | 18    |   |
| de ellos, con más de 2 años             | 47    |   |
| asignaciones de papel                   | 1.940 |   |
| en grupo de administración              | 31    | ← |
| en suscripción                          | 820   | ← |
| en grupo de recursos                    | 760   |   |
| en recurso                              | 329   |   |
| papeles sensibles, permanentes          |       |   |
| Propietario                             | 41    |   |
| Administrador de acceso                 | 12    |   |
| Colaborador en suscripción              | 214   |   |

#### Y las tres asignaciones que resultaron peores:

- 1 la identidad de la canalización de despliegue tenía Colaborador en el grupo de administración «cargas»  
→ alcance: 43 suscripciones, todo  
→ y podía borrar bases de datos de producción
- 2 una identidad administrada asignada por el usuario, creada en 2022 para una prueba, tenía Propietario en la suscripción de producción de pedidos  
→ el recurso que la usaba se borró hace 2 años  
→ la identidad seguía viva, con Propietario ley 25
- 3 un grupo llamado «Proyecto Migración 2023» tenía Colaborador en 9 suscripciones  
→ 34 personas seguían en él  
→ 11 ya no trabajaban en esas cargas  
→ y 3 habían entrado por pertenencia ANIDADA, sin que nadie los añadiera a propósito

#### El alcance medido, que es lo que ordenó el trabajo:

|                               |                      |        |
|-------------------------------|----------------------|--------|
| identidad                     | recursos alcanzables |        |
| canalización de despliegue    | 14.200               | ← todo |
| identidad huérfana de 2022    | 1.840                |        |
| grupo Proyecto Migración      | 6.100                |        |
| api-pedidos (correcta)        | 4                    |        |
| procesador-eventos (correcta) | 7                    |        |

→ dos identidades y un grupo concentraban casi todo el riesgo del inquilino

#### Las correcciones:

##### CANALIZACIÓN

antes Colaborador en grupo de administración  
después 4 identidades federadas, una por propósito  
cada una con asignación en el GRUPO DE RECURSOS que le toca  
y una barrera: ninguna puede asignar papeles ni modificar políticas  
alcance 14.200 → 340 recursos, repartidos en 4

##### IDENTIDAD HUÉRFANA

retirada  
y una comprobación nueva: identidades administradas asignadas por el usuario sin ningún recurso asociado  
→ se encontraron 23 más ley 25

##### GRUPO DE PROYECTO

retirado; sustituido por grupos por carga y entorno  
y revisión trimestral de pertenencia EFECTIVA

##### SECRETOS DE CLIENTE

114 → 12 en cuatro meses

61 pasaron a identidad administrada  
 28 a credencial federada  
 13 se apagaron: eran aplicaciones que ya no existían  
 12 quedan, todos de terceros, con rotación automática  
 y excepción registrada con fecha  
 los 18 caducados y referenciados  
 → 4 de ellos, en aplicaciones que fallaban  
 silenciosamente desde hacía meses ley 13

#### La elevación temporal:

se retiraron TODAS las asignaciones permanentes de  
 Propietario y Administrador de acceso  
 y pasaron a elegibles con activación

|                            |                                                         |
|----------------------------|---------------------------------------------------------|
| Propietario                | aprobación de 2, caducidad 4 h                          |
| Administrador de acceso    | aprobación de 2, caducidad 2 h                          |
| Colaborador en suscripción | activación directa, 8 h                                 |
| Emergencia                 | sin aprobación, alerta<br>inmediata, revisión posterior |

los primeros dos meses

|                                                                                 |               |
|---------------------------------------------------------------------------------|---------------|
| activaciones                                                                    | 412           |
| con justificación útil                                                          | 340           |
| con justificación tipo «trabajo»                                                | 72            |
| → se pidió mejorarlas; a los 3 meses, 11                                        |               |
| activaciones de emergencia                                                      | 3             |
| · 2 incidentes reales                                                           |               |
| · 1 porque el aprobador estaba de vacaciones y nadie<br>había cubierto el turno | ← se corrigió |

y la prueba de emergencia, ejecutada  
 primer intento la cuenta de emergencia no podía activar  
 porque la política condicional creada en  
 el paso siguiente la había incluido  
 sin querer  
 → corregido, y añadido al calendario trimestral

#### La política condicional que dejó al equipo fuera.

se creó una política: «exigir dispositivo conforme para  
 acceder al portal de Azure»  
 se activó directamente para todos

a las 09:40, el sistema de evaluación de conformidad  
 tuvo una incidencia y marcó como no conformes a 190  
 dispositivos  
 → nadie del equipo de plataforma podía entrar al portal  
 → incluidas las 2 cuentas de emergencia, que se habían  
 incluido en el ámbito por error

09:40 se detecta  
 09:52 se localiza a alguien con acceso desde otro camino  
 10:20 política desactivada  
 duración 40 min

qué faltó  
 modo solo informe durante semanas  
 exclusión explícita y COMPROBADA de las cuentas de  
 emergencia  
 y despliegue por grupos clase 200

segundo intento

- 1 solo informe, 3 semanas  
 → 1.140 accesos que se habrían bloqueado  
 → de ellos, 210 legítimos desde dispositivos no  
 registrados: contratistas y 2 equipos con portátiles  
 propios
- 2 se registraron los dispositivos legítimos
- 3 exclusión de cuentas de emergencia, comprobada  
 entrando con ellas
- 4 grupo piloto de 12 personas, 2 semanas
- 5 activación general

accesos bloqueados legítimos tras activar 2

El resto de políticas, con su despliegue:

| política                                               | informe | activa |
|--------------------------------------------------------|---------|--------|
| segundo factor para todos                              | 3 sem   | sí     |
| segundo factor resistente para papeles administrativos | 2 sem   | sí     |
| bloquear autenticación antigua                         | 4 sem   | sí     |
| → el informe encontró 6 aplicaciones que la usaban     |         |        |
| → 4 se corrigieron, 2 se apagaron                      |         |        |
| dispositivo conforme para portal                       | 3 sem   | sí     |
| bloquear países no operados                            | 1 sem   | sí     |
| → 41.000 intentos bloqueados el primer mes             |         |        |
| reautenticación al elevar                              | 1 sem   | sí     |

El resultado, seis meses después:

|                                                   |        |            |
|---------------------------------------------------|--------|------------|
| secretos de cliente                               | 114    | 12         |
| caducados y referenciados                         | 18     | 0          |
| asignaciones en grupo de administración           | 31     | 4          |
| asignaciones en suscripción                       | 820    | 190        |
| Propietario permanente                            | 41     | 0          |
| alcance de la identidad de despliegue             | 14.200 | 340        |
| identidades huérfanas                             | 24     | 0          |
| personas con permisos administrativos permanentes | 267    | 2          |
| (las 2 cuentas de emergencia)                     |        |            |
| prueba de emergencia ejecutada                    | no     | trimestral |
| incidentes por política condicional               | 1      | 0          |

La lección que esta clase deja: el error característico de Azure resultó ser exactamente el equivalente del comodín de la clase 206: no una condición mal escrita, sino un ámbito de asignación demasiado alto, con una sola identidad capaz de tocar catorce mil recursos. Y la política de seguridad que se activó para proteger el portal dejó a la empresa fuera durante cuarenta minutos, incluidas las cuentas de emergencia que existían precisamente para eso y que nadie había comprobado.

## Laboratorio guiado

Ejecuta desde la raíz:

```
python classes/part-18-azure-production-architecture/218-entra-id-workload-identity-pim-y-conditional-access/lab.py
```

El laboratorio selecciona el motor de práctica iam y produce labresult.json. El escenario, sus comprobaciones y el artefacto esperado corresponden a esta clase; no requiere credenciales y deja explícito qué debe revalidarse en un sandbox real.

1. Lee exercise.steps y formula una predicción antes de ejecutar.
2. Ejecuta la práctica y verifica todos los elementos de checks.
3. Provoca el caso de negativetest y explica la señal observada.
4. Materializa azure-identity en evidence/ usando la plantilla indicada.
5. Para proveedor real, sigue sandbox.requires, registra costo y ejecuta destroy.

### Evidencia esperada

El artefacto principal es una matriz de acceso mínimo con prueba de denegación. Además, la entrega debe incluir el comando ejecutado, la salida estructurada y una conclusión que no exceda lo observado.

## Reto verificable

Construye azure-identity para el caso CloudShop. Incluye una alternativa descartada, un supuesto que pueda falsarse, una prueba de fallo y una decisión de rollback.

## ■ Criterio de aceptación

- [ ] lab.py termina con código 0 y genera JSON válido.
- [ ] La entrega conecta al menos tres requisitos con mecanismos verificables.

- [ ] Existe una prueba positiva y una prueba negativa con evidencia.
- [ ] Seguridad, costo y operación aparecen como decisiones, no como anexos.
- [ ] Se declara una limitación y una condición que obligaría a revisar el diseño.
- [ ] Otra persona puede repetir el recorrido sin conocimiento tácito.

## ■ Errores frecuentes

| Síntoma                                                                              | Causa probable                                                            | Corrección                                                                                                                                 |
|--------------------------------------------------------------------------------------|---------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------|
| Una identidad de aplicación puede tocar recursos que no tienen nada que ver con ella | La asignación se hizo en la suscripción o en el grupo de administración   | Asigna en el ámbito del recurso o del grupo de recursos, con el papel más específico disponible, y mide el alcance resultante.             |
| Alguien acaba con permisos de producción sin que nadie se los diera                  | Pertenencia anidada a un grupo con asignaciones amplias                   | Revisa la pertenencia efectiva, no la directa, y retira los grupos de proyecto cuando el proyecto termina.                                 |
| Una identidad sigue teniendo permisos y su recurso ya no existe                      | Identidad administrada asignada por el usuario, que sobrevive al recurso  | Inventaría periódicamente las identidades sin recurso asociado y retíralas.                                                                |
| Una aplicación falla en silencio desde hace meses                                    | Su secreto de cliente caducó y nadie lo vigilaba                          | Sustituye por identidad administrada o federada; para lo que quede, rotación automática y alerta por caducidad próxima.                    |
| Nadie puede entrar al portal cuando falla un sistema auxiliar                        | Una política condicional se activó para todos sin exclusiones comprobadas | Despliega en solo informe, excluye dos cuentas de emergencia y comprueba entrando con ellas antes de activar.                              |
| La gente pide permisos permanentes pese a existir elevación temporal                 | Activar tarda demasiado o no hay aprobadores disponibles                  | Activación en segundos cuando no requiere aprobación, aprobadores con turnos y un papel de emergencia sin aprobación con alerta inmediata. |

## ■ Seguridad, ética y costo

Trabaja con cuentas propias o sandboxes autorizados. No publiques secretos, identificadores reales ni datos personales. Antes de crear recursos pagos define presupuesto, etiquetas y comando de destrucción; después verifica que no queden recursos huérfanos. Los ejemplos locales enseñan contratos, pero no certifican cumplimiento ni disponibilidad de producción.

## ■ Preguntas de comprobación

1. ¿Qué identidad corresponde a una carga que corre en Azure y cuál a una que corre fuera?
2. ¿Cuál es el equivalente en Azure del comodín en la condición de sujeto de AWS?
3. ¿Qué hace que la elevación temporal se rodee y cómo se evita?
4. ¿Por qué hacen falta dos cuentas de acceso de emergencia y qué hay que probar de ellas?
5. ¿Cómo se despliega una política condicional sin dejar a la organización fuera?

## Referencias

- Microsoft (2025). Managed identities for Azure resources.  
<<https://learn.microsoft.com/en-us/entra/identity/managed-identities-azure-resources/overview>>
- Microsoft (2025). Workload identity federation.  
<<https://learn.microsoft.com/en-us/entra/workload-id/workload-identity-federation>>
- Microsoft (2025). Azure RBAC scope and best practices.  
<<https://learn.microsoft.com/en-us/azure/role-based-access-control/best-practices>>
- Microsoft (2025). Privileged Identity Management.  
<<https://learn.microsoft.com/en-us/entra/id-governance/privileged-identity-management/pim-configure>>

- Microsoft (2025). Conditional Access and emergency access accounts.  
<<https://learn.microsoft.com/en-us/entra/identity/role-based-access-control/security-emergency-access>>
- Documentación oficial vigente del servicio implementado; registra URL y fecha de consulta.

Descargar: Parte 18 en PDF · Recorrido de Azure en PDF · Manual integral

| Anterior                                                   | Índice              | Siguiente                                                     |
|------------------------------------------------------------|---------------------|---------------------------------------------------------------|
| ← 217 · Enterprise-scale landing zones y management groups | Parte 18 · Programa | 219 · Hub-spoke, Virtual WAN, Private Link y DNS privado<br>→ |

## Evaluación — 218 Entra ID, workload identity, PIM y Conditional Access

### Preguntas

1. Explica el problema que resuelve esta capacidad sin mencionar un proveedor.
2. Identifica una frontera de responsabilidad y su propietario.
3. Compara dos alternativas mediante confiabilidad, seguridad, costo y operación.
4. ¿Qué demuestra el laboratorio y qué no puede demostrar?
5. Propón un caso límite o una prueba de fallo.

### Reto verificable

Entrega azure-identity con diagrama o configuración, evidencia de ejecución, alternativa descartada, riesgo residual y criterio de rollback.

### Criterio de aceptación

- [ ] Resultado reproducible por una segunda persona.
- [ ] Evidencia vinculada a cada afirmación técnica.
- [ ] Prueba negativa o de fallo incluida.
- [ ] Costos y permisos expresados con unidades y alcance.
- [ ] Limitaciones declaradas sin presentar la simulación como producción.

### Escala

| Nivel             | Evidencia                                                |
|-------------------|----------------------------------------------------------|
| A — competente    | Cumple todo y defiende trade-offs con datos.             |
| B — en desarrollo | Cumple lo esencial; falta profundidad en una dimensión.  |
| C — inicial       | Artefacto parcial o conclusión sin evidencia suficiente. |
| 0                 | Sin entrega reproducible.                                |

# 219 — Hub-spoke, Virtual WAN, Private Link y DNS privado

Parte: 18 — Azure: arquitectura empresarial y operación en producción Nivel: avanzado · Horas estimadas: 4  
Laboratorio: network · Estado: EXECUTABLECORE

## Propósito

Montar la red de Azure conectando decenas de suscripciones sin abrir caminos indeseados. La clase cubre la topología de centro y radios frente a la gestionada, los puntos privados hacia los servicios de la plataforma, y la parte que produce la mayoría de los incidentes de esta capa: la resolución de nombres privados, que en Azure exige enlazar cada zona a cada red y falla en silencio cuando no se hace.

## Resultados de aprendizaje

Al finalizar podrás:

1. Elegir entre centro y radios propio y topología gestionada.
2. Segmentar con grupos de seguridad y rutas, cerrando por ausencia de camino.
3. Conectar a los servicios de la plataforma con puntos privados.
4. Resolver nombres privados en todas las redes, sin huecos.
5. Diagnosticar los fallos característicos de esta topología.

## Conceptos centrales


| Concepto                     | Comprensión verificable                                                                                     |
|------------------------------|-------------------------------------------------------------------------------------------------------------|
| centro y radios              | Topología con una red central que concentra conectividad e inspección, y redes de carga conectadas a ella.  |
| emparejamiento               | Conexión entre dos redes virtuales. No es transitivo por sí solo: hace falta encaminar.                     |
| ruta definida por el usuario | Ruta que obliga al tráfico a pasar por un dispositivo. Es lo que fuerza la inspección.                      |
| punto privado                | Interfaz con dirección de tu red que representa un servicio de la plataforma.                               |
| zona DNS privada             | Zona que resuelve el nombre del servicio a la dirección privada. Debe enlazarse a cada red que la necesite. |
| grupo de seguridad de red    | Reglas de filtrado por subred o interfaz, con prioridades y reglas por defecto que hay que conocer.         |

## Modelo mental

La arquitectura Azure nace del tenant y las políticas heredables, y llega al workload mediante identidades administradas y redes privadas.

Aplicado a esta clase, separa siempre cuatro planos: intención (qué necesita el usuario), configuración (qué declaramos), estado observado (qué existe de verdad) y evidencia (cómo sabemos que cumple). Confundirlos produce diseños que se ven correctos en un diagrama pero fallan al operar.

## ■ Flujo de razonamiento



## Desarrollo

### 1. Topología: centro y radios

La topología estándar de Azure concentra en una red central lo que no debe repetirse.

**EN EL CENTRO**  
 cortafuegos o dispositivo de inspección  
 pasarelas hacia el centro de datos y hacia internet  
 resolutor DNS y sus reglas de reenvío  
 y, a veces, los puntos privados compartidos

**EN CADA RADIO**  
 las cargas, en sus subredes  
 sin pasarela propia ni salida directa a internet

Y la propiedad que hay que entender antes de nada:

**EL EMPAREJAMIENTO NO ES TRANSITIVO**  
 radio A ↔ centro y radio B ↔ centro  
 → A NO alcanza B automáticamente  
 → hace falta que el tráfico pase por un dispositivo del centro y haya rutas que lo lleven allí

→ y esto es una **VENTAJA**: el aislamiento entre radios es el estado por defecto clase 199  
 → abrirlo es una decisión, no un descuido

La elección entre montar el centro o usar la topología gestionada:

**CENTRO PROPIO**  
 + control total: cualquier dispositivo, cualquier diseño  
 + más barato en tráfico  
 - hay que montar y operar el encaminamiento y la alta disponibilidad

**TOPOLOGÍA GESTIONADA (Virtual WAN)**  
 + conecta radios, sedes y usuarios remotos con menos trabajo  
 + encaminamiento y escala gestionados

- + tablas de rutas para segmentar clase 199
- coste por conexión y por gigabyte
- menos control fino

#### CRITERIO

- pocas redes y una región → centro propio
- muchas sedes, varias regiones, usuarios remotos → gestionada

Y lo que hay que decidir en ambos casos:

#### ¿POR DÓNDE SALE EL TRÁFICO A INTERNET?

- salida centralizada por el cortafuegos del centro
- registro, control y direcciones fijas clase 200
- y una ruta definida por el usuario en cada subred que mande 0.0.0.0/0 al cortafuegos

#### ¿QUÉ RADIOS SE VEN ENTRE SÍ?

- por defecto, ninguno
- y lo que se abra, con rutas explícitas y pasando por inspección si cruza fronteras de confianza clase 189

Y una decisión que ahorra dinero y latencia:

- el tráfico entre dos radios que se hablan mucho puede ir directo con un emparejamiento entre ellos
- evita pagar el proceso del cortafuegos dos veces
- y hay que decidirlo, no dejarlo pasar por costumbre clase 199

## 2. Filtrado y rutas: lo que hay que saber

Los grupos de seguridad de red tienen reglas por defecto que sorprenden si no se conocen.

- REGLAS POR DEFECTO, que existen aunque no se vean
- entrante
  - permitido desde la propia red virtual
  - permitido desde el balanceador
  - DENEGADO todo lo demás
- saliente
  - permitido hacia la propia red virtual
  - PERMITIDO HACIA INTERNET ←
  - denegado el resto

- la salida a internet está PERMITIDA por defecto
- y por eso el control de salida es una decisión explícita clase 200, ley 26

Y el funcionamiento por prioridad, que causa confusión:

- las reglas se evalúan por número de prioridad, de menor a mayor, y la PRIMERA que coincide decide
- una regla permisiva con prioridad baja anula las restrictivas posteriores
- y las reglas por defecto tienen prioridades muy altas: siempre se evalúan al final

#### regla práctica

- deja huecos entre prioridades (100, 200, 300...)
- y documenta el orden esperado

Y dónde aplicarlos:

- A LA SUBRED lo habitual; se aplica a todo lo de dentro
- A LA INTERFAZ para excepciones; complica el diagnóstico
- aplicar en los dos sitios a la vez es la causa más común de «no entiendo por qué no llega»

Las rutas definidas por el usuario, que son lo que fuerza la inspección:

- por defecto, cada subred tiene rutas del sistema hacia la propia red, los emparejamientos e internet

una ruta definida por el usuario las sustituye

- 0.0.0.0/0 → dirección del cortafuegos
- todo el tráfico saliente pasa por él

y el error clásico

- poner la ruta en la subred del cortafuegos también

- el tráfico entra en bucle
- la subred del dispositivo NO lleva esa ruta

Y la regla del prefijo más específico, que aquí también manda:

- si hay una ruta más específica hacia otro sitio, gana
  - así se implementan las excepciones clase 194
- y así también se abren caminos sin querer, si alguien añade una ruta «temporal» ley 25

Y una comprobación que resuelve la mitad de los casos:

- la herramienta de diagnóstico de siguiente salto dice, para un origen y un destino concretos, qué ruta se aplica y hacia dónde va
- y hay otra que dice qué regla de seguridad permite o deniega ese flujo
- usarlas antes de suponer clase 202

### 3. Puntos privados y la trampa del DNS

Los puntos privados en Azure resuelven lo mismo que en la clase 200, y tienen una particularidad que causa la mayoría de los incidentes de esta clase.

#### CÓMO FUNCIONA

- se crea un punto privado en una subred: obtiene una dirección de TU red
- el servicio queda alcanzable por esa dirección
- y se puede desactivar su acceso público

#### Y LA PARTE QUE FALLA

- el nombre público del servicio debe resolver a la dirección PRIVADA
- eso lo hace una ZONA DNS PRIVADA
- y esa zona debe estar ENLAZADA a cada red virtual que la necesite

#### X si falta el enlace

- el nombre resuelve a la dirección PÚBLICA
  - el tráfico sale a internet
  - y si el acceso público está desactivado, FALLA
  - y si no lo está, FUNCIONA pagando salida y sin pasar por ningún control ← lo peor

Y por eso el fallo es silencioso:

- funciona desde la red donde se creó el punto privado
- y no funciona –o funciona por internet– desde las demás
- el síntoma es «a mí me va bien» clase 195

El montaje que evita el problema:

#### ZONAS PRIVADAS CENTRALIZADAS

- todas las zonas de puntos privados en la suscripción de conectividad
- enlazadas a TODAS las redes que las necesitan
- y creadas automáticamente por política clase 217
  - una política de tipo «desplegar si no existe» que registra el punto privado en la zona correcta
  - sin ella, cada equipo crea su zona y aparecen duplicadas y divergentes

#### RESOLUTOR PRIVADO EN EL CENTRO

- con regla de reenvío desde el centro de datos hacia Azure y viceversa
- y hay que comprobarlo EN LOS DOS SENTIDOS clase 195

#### COMPROBACIÓN AUTOMÁTICA

- para cada servicio con punto privado, resolver su nombre desde CADA red y verificar que devuelve dirección privada
- función de aptitud, ejecutada a diario clase 190

Y una decisión que hay que tomar y que se olvida:

- DESACTIVAR EL ACCESO PÚBLICO del servicio
- crear el punto privado no cierra el público

- el servicio sigue alcanzable desde internet
- y la política de «sin acceso público» de la clase 217 es lo que lo impide de verdad

Y el consumo de direcciones, que hay que planificar:

- un punto privado = una dirección de la subred
- 30 servicios × 3 entornos = 90 direcciones
- y a eso se suman las subredes que ciertos servicios exigen en exclusiva y con tamaño mínimo
- el plan de direcciones tiene que contarlo      clase 193

## 4. Diagnóstico y operación

Los fallos de esta topología tienen firmas reconocibles.

| SÍNTOMA                                               | CAUSA HABITUAL                                                        |
|-------------------------------------------------------|-----------------------------------------------------------------------|
| funciona desde una red y no desde otra                | falta el enlace de la zona DNS privada                                |
| el tráfico sale a internet pese a tener punto privado | el nombre resuelve a la dirección pública                             |
| dos radios no se ven                                  | el emparejamiento no es transitivo y faltan rutas                     |
| el tráfico no pasa por el cortafuegos                 | falta la ruta definida por el usuario en esa subred                   |
| bucle de encaminamiento                               | la ruta 0.0.0.0/0 se puso también en la subred del cortafuegos        |
| se permite algo que no debería                        | una regla permisiva con prioridad menor gana                          |
| no llega y las reglas parecen correctas               | hay grupo de seguridad en la subred Y en la interfaz                  |
| todo deja de funcionar tras un cambio de red          | alguien cambió una ruta y el prefijo más específico desvió el tráfico |

Y las herramientas, por orden de coste:

- 1 comprobación de siguiente salto y de flujo permitido  
→ responde en segundos qué ruta y qué regla aplican
- 2 registros de flujo de los grupos de seguridad  
→ quién habla con quién, qué se deniega      clase 202
- 3 captura de paquetes  
→ solo cuando lo anterior no basta

Lo que hay que vigilar:

- zonas privadas sin enlazar a redes que las necesitan
- puntos privados cuyo nombre resuelve a dirección pública
- reglas de seguridad con origen o destino demasiado amplios
- rutas definidas por el usuario creadas fuera del proceso
- estado de las pasarelas y de las sesiones hacia el centro de datos      clase 198
- uso de direcciones por subred, frente al total  
→ una subred agotada bloquea el escalado      clase 193

Y una alerta que evita sorpresas:

- «ha aparecido una ruta o una regla que no está en el repositorio»
- detecta los cambios manuales, que son los que se quedan      ley 25

Y la lista de comprobación de la clase:

- la topología está decidida y justificada
- los radios no se ven entre sí salvo decisión explícita
- toda subred de carga tiene ruta 0.0.0.0/0 al cortafuegos

- la subred del cortafuegos NO tiene esa ruta
- los grupos de seguridad están en la subred, no en ambos sitios
- las prioridades dejan huecos y están documentadas
- se sabe que la salida a internet está permitida por defecto
- los servicios de plataforma se alcanzan por punto privado
- el acceso público de esos servicios está desactivado
- las zonas DNS privadas están centralizadas y enlazadas a todas las redes
- hay política que registra los puntos privados en la zona correcta
- hay comprobación diaria de que cada nombre resuelve a dirección privada desde cada red
- el reenvío de nombres con el centro de datos funciona en ambos sentidos
- el plan de direcciones cuenta los puntos privados y las subredes exclusivas
- hay alerta ante rutas o reglas creadas fuera del proceso

Y el cierre que enlaza con la clase siguiente: con jerarquía, identidad y red resueltas, hace falta declarar todo esto como código de forma que se pueda desplegar, revisar y retirar. Es la materia de la clase 220.

## Ejemplo trabajado

CloudShop monta la red de sus 61 suscripciones en Azure. Lo que sigue es el incidente del punto privado que llevaba meses saliendo a internet, el bucle de encaminamiento del primer día, y la comprobación diaria que quedó montada.

La topología elegida:

centro propio, uno por región (2)  
 cortafuegos con inspección  
 pasarela hacia el centro de datos                      clase 198  
 resolutor DNS privado con reglas de reenvío  
 zonas DNS privadas de todos los servicios

43 radios: uno por carga y entorno  
 sin pasarela propia  
 sin salida directa a internet  
 ruta 0.0.0.0/0 → cortafuegos del centro

motivo de centro propio y no gestionado  
 2 regiones, sin sedes remotas ni usuarios remotos  
 y el volumen entre radios y centro justificaba el ahorro  
 → decisión registrada, con la señal que la reabrirla:  
 «si se conectan más de 10 sedes»                      clase 190

Incidente 1 · El bucle de encaminamiento, día uno.

síntoma      al aplicar la ruta 0.0.0.0/0 en todas las subredes  
                  del centro y de los radios, nada funcionaba  
                  el cortafuegos mostraba tráfico que entraba y  
                  volvía a entrar

causa          la ruta se había aplicado también a la subred del  
                  propio cortafuegos  
                  → el tráfico salía del cortafuegos, encontraba la  
                  ruta que apuntaba al cortafuegos, y volvía

corrección  
 la subred del cortafuegos usa las rutas del sistema  
 y se añadió una función de aptitud: ninguna tabla de  
 rutas con 0.0.0.0/0 puede asociarse a la subred del  
 dispositivo de inspección                      clase 190

tiempo perdido                      3 h

Incidente 2 · El punto privado que salía a internet.

síntoma reportado      ninguno

se descubrió al revisar el coste de salida                      clase 214  
 transferencia de salida a internet                      1.940 €/mes  
 esperada, con puntos privados                      ~200 €

#### diagnóstico

27 servicios tenían punto privado creado  
las zonas DNS privadas estaban enlazadas a la red del  
centro y a 4 radios  
→ y había 43 radios

desde los 39 radios sin enlace  
el nombre del servicio resolvía a la dirección PÚBLICA  
el tráfico salía por el cortafuegos a internet  
y volvía a entrar por el punto público del servicio  
→ funcionaba perfectamente  
→ y por eso nadie lo reportó ley 13

cuánto llevaba así  
los primeros radios se crearon hacía 7 meses  
los enlaces se hicieron a mano para los 4 primeros y  
luego nadie los hizo más ley 25

lo que implicaba, además del coste  
el tráfico hacia las bases de datos salía a internet  
cifrado, pero por internet  
y el acceso público de esos servicios seguía activado  
→ cualquiera con la credencial podía llegar desde fuera  
clase 189

#### corrección

- 1 política de tipo «desplegar si no existe» que registra  
cada punto privado en la zona centralizada correcta
- 2 enlace de todas las zonas a las 43 redes, automatizado
- 3 desactivación del acceso público de los 27 servicios  
→ y aquí fallaron 3: dos bases y un almacén tenían  
clientes externos legítimos que se descubrieron al  
cortar  
→ 2 se movieron a punto privado desde el centro de  
datos; 1 quedó con excepción, con dueño y fecha
- 4 comprobación diaria: resolver el nombre de cada  
servicio desde cada red y verificar dirección privada

#### resultado

transferencia de salida 1.940 € → 180 €/mes  
servicios con acceso público 27 → 1 (con  
excepción)  
fallos de la comprobación diaria en 6 meses 4  
→ los 4, radios nuevos creados antes de que la  
automatización enlazara sus zonas  
→ corregidos en menos de 1 hora cada uno

#### Incidente 3 · «No llega y las reglas parecen correctas».

síntoma el servicio de catálogo no podía llamar al de  
precios, en otro radio

lo que se revisó primero (mal)  
las reglas del grupo de seguridad: correctas  
el emparejamiento: existía  
2 horas de revisión manual

lo que lo resolvió, en 90 segundos  
la comprobación de siguiente salto  
→ dijo que el tráfico iba al cortafuegos y ahí se  
detenía  
la comprobación de flujo permitido  
→ dijo que la regla del CORTAFUEGOS, no la del grupo de  
seguridad, lo denegaba

#### causa

el emparejamiento entre radios no es transitivo  
el tráfico pasaba por el centro, correctamente  
y el cortafuegos no tenía regla para ese par  
→ se había asumido que el emparejamiento bastaba

#### corrección

regla en el cortafuegos, y documentación del camino



## Reto verificable

Construye azure-network para el caso CloudShop. Incluye una alternativa descartada, un supuesto que pueda falsarse, una prueba de fallo y una decisión de rollback.

### ■ Criterio de aceptación

- [ ] lab.py termina con código 0 y genera JSON válido.
- [ ] La entrega conecta al menos tres requisitos con mecanismos verificables.
- [ ] Existe una prueba positiva y una prueba negativa con evidencia.
- [ ] Seguridad, costo y operación aparecen como decisiones, no como anexos.
- [ ] Se declara una limitación y una condición que obligaría a revisar el diseño.
- [ ] Otra persona puede repetir el recorrido sin conocimiento tácito.

### ■ Errores frecuentes

| Síntoma                                                                  | Causa probable                                                                                        | Corrección                                                                                                                                             |
|--------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------|
| Un punto privado existe y el tráfico sigue saliendo a internet           | La zona DNS privada no está enlazada a esa red virtual y el nombre resuelve a la dirección pública    | Centraliza las zonas, enlázalas a todas las redes por automatización y comprueba a diario que cada nombre resuelve a dirección privada desde cada red. |
| El servicio sigue siendo alcanzable desde internet pese al punto privado | Crear el punto privado no desactiva el acceso público                                                 | Desactiva el acceso público explícitamente y respáldalo con una política de denegación heredada.                                                       |
| Nada funciona tras aplicar la ruta hacia el cortafuegos                  | La ruta 0.0.0.0/0 se aplicó también a la subred del propio dispositivo                                | Deja esa subred con las rutas del sistema y comprueba la asociación con una función de aptitud.                                                        |
| Dos radios no se comunican aunque estén emparejados con el centro        | El emparejamiento no es transitivo y falta la regla en el cortafuegos                                 | Documenta el camino esperado de cada flujo entre radios y añade la regla correspondiente.                                                              |
| Una regla de seguridad no surte efecto                                   | Otra regla permisiva con prioridad menor decide antes, o hay grupos aplicados en subred y en interfaz | Aplica en la subred, deja huecos entre prioridades y usa la comprobación de flujo permitido antes de suponer.                                          |
| Una subred se queda sin direcciones y bloquea el escalado                | El dimensionado no contó puntos privados ni las subredes exclusivas que exigen ciertos servicios      | Cuenta todos los consumidores y dimensiona con margen, revisando el plan para las particularidades de esta nube.                                       |

### ■ Seguridad, ética y costo

Trabaja con cuentas propias o sandboxes autorizados. No publiques secretos, identificadores reales ni datos personales. Antes de crear recursos pagos define presupuesto, etiquetas y comando de destrucción; después verifica que no queden recursos huérfanos. Los ejemplos locales enseñan contratos, pero no certifican cumplimiento ni disponibilidad de producción.

### ■ Preguntas de comprobación

1. ¿Por qué el aislamiento entre radios es el estado por defecto y qué hace falta para abrirlo?
2. ¿Qué regla por defecto de los grupos de seguridad sorprende y qué implica?
3. ¿Qué ocurre exactamente cuando falta el enlace de una zona DNS privada?
4. ¿Por qué la subred del cortafuegos no debe llevar la ruta hacia el cortafuegos?
5. ¿Qué dos comprobaciones resuelven la mayoría de los diagnósticos de red en Azure?

## Referencias

- Microsoft (2025). Hub-spoke network topology in Azure.  
<<https://learn.microsoft.com/en-us/azure/architecture/networking/architecture/hub-spoke>>
- Microsoft (2025). Azure Private Link and private endpoint DNS configuration.  
<<https://learn.microsoft.com/en-us/azure/private-link/private-endpoint-dns>>
- Microsoft (2025). Network security groups: default rules and evaluation.  
<<https://learn.microsoft.com/en-us/azure/virtual-network/network-security-groups-overview>>
- Microsoft (2025). User-defined routes and forced tunneling.  
<<https://learn.microsoft.com/en-us/azure/virtual-network/virtual-networks-udr-overview>>
- Microsoft (2025). Azure Virtual WAN architecture.  
<<https://learn.microsoft.com/en-us/azure/virtual-wan/virtual-wan-about>>
- Documentación oficial vigente del servicio implementado; registra URL y fecha de consulta.

Descargar: Parte 18 en PDF · Recorrido de Azure en PDF · Manual integral

| Anterior                                                      | Índice              | Siguiente                                                 |
|---------------------------------------------------------------|---------------------|-----------------------------------------------------------|
| ← 218 · Entra ID, workload identity, PIM y Conditional Access | Parte 18 · Programa | 220 · Bicep, deployment stacks y Azure Verified Modules → |

## Evaluación — 219 Hub-spoke, Virtual WAN, Private Link y DNS privado

### Preguntas

1. Explica el problema que resuelve esta capacidad sin mencionar un proveedor.
2. Identifica una frontera de responsabilidad y su propietario.
3. Compara dos alternativas mediante confiabilidad, seguridad, costo y operación.
4. ¿Qué demuestra el laboratorio y qué no puede demostrar?
5. Propón un caso límite o una prueba de fallo.

### Reto verificable

Entrega azure-network con diagrama o configuración, evidencia de ejecución, alternativa descartada, riesgo residual y criterio de rollback.

### Criterio de aceptación

- [ ] Resultado reproducible por una segunda persona.
- [ ] Evidencia vinculada a cada afirmación técnica.
- [ ] Prueba negativa o de fallo incluida.
- [ ] Costos y permisos expresados con unidades y alcance.
- [ ] Limitaciones declaradas sin presentar la simulación como producción.

## Escala

| Nivel             | Evidencia                                                |
|-------------------|----------------------------------------------------------|
| A — competente    | Cumple todo y defiende trade-offs con datos.             |
| B — en desarrollo | Cumple lo esencial; falta profundidad en una dimensión.  |
| C — inicial       | Artefacto parcial o conclusión sin evidencia suficiente. |
| 0                 | Sin entrega reproducible.                                |

# 220 — Bicep, deployment stacks y Azure Verified Modules

Parte: 18 — Azure: arquitectura empresarial y operación en producción Nivel: avanzado · Horas estimadas: 4  
Laboratorio: iac · Estado: EXECUTABLECORE

## Propósito

Declarar la infraestructura de Azure como código de forma que se pueda desplegar, revisar y —lo que casi nunca se resuelve— retirar. La clase cubre Bicep frente a las plantillas nativas y a las herramientas de terceros, las pilas de despliegue que sí saben borrar lo que sobra, los módulos verificados y cuándo conviene usarlos, y los modos de despliegue con su trampa: el modo completo borra lo que no está en la plantilla, y eso incluye lo que creó otro equipo.

## Resultados de aprendizaje

Al finalizar podrás:

1. Elegir entre Bicep y herramientas de terceros con criterio.
2. Estructurar el código por ciclo de vida y por ámbito.
3. Usar pilas de despliegue para gestionar el ciclo de vida completo.
4. Aplicar módulos verificados sin perder control.
5. Evitar los tres errores que borran recursos en producción.

## Conceptos centrales

| Concepto              | Comprensión verificable                                                                                 |
|-----------------------|---------------------------------------------------------------------------------------------------------|
| Bicep                 | Lenguaje declarativo que compila a plantillas nativas de Azure, con módulos, tipos y validación previa. |
| ámbito del despliegue | Nivel al que se despliega: grupo de administración, suscripción, grupo de recursos o inquilino.         |
| modo de despliegue    | Incremental añade y modifica; completo además borra lo que no está declarado.                           |
| pila de despliegue    | Recurso que gestiona un conjunto como unidad, con capacidad de borrar lo que deja de estar declarado.   |
| simulación de cambios | Previsualización de lo que el despliegue creará, modificará o borrará. Se lee antes de aplicar.         |
| módulo verificado     | Módulo mantenido por el proveedor con valores por defecto revisados y opciones de seguridad activadas.  |

## Modelo mental

La arquitectura Azure nace del tenant y las políticas heredables, y llega al workload mediante identidades administradas y redes privadas.

Aplicado a esta clase, separa siempre cuatro planos: intención (qué necesita el usuario), configuración (qué declaramos), estado observado (qué existe de verdad) y evidencia (cómo sabemos que cumple). Confundirlos produce diseños que se ven correctos en un diagrama pero fallan al operar.

## Flujo de razonamiento



## Desarrollo

### 1. Bicep, y cuándo no

Azure tiene su lenguaje propio y también funciona con herramientas multinube. La elección importa menos de lo que parece y más de lo que se cree.

#### BICEP

- + no hay estado que gestionar: el estado es Azure
- + soporte inmediato de recursos nuevos
- + validación y simulación de cambios nativos
- + módulos verificados mantenidos por el proveedor
- solo Azure
- la gestión del ciclo de vida completo exige pilas de despliegue; el despliegue normal no borra nada

#### HERRAMIENTA MULTINUBE (Terraform o similar)

- + una sola forma de trabajar para varias nubes
- + el estado permite saber qué gestiona y borrar lo que sobra
- + ecosistema de módulos enorme
- hay que gestionar y proteger el estado      clase 100
- los recursos nuevos tardan en estar soportados
- y la portabilidad del CÓDIGO es menor de lo que se espera: los recursos son específicos      clase 158

Y el criterio honesto:

¿la organización usa varias nubes de verdad y el equipo ya domina una herramienta multinube?

→ úsala también aquí; la coherencia vale más que la diferencia técnica

¿es una organización solo Azure, o el equipo empieza?

→ Bicep; menos piezas que operar

¿hay que declarar políticas y jerarquía?

→ cualquiera de las dos sirve, y conviene que sea la misma que el resto      clase 217

Y una advertencia sobre la mezcla:

usar las dos a la vez sobre los mismos recursos produce conflictos: cada una cree que gestiona algo que la otra modifica

→ si conviven, que sea con fronteras claras: quién gestiona qué, escrito      clase 183

Los ámbitos, que hay que entender antes de estructurar:

|                         |                                |
|-------------------------|--------------------------------|
| INQUILINO               | grupos de administración       |
| GRUPO DE ADMINISTRACIÓN | políticas, asignaciones        |
| SUSCRIPCIÓN             | grupos de recursos, red, roles |
| GRUPO DE RECURSOS       | la mayoría de los recursos     |

→ un despliegue tiene un ámbito, y desde él puede desplegar módulos en ámbitos inferiores

→ estructurar el código por ámbito es lo que permite desplegar la jerarquía y las cargas por separado

### 2. Estructura por ciclo de vida

El error de estructura es el mismo de la clase 207: una plantilla enorme con todo.

✗ UNA PLANTILLA QUE LO CONTIENE ABSOLUTAMENTE todo  
cada despliegue toca todo  
un fallo bloquea el conjunto  
y los tiempos de despliegue crecen sin control

✓ SEPARADO POR CICLO DE VIDA

|                         |                                             |
|-------------------------|---------------------------------------------|
| jerarquía y políticas   | cambian al trimestre                        |
| red y conectividad      | cambian al mes                              |
| datos: bases, almacenes | cambian poco, NUNCA se borran con el código |
| cargas: aplicaciones    | cambian a diario                            |

→ y los datos SIEMPRE en su propio despliegue, con  
bloqueos de borrado clase 217

Y las reglas que evitan los problemas frecuentes:

SIN VALORES INCRUSTADOS POR ENTORNO  
parámetros por entorno, en ficheros separados

NOMBRES DERIVADOS, NO FIJOS  
y con la unicidad global resuelta donde haga falta  
→ varios servicios exigen nombre único en todo Azure  
→ un nombre fijo funciona en el primer entorno y falla en  
el segundo

SIN SECRETOS EN PARÁMETROS  
referencia al almacén de secretos, no el valor  
→ y los valores de salida NUNCA devuelven secretos: el  
historial de despliegues los conserva

IDENTIDADES Y PERMISOS DECLARADOS  
la asignación de papel es un recurso más, y debe estar  
en el código con su ámbito exacto clase 218

Los módulos verificados, que resuelven un problema real:

QUÉ SON  
módulos mantenidos por el proveedor, con los valores por  
defecto revisados y las opciones de seguridad activadas

QUÉ RESUELVEN  
exactamente la ley 26: los valores por defecto de los  
recursos están elegidos para que la demostración  
funcione, y estos módulos los cambian por los de  
producción  
→ cifrado, sin acceso público, diagnóstico, versión  
mínima de TLS, identidad administrada

CUÁNDO NO USARLOS  
cuando traen mucho más de lo que hace falta y hay que  
entender todo lo que despliegan  
cuando su versión va por detrás de lo que se necesita

→ y en cualquier caso: FIJAR LA VERSIÓN  
un módulo sin versión fija cambia bajo los pies  
clase 106, ley 25

Y una práctica que ahorra revisiones:

la plantilla de servicio nuevo usa los módulos verificados  
y ya cumple las políticas de la organización  
→ el carril fácil cumple solo clase 171  
→ y las funciones de aptitud casi nunca fallan

### 3. Modos, pilas y lo que borra recursos

Aquí están los tres errores que borran cosas en producción.

MODO INCREMENTAL (el predeterminado)  
crea lo que falta, modifica lo que difiere  
NO borra nada de lo que no está en la plantilla  
→ seguro, y deja recursos huérfanos acumulándose  
ley 25

MODO COMPLETO  
además, BORRA todo lo que exista en el grupo de recursos  
y no esté declarado  
→ resuelve los huérfanos  
→ y borra lo que creó otro equipo en ese grupo  
→ y lo que se creó a mano durante un incidente

ERROR 1 usar modo completo sobre un grupo compartido  
ERROR 2 usar modo completo con una plantilla parcial  
(por ejemplo, tras un error de compilación que  
dejó fuera medio fichero)

Y el tercero, el más frecuente:

ERROR 3 no leer la simulación de cambios  
la herramienta dice exactamente qué va a crear, modificar  
y BORRAR  
→ y en una canalización, ese resultado debe publicarse y  
revisarse; si incluye borrados en producción, se para  
→ una puerta automática: «si hay borrados y el entorno es  
producción, exige aprobación» clase 106

Las pilas de despliegue, que resuelven el ciclo de vida sin la brutalidad del modo completo:

QUÉ APORTAN  
gestionan un conjunto de recursos como una unidad  
saben qué recursos les pertenecen  
al desplegar, BORRAN o DESVINCULAN lo que deja de estar  
declarado  
y pueden BLOQUEAR la modificación manual de lo que  
gestionan

→ es lo más parecido al estado de una herramienta  
multinube, sin gestionar un fichero de estado

LA DECISIÓN QUE HAY QUE TOMAR AL CREARLAS  
qué hacer con lo que se quita de la plantilla  
borrar para cargas  
desvincular para datos ← lo prudente  
y qué bloqueo aplicar a lo gestionado  
ninguno · solo lectura · sin borrado

Y la comprobación que hay que hacer antes de usarlas en producción:

probar en un entorno inferior  
quitar un recurso de la plantilla y desplegar  
→ comprobar que hace lo que se espera  
→ y que los datos NO se borran ley 22

La canalización de infraestructura, con las puertas que hacen falta:

- 1 compilar y validar la plantilla
- 2 comprobaciones de política: ¿el despliegue cumpliría?  
→ hay herramientas que evalúan la política ANTES  
→ evita el rechazo en el momento de desplegar
- 3 SIMULACIÓN de cambios, publicada
- 4 puerta: si hay borrados en producción → aprobación
- 5 desplegar con identidad federada, sin secretos  
clase 218
- 6 comprobar que el resultado es el esperado
- 7 y en caso de fallo, saber cómo se vuelve atrás

Y una nota sobre la vuelta atrás:

volver atrás en infraestructura NO es volver a desplegar la  
versión anterior sin más  
un recurso borrado no se recupera desplegando otra vez  
un cambio de tamaño de base no siempre es reversible  
y algunos cambios exigen recrear  
→ por eso los recursos con datos llevan bloqueo y política  
de retención, y el borrado se trata como irreversible  
clase 166

## 4. Revisar, probar y retirar

Qué se revisa en un cambio de infraestructura, que no es lo mismo que en un cambio de código:

¿qué se borra? ← lo primero  
¿qué se recrea? (un cambio de nombre o de ubicación  
destruye y crea)  
¿qué ámbito tiene cada asignación de permisos? clase 218  
¿hay acceso público en algo?  
¿está el diagnóstico enrutado?  
¿tiene etiquetas obligatorias? clase 214  
¿cuánto va a costar al mes?  
→ algunos recursos son muy caros y se aprueban solos en  
una plantilla

Y la última merece automatismo:

estimación de coste del cambio, publicada en la revisión  
→ hay herramientas que la calculan a partir de la simulación  
→ y evita la sorpresa del mes siguiente clase 214

Las pruebas de infraestructura, que son distintas de las de código:

VALIDACIÓN la plantilla es correcta  
SIMULACIÓN el cambio es el esperado  
DESPLIEGUE EN  
ENTORNO EFÍMERO se despliega de cero y funciona  
→ esto es lo que detecta las dependencias no declaradas  
y los recursos que alguien creó a mano y nadie metió  
en el código clase 104  
PRUEBAS DE  
COMPORTAMIENTO ¿el almacén rechaza el acceso público?  
¿la subred no llega a internet?  
→ las pruebas negativas de las clases 217 a 219

Y el desplegar de cero es la más valiosa:

si el entorno completo no se puede desplegar desde el código en un entorno vacío, el código NO describe el sistema  
→ y en un desastre, no sirve clase 215  
→ conviene hacerlo periódicamente, no una vez

La retirada, que es lo que el código como declaración permite y casi nadie usa:

quitar el recurso de la plantilla y desplegar  
con pila de despliegue → se borra o desvincula  
con modo incremental → NO se borra, y queda huérfano

y la comprobación periódica que encuentra los huérfanos  
inventario real frente a lo declarado  
→ lo que existe y no está en ningún código es un hallazgo  
ley 25, clase 253

Y la lista de comprobación de la clase:

- la herramienta elegida es coherente con el resto de la organización
- el código está separado por ciclo de vida y por ámbito
- los datos tienen su propio despliegue, con bloqueos
- no hay valores incrustados por entorno
- los nombres son derivados y resuelven la unicidad global
- no hay secretos en parámetros ni en salidas
- las asignaciones de permisos están en el código, con su ámbito exacto
- los módulos verificados están con versión fija
- el modo completo no se usa sobre grupos compartidos
- la simulación de cambios se publica y se revisa
- hay puerta de aprobación si hay borrados en producción
- las pilas de despliegue se probaron en un entorno inferior
- el entorno se despliega de cero periódicamente
- hay estimación de coste en la revisión
- se comparan periódicamente el inventario real y lo declarado

Y el cierre que enlaza con la clase siguiente: con la base declarada, queda desplegar las cargas. Las tres opciones de cómputo gestionado de Azure —y cuándo conviene cada una— son la materia de la clase 221.

## Ejemplo trabajado

CloudShop pasa su infraestructura de Azure a código. Lo que sigue es el despliegue que borró una base de datos de preproducción, la comparación entre inventario real y código declarado, y las pilas de despliegue que resolvieron los huérfanos.

El punto de partida:

|                            |        |      |
|----------------------------|--------|------|
| recursos en el inventario  | 14.200 |      |
| declarados en algún código | 4.100  | 29 % |
| creados a mano             | 10.100 | 71 % |

|                                            |    |
|--------------------------------------------|----|
| plantillas existentes                      | 31 |
| con valores incrustados por entorno        | 24 |
| con secretos en parámetros                 | 7  |
| con nombres fijos                          | 19 |
| → y por eso solo funcionaban en un entorno |    |

El incidente: el modo completo, semana 3.

qué pasó

un equipo migró su carga a Bicep  
desplegó en modo COMPLETO sobre el grupo de recursos de  
preproducción  
su plantilla declaraba la aplicación y el almacén

el grupo contenía además

una base de datos de preproducción, creada a mano  
dos cuentas de almacenamiento de otro equipo  
un espacio de trabajo de análisis

el modo completo BORRÓ los cuatro

efectos

la base de datos tenía copia de seguridad: recuperada en  
2 h 40  
las cuentas de almacenamiento del otro equipo: 1 se  
recuperó del borrado reversible, la otra había superado  
la ventana → 11 GB de resultados de pruebas perdidos  
el espacio de análisis: recreado, sin las consultas  
guardadas

tiempo total de recuperación 6 h

Y el análisis:

la simulación de cambios SE HABÍA EJECUTADO  
y decía claramente «se eliminarán 4 recursos»  
nadie la leyó: la canalización la imprimía en un registro  
de 400 líneas y pasaba al paso siguiente ley 15

correcciones

- 1 la simulación se publica como resumen legible, con los borrados destacados
- 2 puerta automática: si hay borrados, exige aprobación explícita, en cualquier entorno
- 3 el modo completo queda PROHIBIDO por política; se usan pilas de despliegue
- 4 un grupo de recursos por equipo y por carga: nada compartido clase 183
- 5 bloqueo de borrado en todos los recursos con datos

La estructura nueva:

infra/

jerarquia/ ámbito: grupo de administración  
grupos de administración, iniciativas de política  
despliegue trimestral

conectividad/ ámbito: suscripción  
centro, radios, cortafuegos, zonas DNS privadas  
despliegue mensual

datos/ ámbito: grupo de recursos  
bases, almacenes, espacios de análisis  
con bloqueo de borrado y política de retención  
despliegue: raro, y siempre con aprobación

cargas/ ámbito: grupo de recursos  
aplicaciones, planes, identidades, asignaciones  
despliegue diario

parámetros por entorno, en ficheros separados

nombres derivados: {carga}-{entorno}-{region}-{sufijo único}

secretos: referencias al almacén, nunca valores

Los módulos verificados, y lo que cambiaron.

se migraron 9 tipos de recurso a módulos verificados  
con versión fija

lo que traían activado que las plantillas propias no tenían

|                                 |                    |
|---------------------------------|--------------------|
| cuenta de almacenamiento        |                    |
| acceso público                  | desactivado        |
| versión mínima de TLS           | 1.2                |
| diagnóstico                     | enrutado           |
| identidad administrada          | activada           |
| clave gestionada por el cliente | opcional, activada |
| base de datos                   |                    |
| acceso público                  | desactivado        |
| conexión por punto privado      | sí                 |
| auditoría                       | activada           |
| retención de copias             | 35 días            |
| plan de aplicación              |                    |
| versión mínima de TLS           | 1.2                |
| registro de aplicación          | activado           |

→ 14 valores por defecto cambiados sin escribir una línea  
 → y el cumplimiento de las iniciativas de la clase 217  
 pasó del 62 % al 97 % en las cargas nuevas

ley 26

#### Y la decisión sobre versiones:

los módulos se fijan a una versión concreta  
 se actualizan una vez al trimestre, revisando el registro de cambios  
 → en la primera actualización, un módulo cambió un valor por defecto que recreaba el recurso  
 → la simulación lo detectó y se planificó, en vez de ocurrir de madrugada clase 106

#### Las pilas de despliegue:

se adoptaron para cargas y para conectividad

|               |                                                                                    |
|---------------|------------------------------------------------------------------------------------|
| configuración |                                                                                    |
| cargas        | lo que se quita de la plantilla → BORRAR<br>bloqueo de lo gestionado → sin borrado |
| conectividad  | lo que se quita → BORRAR<br>bloqueo → solo lectura                                 |
| datos         | NO se usan pilas; despliegue incremental con bloqueos y aprobación                 |

y la prueba, en preproducción  
 se quitó un recurso de la plantilla de cargas  
 → borrado, correctamente  
 se quitó un recurso de la plantilla de datos por error  
 → NO se borró, porque datos no usa pilas ✓

efecto sobre los huérfanos  
 recursos huérfanos en cargas 1.140 → 0 en 3 meses  
 → al migrar cada carga a pila, lo no declarado se revisaba y se borraba o se declaraba

#### La comparación entre inventario y código:

se montó una comprobación semanal  
 inventario real frente a lo declarado en el repositorio

|                                     |        |
|-------------------------------------|--------|
| primera ejecución                   |        |
| recursos existentes y no declarados | 10.100 |

|                                                                                         |        |
|-----------------------------------------------------------------------------------------|--------|
| seis meses después                                                                      |        |
| recursos existentes y no declarados                                                     | 410    |
| de ellos, con excepción registrada                                                      | 340    |
| · recursos gestionados por servicios (subredes de integración, identidades del sistema) |        |
| sin excepción                                                                           | 70     |
| → 70 hallazgos, revisados uno a uno                                                     |        |
| → 41 se declararon, 22 se borraron, 7 resultaron ser de un proyecto que nadie recordaba | ley 25 |

#### El despliegue de cero, ejecutado dos veces:

primer intento (mes 4)

se desplegó el entorno de preproducción completo en una suscripción vacía  
 falló en 6 puntos

- una zona DNS privada que se creaba a mano
- una asignación de papel al grupo del equipo, que existía desde 2022 y no estaba en el código
- un certificado subido manualmente
- dos reglas del cortafuegos
- una cuota que había que pedir con antelación

tiempo 3 días con correcciones

segundo intento (mes 7)  
 desplegado de cero, sin intervención  
 tiempo 94 min  
 → y ese número es el que se usa en el plan de continuidad  
 clase 215

El resultado:

|                                                        |           |        |
|--------------------------------------------------------|-----------|--------|
| recursos declarados en código                          | 29 %      | 97 %   |
| plantillas con secretos                                | 7         | 0      |
| plantillas con nombres fijos                           | 19        | 0      |
| recursos borrados por error                            | 4         | 0      |
| cumplimiento de iniciativas (cargas nuevas)            | 62 %      | 97 %   |
| huérfanos en grupos de cargas                          | 1.140     | 0      |
| tiempo de despliegue de cero                           | imposible | 94 min |
| valores por defecto corregidos por módulos verificados | —         | 14     |

La lección que esta clase deja: el incidente que borró cuatro recursos no fue por una herramienta peligrosa: la simulación había dicho exactamente qué iba a borrar, y estaba en un registro de cuatrocientas líneas que nadie leía. Y los módulos verificados corrigieron catorce valores por defecto sin escribir una línea de código, que es la forma más barata que este programa ha encontrado de tratar la ley 26.

## Laboratorio guiado

Ejecuta desde la raíz:

```
python classes/part-18-azure-production-architecture/220-bicep-deployment-stacks-y-azure-verified-modules/lab.py
```

El laboratorio selecciona el motor de práctica iac y produce labresult.json. El escenario, sus comprobaciones y el artefacto esperado corresponden a esta clase; no requiere credenciales y deja explícito qué debe revalidarse en un sandbox real.

1. Lee exercise.steps y formula una predicción antes de ejecutar.
2. Ejecuta la práctica y verifica todos los elementos de checks.
3. Provoca el caso de negativetest y explica la señal observada.
4. Materializa azure-bicep-stack en evidence/ usando la plantilla indicada.
5. Para proveedor real, sigue sandbox.requires, registra costo y ejecuta destroy.

### Evidencia esperada

El artefacto principal es un plan reproducible sin secretos ni cambios inesperados. Además, la entrega debe incluir el comando ejecutado, la salida estructurada y una conclusión que no exceda lo observado.

## Reto verificable

Construye azure-bicep-stack para el caso CloudShop. Incluye una alternativa descartada, un supuesto que pueda falsarse, una prueba de fallo y una decisión de rollback.

## ■ Criterio de aceptación

- [ ] lab.py termina con código 0 y genera JSON válido.
- [ ] La entrega conecta al menos tres requisitos con mecanismos verificables.

- [ ] Existe una prueba positiva y una prueba negativa con evidencia.
- [ ] Seguridad, costo y operación aparecen como decisiones, no como anexos.
- [ ] Se declara una limitación y una condición que obligaría a revisar el diseño.
- [ ] Otra persona puede repetir el recorrido sin conocimiento tácito.

## ■ Errores frecuentes

| Síntoma                                                            | Causa probable                                                              | Corrección                                                                                                           |
|--------------------------------------------------------------------|-----------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------|
| Un despliegue borra recursos que no eran suyos                     | Modo completo sobre un grupo de recursos compartido                         | Un grupo por equipo y carga, prohíbe el modo completo y usa pilas de despliegue con la política de borrado decidida. |
| La simulación avisaba del borrado y nadie lo vio                   | El resultado se imprimía en un registro larguísimo y la canalización seguía | Publica un resumen legible con los borrados destacados y pon una puerta de aprobación cuando existan.                |
| La plantilla funciona en un entorno y falla en el siguiente        | Nombres fijos y valores incrustados por entorno                             | Deriva los nombres del entorno y resuelve la unidad global; parámetros en ficheros separados.                        |
| Los recursos nuevos no cumplen las políticas de la organización    | Se declaran con los valores por defecto del recurso                         | Usa módulos verificados con versión fija; traen los valores de producción activados.                                 |
| Se acumulan recursos que nadie declaró ni recuerda                 | El despliegue incremental nunca borra lo que deja de estar en la plantilla  | Usa pilas de despliegue y compara periódicamente el inventario real con lo declarado.                                |
| En un desastre, el entorno no se puede reconstruir desde el código | Hay piezas creadas a mano que nunca entraron en el repositorio              | Despliega el entorno de cero en una suscripción vacía periódicamente y corrige lo que falte.                         |

## ■ Seguridad, ética y costo

Trabaja con cuentas propias o sandboxes autorizados. No publiques secretos, identificadores reales ni datos personales. Antes de crear recursos pagos define presupuesto, etiquetas y comando de destrucción; después verifica que no queden recursos huérfanos. Los ejemplos locales enseñan contratos, pero no certifican cumplimiento ni disponibilidad de producción.

## ■ Preguntas de comprobación

1. ¿Qué diferencia hay entre el modo incremental y el completo, y qué riesgo tiene el segundo?
2. ¿Qué aportan las pilas de despliegue frente al despliegue normal?
3. ¿Por qué los módulos verificados son una respuesta directa a la ley 26?
4. ¿Qué se revisa primero en un cambio de infraestructura?
5. ¿Qué detecta desplegar el entorno de cero que ninguna otra prueba detecta?

## Referencias

- Microsoft (2025). Bicep documentation. <https://learn.microsoft.com/en-us/azure/azure-resource-manager/bicep/overview>
- Microsoft (2025). Deployment stacks. <https://learn.microsoft.com/en-us/azure/azure-resource-manager/bicep/deployment-stacks>
- Microsoft (2025). ARM template deployment modes. <https://learn.microsoft.com/en-us/azure/azure-resource-manager/templates/deployment-modes>
- Microsoft (2025). Azure Verified Modules. <https://azure.github.io/Azure-Verified-Modules/>

- Microsoft (2025). ARM template what-if operation.  
<<https://learn.microsoft.com/en-us/azure/azure-resource-manager/templates/deploy-what-if>>
- Documentación oficial vigente del servicio implementado; registra URL y fecha de consulta.

Descargar: Parte 18 en PDF · Recorrido de Azure en PDF · Manual integral

| Anterior                                                   | Índice              | Siguiente                                                     |
|------------------------------------------------------------|---------------------|---------------------------------------------------------------|
| ← 219 · Hub-spoke, Virtual WAN, Private Link y DNS privado | Parte 18 · Programa | 221 · App Service, Functions y Container Apps en producción → |

## Evaluación — 220 Bicep, deployment stacks y Azure Verified Modules

### Preguntas

1. Explica el problema que resuelve esta capacidad sin mencionar un proveedor.
2. Identifica una frontera de responsabilidad y su propietario.
3. Compara dos alternativas mediante confiabilidad, seguridad, costo y operación.
4. ¿Qué demuestra el laboratorio y qué no puede demostrar?
5. Propón un caso límite o una prueba de fallo.

### Reto verificable

Entrega azure-bicep-stack con diagrama o configuración, evidencia de ejecución, alternativa descartada, riesgo residual y criterio de rollback.

### Criterio de aceptación

- [ ] Resultado reproducible por una segunda persona.
- [ ] Evidencia vinculada a cada afirmación técnica.
- [ ] Prueba negativa o de fallo incluida.
- [ ] Costos y permisos expresados con unidades y alcance.
- [ ] Limitaciones declaradas sin presentar la simulación como producción.

### Escala

| Nivel             | Evidencia                                                |
|-------------------|----------------------------------------------------------|
| A — competente    | Cumple todo y defiende trade-offs con datos.             |
| B — en desarrollo | Cumple lo esencial; falta profundidad en una dimensión.  |
| C — inicial       | Artefacto parcial o conclusión sin evidencia suficiente. |
| 0                 | Sin entrega reproducible.                                |

# 221 — App Service, Functions y Container Apps en producción

Parte: 18 — Azure: arquitectura empresarial y operación en producción Nivel: avanzado · Horas estimadas: 4  
Laboratorio: serverless · Estado: EXECUTABLECORE

## Propósito

Elegir entre las tres opciones de cómputo gestionado de Azure y configurarlas para producción, que es distinto de configurarlas para que funcionen. La clase compara servicio de aplicaciones, funciones y aplicaciones de contenedor por lo que de verdad las diferencia —modelo de escalado, arranque en frío, integración de red y coste—, y desarrolla los ajustes que separan un despliegue estable de uno que corta peticiones y se queda sin conexiones.

## Resultados de aprendizaje

Al finalizar podrás:

1. Elegir entre las tres opciones con criterios comprobables.
2. Integrar las cargas en la red privada, de entrada y de salida.
3. Configurar escalado, arranque en frío y límites sin desperdiciar.
4. Desplegar con ranuras o revisiones, sin cortar peticiones.
5. Evitar el agotamiento de puertos y de conexiones bajo carga.

## Conceptos centrales


| Concepto                    | Comprensión verificable                                                                                  |
|-----------------------------|----------------------------------------------------------------------------------------------------------|
| plan de servicio            | Conjunto de recursos de cómputo compartido por varias aplicaciones. Es donde se paga y donde se compite. |
| ranura de despliegue        | Copia de la aplicación con su propia dirección, que se intercambia con producción en caliente.           |
| intercambio en caliente     | Cambio de la ranura de preparación a producción tras calentarla, sin reiniciar.                          |
| plan de consumo             | Modelo de facturación por ejecución, con escalado a cero y arranque en frío.                             |
| integración de red saliente | Mecanismo que hace que el tráfico de salida de la aplicación pase por la red virtual.                    |
| agotamiento de puertos      | Falta de puertos efímeros por no reutilizar conexiones. Produce fallos intermitentes bajo carga.         |

## Modelo mental

La arquitectura Azure nace del tenant y las políticas heredables, y llega al workload mediante identidades administradas y redes privadas.

Aplicado a esta clase, separa siempre cuatro planos: intención (qué necesita el usuario), configuración (qué declaramos), estado observado (qué existe de verdad) y evidencia (cómo sabemos que cumple). Confundirlos produce diseños que se ven correctos en un diagrama pero fallan al operar.

## ■ Flujo de razonamiento



## Desarrollo

### 1. Tres opciones, y cómo elegir

Las tres ejecutan código gestionado y se diferencian en el modelo de escalado, en lo que hay que empaquetar y en el coste.

#### SERVICIO DE APLICACIONES

- aplicaciones web y APIs con proceso continuo
  - + ranuras de despliegue con intercambio en caliente
  - + escalado por reglas, con instancias siempre encendidas
  - + integración de red madura
  - se paga el plan aunque no haya tráfico
  - varias aplicaciones en un plan COMPITEN por sus recursos
- ← ver abajo

#### FUNCIONES

- para eventos, trabajos programados y pegamento
- + escalado por evento; en consumo, escala a cero
- + integración directa con colas, temas y almacenes
- arranque en frío si escala a cero
- los planes que lo evitan cuestan como una instancia

#### APLICACIONES DE CONTENEDOR

- contenedores sin gestionar orquestador
- + escala a cero y escalado por peticiones o por cola
- + revisiones con reparto de tráfico por peso
- + trabajos por lotes y procesos de larga duración
- menos control que un orquestador completo
- arranque en frío si escala a cero

Y el criterio, en preguntas:

¿es una web o API con tráfico continuo y en un lenguaje soportado?  
→ servicio de aplicaciones

¿es código que reacciona a eventos y no está siempre activo?  
→ funciones

¿hay contenedores, varios lenguajes, o hace falta escalar a cero con reparto de tráfico?  
→ aplicaciones de contenedor

¿hace falta control fino del planificador, operadores o cargas heterogéneas?  
→ Kubernetes

clase 222

Y el error de elección más frecuente:

- usar funciones para una API con tráfico continuo
  - se paga por ejecución algo que estaría más barato en un plan
  - y se sufre arranque en frío sin necesidad
- el modelo de facturación por ejecución gana cuando el tráfico es IRREGULAR, no cuando es alto y constante

El plan compartido, que produce incidentes difíciles de diagnosticar:

varias aplicaciones en el mismo plan comparten CPU, memoria

y puertos  
→ una aplicación con una fuga de memoria afecta a las demás  
→ y el escalado del plan lo dispara cualquiera de ellas

regla producción, en su propio plan  
y las aplicaciones de un mismo plan, del mismo equipo y con perfiles parecidos

clase 183

## 2. Red: entrada privada y salida integrada

Estos servicios nacen con dirección pública. Meterlos en la red privada exige dos cosas distintas que se confunden.

ENTRADA – punto privado  
la aplicación se alcanza por una dirección de tu red  
y el acceso público se desactiva  
→ y hace falta la zona DNS privada enlazada a todas las  
redes que la llamen clase 219

SALIDA – integración con la red virtual  
 el tráfico SALIENTE de la aplicación pasa por una subred  
 → sin esto, la aplicación sale a internet aunque tenga  
 punto privado de entrada  
 → y por tanto no alcanza recursos privados y no pasa por  
 el cortafuegos

clase 200

Y la confusión que produce incidentes:

- NO: la entrada es privada y la salida sigue siendo pública
- hay que configurar las dos

y el síntoma  
la aplicación no puede llegar a la base de datos privada  
o el tráfico hacia el almacén sale a internet y se paga  
clase 219, ley 26

Y los detalles de la integración de salida:

exige una subred DEDICADA y delegada al servicio  
con tamaño suficiente: cada instancia consume direcciones  
→ dimensionar por el máximo del escalado      clase 193

- y hay que decidir si CUANTO tráfico salga va por la red
  - por defecto, solo el privado; el resto sale directo
  - para forzar la salida por el cortafuegos hay que activarlo explícitamente

Y una comprobación que hay que hacer:

desde la aplicación, resolver el nombre de un servicio con punto privado  
→ debe devolver dirección privada  
y comprobar la dirección de salida observada  
→ debe ser la del cortafuegos, no una pública del servicio

### 3. Escalado, arranque en frío y despliegue

El escalado, con la misma lección de la clase 212:

LA SEÑAL

- ✗ CPU, en servicios que esperan a la red
- ✓ peticiones en cola, longitud de cola, o métrica propia

→ en aplicaciones de contenedor, el escalado por cola es directo y es el que corresponde a un trabajador

clase 210

EL RETRASO  
 detección + decisión + arranque de instancia  
 → minutos, igual que en la clase 212  
 → y por eso el margen y el escalado programado siguen haciendo falta

MÍNIMO DE INSTANCIAS

- con escala a cero, la primera petición paga el arranque
- para el camino crítico, mínimo 1 o más
- y ahí desaparece la ventaja de coste de escalar a cero

El arranque en frío, con las palancas de siempre:

- paquete pequeño y dependencias mínimas
- trabajo fuera de la inicialización, salvo lo reutilizable
- instancias siempre listas (se pagan)
- calentamiento antes de recibir tráfico
- y esto último es lo que hacen bien las ranuras

El despliegue sin cortar peticiones, que aquí tiene mecanismos propios:

RANURAS DE DESPLIEGUE (servicio de aplicaciones)

- se despliega en una ranura de preparación
- se CALIENTA: se piden rutas que fuercen la inicialización
- se intercambia con producción
- el intercambio cambia el enrutamiento, no reinicia
- y si algo va mal, se intercambia de vuelta en segundos

- y el detalle que decide si funciona
- la configuración con marca de «ranura» NO se intercambia
- así la ranura de preparación apunta a la base de preparación, y producción a la suya
- olvidarlo hace que preparación escriba en producción

REVISIONES (aplicaciones de contenedor)

- cada despliegue crea una revisión
- el tráfico se reparte por peso entre revisiones
- despliegue escalonado nativo, con vuelta atrás inmediata

clase 102

Y EN AMBOS CASOS

- parada elegante: atender la señal de terminación
- drenaje mayor que la petición más larga

clase 212

Y una advertencia sobre el calentamiento:

- intercambiar sin calentar traslada el arranque en frío a los primeros usuarios de producción
- y el síntoma es «tras cada despliegue, unos minutos de latencia alta»

## 4. Lo que rompe bajo carga

El agotamiento de puertos efímeros es el fallo característico de estos servicios y se diagnostica mal.

QUÉ PASA

- cada conexión saliente consume un puerto efímero
- el puerto queda ocupado un tiempo tras cerrarse
- el número de puertos por instancia es limitado

- si el código abre una conexión NUEVA en cada llamada
- bajo carga se agotan
- y aparecen fallos intermitentes de conexión, sin patrón claro

LA CAUSA CASI SIEMPRE

- crear el cliente HTTP dentro de la función o del controlador, en vez de reutilizarlo
- cada petición abre una conexión nueva

LA CORRECCIÓN

- cliente único y reutilizado, con agrupación de conexiones
- y para bases de datos, agrupación configurada con límite

Y EL DIAGNÓSTICO

- la métrica de conexiones salientes por instancia
- si crece linealmente con el tráfico y no se estabiliza, no se están reutilizando

Y el otro fallo característico, ya conocido:

## CONEXIONES A LA BASE DE DATOS

cada instancia abre su propia agrupación  
20 instancias × 100 conexiones = 2.000  
→ y la base admite 400 clase 207  
→ el límite de la agrupación se calcula por instancia,  
contando el máximo del escalado

Lo que hay que vigilar:

peticiones, errores y latencia por percentil clase 211  
instancias activas frente al máximo  
conexiones salientes por instancia  
tiempo de arranque y peticiones que lo pagan  
uso de CPU y memoria, y REINICIOS por memoria  
y en funciones: ejecuciones, retrasos de disparador y  
mensajes pendientes

Y una alerta específica de estos servicios:

«la aplicación se ha reiniciado N veces en la última hora»  
→ los reinicios silenciosos por memoria o por fallo de  
la comprobación son la señal que más se pierde  
ley 13

Y la lista de comprobación de la clase:

- la opción elegida corresponde al perfil de la carga
- producción no comparte plan con otras cargas
- la entrada es por punto privado y el acceso público está desactivado
- la salida está integrada con la red virtual
- la subred de integración está dimensionada por el máximo
- se ha comprobado que la salida pasa por el cortafuegos
- el escalado usa una señal distinta de la CPU si procede
- el mínimo de instancias cubre el camino crítico
- hay ranuras o revisiones, con calentamiento previo
- la configuración específica de ranura está marcada
- la aplicación atiende la señal de terminación
- los clientes HTTP y de base se reutilizan
- el límite de agrupación se calculó por instancia
- hay alerta de reinicios y de conexiones salientes

Y el cierre que enlaza con la clase siguiente: cuando la carga exige control fino, operadores o cargas heterogéneas, aparece Kubernetes gestionado con sus particularidades de identidad y de entrada en esta nube. Es la materia de la clase 222.

## Ejemplo trabajado

CloudShop despliega su plataforma en Azure. Lo que sigue es la elección de opción por carga, el incidente de la ranura que escribió en producción, y el agotamiento de puertos que se diagnosticó como «problema de red» durante tres semanas.

La elección, carga por carga:

| carga                 | perfil                               | elección                              |
|-----------------------|--------------------------------------|---------------------------------------|
| api de pedidos        | continuo, 900 pet/s                  | servicio de aplicaciones              |
| web de tienda         | continuo                             | servicio de aplicaciones              |
| procesador de eventos | por cola, irregular                  | aplicaciones de contenedor            |
| trabajos programados  | 12/día                               | funciones, plan de consumo            |
| notificaciones        | picos, escala a cero                 | funciones, plan de consumo            |
| informes nocturnos    | 1/día, 40 min                        | trabajo de aplicaciones de contenedor |
| búsqueda              | contenedor propio, imagen específica | aplicaciones de contenedor            |

y lo que se descartó

poner la api de pedidos en funciones  
→ estimación: 1.840 €/mes en consumo frente a 610 € en un plan, con tráfico continuo  
→ y arranque en frío innecesario

#### Incidente 1 · La ranura que escribió en producción.

síntoma    tras un despliegue de rutina, aparecieron 41 pedidos de prueba en la base de producción con importes de 0,01 € y direcciones falsas

diagnóstico  
la cadena de conexión a la base estaba en la configuración de la aplicación  
NO estaba marcada como específica de ranura  
→ al intercambiar, la configuración de preparación viajó a producción y la de producción a preparación  
→ durante 8 minutos, antes de que alguien lo notara, las pruebas de humo de preparación escribieron en producción

corrección  
toda la configuración que apunta a recursos externos, marcada como específica de ranura  
y mejor: las cadenas se resuelven por referencia al almacén de secretos, con el nombre del secreto distinto por ranura  
y una comprobación previa al intercambio: la ranura de preparación debe apuntar a la base de preparación

y lo que se limpió  
41 pedidos borrados, con registro de la incidencia

#### Incidente 2 · «Fallos intermitentes de red», tres semanas.

síntoma    entre las 11:00 y las 13:00, un 2-4 % de las llamadas de la api de pedidos al servicio de precios fallaban con error de conexión fuera de esas horas, nunca

lo que se revisó (mal)  
reglas del grupo de seguridad                      correctas  
rutas y cortafuegos                                    correctos  
capturas de paquetes                                  sin nada raro  
se abrió incidencia con el proveedor              3 semanas

lo que lo resolvió  
la métrica de conexiones salientes por instancia

| hora  | peticiones/s | conexiones salientes |                 |
|-------|--------------|----------------------|-----------------|
| 09:00 | 210          | 240                  |                 |
| 10:00 | 390          | 450                  |                 |
| 11:00 | 720          | 830                  |                 |
| 12:00 | 1.100        | 1.270                | ← límite ~1.280 |
| 14:00 | 380          | 440                  |                 |

→ las conexiones crecían LINEALMENTE con las peticiones  
→ no se estaban reutilizando

causa  
el código creaba un cliente HTTP nuevo en cada llamada al servicio de precios  
cada uno abría su conexión, que quedaba ocupada tras cerrarse  
→ a partir de cierto tráfico, no había puertos libres

corrección  
un cliente único reutilizado, con agrupación configurada  
conexiones salientes en el pico    1.270 → 46  
fallos intermitentes                      2-4 % → 0

y lo que enseñó  
la métrica que resolvió el caso estaba disponible desde el primer día y no estaba en ningún panel              ley 15



|                                               |             |      |
|-----------------------------------------------|-------------|------|
| fallos intermitentes de conexión              | 2-4 %       | 0    |
| conexiones salientes en el pico               | 1.270       | 46   |
| pedidos de prueba en producción               | 41          | 0    |
| peticiones lentas tras despliegue             | 340         | 0    |
| aplicaciones compartiendo plan con producción | 2           | 0    |
| salida que no pasa por el cortafuegos         | 1           | 0    |
| tiempo de vuelta atrás                        | redesplegar | 15 s |

La lección que esta clase deja: tres semanas de incidencia con el proveedor y capturas de paquetes por un problema que no era de red: el código abría una conexión nueva en cada llamada y agotaba los puertos efímeros a partir de cierto tráfico. La métrica que lo resolvía estaba disponible desde el primer día. Y el incidente más embarazoso —cuarenta y un pedidos de prueba en producción— lo causó una configuración que no estaba marcada como específica de ranura, que es exactamente el tipo de detalle que funciona hasta el día del intercambio.

## Laboratorio guiado

Ejecuta desde la raíz:

```
python classes/part-18-azure-production-architecture/221-app-service-functions-y-container-apps-en-produccion/lab.py
```

El laboratorio selecciona el motor de práctica serverless y produce labresult.json. El escenario, sus comprobaciones y el artefacto esperado corresponden a esta clase; no requiere credenciales y deja explícito qué debe revalidarse en un sandbox real.

1. Lee exercise.steps y formula una predicción antes de ejecutar.
2. Ejecuta la práctica y verifica todos los elementos de checks.
3. Provoca el caso de negativetest y explica la señal observada.
4. Materializa azure-app-platform en evidence/ usando la plantilla indicada.
5. Para proveedor real, sigue sandbox.requires, registra costo y ejecuta destroy.

## Evidencia esperada

El artefacto principal es una función con límites, reintentos e idempotencia. Además, la entrega debe incluir el comando ejecutado, la salida estructurada y una conclusión que no exceda lo observado.

## Reto verificable

Construye azure-app-platform para el caso CloudShop. Incluye una alternativa descartada, un supuesto que pueda falsarse, una prueba de fallo y una decisión de rollback.

## ■ Criterio de aceptación

- [ ] lab.py termina con código 0 y genera JSON válido.
- [ ] La entrega conecta al menos tres requisitos con mecanismos verificables.
- [ ] Existe una prueba positiva y una prueba negativa con evidencia.
- [ ] Seguridad, costo y operación aparecen como decisiones, no como anexos.
- [ ] Se declara una limitación y una condición que obligaría a revisar el diseño.
- [ ] Otra persona puede repetir el recorrido sin conocimiento tácito.

## ■ Errores frecuentes

| Síntoma                                                               | Causa probable                                                                         | Corrección                                                                                                                        |
|-----------------------------------------------------------------------|----------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------|
| Fallos intermitentes de conexión que aparecen solo con tráfico alto   | El código crea un cliente nuevo por llamada y agota los puertos efímeros               | Reutiliza un cliente único con agrupación de conexiones y vigila las conexiones salientes por instancia.                          |
| La aplicación no alcanza recursos privados pese a tener punto privado | El punto privado resuelve la entrada; la salida sigue siendo pública                   | Configura además la integración de salida con la red virtual y comprueba la dirección de salida observada.                        |
| Tras un intercambio de ranuras, la preparación escribe en producción  | La configuración con la cadena de conexión no estaba marcada como específica de ranura | Marca toda la configuración que apunte a recursos externos y comprueba antes del intercambio a qué apunta cada ranura.            |
| Tras cada despliegue hay unos minutos de latencia alta                | Se intercambia sin calentar y el arranque en frío lo pagan los usuarios                | Pide rutas que fuercen la inicialización en la ranura de preparación antes de intercambiar.                                       |
| Una aplicación con problemas degrada a otras sin relación             | Comparten plan de servicio y por tanto recursos                                        | Producción en su propio plan; agrupa solo aplicaciones del mismo equipo con perfiles parecidos.                                   |
| Se paga mucho por una API con tráfico continuo                        | Se eligió el modelo de facturación por ejecución para una carga constante              | El pago por ejecución gana con tráfico irregular; con tráfico alto y continuo, un plan sale más barato y evita arranques en frío. |

## ■ Seguridad, ética y costo

Trabaja con cuentas propias o sandboxes autorizados. No publiques secretos, identificadores reales ni datos personales. Antes de crear recursos pagos define presupuesto, etiquetas y comando de destrucción; después verifica que no queden recursos huérfanos. Los ejemplos locales enseñan contratos, pero no certifican cumplimiento ni disponibilidad de producción.

## ■ Preguntas de comprobación

1. ¿Qué pregunta decide entre las tres opciones de cómputo gestionado?
2. ¿Qué diferencia hay entre el punto privado de entrada y la integración de salida?
3. ¿Qué configuración no debe intercambiarse al usar ranuras y por qué?
4. ¿Cuál es la causa habitual del agotamiento de puertos y cómo se detecta?
5. ¿Por qué el calentamiento previo al intercambio es parte del despliegue?

## Referencias

- Microsoft (2025). Azure App Service deployment slots.  
<<https://learn.microsoft.com/en-us/azure/app-service/deploy-staging-slots>>
- Microsoft (2025). Azure Functions hosting options.  
<<https://learn.microsoft.com/en-us/azure/azure-functions/functions-scale>>
- Microsoft (2025). Azure Container Apps revisions and traffic splitting.  
<<https://learn.microsoft.com/en-us/azure/container-apps/revisions>>
- Microsoft (2025). Integrate your app with an Azure virtual network.  
<<https://learn.microsoft.com/en-us/azure/app-service/overview-vnet-integration>>
- Microsoft (2025). Troubleshooting SNAT port exhaustion.  
<<https://learn.microsoft.com/en-us/azure/load-balancer/troubleshoot-outbound-connection>>
- Documentación oficial vigente del servicio implementado; registra URL y fecha de consulta.

Descargar: Parte 18 en PDF · Recorrido de Azure en PDF · Manual integral

| Anterior                                                  | Índice              | Siguiente                                        |
|-----------------------------------------------------------|---------------------|--------------------------------------------------|
| ← 220 · Bicep, deployment stacks y Azure Verified Modules | Parte 18 · Programa | 222 · AKS, workload identity, ingress y GitOps → |

## Evaluación — 221 App Service, Functions y Container Apps en producción

### Preguntas

1. Explica el problema que resuelve esta capacidad sin mencionar un proveedor.
2. Identifica una frontera de responsabilidad y su propietario.
3. Compara dos alternativas mediante confiabilidad, seguridad, costo y operación.
4. ¿Qué demuestra el laboratorio y qué no puede demostrar?
5. Propón un caso límite o una prueba de fallo.

### Reto verificable

Entrega azure-app-platform con diagrama o configuración, evidencia de ejecución, alternativa descartada, riesgo residual y criterio de rollback.

### Criterio de aceptación

- ☐ Resultado reproducible por una segunda persona.
- ☐ Evidencia vinculada a cada afirmación técnica.
- ☐ Prueba negativa o de fallo incluida.
- ☐ Costos y permisos expresados con unidades y alcance.
- ☐ Limitaciones declaradas sin presentar la simulación como producción.

### Escala

| Nivel             | Evidencia                                                |
|-------------------|----------------------------------------------------------|
| A — competente    | Cumple todo y defiende trade-offs con datos.             |
| B — en desarrollo | Cumple lo esencial; falta profundidad en una dimensión.  |
| C — inicial       | Artefacto parcial o conclusión sin evidencia suficiente. |
| 0                 | Sin entrega reproducible.                                |

## 222 — AKS, workload identity, ingress y GitOps

Parte: 18 — Azure: arquitectura empresarial y operación en producción Nivel: avanzado · Horas estimadas: 4  
Laboratorio: kubernetes · Estado: EXECUTABLECORE

### Propósito

Operar Kubernetes gestionado en Azure con las particularidades que lo diferencian de lo visto en la clase 213: la identidad de carga federada con el directorio, el modelo de red —que en esta nube tiene una decisión irreversible sobre el consumo de direcciones—, la entrada gestionada y la reconciliación desde el repositorio. Y la pregunta de siempre antes de empezar: ¿hace falta, o basta con lo de la clase 221?

### Resultados de aprendizaje

Al finalizar podrás:

1. Decidir si el clúster compensa frente a las opciones gestionadas.
2. Elegir el modelo de red conociendo su consumo de direcciones.
3. Dar identidad a las cargas con federación, sin secretos.
4. Configurar la entrada gestionada con certificados y filtrado.
5. Planificar actualizaciones de versión y de complementos.

### Conceptos centrales


| Concepto                          | Comprensión verificable                                                                              |
|-----------------------------------|------------------------------------------------------------------------------------------------------|
| identidad de carga                | Cuenta de servicio del clúster federada con una identidad administrada del directorio. Sin secretos. |
| modelo de red superpuesta         | Los pods usan un rango propio no enrutado; solo los nodos consumen direcciones de la subred.         |
| modelo de red plana               | Cada pod recibe una dirección de la subred. Consume muchísimas direcciones.                          |
| controlador de entrada gestionado | Entrada operada por la plataforma, con certificados y filtrado integrados.                           |
| grupo de nodos                    | Conjunto de nodos con el mismo tamaño y configuración. Se actualizan y escalan por grupo.            |
| canal de actualización            | Política que decide cuándo se aplican versiones nuevas de plano de control y de nodos.               |

### Modelo mental

La arquitectura Azure nace del tenant y las políticas heredables, y llega al workload mediante identidades administradas y redes privadas.

Aplicado a esta clase, separa siempre cuatro planos: intención (qué necesita el usuario), configuración (qué declaramos), estado observado (qué existe de verdad) y evidencia (cómo sabemos que cumple). Confundirlos produce diseños que se ven correctos en un diagrama pero fallan al operar.

### ■ Flujo de razonamiento



## Desarrollo

### 1. ¿Hace falta, y con qué configuración?

La pregunta de la clase 213 sigue siendo la primera, y en Azure tiene una respuesta adicional: las aplicaciones de contenedor cubren muchos casos que antes exigían clúster.

#### NO HACE FALTA SI

- son contenedores web y trabajadores por cola
- las aplicaciones de contenedor lo hacen con escala a  
cero y reparto por revisión clase 221
- el equipo es pequeño
- no hay cargas con requisitos especiales

#### SÍ COMPENSA SI

- hay operadores o recursos propios que gestionar
- hay cargas heterogéneas: GPU, procesos largos, lotes con  
prioridades
- varios equipos necesitan autonomía sobre una base común
- o ya se opera Kubernetes en otra nube y la coherencia  
vale clase 158

Y las decisiones de configuración que se toman al crear y cuestan corregir:

- 1 MODELO DE RED ← irreversible sin recrear
- 2 MODO DE IDENTIDAD ← se puede migrar, con trabajo
- 3 PLANO DE CONTROL PRIVADO O PÚBLICO
- 4 GRUPOS DE NODOS: uno de sistema, y los de carga aparte
- 5 CANAL DE ACTUALIZACIÓN

El modelo de red, que es la decisión irreversible:

**RED PLANA** (cada pod una dirección de la subred)

- + los pods son alcanzables directamente desde la red
- + útil si algo externo tiene que llamar a un pod concreto
- CONSUME MUCHÍSIMAS DIRECCIONES
- dimensionado = nodos máximos × pods por nodo
- 40 nodos × 110 pods = 4.400 direcciones
- una subred /22 se queda corta
- y el número de pods por nodo se fija al crear el grupo

**RED SUPERPUESTA** (pods en rango propio)

- + los nodos consumen direcciones; los pods, no
- 40 nodos = 40 direcciones
- + el rango de pods puede reutilizarse entre clústeres
- los pods no son alcanzables directamente desde fuera
- hay que salir por servicios y por la entrada

- la superpuesta es la elección razonable salvo requisito concreto clase 193
- y cambiar de una a otra exige recrear el clúster

Y una decisión relacionada:

- el plano de control puede ser público o privado
- privado solo alcanzable desde la red; más seguro
- y entonces la canalización debe alcanzarlo
  - agente autoalojado en la red, o punto privado del plano de control
  - decidirlo antes evita rehacer la canalización

## 2. Identidad de carga, sin secretos

El mecanismo es el mismo de la clase 213, con las piezas de Azure.

CÓMO FUNCIONA

- el clúster expone un emisor de testigos
  - se declara una CREDENCIAL FEDERADA en una identidad administrada, atada a
    - el emisor del clúster
    - el ESPACIO DE NOMBRES
    - y el NOMBRE de la cuenta de servicio
  - la cuenta de servicio se anota con el identificador de esa identidad
  - el pod recibe un testigo y lo intercambia
- y los permisos se asignan a esa identidad, en el ámbito del recurso clase 218

Y los patrones que hay que dejar atrás:

- X IDENTIDAD DEL NODO**
  - permisos en la identidad de la máquina
  - todos los pods del nodo los tienen
  - y hay que bloquear el acceso de los pods al servicio de metadatos, o los piden aunque tengan la suya
- X SECRETOS DE KUBERNETES CON CREDENCIALES**
  - un objeto de tipo secreto está codificado, no cifrado
  - activar el cifrado del almacén del plano de control
  - y para secretos reales, obtenerlos del almacén externo en ejecución con un controlador, no guardarlos

Y el error de configuración que repite el de las clases 206 y 218:

- la credencial federada debe atar emisor, espacio de nombres y cuenta de servicio
- X atar solo el emisor**
  - cualquier cuenta de servicio de cualquier espacio de nombres obtiene esa identidad

- prueba negativa
  - desde un pod de otro espacio de nombres, intentar obtener el testigo y usarlo
  - debe fallar ley 22

Y la separación por equipos, con lo que aporta cada pieza:

- espacio de nombres por equipo o carga
- cuotas de recursos por espacio clase 213
- política de admisión, con mensajes que expliquen
  - qué imágenes se admiten: del registro propio y firmadas
  - sin privilegios, sin red del anfitrión
  - etiquetas obligatorias clase 214
- política de red con denegación por defecto
  - y hay que activarla al crear: por defecto, todo pod habla con todo pod ley 26

## 3. Entrada, salida y complementos

La entrada, con la elección que hay que hacer:

- CONTROLADOR GESTIONADO POR LA PLATAFORMA
- + certificados, filtrado y escalado integrados

- + menos que operar
- menos control de configuración fina

#### CONTROLADOR PROPIO EN EL CLÚSTER

- + control total, y portable a otras nubes clase 158
- hay que operarlo, escalarlo y actualizarlo
- y gestionar certificados con un componente más

→ si el objetivo es reducir lo que se mantiene, el gestionado; si la portabilidad es un requisito real, el propio ley 23

Y lo que hay que resolver en cualquiera de los dos:

- certificados: emisión y renovación automáticas
- y ALERTA POR ANTIGÜEDAD, no solo por caducidad clase 196
- filtrado de aplicación delante clase 209
- plazos y drenaje coherentes clase 212
- y la entrada NO debe ser el único control de acceso:
- la autorización entre servicios va aparte clase 201

La salida, que en un clúster es fácil de dejar abierta:

por defecto, los pods salen a internet por la dirección del balanceador de salida  
→ y eso es salida sin control ley 26

- lo que hay que hacer
- ruta 0.0.0.0/0 hacia el cortafuegos clase 219
- y política de red que restrinja a dónde puede salir cada espacio de nombres clase 200
- y comprobar con una prueba negativa: sacar datos a un destino no declarado debe fallar

Los complementos, que son el trabajo continuo:

- los habituales
- controlador de entrada
- proveedor de secretos desde el almacén externo
- autoescalado de nodos
- recolección de métricas y registros
- política de admisión
- controlador de certificados
- y los operadores de cada equipo
- y cada uno
- tiene su matriz de compatibilidad con la versión del clúster
- se actualiza en su propio calendario
- y puede bloquear la actualización del clúster ley 23
- los que la plataforma ofrece como complemento gestionado se actualizan con el clúster, y eso vale mucho
- los instalados a mano, no clase 213

Y la decisión práctica:

- usa complementos gestionados donde existan
- y para el resto, mantén la matriz de compatibilidad escrita y comprobada antes de cada actualización

## 4. Actualizaciones y operación

Las actualizaciones tienen aquí tres piezas que se planifican por separado.

- 1 PLANO DE CONTROL
  - se actualiza primero; la ventana de soporte es corta
  - 2 o 3 veces al año, obligatorio ley 25
- 2 GRUPOS DE NODOS
  - se actualizan después, por grupos
  - con acordonado y drenaje, respetando el presupuesto de interrupción clase 213
  - y hay que tener capacidad de sobra para el reemplazo

### 3 IMAGEN DE LOS NODOS

- parches del sistema operativo, más frecuentes
- conviene automatizarlos con ventana de mantenimiento

Y las decisiones que evitan sorpresas:

#### CANAL DE ACTUALIZACIÓN

- manual control total, y se olvida ley 25
- parches aplica parches automáticamente ← razonable
- estable sube versión menor automáticamente
- con VENTANA DE MANTENIMIENTO declarada, para que no ocurra en hora punta

#### Y LA COMPROBACIÓN PREVIA

- interfaces retiradas en los manifiestos
- compatibilidad de complementos
- y un clúster de prueba GENERADO DEL MISMO CÓDIGO
- en la clase 213, la prueba pasó porque el clúster de prueba no era idéntico

La reconciliación desde el repositorio, con la misma alerta imprescindible:

- el estado deseado en el repositorio; un controlador lo aplica y corrige la deriva clase 213

y la alerta

- «la sincronización lleva N minutos sin completarse»
- un bucle parado no da error: deja de aplicar ley 13

Y el modo automático de la plataforma, que conviene conocer:

- hay una variante gestionada de reconciliación como complemento
- + menos que operar
- menos control sobre versiones y extensiones
- misma decisión que con los demás complementos

Lo que hay que vigilar, además de lo de la clase 213:

- versión del clúster y días hasta el fin de soporte ley 25
- nodos con imagen desactualizada
- antigüedad de la sincronización
- direcciones libres en la subred de nodos
- si se agota, no se puede escalar clase 193
- cuota de cómputo frente al máximo del escalado
- la cuota es de la suscripción y se topa clase 217
- y reinicios por memoria y estrangulamiento por CPU
- clase 213

Y la lista de comprobación de la clase:

- la decisión de usar clúster está justificada frente a las opciones gestionadas
- el modelo de red se eligió contando direcciones
- el plano de control es privado, y la canalización lo alcanza
- hay grupo de nodos de sistema separado de los de carga
- las cargas usan identidad federada, no la del nodo
- los pods no pueden alcanzar el servicio de metadatos
- la credencial federada ata emisor, espacio de nombres y cuenta de servicio
- los secretos vienen del almacén externo en ejecución
- la política de red está activada, con denegación por defecto
- la salida pasa por el cortafuegos y está restringida
- los certificados tienen alerta por antigüedad
- se usan complementos gestionados donde existen
- hay matriz de compatibilidad de los instalados a mano
- el canal de actualización y la ventana están decididos
- el clúster de prueba se genera del mismo código
- hay alerta de antigüedad de la sincronización
- se vigilan direcciones libres y cuota frente al máximo

Y el cierre que enlaza con la clase siguiente: con el cómputo resuelto, quedan los datos, que en Azure ofrecen tres familias con modelos de consistencia distintos y una de ellas con cinco niveles a elegir. Es la materia de la clase 223.

CloudShop monta su clúster en Azure para las cargas del equipo de datos y el buscador. Lo que sigue es la decisión del modelo de red que evitó recrear el clúster a los cuatro meses, y los dos incidentes del primer año.

- lo que se pedía
  - 2 cargas con GPU para el equipo de datos
  - un operador de base vectorial que ese equipo ya usa
  - trabajos por lotes con prioridades
  - el buscador, con imagen propia y ajustes de sistema

lo que ya estaba resuelto  
web, API y trabajadores por cola, en aplicaciones de  
contenedor

```

decisión
  clúster SOLO para esas 4 cargas
  las 11 aplicaciones de contenedor se quedan donde están
  motivo funcionan, y moverlas añade trabajo sin
      beneficio                                ley 23

```

el equipo iba a elegir red plana «porque es lo que usamos en la otra nube»

[illegible]

y el contexto  
el plan de direcciones asignaba /21 por radio  
→ con red plana, el clúster se habría comido más de la  
mitad del radio y habría bloqueado el crecimiento

decisión red superpuesta  
y lo que se comprobó antes  
¿algo externo necesita llamar a un pod concreto?  
→ no; todo pasa por servicios y por la entrada  
→ sin ese requisito, la superpuesta no quita nada

y el coste de equivocarse  
cambiar el modelo exige RECREAR el clúster  
→ migrar 4 cargas, sus datos y sus operadores: semanas  
lev 14

se descubrió en la revisión de seguridad, no en un incidente

- la política de red NO estaba activada
  - es una opción que se activa al crear el clúster
  - y por defecto está desactivada

qué implicaba  
un pod del espacio de nombres de pruebas del equipo de  
datos podía llamar al buscador y a la base vectorial  
y el alcance desde cualquier pod comprometido era el  
clúster entero clase 189

y lo peor  
activarla exige recrear el clúster en algunas configuraciones  
→ en este caso se pudo activar sin recrear, con suerte

corrección  
política de red activada  
denegación por defecto entre espacios de nombres  
y reglas explícitas: 9 pares permitidos, de 42 posibles  
alcance desde un pod comprometido clúster → 2 servicios

y una comprobación añadida a la creación de clústeres  
función de aptitud: ningún clúster sin política de red  
clase 190

## Incidente 2 · La actualización que no cabía, mes 9.

situación la versión entraba en fin de soporte  
se lanzó la actualización de los grupos de nodos

qué pasó  
la actualización reemplaza nodos: acordona, drena y crea uno nuevo  
para crear el nuevo hacía falta cuota de cómputo  
→ la suscripción estaba al 96 % de su cuota para esa familia de máquinas clase 217  
→ el nodo nuevo no se pudo crear  
→ la actualización quedó a medias: 3 nodos acordonados y drenados, sin sustituto

capacidad efectiva -22 %  
y las cargas con GPU no tenían dónde ir: su grupo tenía 2 nodos y uno estaba acordonado  
duración 4 h 20

corrección inmediata  
se descordonó lo drenado y se pidió ampliación de cuota  
→ tardó 6 h en concederse

corrección de fondo  
cuota pedida con margen del 30 % sobre el máximo del escalado  
alerta al 80 % de la cuota clase 262  
y regla: no se actualiza si el margen de cuota es menor que un nodo del grupo más grande

## La identidad, montada bien desde el principio:

7 identidades administradas, una por carga  
credencial federada atando emisor + espacio de nombres + cuenta de servicio  
permisos asignados en el ámbito del RECURSO clase 218  
acceso de los pods al servicio de metadatos: bloqueado  
secretos desde el almacén externo, montados en ejecución

pruebas negativas  
✓ pod de «datos-pruebas» intentando obtener la identidad de «buscador» denegado  
✓ pod leyendo credenciales del nodo bloqueado  
✓ cuenta de servicio sin anotación sin identidad  
✗ un pod del espacio «datos» podía leer un almacén de producción  
→ la asignación se había hecho en el ámbito del grupo de recursos, no del almacén  
→ corregido clase 218

## La entrada y los complementos:

entrada controlador gestionado por la plataforma  
motivo: la portabilidad no era requisito y hay menos que mantener ley 23  
certificados automáticos, con alerta por antigüedad clase 196

complementos  
 gestionados métricas, registros, proveedor de  
 secretos, política, autoescalado  
 a mano el operador de base vectorial del equipo  
 de datos  
 → 1 solo, con su matriz de compatibilidad

→ frente a los 12 complementos a mano de la clase 213,  
 aquí quedó 1  
 → y la actualización siguiente tardó 2 h en vez de 4

Las actualizaciones, planificadas:

canal parches automáticos  
 ventana domingos 02:00-06:00  
 versión menor manual, 3 veces al año, planificada

antes de cada una  
 revisión de interfaces retiradas en la canalización  
 clúster de prueba generado del mismo código clase 213  
 comprobación de cuota disponible  
 matriz de compatibilidad del operador

segunda actualización (mes 13)  
 duración 2 h  
 incidencias 0  
 manifiestos corregidos antes 6

El resultado, al año:

|                                                                            |                 |           |
|----------------------------------------------------------------------------|-----------------|-----------|
| direcciones consumidas por el clúster<br>(si se hubiera elegido red plana) | -5.610          | 60        |
| alcance desde un pod comprometido                                          | todo el clúster | 2 serv.   |
| complementos instalados a mano                                             | —               | 1         |
| duración de una actualización                                              | 4 h 20          | 2 h       |
| incidentes por cuota                                                       | 1               | 0         |
| cargas movidas al clúster sin necesidad                                    | 0               | 0         |
| capacidad de equipo consumida                                              | n/d             | 0,3 pers. |

La lección que esta clase deja: la decisión que más valor tuvo se tomó antes de crear el clúster: elegir el modelo de red superpuesta ahorró más de cinco mil quinientas direcciones y evitó que el clúster se comiera medio radio del plan. Cambiarla después habría exigido recrearlo. Y el hallazgo de seguridad más grave —todos los pods podían hablar con todos— no lo produjo ningún error: era el valor por defecto, y se descubrió en una revisión, no en un incidente.

## Laboratorio guiado

Ejecuta desde la raíz:

```
python classes/part-18-azure-production-architecture/222-aks-workload-identity-ingress-y-gitops/lab.py
```

El laboratorio selecciona el motor de práctica kubernetes y produce labresult.json. El escenario, sus comprobaciones y el artefacto esperado corresponden a esta clase; no requiere credenciales y deja explícito qué debe revalidarse en un sandbox real.

1. Lee exercise.steps y formula una predicción antes de ejecutar.
2. Ejecuta la práctica y verifica todos los elementos de checks.
3. Provoca el caso de negativetest y explica la señal observada.
4. Materializa azure-aks-platform en evidence/ usando la plantilla indicada.
5. Para proveedor real, sigue sandbox.requires, registra costo y ejecuta destroy.

## Evidencia esperada

El artefacto principal es manifiestos declarativos con estado observado. Además, la entrega debe incluir el comando ejecutado, la salida estructurada y una conclusión que no exceda lo observado.

## Reto verificable

Construye azure-aks-platform para el caso CloudShop. Incluye una alternativa descartada, un supuesto que pueda falsarse, una prueba de fallo y una decisión de rollback.

### ■ Criterio de aceptación

- [ ] lab.py termina con código 0 y genera JSON válido.
- [ ] La entrega conecta al menos tres requisitos con mecanismos verificables.
- [ ] Existe una prueba positiva y una prueba negativa con evidencia.
- [ ] Seguridad, costo y operación aparecen como decisiones, no como anexos.
- [ ] Se declara una limitación y una condición que obligaría a revisar el diseño.
- [ ] Otra persona puede repetir el recorrido sin conocimiento tácito.

### ■ Errores frecuentes

| Síntoma                                                                    | Causa probable                                                                          | Corrección                                                                                                                        |
|----------------------------------------------------------------------------|-----------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------|
| El clúster consume miles de direcciones y bloquea el crecimiento de la red | Se eligió el modelo de red plana, en el que cada pod toma una dirección de la subred    | Calcula nodos por pods antes de crear el clúster y elige el modelo superpuesto salvo requisito concreto; cambiarlo exige recrear. |
| Cualquier pod puede hablar con cualquier otro                              | La política de red no está activada; por defecto no lo está                             | Actívala al crear el clúster, con denegación por defecto y reglas explícitas, y compruébalo con una función de aptitud.           |
| Un pod usa permisos que no le corresponden                                 | Los permisos están en la identidad del nodo o la credencial federada solo ata al emisor | Identidad por carga, credencial atada a espacio de nombres y cuenta de servicio, y bloqueo del acceso al servicio de metadatos.   |
| Una actualización deja nodos drenados sin sustituto                        | No hay cuota de cómputo para crear los nodos nuevos                                     | Pide cuota con margen sobre el máximo del escalado, alerta al 80 % y no actualices si el margen es menor que un nodo.             |
| La actualización del clúster se bloquea por los complementos               | Muchos complementos instalados a mano, cada uno con su compatibilidad                   | Usa complementos gestionados donde existan y mantén escrita la matriz de los que queden.                                          |
| Los cambios del repositorio dejan de aplicarse sin aviso                   | El bucle de reconciliación falló en silencio                                            | Alerta por antigüedad de la sincronización, con destino a un canal con guardia.                                                   |

### ■ Seguridad, ética y costo

Trabaja con cuentas propias o sandboxes autorizados. No publiques secretos, identificadores reales ni datos personales. Antes de crear recursos pagos define presupuesto, etiquetas y comando de destrucción; después verifica que no queden recursos huérfanos. Los ejemplos locales enseñan contratos, pero no certifican cumplimiento ni disponibilidad de producción.

### ■ Preguntas de comprobación

1. ¿Qué diferencia hay entre el modelo de red plana y el superpuesto, y por qué es irreversible?
2. ¿A qué debe atarse una credencial federada para una carga del clúster?
3. ¿Qué está permitido por defecto entre pods y cómo se cierra?
4. ¿Qué puede impedir que una actualización de nodos termine?
5. ¿Qué ventaja tienen los complementos gestionados frente a los instalados a mano?

## Referencias

- Microsoft (2025). Azure Kubernetes Service: workload identity.  
<<https://learn.microsoft.com/en-us/azure/aks/workload-identity-overview>>
- Microsoft (2025). AKS networking: Azure CNI overlay.  
<<https://learn.microsoft.com/en-us/azure/aks/azure-cni-overlay>>
- Microsoft (2025). Application routing add-on and managed ingress.  
<<https://learn.microsoft.com/en-us/azure/aks/app-routing>>
- Microsoft (2025). AKS cluster upgrades and maintenance windows.  
<<https://learn.microsoft.com/en-us/azure/aks/upgrade-cluster>>
- Microsoft (2025). AKS baseline architecture.  
<<https://learn.microsoft.com/en-us/azure/architecture/reference-architectures/containers/aks/baseline-aks>>
- Documentación oficial vigente del servicio implementado; registra URL y fecha de consulta.

Descargar: Parte 18 en PDF · Recorrido de Azure en PDF · Manual integral

| Anterior                                                      | Índice              | Siguiente                                               |
|---------------------------------------------------------------|---------------------|---------------------------------------------------------|
| ← 221 · App Service, Functions y Container Apps en producción | Parte 18 · Programa | 223 · Azure SQL, Cosmos DB y consistencia distribuida → |

## Evaluación — 222 AKS, workload identity, ingress y GitOps

### Preguntas

1. Explica el problema que resuelve esta capacidad sin mencionar un proveedor.
2. Identifica una frontera de responsabilidad y su propietario.
3. Compara dos alternativas mediante confiabilidad, seguridad, costo y operación.
4. ¿Qué demuestra el laboratorio y qué no puede demostrar?
5. Propón un caso límite o una prueba de fallo.

### Reto verificable

Entrega azure-aks-platform con diagrama o configuración, evidencia de ejecución, alternativa descartada, riesgo residual y criterio de rollback.

### Criterio de aceptación

- [ ] Resultado reproducible por una segunda persona.
- [ ] Evidencia vinculada a cada afirmación técnica.
- [ ] Prueba negativa o de fallo incluida.
- [ ] Costos y permisos expresados con unidades y alcance.
- [ ] Limitaciones declaradas sin presentar la simulación como producción.

## Escala

| Nivel             | Evidencia                                                |
|-------------------|----------------------------------------------------------|
| A — competente    | Cumple todo y defiende trade-offs con datos.             |
| B — en desarrollo | Cumple lo esencial; falta profundidad en una dimensión.  |
| C — inicial       | Artefacto parcial o conclusión sin evidencia suficiente. |
| 0                 | Sin entrega reproducible.                                |

# 223 — Azure SQL, Cosmos DB y consistencia distribuida

Parte: 18 — Azure: arquitectura empresarial y operación en producción Nivel: avanzado · Horas estimadas: 4  
Laboratorio: data · Estado: EXECUTABLECORE

## Propósito

Elegir y configurar el almacén de datos en Azure, donde hay una decisión que no existe en otras nubes: cinco niveles de consistencia a elegir, con su coste y su latencia. La clase compara la base relacional gestionada, la distribuida multimodelo y el resto de la familia, explica qué significa cada nivel de consistencia en la práctica, y desarrolla el modelo de capacidad —unidades de petición— que es donde se rompen los presupuestos y las latencias.

## Resultados de aprendizaje

Al finalizar podrás:

1. Elegir entre base relacional gestionada y distribuida con criterios.
2. Decidir el nivel de consistencia por operación y conocer su coste.
3. Dimensionar capacidad con unidades de petición y evitar el estrangulamiento.
4. Distribuir datos entre regiones sabiendo qué se gana y qué se paga.
5. Diagnosticar los fallos característicos de cada familia.

## Conceptos centrales


| Concepto                   | Comprensión verificable                                                                          |
|----------------------------|--------------------------------------------------------------------------------------------------|
| unidad de petición         | Medida normalizada del coste de una operación. Determina capacidad, latencia y factura.          |
| clave de partición lógica  | Campo que agrupa elementos. Decide el reparto y no se puede cambiar sin migrar.                  |
| consistencia acotada       | Nivel que garantiza un desfase máximo, en versiones o en tiempo.                                 |
| consistencia de sesión     | Nivel por defecto: un cliente ve sus propias escrituras y no retrocede.                          |
| grupo de escalado elástico | Conjunto de bases que comparten recursos, para cargas de uso irregular.                          |
| escritura multirregión     | Opción que permite escribir en varias regiones. Duplica el coste y obliga a resolver conflictos. |

## Modelo mental

La arquitectura Azure nace del tenant y las políticas heredables, y llega al workload mediante identidades administradas y redes privadas.

Aplicado a esta clase, separa siempre cuatro planos: intención (qué necesita el usuario), configuración (qué declaramos), estado observado (qué existe de verdad) y evidencia (cómo sabemos que cumple). Confundirlos produce diseños que se ven correctos en un diagrama pero fallan al operar.

## ■ Flujo de razonamiento



## Desarrollo

### 1. Elegir la familia

Azure ofrece varias familias y la elección se hace igual que siempre: por los patrones de acceso.

#### BASE RELACIONAL GESTIONADA

- transacciones, uniones, consultas que no se conocen de antemano, informes
- + SQL, herramientas maduras, migración desde lo heredado
- + réplicas de lectura y conmutación gestionada
- escala vertical con límite; la horizontal exige particionar a mano
- y las conexiones son un recurso limitado clase 207

#### BASE DISTRIBUIDA MULTIMODELO

- patrones conocidos, escala grande, latencia baja y distribución global
- + escala horizontal transparente
- + distribución multirregión con una casilla
- + cinco niveles de consistencia a elegir
- el modelo se deduce de los patrones clase 208
- y el coste se mide en unidades de petición, que hay que entender

#### Y EL RESTO DE LA FAMILIA

- caché en memoria para lecturas calientes
- almacén de tablas barato y limitado
- almacenamiento de objetos con capas para lo frío
- y motores gestionados de código abierto para migraciones

Y el criterio, que ya conocemos:

- ¿las consultas se conocen de antemano?
  - no → relacional; o distribuida MÁS un almacén analítico
  - sí → distribuida, si el volumen o la latencia lo piden

¿hace falta transacción entre entidades no relacionadas?

→ relacional

¿hace falta latencia baja en varias regiones?

→ distribuida

Y el patrón que resuelve la mayoría de los casos reales:

distribuida para el camino operativo

+ enlace analítico o flujo de cambios hacia un almacén de análisis para informes y exploración

→ y así ninguna de las dos hace lo que no sabe hacer  
clases 208, 150

Y una advertencia sobre la migración desde lo heredado:

la instancia gestionada permite migrar bases antiguas con casi cero cambios

+ resuelve la migración

- y traslada el modelo antiguo, con sus problemas

→ es una decisión de plazo, no de arquitectura; conviene escribir que es temporal, con fecha  
ley 25

## 2. Los cinco niveles de consistencia

Esta es la particularidad que no existe en otras nubes: el nivel de consistencia se elige, por cuenta y por operación.

### FUERTE

toda lectura ve la última escritura confirmada

coste el más alto; y NO se puede usar con escritura multirregión

latencia añadida entre regiones

### OBSOLESCENCIA ACOTADA

el desfase máximo está garantizado: N versiones o T segundos

→ útil cuando se puede tolerar un retraso conocido

→ y es la única que da una COTA, que es lo que suele hacer falta

### SESIÓN ← el valor por defecto

el cliente ve sus propias escrituras y no retrocede

coste la mitad de lectura que la fuerte

→ y es lo que la mayoría de los sistemas necesitan de verdad  
clase 187

### PREFIJO COHERENTE

las escrituras se leen en orden, sin huecos

→ sin garantía de recencia

### EVENTUAL

converge, sin plazo ni orden

coste el más bajo

Y las tres cosas que hay que saber para decidir:

#### 1 EL COSTE DE LECTURA CAMBIA

fuerte y acotada cuestan el DOBLE de unidades de petición que sesión, prefijo o eventual

→ cambiar el nivel por defecto de fuerte a sesión puede reducir la factura de lectura a la mitad

#### 2 SE PUEDE RELAJAR POR PETICIÓN

la cuenta fija el nivel por defecto

y cada petición puede pedir uno MÁS DÉBIL, nunca más fuerte

→ conviene poner la cuenta en el nivel más fuerte que necesite alguna operación, y relajar el resto

#### 3 LA ESCRITURA MULTIRREGIÓN LIMITA LAS OPCIONES

con varias regiones de escritura, fuerte no está disponible

→ y hay que resolver conflictos, con las trampas de los relojes  
clase 187

Y la decisión práctica, con el método de la clase 187:

por cada operación  
reservar plaza / cobrar → fuerte, o escritura  
condicionada  
ver lo propio → sesión  
listar catálogo → eventual  
panel → eventual, marcado

y el nivel de la cuenta = el más fuerte que necesite alguna  
→ el resto relaja explícitamente

Y una advertencia sobre la consistencia fuerte:

con regiones distribuidas, la lectura fuerte obliga a  
coordinar  
→ la latencia crece con la distancia  
→ y por eso «pongo todo en fuerte por si acaso» es la  
decisión más cara que se puede tomar aquí ley 26

### 3. Unidades de petición y estrangulamiento

Todo el coste, la capacidad y la latencia de la base distribuida se expresan en unidades de petición, y no entenderlas es la causa de los sustos.

#### QUÉ CONSUME

leer un elemento por su clave: poco, y proporcional al  
tamaño  
escribir: bastante más que leer  
índices: cada índice encarece la escritura  
consulta que recorre varias particiones: MUCHO  
→ y esa es la que arruina el presupuesto

#### LOS MODELOS DE CAPACIDAD

APROVISIONADA se reservan unidades por segundo  
+ barata con tráfico alto y estable  
- hay que dimensionar y vigilar el estrangulamiento  
AUTOESCALADO entre un mínimo y diez veces ese  
mínimo  
+ absorbe picos  
- precio por unidad mayor  
SIN SERVIDOR se paga por consumo  
+ ideal para desarrollo y cargas pequeñas  
- límites de caudal y de almacenamiento

Y el reparto por partición, que es donde se falla:

#### LAS UNIDADES SE REPARTEN ENTRE PARTICIONES FÍSICAS

10.000 unidades y 10 particiones → 1.000 por partición

→ si el tráfico va a una sola clave, se dispone de 1.000,  
no de 10.000  
→ y aparece el estrangulamiento con la base «al 10 % de  
uso»  
→ es exactamente el problema de la clase 208, con otro  
nombre

Y el diagnóstico y las correcciones:

SÍNTOMA error de petición limitada, con reintento sugerido  
latencia alta en horas concretas  
y consumo total muy por debajo de lo  
aprovisionado

#### QUÉ MIRAR

unidades consumidas POR PARTICIÓN, no en total  
y las claves de partición más consumidoras

#### CORRECCIONES

clave que reparta mejor ← lo correcto  
clave sintética con sufijo ← si ya es tarde  
caché delante para lecturas calientes  
y revisar las consultas que cruzan particiones

Y dos ajustes que reducen mucho el consumo:

#### POLÍTICA DE ÍNDICES

por defecto se indexa CUALQUIER campo

- cada escritura paga por indexar campos que nadie consulta ley 26
- excluir lo que no se filtra reduce el consumo de escritura de forma notable

#### TAMAÑO DEL ELEMENTO

- el coste de lectura crece con el tamaño
- guardar campos grandes fuera y referenciarlos

Y la vigilancia imprescindible:

- peticiones limitadas: alerta si superan un umbral bajo
- unidades consumidas frente a las aprovisionadas
- las 10 claves de partición que más consumen
- y el coste por operación de negocio clase 214

## 4. Distribución, continuidad y la familia relacional

La distribución multirregión de la base distribuida se activa fácilmente y tiene consecuencias.

#### AÑADIR UNA REGIÓN DE LECTURA

- duplica el almacenamiento y las unidades de petición
- el coste se multiplica por el número de regiones
- + latencia baja en esa región
- + y conmutación gestionada

#### AÑADIR ESCRITURA MULTIRREGIÓN

- + escritura local en cada región
- conflictos: hay que definir la política de resolución
- y con relojes derivando, «el último gana» tiene las trampas conocidas clase 187
- solo tiene sentido si cada dato lo escribe una sola región ley 21

#### CONMUTACIÓN

- automática o manual
- automática es cómoda y quita el control del momento
- y volver exige que la región original se ponga al día clase 215

Y el consejo:

- empieza con una región de escritura y las de lectura que hagan falta
- y mide antes de activar escritura multirregión: casi nunca es lo que se necesita

La familia relacional, con sus decisiones propias:

#### NIVEL DE SERVICIO

- el modelo por núcleos permite elegir cómputo y almacenamiento por separado
- más predecible que el modelo por unidades combinadas

#### GRUPOS ELÁSTICOS

- varias bases comparten recursos
- ideal para multi-inquilino con uso irregular
- y evita pagar capacidad por cada base

#### RÉPLICAS DE LECTURA

- descargan informes y consultas pesadas
- con el retraso de réplica vigilado clase 161

#### CONTINUIDAD

- grupo de conmutación con nombre de escritura y de lectura
- la aplicación usa el nombre, no la instancia
- y el plazo real se MIDE, incluida la caché del cliente clases 195, 215

#### CONEXIONES

- el límite depende del nivel
- y con cómputo que escala, hay que calcularlo por instancia clase 221
- o usar un intermediario de conexiones

- el nivel sin servidor de la base relacional pausa la base tras un tiempo sin uso
- + muy barato en desarrollo
- la primera conexión tras la pausa tarda
- excelente para entornos no productivos
- y una mala idea en producción con tráfico esporádico

- la familia elegida corresponde a los patrones de acceso
- los patrones están escritos antes del modelo
- la clave de partición reparte y está en las consultas
- el nivel de consistencia de la cuenta es el más fuerte necesario, y el resto se relaja por petición
- se conoce el coste doble de lectura de los niveles fuertes
- el modelo de capacidad corresponde al perfil de tráfico
- se vigilan las unidades por partición, no solo el total
- hay alerta de peticiones limitadas
- la política de índices excluye lo que no se consulta
- los campos grandes no viven dentro del elemento
- las regiones añadidas están justificadas por su coste
- la escritura multirregión, si existe, tiene política de conflictos escrita
- la aplicación usa nombres de conmutación, no instancias
- el límite de conexiones se calculó por instancia
- el plazo de conmutación se ha medido, no calculado

## Ejemplo trabajado

|                                        |             |
|----------------------------------------|-------------|
| estimación inicial                     | 1.800 €/mes |
| factura real                           | 5.740 €/mes |
| desglose                               |             |
| base distribuida (pedidos y clientes)  | 4.100 €     |
| base relacional (facturación heredada) | 980 €       |
| caché en memoria                       | 340 €       |
| almacenamiento de objetos              | 320 €       |

- ninguna operación necesitaba FUERTE
- la más exigente era el cierre contable, con acotada

cambio  
nivel de la cuenta fuerte → obsolescencia  
acotada (5 s)  
y las lecturas normales piden explícitamente sesión o  
eventual

efecto  
unidades de lectura consumidas -47 %  
coste 4.100 € → 2.380 €  
latencia p99 de lectura 38 ms → 9 ms

Y la observación:

el nivel de consistencia se había elegido en el asistente  
de creación, en 20 segundos, sin escribir ningún patrón  
→ y costaba 1.720 €/mes ley 14, ley 26

Causa 2 · La política de índices por defecto.

por defecto se indexan TODOS los campos

el documento de pedido tenía 61 campos  
campos usados en filtros u ordenaciones 7  
campos indexados 61

consumo de escritura por pedido 42 unidades  
tras excluir los 54 campos no consultados  
17 unidades

efecto  
escrituras al mes 41 M  
coste de escritura 1.720 € → 700 €

Y un efecto secundario que no se buscaba:

dos campos indexados contenían texto largo de descripción  
→ excluirlos redujo también el TAMAÑO del índice  
→ almacenamiento 410 GB → 240 GB

El estrangulamiento con la base al 11 %.

síntoma entre las 11:00 y las 12:30, errores de petición  
limitada  
consumo total 2.100 de 20.000  
unidades aprovisionadas

diagnóstico  
unidades por partición, no en total  
el panel de claves más consumidoras

| clave de partición    | unidades consumidas |
|-----------------------|---------------------|
| cliente#EMPRESA-A     | 1.740 ← el 83 %     |
| resto (41.000 claves) | 360                 |

el cliente EMPRESA-A hacía pedidos automáticos desde su  
sistema, con ráfagas a mediodía  
su partición disponía de ~1.800 unidades de las 20.000  
→ estrangulada, mientras el resto de la base estaba  
ociosa

corrección  
no se cambió la clave: habría exigido migrar  
→ el sistema de EMPRESA-A pasó a agrupar sus pedidos en  
lotes con límite de ritmo  
→ y se añadió una alerta: «una sola clave consume más del  
30 % del total»

y la decisión registrada  
«si aparece un segundo cliente con este perfil, se  
introduce clave sintética con sufijo y se migra»  
clases 208, 190

La distribución multirregión, evaluada y recortada.

se había activado escritura multirregión en 3 regiones  
motivo «para estar preparados»

lo que costaba  
almacenamiento × 3  
unidades de petición × 3  
→ 2.380 € pasaban a ser ~4.900 € solo por eso

lo que aportaba  
el 98,4 % del tráfico venía de Europa occidental  
las otras dos regiones servían 1,6 %  
y la escritura multirregión obligaba a una política de  
resolución de conflictos que nadie había definido

decisión  
1 región de escritura (Europa occidental)  
1 región de lectura (Europa norte), para continuidad  
clase 215  
la tercera, retirada  
escritura multirregión, desactivada

coste 4.900 € → 2.380 €  
(con la región de lectura ya incluida)

La base relacional, con lo suyo:

facturación heredada, migrada a instancia gestionada  
→ decisión registrada como TEMPORAL, con revisión a 18  
meses ley 25

ajustes  
nivel por núcleos, cómputo y almacenamiento separados  
réplica de lectura para los informes  
→ descargó el 61 % de las consultas del primario  
grupo de conmutación con nombres de escritura y lectura  
→ la aplicación usa el nombre, no la instancia

y las conexiones  
cómputo con escalado a 30 instancias clase 221  
agrupación por instancia 20  
30 × 20 = 600 > 400 del nivel contratado  
→ se bajó la agrupación a 12 y se añadió intermediario  
→ conexiones máximas observadas 214

y los entornos no productivos  
nivel sin servidor con pausa automática  
coste de desarrollo y preproducción 480 € → 90 €  
clase 214

El resultado:

|                                       |         |         |
|---------------------------------------|---------|---------|
| coste mensual de datos                | 5.740 € | 2.910 € |
| base distribuida                      | 4.100 € | 1.680 € |
| base relacional                       | 980 €   | 810 €   |
| no productivos                        | 480 €   | 90 €    |
| unidades por escritura de pedido      | 42      | 17      |
| latencia p99 de lectura               | 38 ms   | 9 ms    |
| errores de petición limitada          | 140/día | 0       |
| almacenamiento de la base distribuida | 410 GB  | 240 GB  |
| regiones activas                      | 3       | 2       |
| escritura multirregión                | sí      | no      |
| conexiones máximas a la relacional    | 600     | 214     |

La lección que esta clase deja: de los cinco mil setecientos euros mensuales, más de la mitad venía de dos decisiones tomadas en el asistente de creación: el nivel de consistencia fuerte y la política de índices que lo indexa todo. Ninguna operación necesitaba consistencia fuerte, y siete de sesenta y un campos se consultaban. Y el estrangulamiento con la base al once por ciento de uso resultó ser un solo cliente concentrando el ochenta y tres por ciento del consumo en una partición, que es el mismo problema de la clase 208 con otro nombre.

## Laboratorio guiado

Ejecuta desde la raíz:

```
python classes/part-18-azure-production-architecture/223-azure-sql-cosmos-db-y-consistencia-  
distribuida/lab.py
```

El laboratorio selecciona el motor de práctica data y produce labresult.json. El escenario, sus comprobaciones y el artefacto esperado corresponden a esta clase; no requiere credenciales y deja explícito qué debe revalidarse en un sandbox real.

1. Lee exercise.steps y formula una predicción antes de ejecutar.
2. Ejecuta la práctica y verifica todos los elementos de checks.
3. Provoca el caso de negativetest y explica la señal observada.
4. Materializa azure-data-platform en evidence/ usando la plantilla indicada.
5. Para proveedor real, sigue sandbox.requires, registra costo y ejecuta destroy.

## Evidencia esperada

El artefacto principal es un modelo de datos ligado a patrones de acceso. Además, la entrega debe incluir el comando ejecutado, la salida estructurada y una conclusión que no exceda lo observado.

## Reto verificable

Construye azure-data-platform para el caso CloudShop. Incluye una alternativa descartada, un supuesto que pueda falsarse, una prueba de fallo y una decisión de rollback.

## ■ Criterio de aceptación

- [ ] lab.py termina con código 0 y genera JSON válido.
- [ ] La entrega conecta al menos tres requisitos con mecanismos verificables.
- [ ] Existe una prueba positiva y una prueba negativa con evidencia.
- [ ] Seguridad, costo y operación aparecen como decisiones, no como anexos.
- [ ] Se declara una limitación y una condición que obligaría a revisar el diseño.
- [ ] Otra persona puede repetir el recorrido sin conocimiento tácito.

## ■ Errores frecuentes

| Síntoma                                                    | Causa probable                                                                 | Corrección                                                                                                                      |
|------------------------------------------------------------|--------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------|
| El coste de lectura es el doble de lo esperado             | La cuenta usa un nivel de consistencia fuerte que ninguna operación necesita   | Decide el nivel por operación, fija en la cuenta el más fuerte necesario y relaja el resto por petición.                        |
| Cada escritura consume muchísimas unidades                 | La política de índices indexa todos los campos por defecto                     | Excluye del índice los campos que no se filtran ni se ordenan, y saca los textos largos del elemento.                           |
| Hay estrangulamiento con la base al diez por ciento de uso | Las unidades se reparten entre particiones y el tráfico va a una sola clave    | Mira el consumo por partición y las claves más consumidoras; corrige la clave, agrupa en lotes o añade sufijo sintético.        |
| La factura se multiplica al añadir regiones                | Cada región replica almacenamiento y unidades de petición                      | Justifica cada región con el tráfico que sirve y activa la escritura multirregión solo si cada dato lo escribe una sola región. |
| La base relacional agota conexiones al escalar el cómputo  | Cada instancia abre su propia agrupación y el total supera el límite del nivel | Calcula la agrupación por instancia contando el máximo del escalado, o usa un intermediario de conexiones.                      |
| La aplicación no sigue la conmutación de la base           | Se conecta a la instancia y no al nombre del grupo de conmutación              | Usa siempre el nombre de escritura o de lectura, y mide el plazo real de conmutación incluyendo la caché del cliente.           |

## ■ Seguridad, ética y costo

Trabaja con cuentas propias o sandboxes autorizados. No publiques secretos, identificadores reales ni datos personales. Antes de crear recursos pagos define presupuesto, etiquetas y comando de destrucción; después verifica que no queden recursos huérfanos. Los ejemplos locales enseñan contratos, pero no certifican cumplimiento ni disponibilidad de producción.

## ■ Preguntas de comprobación

1. ¿Cuáles son los cinco niveles de consistencia y cuál es el valor por defecto?
2. ¿Qué niveles cuestan el doble de unidades al leer?
3. ¿Por qué puede haber estrangulamiento con la base muy por debajo de su capacidad total?
4. ¿Qué efecto tiene la política de índices por defecto sobre el coste de escritura?
5. ¿Qué obliga a resolver la escritura multirregión y cuándo tiene sentido?

## Referencias

- Microsoft (2025). Azure Cosmos DB consistency levels.  
<<https://learn.microsoft.com/en-us/azure/cosmos-db/consistency-levels>>
- Microsoft (2025). Request units in Azure Cosmos DB.  
<<https://learn.microsoft.com/en-us/azure/cosmos-db/request-units>>
- Microsoft (2025). Partitioning and horizontal scaling.  
<<https://learn.microsoft.com/en-us/azure/cosmos-db/partitioning-overview>>
- Microsoft (2025). Indexing policies in Azure Cosmos DB.  
<<https://learn.microsoft.com/en-us/azure/cosmos-db/index-policy>>
- Microsoft (2025). Azure SQL Database: failover groups and elastic pools.  
<<https://learn.microsoft.com/en-us/azure/azure-sql/database/failover-group-sql-db>>
- Documentación oficial vigente del servicio implementado; registra URL y fecha de consulta.

Descargar: Parte 18 en PDF · Recorrido de Azure en PDF · Manual integral

| Anterior                                         | Índice              | Siguiente                                    |
|--------------------------------------------------|---------------------|----------------------------------------------|
| ← 222 · AKS, workload identity, ingress y GitOps | Parte 18 · Programa | 224 · Service Bus, Event Grid y Event Hubs → |

## Evaluación — 223 Azure SQL, Cosmos DB y consistencia distribuida

### Preguntas

1. Explica el problema que resuelve esta capacidad sin mencionar un proveedor.
2. Identifica una frontera de responsabilidad y su propietario.
3. Compara dos alternativas mediante confiabilidad, seguridad, costo y operación.
4. ¿Qué demuestra el laboratorio y qué no puede demostrar?
5. Propón un caso límite o una prueba de fallo.

### Reto verificable

Entrega azure-data-platform con diagrama o configuración, evidencia de ejecución, alternativa descartada, riesgo residual y criterio de rollback.

## Criterio de aceptación

- ☐ Resultado reproducible por una segunda persona.
- ☐ Evidencia vinculada a cada afirmación técnica.
- ☐ Prueba negativa o de fallo incluida.
- ☐ Costos y permisos expresados con unidades y alcance.
- ☐ Limitaciones declaradas sin presentar la simulación como producción.

## Escala

| Nivel             | Evidencia                                                |
|-------------------|----------------------------------------------------------|
| A — competente    | Cumple todo y defiende trade-offs con datos.             |
| B — en desarrollo | Cumple lo esencial; falta profundidad en una dimensión.  |
| C — inicial       | Artefacto parcial o conclusión sin evidencia suficiente. |
| 0                 | Sin entrega reproducible.                                |

## 224 — Service Bus, Event Grid y Event Hubs

Parte: 18 — Azure: arquitectura empresarial y operación en producción Nivel: avanzado · Horas estimadas: 4  
Laboratorio: messaging · Estado: EXECUTABLECORE

### Propósito

Elegir entre los tres servicios de mensajería de Azure, que se confunden constantemente porque los tres «llevan mensajes» y resuelven cosas distintas. La clase separa el bus de mensajes empresarial, el enrutador de eventos y el flujo de gran volumen por lo que cada uno garantiza, desarrolla los mecanismos propios del primero —sesiones, transacciones, detección de duplicados— y aplica la disciplina de siempre: idempotencia, cola de fallidos vigilada y reproceso probado.

### Resultados de aprendizaje

Al finalizar podrás:

1. Elegir entre bus, enrutador y flujo según lo que se garantiza.
2. Usar sesiones, transacciones y detección de duplicados donde aportan.
3. Configurar bloqueo, reintentos y cola de fallidos coherentemente.
4. Consumir un flujo con posiciones y reparto por partición.
5. Operar los mensajes fallidos con alerta, diagnóstico y reproceso.

### Conceptos centrales


| Concepto                | Comprensión verificable                                                                                                 |
|-------------------------|-------------------------------------------------------------------------------------------------------------------------|
| bus de mensajes         | Colas y temas con garantías empresariales: orden por sesión, transacciones, detección de duplicados y cola de fallidos. |
| enrutador de eventos    | Servicio que entrega eventos a destinos según filtros. Uno a muchos, con reintentos y destino de fallidos.              |
| flujo de eventos        | Registro particionado de gran volumen, con lectores independientes y reproceso por posición.                            |
| sesión                  | Agrupación de mensajes por clave que garantiza orden y entrega al mismo consumidor.                                     |
| bloqueo del mensaje     | Tiempo durante el que el mensaje tomado no se entrega a otro. Debe superar el proceso o hay duplicados.                 |
| detección de duplicados | Descarte de mensajes con el mismo identificador dentro de una ventana. No sustituye a la idempotencia.                  |

### Modelo mental

La arquitectura Azure nace del tenant y las políticas heredables, y llega al workload mediante identidades administradas y redes privadas.

Aplicado a esta clase, separa siempre cuatro planos: intención (qué necesita el usuario), configuración (qué declaramos), estado observado (qué existe de verdad) y evidencia (cómo sabemos que cumple). Confundirlos produce diseños que se ven correctos en un diagrama pero fallan al operar.

### ■ Flujo de razonamiento



## Desarrollo

### 1. Tres servicios, tres propósitos

Los tres transportan mensajes y garantizan cosas distintas. Elegir mal produce sistemas que funcionan hasta que hay carga o hay que reprocesar.

#### BUS DE MENSAJES (Service Bus)

- colas y temas con suscripciones
- garantiza
  - entrega al menos una vez, con bloqueo y confirmación
- ORDEN por sesión
- transacciones entre entidades del propio bus
- detección de duplicados en una ventana
- cola de fallidos integrada
- y mensajes programados y diferidos
- para pedidos, pagos, integraciones donde perder o desordenar cuesta dinero
- ojo caudal moderado; no es para millones por segundo

#### ENRUTADOR DE EVENTOS (Event Grid)

- entrega eventos a destinos según filtros de contenido
- garantiza
  - entrega al menos una vez, con reintentos y retroceso
- destino de fallidos
- y filtros declarativos
- para reaccionar a lo que ocurre; uno a muchos
- incluidos los eventos de la propia plataforma
- ojo NO garantiza orden

#### FLUJO (Event Hubs)

- registro particionado, con lectores independientes
- garantiza
  - orden DENTRO de la partición
  - retención por tiempo y reproceso por posición
  - varios grupos de consumidores sin duplicar el almacenamiento
- para telemetría, trazas, clics, sensores: gran volumen
- ojo el consumidor gestiona su posición; si la pierde, reprocesa o se salta clase 116

Y la combinación habitual, que es la que hay que reconocer:

- algo ocurre → ENRUTADOR (uno a muchos, con filtros)
  - COLA del bus por consumidor
  - función o contenedor

y por separado

- telemetría de alto volumen → FLUJO → procesamiento y almacén analítico

→ y la cola entre el enrutador y el consumidor sigue siendo lo que amortigua y da control de reintentos clase 210

Y el error de elección más caro:

- usar el flujo como si fuera una cola
- no hay bloqueo por mensaje ni confirmación individual

no hay cola de fallidos integrada  
un mensaje venenoso bloquea la partición entera  
→ hay que implementar todo eso a mano

y al revés: usar el bus para telemetría de alto volumen  
→ caudal insuficiente y coste alto

## 2. Los mecanismos del bus

El bus tiene mecanismos que no existen en otros servicios y que resuelven problemas concretos.

### SESIONES – orden por clave

los mensajes con la misma clave de sesión van al mismo consumidor, en orden  
→ resuelve «los eventos de un pedido deben procesarse en orden» sin serializar todo  
coste  
el caudal por sesión lo limita un solo consumidor  
y el consumidor debe mantener la sesión bloqueada  
→ usar sesiones solo donde el orden importe    clase 203

### TRANSACCIONES

varias operaciones del bus en una unidad atómica  
→ recibir de una cola y enviar a otra, todo o nada  
ojo solo dentro del mismo espacio de nombres; NO incluye la base de datos  
→ para eso sigue haciendo falta la tabla de salida  
clase 118

### DETECCIÓN DE DUPLICADOS

descarta mensajes con el mismo identificador dentro de una ventana de tiempo  
+ evita duplicados del PRODUCTOR que reintenta  
– no cubre el reproceso ni la reentrega tras bloqueo vencido  
→ NO sustituye a la idempotencia del consumidor  
clase 210

### MENSAJES PROGRAMADOS Y DIFERIDOS

programado se entrega a una hora futura  
diferido el consumidor lo aparta y lo recupera por su número de secuencia  
→ útiles para reintentos con retroceso largo y para esperar a que llegue otra cosa

Los parámetros que producen duplicados, con la misma aritmética de la clase 210:

### DURACIÓN DEL BLOQUEO

el mensaje tomado queda bloqueado ese tiempo  
si el proceso tarda más, el bloqueo VENCE y el mensaje se reentrega  
→ duplicados

### dos soluciones

bloqueo mayor que el proceso máximo  
o RENOVAR el bloqueo desde el consumidor mientras trabaja  
→ la renovación automática existe en las bibliotecas y hay que activarla

### RECUENTO MÁXIMO DE ENTREGAS

cuántas veces antes de ir a la cola de fallidos  
típico 3 a 5

### TAMAÑO DE LOTE Y PREBÚSQUEDA

la prebúsqueda trae mensajes por adelantado  
+ menos latencia  
– esos mensajes están bloqueados aunque no se procesen  
→ prebúsqueda alta con proceso lento = bloqueos vencidos y duplicados

Y la regla:

prebúsqueda × tiempo de proceso < duración del bloqueo  
→ o se renueva el bloqueo activamente

### 3. El flujo y sus posiciones

El flujo funciona distinto y su operación tiene sus propias trampas.

#### PARTICIONES

- el caudal se reparte entre particiones
- la CLAVE decide en cuál cae cada evento
  - misma clave, misma partición, mismo orden    clase 116
  - y una clave caliente satura una partición mientras las demás están ociosas

- y el número de particiones
  - condiciona el paralelismo máximo del consumo
  - más consumidores que particiones = consumidores ociosos

#### POSICIÓN DEL LECTOR

- cada grupo de consumidores guarda por dónde va
  - y esa posición hay que persistirla
  - si se pierde, se reprocesa desde el principio o se salta lo pendiente

#### LA REGLA

- guardar la posición DESPUÉS de procesar, no antes
  - guardarla antes produce pérdida silenciosa    ley 13
  - guardarla después produce reproceso, que la idempotencia absorbe

#### RETENCIÓN

- los eventos viven un tiempo, no hasta que se consumen
  - si el consumidor está caído más que la retención, se pierden eventos
  - alerta por RETRASO del consumidor frente a la retención    ley 13

Y el mensaje venenoso, que aquí es más grave:

- en una cola, un mensaje que falla acaba en la cola de fallidos y los demás siguen

- en un flujo, si el consumidor falla y no avanza, la PARTICIÓN ENTERA se detiene
  - hay que decidir qué hacer con lo que no se puede procesar
    - apartarlo a una cola de fallidos propia y avanzar
    - o parar y alertar, si perder orden es inaceptable
  - y esa decisión hay que escribirla; no viene dada

Y la captura hacia almacenamiento, que ahorra trabajo:

- el flujo puede volcar automáticamente a almacenamiento de objetos
  - da el histórico para análisis sin escribir un consumidor
  - y el reproceso de meses se hace desde ahí, no desde el flujo    clase 150

### 4. Fallidos, reproceso y operación

La disciplina es la misma de la clase 210, con las piezas de Azure.

#### LA COLA DE FALLIDOS DEL BUS

- cada cola y cada suscripción tiene la suya, integrada los mensajes llegan con el MOTIVO y la descripción
  - y eso es lo que permite distinguir veneno de dependencia    clase 210

- y llegan también por caducidad del mensaje
  - error de evaluación de una regla de suscripción
  - y tamaño excedido
  - tres causas que no son «el consumidor falló»

#### LAS ALERTAS

- «hay mensajes en la cola de fallidos»    insuficiente

«el mensaje más antiguo supera 1 hora» ← la útil  
«la cola activa crece de forma sostenida»  
«el retraso del consumidor del flujo se acerca a la  
retención» ← crítica

Y el reproceso, con la lección de la clase 210:

procedimiento escrito, con límite de ritmo y por lotes  
con posibilidad de reprocesar uno solo  
ejecutado por alguien que no lo escribió ley 22  
y los venenos, descartados con registro

→ reprocesar todo de golpe dispara la concurrencia y tumba  
lo que se acababa de recuperar clase 207

La idempotencia, que sigue siendo obligatoria:

la detección de duplicados del bus cubre al productor  
las sesiones cubren el orden  
NINGUNA de las dos cubre  
el bloqueo vencido y la reentrega  
el reproceso desde la cola de fallidos  
el reproceso del flujo desde una posición anterior

→ clave de idempotencia del productor, registro con estados  
y escritura condicionada clase 210

Lo que hay que vigilar:

mensajes activos, programados y en cola de fallidos  
antigüedad del más viejo, en las tres  
bloqueos vencidos: señal directa de duración mal puesta  
entregas repetidas del mismo mensaje  
retraso del consumidor del flujo, en eventos y en tiempo  
unidades de caudal del flujo frente a lo consumido  
y el retraso entre que ocurre el hecho y se procesa  
→ la medida que le importa al negocio clase 211

Y la lista de comprobación de la clase:

- el servicio elegido corresponde a lo que hay que garantizar
- hay cola entre el enrutador y el consumidor
- las sesiones se usan solo donde el orden importa
- la duración del bloqueo supera el proceso, o se renueva
- $\text{prebúsqueda} \times \text{tiempo de proceso} < \text{duración del bloqueo}$
- la detección de duplicados no se usa como sustituto de la idempotencia
- toda operación con efecto es idempotente
- el número de particiones del flujo permite el paralelismo necesario
- la posición del lector se guarda DESPUÉS de procesar
- está decidido qué hacer con un mensaje venenoso en el flujo
- hay alerta por antigüedad en la cola de fallidos
- hay alerta de retraso del consumidor frente a la retención
- el procedimiento de reproceso existe y se ha ejecutado
- los venenos se descartan con registro

Y el cierre que enlaza con la clase siguiente: con datos y mensajería en pie, falta saber qué ocurre cuando algo va mal. Observabilidad en Azure, con instrumentación estándar, es la materia de la clase 225.

## Ejemplo trabajado

CloudShop monta la mensajería de su plataforma en Azure. Lo que sigue son los tres errores de elección del primer diseño, el incidente del flujo que perdió cuatro horas de telemetría, y los parámetros que quedaron.

El primer diseño, con las tres elecciones equivocadas:

confirmación de pedido → enrutador de eventos, directo  
a 3 funciones  
telemetría de la web → bus de mensajes  
integración con el ERP → enrutador de eventos

Y lo que falló en cada una:

- 1 CONFIRMACIÓN DE PEDIDO al enrutador, directo a funciones sin cola en medio  
→ sin amortiguación: en campaña, las funciones escalaron a 2.400 y tumbaron la base clase 207  
→ sin control de reintentos por consumidor  
→ y sin cola de fallidos por consumidor: los tres compartían destino de fallidos y no se distinguía cuál había fallado

corrección

enrutador → 3 colas del bus → 3 consumidores  
cada una con su bloqueo, reintentos y cola de fallidos

- 2 TELEMETRÍA de la web al bus de mensajes  
volumen 41.000 eventos/s  
el espacio de nombres del bus se saturó  
coste estimado con el nivel necesario 3.900 €/mes

corrección

flujo de eventos, 8 particiones  
coste 340 €/mes  
y captura automática a almacenamiento para el histórico  
clase 150

- 3 INTEGRACIÓN CON EL ERP al enrutador  
el ERP exigía procesar las líneas de un pedido EN ORDEN  
el enrutador no garantiza orden  
→ líneas procesadas fuera de orden: 61 pedidos con estado incorrecto en 3 semanas

corrección

cola del bus CON SESIONES, clave = identificador de pedido  
→ orden garantizado dentro de cada pedido  
→ y paralelismo entre pedidos distintos

El incidente del flujo: cuatro horas de telemetría perdidas.

situación el consumidor del flujo se desplegó con un fallo y entró en bucle de reinicio  
retención del flujo 1 día  
pero el consumidor guardaba su posición ANTES de procesar

qué pasó

al arrancar, el consumidor leía un lote, guardaba la posición, y fallaba al procesar  
al reiniciar, leía DESDE LA POSICIÓN GUARDADA  
→ los eventos de ese lote nunca se procesaron  
→ y no quedaba rastro: la posición decía que estaban hechos

duración del bucle 4 h 10  
eventos perdidos ~610 millones  
cómo se detectó el panel de negocio mostró 0 visitas durante 4 horas ley 15

qué salvó el caso

la captura automática a almacenamiento seguía activa  
→ los eventos estaban ahí  
→ se reprocesaron desde los ficheros, en 6 h

correcciones

- 1 la posición se guarda DESPUÉS de procesar  
→ produce reproceso, que la idempotencia absorbe
- 2 alerta de retraso del consumidor: «el retraso supera el 50 % de la retención»
- 3 alerta de reinicios del consumidor clase 221
- 4 y una comprobación de negocio: «visitas por minuto por debajo del mínimo esperado»  
→ esta es la que lo habría detectado en 5 minutos  
clase 211

## Los duplicados del bus, y el bloqueo.

síntoma    bajo carga, algunos pedidos generaban dos  
              notificaciones

### diagnóstico

|                               |                |
|-------------------------------|----------------|
| duración del bloqueo          | 30 s (defecto) |
| prebúsqueda                   | 20 mensajes    |
| tiempo de proceso por mensaje | 1,8 s          |

$$20 \times 1,8 = 36 \text{ s} > 30 \text{ s}$$

→ los últimos mensajes del lote perdían el bloqueo antes de procesarse

→ se reentregaban a otro consumidor

y la métrica que lo confirmaba

«bloqueos vencidos»: 340/hora en el pico

→ estaba disponible y no estaba en ningún panel

ley 15

### correcciones

|                                                   |              |
|---------------------------------------------------|--------------|
| duración del bloqueo                              | 30 s → 120 s |
| prebúsqueda                                       | 20 → 10      |
| renovación automática del bloqueo                 | activada     |
| e idempotencia en el consumidor de notificaciones |              |

|                           |           |
|---------------------------|-----------|
| bloqueos vencidos         | 340/h → 0 |
| notificaciones duplicadas | 61 → 0    |

## La configuración final:

### ENRUTADOR DE EVENTOS

eventos de negocio y de la plataforma

filtros por tipo y por contenido

destino: colas del bus, nunca funciones directas

reintentos: 5 con retroceso; destino de fallidos

configurado

### BUS DE MENSAJES

| cola           | bloqueo | prebúsq. | entregas | sesiones |
|----------------|---------|----------|----------|----------|
| notificaciones | 120 s   | 10       | 5        | no       |
| inventario     | 180 s   | 10       | 5        | no       |
| facturación    | 300 s   | 5        | 5        | no       |
| erp            | 240 s   | 1        | 3        | SÍ       |

→ la de sesiones con prebúsqueda 1: el orden importa más que la latencia

detección de duplicados activada en la cola de pedidos, ventana de 10 minutos

→ y aun así, idempotencia en los cuatro consumidores

### FLUJO

8 particiones, clave = identificador de sesión de usuario

2 grupos de consumidores: proceso en tiempo real y análisis

retención 3 días (subida desde 1)

captura automática a almacenamiento, cada 5 min

posición guardada después de procesar

## Las alertas montadas:

antigüedad del mensaje más viejo en cada cola de fallidos

umbral 1 hora → canal de guardia

cola activa creciendo de forma sostenida

bloqueos vencidos > 0

retraso del consumidor del flujo > 50 % de la retención

eventos por minuto por debajo del mínimo esperado

→ la de negocio, que detecta lo que las técnicas no reinicios de consumidores

## El reproceso, probado:

primer ensayo

se dejaron 8.000 mensajes en la cola de fallidos a

propósito

quien lo ejecutó no había escrito el procedimiento  
→ 2 de 7 pasos necesitaron aclaración  
→ y el límite de ritmo estaba en el paso 4, no en el 1  
→ se movió al 1 clase 216

segundo ensayo

|                                      |    |
|--------------------------------------|----|
| 8.000 mensajes reprocesados en 3 min |    |
| conurrencia máxima                   | 40 |
| incidencias                          | 0  |

El resultado:

|                                             |          |       |
|---------------------------------------------|----------|-------|
| notificaciones duplicadas                   | 61       | 0     |
| pedidos con estado incorrecto (orden)       | 61       | 0     |
| eventos de telemetría perdidos              | 610 M    | 0     |
| coste de la telemetría                      | 3.900 €  | 340 € |
| bloqueos vencidos                           | 340/hora | 0     |
| tiempo de detección de un consumidor parado | 4 h 10   | 5 min |
| reprocesos ejecutados                       | 0        | 4     |
| que causaron incidente                      | —        | 0     |

La lección que esta clase deja: los tres errores del primer diseño fueron de elección de servicio, no de configuración: el enrutador directo a funciones sin amortiguar, el bus para telemetría de gran volumen y el enrutador para algo que necesitaba orden. Y el incidente más grave —seiscientos diez millones de eventos perdidos— lo causó guardar la posición del lector antes de procesar, un detalle de una línea que producía pérdida silenciosa; lo salvó una captura automática a almacenamiento que se había activado por otro motivo.

## Laboratorio guiado

Ejecuta desde la raíz:

```
python classes/part-18-azure-production-architecture/224-service-bus-event-grid-y-event-hubs/lab.py
```

El laboratorio selecciona el motor de práctica messaging y produce labresult.json. El escenario, sus comprobaciones y el artefacto esperado corresponden a esta clase; no requiere credenciales y deja explícito qué debe revalidarse en un sandbox real.

1. Lee exercise.steps y formula una predicción antes de ejecutar.
2. Ejecuta la práctica y verifica todos los elementos de checks.
3. Provoca el caso de negativetest y explica la señal observada.
4. Materializa azure-event-platform en evidence/ usando la plantilla indicada.
5. Para proveedor real, sigue sandbox.requires, registra costo y ejecuta destroy.

### Evidencia esperada

El artefacto principal es un flujo que declara orden, entrega y manejo de errores. Además, la entrega debe incluir el comando ejecutado, la salida estructurada y una conclusión que no exceda lo observado.

## Reto verificable

Construye azure-event-platform para el caso CloudShop. Incluye una alternativa descartada, un supuesto que pueda falsarse, una prueba de fallo y una decisión de rollback.

### ■ Criterio de aceptación

- [ ] lab.py termina con código 0 y genera JSON válido.
- [ ] La entrega conecta al menos tres requisitos con mecanismos verificables.
- [ ] Existe una prueba positiva y una prueba negativa con evidencia.
- [ ] Seguridad, costo y operación aparecen como decisiones, no como anexos.
- [ ] Se declara una limitación y una condición que obligaría a revisar el diseño.
- [ ] Otra persona puede repetir el recorrido sin conocimiento tácito.

## ■ Errores frecuentes

| Síntoma                                                   | Causa probable                                                            | Corrección                                                                                                                          |
|-----------------------------------------------------------|---------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------|
| Un pico de eventos tumba la base de datos                 | El enrutador entrega directamente a las funciones, sin cola que amortigüe | Pon una cola por consumidor entre el enrutador y el proceso, con su bloqueo, reintentos y cola de fallidos propios.                 |
| Se procesan mensajes fuera de orden y el estado queda mal | Se eligió un servicio que no garantiza orden                              | Usa colas con sesiones y clave por entidad; el orden se garantiza dentro de la sesión y sigue habiendo paralelismo entre entidades. |
| Aparecen duplicados solo con carga alta                   | La prebúsqueda por el tiempo de proceso supera la duración del bloqueo    | Aumenta el bloqueo, reduce la prebúsqueda y activa la renovación automática; vigila la métrica de bloqueos vencidos.                |
| Se pierden eventos sin ningún error                       | La posición del lector se guarda antes de procesar                        | Guarda la posición después de procesar y absorbe el reproceso con idempotencia; alerta si el retraso se acerca a la retención.      |
| Un mensaje incorrecto detiene todo el consumo             | En un flujo, el consumidor no avanza y bloquea la partición entera        | Decide y escribe qué hacer con el veneno: apartarlo a una cola propia y avanzar, o parar y alertar.                                 |
| La factura de mensajería es muy alta para telemetría      | Se usa el bus de mensajes para volúmenes que corresponden a un flujo      | Usa el flujo para gran volumen, con captura automática a almacenamiento para el histórico.                                          |

## ■ Seguridad, ética y costo

Trabaja con cuentas propias o sandboxes autorizados. No publiques secretos, identificadores reales ni datos personales. Antes de crear recursos pagos define presupuesto, etiquetas y comando de destrucción; después verifica que no queden recursos huérfanos. Los ejemplos locales enseñan contratos, pero no certifican cumplimiento ni disponibilidad de producción.

## ■ Preguntas de comprobación

1. ¿Qué garantiza el bus que no garantiza el enrutador de eventos?
2. ¿Qué relación deben cumplir prebúsqueda, tiempo de proceso y duración del bloqueo?
3. ¿Por qué la detección de duplicados no sustituye a la idempotencia?
4. ¿Cuándo se debe guardar la posición del lector de un flujo y por qué?
5. ¿Qué ocurre con un mensaje venenoso en un flujo y qué hay que decidir?

## Referencias

- Microsoft (2025). Azure Service Bus: message sessions, transactions and dead-letter queues. <<https://learn.microsoft.com/en-us/azure/service-bus-messaging/service-bus-messaging-overview>>
- Microsoft (2025). Azure Event Grid: event delivery and retry. <<https://learn.microsoft.com/en-us/azure/event-grid/delivery-and-retry>>
- Microsoft (2025). Azure Event Hubs: partitions, consumer groups and capture. <<https://learn.microsoft.com/en-us/azure/event-hubs/event-hubs-features>>
- Microsoft (2025). Choose between Azure messaging services. <<https://learn.microsoft.com/en-us/azure/service-bus-messaging/compare-messaging-services>>
- Hohpe, G. y Woolf, B. (2003). Enterprise Integration Patterns. <<https://www.enterpriseintegrationpatterns.com/>>
- Documentación oficial vigente del servicio implementado; registra URL y fecha de consulta.

Descargar: Parte 18 en PDF · Recorrido de Azure en PDF · Manual integral

| Anterior                                                | Índice              | Siguiente                                                      |
|---------------------------------------------------------|---------------------|----------------------------------------------------------------|
| ← 223 · Azure SQL, Cosmos DB y consistencia distribuida | Parte 18 · Programa | 225 · Azure Monitor, Application Insights y OpenTelemetry<br>→ |

## Evaluación — 224 Service Bus, Event Grid y Event Hubs

### Preguntas

1. Explica el problema que resuelve esta capacidad sin mencionar un proveedor.
2. Identifica una frontera de responsabilidad y su propietario.
3. Compara dos alternativas mediante confiabilidad, seguridad, costo y operación.
4. ¿Qué demuestra el laboratorio y qué no puede demostrar?
5. Propón un caso límite o una prueba de fallo.

### Reto verificable

Entrega azure-event-platform con diagrama o configuración, evidencia de ejecución, alternativa descartada, riesgo residual y criterio de rollback.

### Criterio de aceptación

- ☐ Resultado reproducible por una segunda persona.
- ☐ Evidencia vinculada a cada afirmación técnica.
- ☐ Prueba negativa o de fallo incluida.
- ☐ Costos y permisos expresados con unidades y alcance.
- ☐ Limitaciones declaradas sin presentar la simulación como producción.

### Escala

| Nivel             | Evidencia                                                |
|-------------------|----------------------------------------------------------|
| A — competente    | Cumple todo y defiende trade-offs con datos.             |
| B — en desarrollo | Cumple lo esencial; falta profundidad en una dimensión.  |
| C — inicial       | Artefacto parcial o conclusión sin evidencia suficiente. |
| 0                 | Sin entrega reproducible.                                |

# 225 — Azure Monitor, Application Insights y OpenTelemetry

Parte: 18 — Azure: arquitectura empresarial y operación en producción Nivel: avanzado · Horas estimadas: 4  
Laboratorio: observability · Estado: EXECUTABLECORE

## Propósito

Montar la observabilidad de Azure con instrumentación estándar, de forma que no haya que rehacerla al cambiar de nube ni de proveedor de análisis. La clase cubre el destino único de registros y métricas, el muestreo que decide el coste, y los dos asuntos que este programa lleva señalando y que aquí tienen forma propia: la ingesta sin límite factura más que el cómputo, y la instrumentación específica de un proveedor se convierte en un cambio caro el día que se quiere mover.

## Resultados de aprendizaje

Al finalizar podrás:

1. Enrutar registros y métricas de todos los recursos a un destino común.
2. Instrumentar con el estándar abierto para no quedar atado.
3. Controlar el coste con muestreo, niveles y planes de tabla.
4. Definir alertas y objetivos junto al servicio, como código.
5. Correlacionar desde la alerta hasta la causa sin eslabones rotos.

## Conceptos centrales


| Concepto                     | Comprensión verificable                                                                                  |
|------------------------------|----------------------------------------------------------------------------------------------------------|
| área de trabajo              | Destino de registros y métricas, con su retención, sus permisos y su facturación.                        |
| configuración de diagnóstico | Ajuste por recurso que decide qué categorías se envían y a dónde. Sin ella, el recurso no registra nada. |
| muestreo adaptativo          | Reducción automática del volumen enviado, con factor registrado para poder extrapolar.                   |
| instrumentación estándar     | Emisión de trazas, métricas y registros con el estándar abierto, independiente del destino.              |
| plan de tabla                | Nivel de una tabla de registros: analítico, básico o de archivo. Cambia precio y capacidad de consulta.  |
| regla de recopilación        | Definición de qué datos se recogen de qué recursos y con qué transformación antes de almacenarlos.       |

## Modelo mental

La arquitectura Azure nace del tenant y las políticas heredables, y llega al workload mediante identidades administradas y redes privadas.

Aplicado a esta clase, separa siempre cuatro planos: intención (qué necesita el usuario), configuración (qué declaramos), estado observado (qué existe de verdad) y evidencia (cómo sabemos que cumple). Confundirlos produce diseños que se ven correctos en un diagrama pero fallan al operar.

## ■ Flujo de razonamiento



## Desarrollo

### 1. Un destino, y la configuración que casi nadie pone

En Azure, un recurso no envía nada por defecto. La configuración de diagnóstico es lo que enruta sus registros y métricas, y si falta, ese recurso es invisible.

LO QUE HAY QUE DECIDIR POR RECURSO  
 qué categorías de registro se envían  
 si se envían métricas  
 y a qué destino: área de trabajo, almacenamiento, flujo

Y LO QUE PASA SI FALTA  
 el recurso funciona  
 no aparece en ninguna consulta  
 y cuando hay un incidente, no hay datos de las horas anteriores  
 ley 13

Y por eso se resuelve con política, no con disciplina:

política de tipo «desplegar si no existe» que crea la configuración de diagnóstico en cada recurso nuevo  
 clase 217  
 → y con la estimación de coste hecha ANTES de asignarla  
 → y con las categorías elegidas, no todas

El destino, con la decisión de cuántas áreas de trabajo:

UNA POR ENTORNO, no una por suscripción  
 → correlacionar entre servicios exige que estén juntos  
 → y las consultas cruzadas entre áreas son más lentas y más incómodas

Y LOS PERMISOS SE RESUELVEN APARTE  
 quien no debe ver los registros de otro equipo se controla con permisos por tabla o por recurso  
 → no separando áreas  
 clase 218

EXCEPCIONES RAZONABLES  
 registros de auditoría y de seguridad, en un área aparte, en una suscripción donde el comprometido no pueda borrarlos  
 clases 141, 226

Y los planes de tabla, que son la palanca de coste más directa:

|           |                                                                                                                                       |
|-----------|---------------------------------------------------------------------------------------------------------------------------------------|
| ANALÍTICO | consulta completa, alertas, retención larga<br>el más caro por gigabyte                                                               |
| BÁSICO    | consulta limitada, sin alertas, retención corta<br>mucho más barato<br>→ para registros voluminosos que solo se miran al diagnosticar |
| ARCHIVO   | almacenamiento barato, restauración bajo demanda<br>→ para lo que hay que conservar por norma                                         |

- poner en básico las tablas de registros voluminosos de aplicación suele reducir la factura a la mitad
- y hay que comprobar antes que no se necesitan alertas sobre ellas

## 2. Instrumentar con el estándar abierto

Aquí hay una decisión de arquitectura que se toma sin pensarla y se paga años después.

### INSTRUMENTACIÓN ESPECÍFICA DEL PROVEEDOR

- la biblioteca del proveedor, con su API
- + integración inmediata y algunas funciones extra
- el código queda atado: cambiar de destino exige tocar todas las aplicaciones clase 158

### INSTRUMENTACIÓN ESTÁNDAR (OpenTelemetry)

- API y formato comunes; el destino es configuración
- + cambiar de proveedor de análisis es un cambio de exportador, no de código
- + la misma instrumentación vale en las tres nubes
- algunas funciones del proveedor no están cubiertas

- y esta es la decisión: el código emite en estándar y el destino se configura
- el coste de cambiarla más adelante es alto: toca todas las aplicaciones ley 14

Y lo que hay que emitir, con la disciplina de la clase 211:

### TRAZAS con contexto propagado

- incluidas las llamadas asíncronas: el contexto viaja DENTRO del mensaje clase 224
- sin eso, la traza se corta en la primera cola

### MÉTRICAS

- las cuatro señales y las de negocio
- con dimensiones de baja cardinalidad clase 211
- el identificador de pedido va al registro, no a una dimensión

### REGISTROS estructurados

- con traza, servicio, versión, entorno y duración
- y sin secretos ni datos personales completos

Y el detalle que decide la utilidad del conjunto:

### EL MISMO IDENTIFICADOR DE TRAZA en las tres señales

- así se salta de una métrica a las trazas del periodo, y de una traza a sus registros
- si cada capa usa su propio identificador, la cadena se rompe clase 211

El muestreo, que es lo que hace viable el coste:

### MUESTREO ADAPTATIVO

- el agente reduce el volumen según la carga y registra el FACTOR aplicado
- los recuentos se pueden extrapolar
- y por eso hay que usar las funciones que lo tienen en cuenta al contar

### QUÉ SE MUESTREA Y QUÉ NO

- peticiones correctas 1-5 %
- errores 100 %, siempre
- peticiones lentas 100 %
- y todo lo de un usuario concreto, activable para diagnosticar

### EL ERROR HABITUAL

- muestrear y luego contar sin tener en cuenta el factor
- los paneles muestran cifras que no son

## 3. Alertas y objetivos, como código

La disciplina es la de la clase 211, con las piezas de esta nube.

LO QUE SE DECLARA JUNTO AL SERVICIO  
configuración de diagnóstico  
reglas de recopilación  
consultas guardadas de diagnóstico  
panel del servicio  
objetivo de nivel de servicio  
reglas de alerta con su grupo de acción

→ y una función de aptitud: ningún servicio se despliega sin ellas  
clase 190

Los tipos de alerta, con el uso de cada uno:

|                        |                                                                                                             |
|------------------------|-------------------------------------------------------------------------------------------------------------|
| POR MÉTRICA            | rápida y barata; para señales continuas                                                                     |
| POR CONSULTA           | flexible; para lo que exige agregar o correlacionar<br>→ con coste por ejecución: cuidado con la frecuencia |
| POR ACTIVIDAD          | cambios en recursos, políticas y permisos<br>→ «alguien quitó una asignación de política»<br>clase 217      |
| POR SALUD DEL SERVICIO | incidencias del propio proveedor<br>→ y esta la olvida casi todo el mundo                                   |

Y las que este programa exige siempre:

ALERTA POR AUSENCIA  
«esta función no se ha ejecutado en N minutos»  
→ un trabajo programado que deja de dispararse no genera error  
ley 13

ALERTA POR ANTIGÜEDAD  
cola de fallidos, certificados, sincronización  
clases 224, 196, 222

Y POR RITMO DE CONSUMO DEL PRESUPUESTO DE ERROR  
→ la que despierta, en vez del error suelto  
clase 211

Y el destino, con la lección repetida:

un grupo de acción por turno de guardia, no uno por servicio  
→ crear un grupo por equipo garantiza que alguno quede sin destinatarios  
ley 15, clases 210, 211

y la comprobación  
provocar la condición y ver si llega  
ley 22  
→ en la clase 211, 7 de 40 no llegaron a la primera

Y una nota sobre el coste de las alertas por consulta:

una alerta por consulta que se ejecuta cada minuto sobre mucho volumen factura  
→ frecuencia acorde a lo que se detecta  
→ y una alerta que nunca se ha disparado en un año, o sobra o su umbral está mal  
clase 190

#### 4. Consultar, correlacionar y controlar el gasto

Las consultas preparadas, que ahorran minutos durante un incidente:

«dame todo lo de esta traza, en las tres señales»  
«errores de este servicio en la última hora, por tipo»  
«peticiones más lentas y qué dependencia domina»  
«qué cambió en los recursos en la última hora»  
«compara esta hora con la misma de ayer»

→ guardadas y enlazadas desde el procedimiento de la alerta  
clase 127

La cadena de diagnóstico, con sus eslabones:

alerta por objetivo  
→ panel del servicio  
→ trazas del periodo

- registros de esas trazas
- registro de actividad: ¿qué se desplegó o cambió?  
clase 122

→ y si un eslabón falta, el diagnóstico se hace a ojo

El control del gasto, que aquí tiene palancas concretas:

- 1 CATEGORÍAS ELEGIDAS, no todas  
muchas categorías de diagnóstico son voluminosas y  
nadie las consulta
- 2 TRANSFORMACIÓN EN LA RECOPIACIÓN  
filtrar y recortar antes de almacenar  
→ quitar campos que no se usan, descartar líneas de  
nivel bajo  
→ es lo que más reduce sin perder capacidad de  
diagnóstico
- 3 PLAN DE TABLA por volumen y uso
- 4 RETENCIÓN por tabla, no global  
→ los registros de auditoría, largos; los de aplicación,  
cortos  
clase 141
- 5 MUESTREO en la aplicación
- 6 Y COMPROMISO DE CAPACIDAD si el volumen es estable  
→ descuento por gigabyte comprometido

Y la comprobación honesta:

- ¿cuánto cuesta la observabilidad frente al cómputo?
- en la clase 211 costaba el doble
- y en la 214 era el 11 % de la factura total
- conviene mirarlo cada trimestre, no una vez  
clase 214

Y la lista de comprobación de la clase:

- hay política que crea la configuración de diagnóstico en  
cada recurso
- las categorías están elegidas, no todas
- hay un área de trabajo por entorno, no por suscripción
- los registros de auditoría van a un área separada e  
inalcanzable desde producción
- la instrumentación de las aplicaciones es estándar
- el contexto de traza viaja dentro de los mensajes
- las dimensiones no tienen cardinalidad alta
- el muestreo registra el factor y las consultas lo tienen  
en cuenta
- los errores y las peticiones lentas no se muestrean
- paneles, objetivos y alertas están en la plantilla del  
servicio
- hay alertas por ausencia, por antigüedad y por ritmo de  
consumo
- hay alerta de salud del servicio del proveedor
- el destino es un grupo de acción con guardia
- cada alerta se ha probado provocando la condición
- hay transformación en la recopilación y planes de tabla  
por volumen
- el coste de observabilidad se revisa cada trimestre

Y el cierre que enlaza con la clase siguiente: con la observabilidad en pie, queda la parte que mira lo mismo con otra intención: detectar lo que no debería estar pasando. Postura de seguridad, cumplimiento y detección es la materia de la clase 226.

## Ejemplo trabajado

CloudShop monta la observabilidad de su plataforma en Azure. Lo que sigue son los recursos que no registraban nada, la factura de ingesta que superaba al cómputo, y la decisión de instrumentación que evitó un cambio de meses dos años después.

El punto de partida:

|                                                                             |         |       |
|-----------------------------------------------------------------------------|---------|-------|
| recursos                                                                    | 14.200  |       |
| con configuración de diagnóstico                                            | 940     | 6,6 % |
| sin ella                                                                    | 13.260  |       |
| áreas de trabajo                                                            | 31      |       |
| una por suscripción, creadas al azar                                        |         |       |
| → correlacionar entre servicios exigía consultas cruzadas entre 4 o 5 áreas |         |       |
| instrumentación de aplicaciones                                             |         |       |
| con la biblioteca específica del proveedor                                  | 14      |       |
| con estándar abierto                                                        | 0       |       |
| coste mensual de observabilidad                                             | 6.900 € |       |
| ingesta                                                                     | 4.400 € |       |
| retención                                                                   | 1.800 € |       |
| alertas por consulta                                                        | 700 €   |       |

Y lo que reveló el primer incidente serio:

un fallo del cortafuegos del centro dejó sin conectividad a 9 radios durante 40 minutos

al investigar  
  el cortafuegos NO tenía configuración de diagnóstico  
  → no había ni un registro de las horas anteriores  
  → la causa se dedujo por descarte, en 3 horas

y los 13.260 recursos sin diagnóstico incluían  
  el cortafuegos central  
  4 de las 6 pasarelas  
  todas las cuentas de almacenamiento  
  y las 43 redes virtuales

Las correcciones estructurales:

POLÍTICA que crea la configuración de diagnóstico en cada recurso nuevo y remedia los existentes      clase 217

y la estimación previa del coste  
  si se enviaban TODAS las categorías      ~9.400 €/mes  
  con categorías elegidas      ~1.900 €/mes

categorías elegidas  
  cortafuegos      reglas aplicadas, DNS, amenazas  
                      → no: estadísticas detalladas por flujo  
  almacenamiento      operaciones de escritura y borrado  
                      → no: cada lectura  
  redes      registros de flujo, ya existentes  
  bases      auditoría, consultas lentas  
                      → no: cada consulta

ÁREAS DE TRABAJO  
  31 → 3 (producción, preproducción, desarrollo)  
  + 1 de auditoría y seguridad, en la suscripción de seguridad, sin acceso desde producción      clase 141  
  permisos por tabla para separar lo que cada equipo ve

La instrumentación: la decisión que se registró.

el equipo iba a seguir con la biblioteca específica  
  «funciona y es lo que sabemos»

el argumento que cambió la decisión  
  la parte 19 iba a montar lo mismo en otra nube  
  y el equipo de datos ya usaba otro proveedor de análisis para sus cargas  
  → tres destinos distintos, y el código atado a uno

decisión  
  migrar a instrumentación estándar  
  el destino es un exportador configurado, no código  
  coste de la migración      14 aplicaciones,  
  6 semanas

|                      |                                                                                        |
|----------------------|----------------------------------------------------------------------------------------|
| registro de decisión | clase 190                                                                              |
| premisa              | habrá al menos dos destinos de análisis                                                |
| qué la reabrirla     | si el proveedor deja de soportar el estándar, o si su coste sube por encima del propio |

y dos años después

|                                                                  |           |
|------------------------------------------------------------------|-----------|
| se cambió el proveedor de análisis de las cargas de datos        |           |
| cambio necesario en las aplicaciones                             | ninguno   |
| se cambió el exportador y el destino                             |           |
| tiempo                                                           | 2 días    |
| → sin esta decisión, habrían sido meses de tocar 14 aplicaciones | clase 158 |

#### El coste, atacado con las cinco palancas:

|                                            |             |
|--------------------------------------------|-------------|
| ingesta inicial tras aplicar las políticas | 1.900 €/mes |
|--------------------------------------------|-------------|

- 1 TRANSFORMACIÓN EN LA RECOPILOACIÓN
  - los registros de aplicación traían 41 campos; se consultaban 9
  - se descartan las líneas de nivel de información de 3 servicios muy habladores
  - 1.900 € → 1.140 €
- 2 PLANES DE TABLA
  - registros de flujo de red y de contenedores → básico
  - no se necesitaban alertas sobre ellos, comprobado
  - 1.140 € → 640 €
- 3 RETENCIÓN POR TABLA
 

|              |                              |
|--------------|------------------------------|
| aplicación   | 30 días                      |
| flujo de red | 14 días                      |
| auditoría    | 400 días, en archivo tras 90 |
| retención    | 1.800 € → 410 €              |
- 4 MUESTREO EN LA APLICACIÓN
  - peticiones correctas al 4 %, errores y lentas al 100 %
  - y las consultas ajustadas para tener en cuenta el factor
  - aquí hubo un susto: durante dos semanas, el panel de pedidos por minuto mostró cifras 25 veces menores
  - porque la consulta contaba filas sin aplicar el factor de muestreo
- 5 ALERTAS POR CONSULTA
  - 41 alertas por consulta, 12 de ellas cada minuto
  - se bajó la frecuencia de las que detectan cosas lentas
  - 700 € → 210 €

|       |                       |
|-------|-----------------------|
| total | 6.900 € → 1.260 €/mes |
|-------|-----------------------|

#### Las alertas, revisadas:

|                                                                          |          |
|--------------------------------------------------------------------------|----------|
| antes                                                                    | 112      |
| disparadas al mes                                                        | 890      |
| accionables                                                              | 71 (8 %) |
| con destino a grupos de acción por equipo                                | 63       |
| de ellos, SIN destinatarios                                              | 14       |
| después                                                                  | 58       |
| por objetivo de nivel de servicio                                        | 9        |
| por ausencia                                                             | 11       |
| · funciones y trabajos programados                                       |          |
| por antigüedad                                                           | 8        |
| · colas de fallidos, certificados, sincronización                        |          |
| por actividad                                                            | 6        |
| · cambios de política, de permisos, de rutas                             |          |
| por salud del servicio del proveedor                                     | 1        |
| → esta detectó 2 incidencias del proveedor antes de que nadie las notara |          |
| el resto, técnicas                                                       | 23       |

|                   |                              |           |
|-------------------|------------------------------|-----------|
| destino           | un grupo de acción por turno |           |
| disparadas al mes |                              | 74        |
| accionables       |                              | 68 (92 %) |

y la prueba de extremo a extremo  
 58 alertas, condición provocada una a una  
 no llegaron 6  
 3 por umbral mal puesto  
 2 por destino equivocado  
 1 porque la consulta tenía un error de sintaxis y la  
 regla estaba en estado de error desde su creación  
 ley 22

La cadena de diagnóstico, comprobada:

```
02:41 alerta: el objetivo de confirmación de pedido
       consume presupuesto de error 11x más rápido
02:41 el mensaje enlaza el panel del servicio
02:42 el panel muestra el p99 disparado desde las 02:33
02:42 registro de actividad: cambio en una regla del
       cortafuegos a las 02:31 clase 122
02:43 trazas del periodo: el tramo lento es la llamada al
       servicio de precios
02:44 registros de esas trazas: tiempo de espera agotado
       al conectar
02:46 se revierte el cambio del cortafuegos
02:51 restablecido
```

|                                   |       |
|-----------------------------------|-------|
| tiempo hasta identificar la causa | 3 min |
|-----------------------------------|-------|

El resultado:

|                                           |            |           |
|-------------------------------------------|------------|-----------|
| recursos con diagnóstico                  | 6,6 %      | 99,1 %    |
| áreas de trabajo                          | 31         | 4         |
| coste de observabilidad                   | 6.900 €    | 1.260 €   |
| alertas configuradas                      | 112        | 58        |
| accionables                               | 71 (8 %)   | 68 (92 %) |
| alertas sin destinatarios                 | 14         | 0         |
| instrumentación estándar                  | 0/14       | 14/14     |
| tiempo de cambio de proveedor de análisis | meses      | 2 días    |
| tiempo medio hasta identificar causa      | 3 h (est.) | 3 min     |

La lección que esta clase deja: el 93 % de los recursos no registraba nada, incluido el cortafuegos central, y eso se descubrió en un incidente en el que no había datos de las horas anteriores. La factura de observabilidad superaba a la de cómputo y se redujo un 82 % sin perder capacidad de diagnóstico, con cinco palancas de configuración. Y la decisión que más valió no dio ningún beneficio el primer año: instrumentar con el estándar abierto, que dos años después convirtió un cambio de proveedor de meses en dos días.

## Laboratorio guiado

Ejecuta desde la raíz:

```
python classes/part-18-azure-production-architecture/225-azure-monitor-application-insights-y-opentelemetry/lab.py
```

El laboratorio selecciona el motor de práctica observability y produce labresult.json. El escenario, sus comprobaciones y el artefacto esperado corresponden a esta clase; no requiere credenciales y deja explícito qué debe revalidarse en un sandbox real.

1. Lee exercise.steps y formula una predicción antes de ejecutar.
2. Ejecuta la práctica y verifica todos los elementos de checks.
3. Provoca el caso de negativetest y explica la señal observada.
4. Materializa azure-observability en evidence/ usando la plantilla indicada.
5. Para proveedor real, sigue sandbox.requires, registra costo y ejecuta destroy.

## Evidencia esperada

El artefacto principal es telemetría correlacionada con una pregunta operativa. Además, la entrega debe incluir el comando ejecutado, la salida estructurada y una conclusión que no exceda lo observado.

## Reto verificable

Construye azure-observability para el caso CloudShop. Incluye una alternativa descartada, un supuesto que pueda falsarse, una prueba de fallo y una decisión de rollback.

### ■ Criterio de aceptación

- [ ] lab.py termina con código 0 y genera JSON válido.
- [ ] La entrega conecta al menos tres requisitos con mecanismos verificables.
- [ ] Existe una prueba positiva y una prueba negativa con evidencia.
- [ ] Seguridad, costo y operación aparecen como decisiones, no como anexos.
- [ ] Se declara una limitación y una condición que obligaría a revisar el diseño.
- [ ] Otra persona puede repetir el recorrido sin conocimiento tácito.

### ■ Errores frecuentes

| Síntoma                                                                   | Causa probable                                                                    | Corrección                                                                                                                      |
|---------------------------------------------------------------------------|-----------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------|
| Un recurso no aparece en ninguna consulta durante un incidente            | No tiene configuración de diagnóstico y por defecto no envía nada                 | Crea la configuración con una política que la despliegue en todo recurso nuevo, con categorías elegidas y coste estimado antes. |
| Correlacionar entre servicios exige consultas cruzadas entre muchas áreas | Se creó un área de trabajo por suscripción                                        | Una por entorno, con permisos por tabla para separar lo que cada equipo ve, y una aparte para auditoría.                        |
| Cambiar de proveedor de análisis obligaría a tocar todas las aplicaciones | Se instrumentó con la biblioteca específica del proveedor                         | Emite con el estándar abierto y deja el destino como configuración; el coste de cambiarlo después es alto.                      |
| Los paneles muestran cifras muy inferiores a la realidad                  | Hay muestreo y las consultas cuentan filas sin aplicar el factor                  | Usa las funciones que tienen en cuenta el factor de muestreo y comprueba los recuentos contra una fuente independiente.         |
| La factura de observabilidad supera a la de cómputo                       | Todas las categorías, sin transformación, en plan analítico y con retención larga | Elige categorías, transforma en la recopilación, usa planes de tabla por volumen y fija retención por tabla.                    |
| Una alerta nunca ha llegado a nadie                                       | Su grupo de acción no tiene destinatarios o la regla está en estado de error      | Un grupo de acción por turno de guardia y prueba de extremo a extremo provocando la condición de cada alerta.                   |

### ■ Seguridad, ética y costo

Trabaja con cuentas propias o sandboxes autorizados. No publiques secretos, identificadores reales ni datos personales. Antes de crear recursos pagos define presupuesto, etiquetas y comando de destrucción; después verifica que no queden recursos huérfanos. Los ejemplos locales enseñan contratos, pero no certifican cumplimiento ni disponibilidad de producción.

### ■ Preguntas de comprobación

1. ¿Qué ocurre con un recurso que no tiene configuración de diagnóstico?
2. ¿Por qué conviene un área de trabajo por entorno y no por suscripción?
3. ¿Qué se gana instrumentando con el estándar abierto y cuándo se cobra esa ganancia?
4. ¿Qué error de consulta produce el muestreo si no se tiene en cuenta?

5. ¿Cuáles son las cinco palancas para reducir el coste de ingesta?

## Referencias

- Microsoft (2025). Azure Monitor: diagnostic settings.  
<<https://learn.microsoft.com/en-us/azure/azure-monitor/essentials/diagnostic-settings>>
- Microsoft (2025). Application Insights with OpenTelemetry.  
<<https://learn.microsoft.com/en-us/azure/azure-monitor/app/opentelemetry-enable>>
- Microsoft (2025). Log Analytics table plans and data transformations.  
<<https://learn.microsoft.com/en-us/azure/azure-monitor/logs/data-platform-logs>>
- Microsoft (2025). Sampling in Application Insights.  
<<https://learn.microsoft.com/en-us/azure/azure-monitor/app/sampling>>
- OpenTelemetry (2025). Specification and semantic conventions. <<https://opentelemetry.io/docs/specs/otel/>>
- Documentación oficial vigente del servicio implementado; registra URL y fecha de consulta.

Descargar: Parte 18 en PDF · Recorrido de Azure en PDF · Manual integral

| Anterior                                     | Índice              | Siguiente                                     |
|----------------------------------------------|---------------------|-----------------------------------------------|
| ← 224 · Service Bus, Event Grid y Event Hubs | Parte 18 · Programa | 226 · Defender for Cloud, Policy y Sentinel → |

## Evaluación — 225 Azure Monitor, Application Insights y OpenTelemetry

### Preguntas

1. Explica el problema que resuelve esta capacidad sin mencionar un proveedor.
2. Identifica una frontera de responsabilidad y su propietario.
3. Compara dos alternativas mediante confiabilidad, seguridad, costo y operación.
4. ¿Qué demuestra el laboratorio y qué no puede demostrar?
5. Propón un caso límite o una prueba de fallo.

### Reto verificable

Entrega azure-observability con diagrama o configuración, evidencia de ejecución, alternativa descartada, riesgo residual y criterio de rollback.

### Criterio de aceptación

- [ ] Resultado reproducible por una segunda persona.
- [ ] Evidencia vinculada a cada afirmación técnica.
- [ ] Prueba negativa o de fallo incluida.
- [ ] Costos y permisos expresados con unidades y alcance.
- [ ] Limitaciones declaradas sin presentar la simulación como producción.

## Escala

| Nivel             | Evidencia                                                |
|-------------------|----------------------------------------------------------|
| A — competente    | Cumple todo y defiende trade-offs con datos.             |
| B — en desarrollo | Cumple lo esencial; falta profundidad en una dimensión.  |
| C — inicial       | Artefacto parcial o conclusión sin evidencia suficiente. |
| 0                 | Sin entrega reproducible.                                |

## 226 — Defender for Cloud, Policy y Sentinel

Parte: 18 — Azure: arquitectura empresarial y operación en producción Nivel: avanzado · Horas estimadas: 4  
Laboratorio: security · Estado: EXECUTABLECORE

### Propósito

Montar la seguridad operativa de Azure: la evaluación continua de la postura, el cumplimiento medido contra un marco, y la detección con su parte incómoda. La clase separa lo que cada herramienta hace de verdad, ordena las recomendaciones por alcance en vez de por su puntuación, y desarrolla el asunto que decide si un centro de operaciones funciona: una detección que nadie ha comprobado no detecta, y una que genera mil alertas al día no se mira.

### Resultados de aprendizaje

Al finalizar podrás:

1. Distinguir postura, cumplimiento y detección, y qué resuelve cada uno.
2. Priorizar recomendaciones por alcance real, no por la puntuación.
3. Medir el cumplimiento contra un marco sin convertirlo en trámite.
4. Configurar detección con reglas propias y comprobarlas.
5. Controlar el coste de la ingesta de seguridad.

### Conceptos centrales


| Concepto                | Comprensión verificable                                                                           |
|-------------------------|---------------------------------------------------------------------------------------------------|
| postura de seguridad    | Evaluación continua de la configuración frente a buenas prácticas. Dice qué está mal configurado. |
| puntuación de seguridad | Cifra agregada de la postura. Útil como tendencia, engañosa como prioridad.                       |
| cumplimiento normativo  | Medida de la configuración contra un marco concreto, con sus controles.                           |
| detección               | Reglas que generan incidentes a partir de señales. Requiere ingesta, reglas y quien las atienda.  |
| simulación de ataque    | Ejecución controlada de una técnica conocida para comprobar si se detecta.                        |
| conector de datos       | Origen de señales que se ingiere para detectar. Cada uno tiene su volumen y su coste.             |

### Modelo mental

La arquitectura Azure nace del tenant y las políticas heredables, y llega al workload mediante identidades administradas y redes privadas.

Aplicado a esta clase, separa siempre cuatro planos: intención (qué necesita el usuario), configuración (qué declaramos), estado observado (qué existe de verdad) y evidencia (cómo sabemos que cumple). Confundirlos produce diseños que se ven correctos en un diagrama pero fallan al operar.

### ■ Flujo de razonamiento



## Desarrollo

### 1. Postura, cumplimiento y detección

Tres cosas distintas que se mezclan y responden preguntas diferentes.

#### POSTURA

¿qué está mal configurado, ahora mismo?  
evaluación continua contra buenas prácticas  
produce recomendaciones  
ejemplo «esta base tiene acceso público»

#### CUMPLIMIENTO

¿cumplimos este marco concreto?  
la misma información, agrupada por controles de una norma  
produce evidencia para auditoría  
ejemplo «el control A.9.4 está cubierto por estas 12 políticas»

#### DETECCIÓN

¿está ocurriendo algo ahora?  
reglas sobre señales que generan incidentes  
produce incidentes que alguien atiende  
ejemplo «esta identidad ha accedido desde dos países en 10 minutos»

Y la relación entre las tres, que ordena el trabajo:

la POSTURA reduce lo que hay que detectar  
→ un almacén sin acceso público no puede ser accedido desde internet  
→ arreglar configuración es más barato que detectar su explotación

el CUMPLIMIENTO no mejora la seguridad por sí mismo  
→ mide y da evidencia; no cierra nada  
→ y perseguir el porcentaje produce trámite ley 17

la DETECCIÓN cubre lo que la configuración no puede  
→ uso legítimo de credenciales robadas, abuso de permisos concedidos, comportamiento anómalo

La puntuación de seguridad, con su trampa:

es una cifra agregada y ponderada  
+ útil como TENDENCIA: si baja, algo se ha degradado  
- engañosa como prioridad: la recomendación que más sube la puntuación no es la que más riesgo reduce

ejemplo típico

«activar cifrado en 400 discos de desarrollo»  
+6 puntos, riesgo bajo  
«una identidad con Propietario en producción»  
+0,2 puntos, riesgo máximo clase 218

→ ordena por ALCANCE desde el punto comprometido, no por

## 2. Postura: priorizar bien

La herramienta produce cientos de recomendaciones. El trabajo es ordenarlas.

### LAS PREGUNTAS QUE ORDENAN

- 1 ¿está expuesto a internet?
- 2 ¿tiene datos sensibles?
- 3 ¿hasta dónde se llega desde ahí? ← la que decide
- 4 ¿existe ya explotación conocida de esa vulnerabilidad?
- 5 ¿cuántos recursos afecta?

→ y las herramientas modernas calculan CAMINOS DE ATAQUE:  
 «desde esta máquina expuesta se llega, por esta identidad, a esta base con datos de clientes»  
 → eso vale más que cualquier lista ordenada por puntos

Y las categorías de recomendación, con lo que cuesta cada una:

CONFIGURACIÓN (acceso público, cifrado, versión de TLS)  
 → se resuelven con política, en masa clase 217  
 → y lo nuevo se impide con denegación

IDENTIDAD (permisos amplios, sin segundo factor)  
 → las de más alcance y las más difíciles de arreglar  
 clase 218

VULNERABILIDADES (software sin parchear)  
 → parcheo y actualización de imágenes clase 254  
 → y con exploración continua, no solo al construir  
 clase 212

DATOS (almacenes sin clasificar, sin cifrado propio)  
 → hay que saber dónde están los datos sensibles primero

Y el orden de trabajo que funciona:

- 1 cerrar lo expuesto a internet con datos detrás
- 2 reducir el alcance de las identidades más amplias
- 3 impedir por política que lo arreglado vuelva a ocurrir
- 4 remediar el resto por lotes, con tareas automáticas
- 5 y aceptar por escrito lo que no compensa arreglar  
 clase 189

Y una advertencia sobre las exenciones:

una recomendación se puede marcar como exenta  
 → y sin dueño ni fecha, desaparece del radar para siempre  
 ley 25  
 → toda exención con motivo, nombre y caducidad, y un panel  
 de las que vencen clase 217

El cumplimiento, con la disciplina que lo hace útil:

se elige el marco que aplica de verdad, no todos  
 cada control tiene DUEÑO y evidencia  
 lo que la herramienta no puede comprobar se documenta  
 aparte  
 → una parte importante de cualquier marco es  
 organizativa, no técnica

y la medida honesta  
 no «cumplimos el 94 %»  
 sino «de los 114 controles, 71 automatizados y verdes,  
 22 automatizados con excepciones, 21 manuales con  
 evidencia, y estos 3 no los cumplimos, con este plan»

## 3. Detección: lo que cuesta y lo que hay que comprobar

Un centro de operaciones de seguridad tiene tres partes y las tres tienen que existir.

- 1 INGESTA qué señales entran
  - 2 REGLAS qué se considera sospechoso
  - 3 RESPUESTA quién actúa, y cómo
- si falta cualquiera, no hay detección: hay una consola

La ingesta, que decide el coste y el alcance:

CONECTORES HABITUALES, por valor y por volumen  
registros de identidad y de inicio de sesión  
valor ALTO, volumen medio ← el primero, siempre  
registro de actividad de la nube  
valor alto, volumen bajo ← barato y útil  
alertas de la propia herramienta de postura  
valor alto, volumen muy bajo  
registros de dispositivos y puntos finales  
valor alto, volumen alto  
registros de red (flujos, cortafuegos)  
valor medio, volumen MUY alto ← el que dispara la  
factura  
registros de aplicación  
valor variable

→ y la decisión no es «todo»: es qué se ingiere para  
detectar, qué se guarda barato para investigar y qué no  
se guarda clase 225

Y el patrón que resuelve el coste:

lo que alimenta REGLAS → plan analítico  
lo que solo se consulta al  
investigar → plan básico o archivo  
lo que hay que conservar  
por norma → archivo

→ y las reglas de detección sobre datos en plan básico no  
se pueden hacer: por eso hay que decidir antes

Las reglas, con las dos preguntas que deciden si valen:

¿ESTÁ COMPROBADA?  
simular la técnica que dice detectar  
→ en la clase 179, 2 de 6 técnicas simuladas NO se  
detectaban, y las reglas existían ley 22  
→ y en la clase 189, 3 de 14 pruebas fallaron sobre  
controles documentados como implantados

¿ES ACCIONABLE?  
¿qué hace quien la recibe?  
→ si no hay respuesta posible, la regla genera ruido  
→ y el ruido esconde lo real clase 125

Y la calibración, que es trabajo continuo:

una regla nueva se despliega en modo de observación  
se mide cuántas veces se dispararía y sobre qué  
se ajustan las exclusiones legítimas  
→ el escáner de vulnerabilidades propio  
→ la cuenta de la copia de seguridad  
→ los rangos de la sede  
y solo entonces genera incidentes

→ es el mismo orden de las clases 200, 209 y 217

Y la medida de si el centro funciona:

incidentes al día, y proporción que resulta ser algo  
tiempo hasta la primera acción  
y –la que más dice– PROPORCIÓN DE TÉCNICAS SIMULADAS QUE SE  
DETECTAN  
→ esa cifra es la única que mide la detección de verdad

## 4. Respuesta y coste

La respuesta, con la decisión de qué se automatiza:

SE AUTOMATIZA  
enriquecer el incidente: quién es esa identidad, qué  
recursos toca, de dónde viene esa dirección  
aislar un dispositivo comprometido  
revocar sesiones de una identidad  
bloquear una dirección

→ acciones reversibles y de bajo daño si el aviso es falso

#### NO SE AUTOMATIZA

apagar producción  
borrar recursos  
bloquear cuentas de administración  
→ un falso positivo con esas acciones es un incidente peor que el que se intentaba evitar

#### Y EN CUALQUIER CASO

toda acción automática deja registro y es reversible  
y hay una forma de desactivar la automatización rápidamente clase 259

Y el procedimiento, con lo que este programa exige:

cada regla con procedimiento enlazado clase 125  
probado por alguien que no lo escribió ley 22  
y con el paso de contención al principio, no al final clase 216

El coste, que en seguridad se dispara con facilidad:

#### LAS DOS PARTIDAS

planes de protección por recurso: por servidor, por base, por almacén  
ingesta y retención de las señales

#### Y LAS DECISIONES

activar la protección donde hay datos o exposición, no en todo  
ingerir para detectar solo lo que alimenta reglas  
el resto, en plan barato para investigar  
y compromiso de capacidad si el volumen es estable

→ y hay que revisarlo cada trimestre, como el resto clase 214

Y una comprobación honesta que conviene hacer:

¿cuántos incidentes reales ha detectado este centro en el último año?  
¿y cuántos se detectaron por otra vía –un usuario, una factura, un socio–?  
→ la segunda cifra dice qué no cubre la detección  
→ en la clase 200, la exfiltración de 14 meses la encontró un inventario, no una alerta

Y la lista de comprobación de la clase:

- las recomendaciones se ordenan por alcance, no por puntuación
- se usan los caminos de ataque para priorizar
- lo arreglado se impide por política para que no vuelva
- toda exención tiene motivo, dueño y caducidad
- el marco de cumplimiento elegido es el que aplica
- cada control tiene dueño y evidencia
- lo manual está documentado aparte, sin inflar el porcentaje
- los conectores se eligieron por valor y volumen
- lo que alimenta reglas está en plan analítico
- las reglas se calibraron en modo observación antes
- cada regla tiene procedimiento enlazado
- se simulan técnicas periódicamente y se mide qué proporción se detecta
- las acciones automáticas son reversibles y registradas
- hay forma rápida de desactivar la automatización
- se mide cuántos incidentes se detectaron por otra vía
- el coste de protección e ingesta se revisa cada trimestre

Y el cierre que enlaza con la clase siguiente: con seguridad, observabilidad y datos en pie, quedan el coste y la resiliencia, que en esta nube tienen herramientas propias y una para provocar fallos de forma controlada. Es la materia de la clase 227.

## Ejemplo trabajado

CloudShop monta la seguridad operativa de Azure. Lo que sigue son las recomendaciones ordenadas por alcance en vez de por puntos, la simulación que reveló que la mitad de las técnicas no se detectaban, y la factura que hubo que recortar.

La postura, al empezar:

|                          |       |
|--------------------------|-------|
| recomendaciones abiertas | 1.847 |
| puntuación de seguridad  | 47 %  |

ordenadas por PUNTOS, las cinco primeras

|   |                                        |          |
|---|----------------------------------------|----------|
| 1 | cifrado en discos de máquinas          | +7,2 pts |
|   | 412 recursos, casi todos de desarrollo |          |
| 2 | copias de seguridad habilitadas        | +6,1 pts |
| 3 | versión de TLS mínima                  | +5,4 pts |
| 4 | agente de supervisión instalado        | +4,8 pts |
| 5 | cifrado en tránsito en almacenes       | +4,1 pts |

ordenadas por ALCANCE, las cinco primeras

|   |                                                                                                                          |           |
|---|--------------------------------------------------------------------------------------------------------------------------|-----------|
| 1 | una máquina expuesta a internet con puerto de administración abierto, y desde su identidad se alcanza la base de pedidos |           |
| 2 | 3 identidades con Propietario en producción                                                                              | clase 218 |
| 3 | 2 cuentas de almacenamiento públicas con datos de clientes                                                               |           |
| 4 | una base de datos con acceso público y contraseña de administrador antigua                                               |           |
| 5 | una identidad de canalización que puede asignar papeles                                                                  |           |

→ ninguna de las cinco de alcance estaba entre las 40 primeras por puntos

Y el camino de ataque que la herramienta calculó:

internet

- máquina de salto con puerto de administración abierto
- su identidad administrada tiene Colaborador en la suscripción
- alcanza la base de pedidos y el almacén de copias
- 2,3 M de registros de clientes

|                                |         |
|--------------------------------|---------|
| pasos                          | 4       |
| recursos comprometibles        | 11.400  |
| tiempo estimado de explotación | minutos |

→ ese único camino concentraba más riesgo que las 1.800 recomendaciones restantes juntas

El orden de trabajo que se siguió:

|             |                                                                                  |           |
|-------------|----------------------------------------------------------------------------------|-----------|
| semana 1    | los 5 caminos de ataque: cerrados                                                |           |
|             | puerto de administración cerrado; acceso por servicio de administración temporal | clase 256 |
|             | identidades reducidas de ámbito                                                  | clase 218 |
|             | almacenes públicos cerrados                                                      |           |
| semana 2    | políticas de denegación para que no vuelvan                                      | clase 217 |
| semanas 3-9 | remediación por lotes del resto                                                  |           |
|             | tareas automáticas para lo que se puede                                          |           |
| semana 10   | exenciones escritas para lo que no compensa                                      |           |
|             | 41 exenciones, todas con motivo, dueño y fecha                                   |           |

|                                      |             |
|--------------------------------------|-------------|
| puntuación de seguridad              | 47 % → 81 % |
| recomendaciones abiertas             | 1.847 → 214 |
| caminos de ataque con datos al final | 5 → 0       |

Y la observación:

la puntuación subió 34 puntos  
y los 34 puntos NO son la medida de lo que mejoró  
→ lo que mejoró fue cerrar 5 caminos, que valían 0,9 puntos

## El cumplimiento, medido con honestidad:

marco elegido el que exige el contrato con el mayor cliente empresarial; no se activaron los otros cuatro que ofrecía la herramienta

|                                                                  |     |
|------------------------------------------------------------------|-----|
| resultado presentado a auditoría                                 |     |
| controles del marco                                              | 114 |
| automatizados y conformes                                        | 71  |
| automatizados con excepciones documentadas                       | 22  |
| manuales, con evidencia adjunta                                  | 18  |
| NO cumplidos                                                     | 3   |
| · rotación de claves de cifrado propias                          |     |
| · segregación de funciones en dos procesos                       |     |
| · registro de acceso físico (fuera de alcance: es del proveedor) |     |

y un plan con fecha para los 3

→ lo que la herramienta mostraba como «94 % conforme» ocultaba que 18 controles eran manuales y que 3 no se cumplían

## La detección: la simulación que dolió.

se montaron 61 reglas de detección  
la mayoría, plantillas del proveedor

|                                               |             |
|-----------------------------------------------|-------------|
| la simulación, con 14 técnicas conocidas      |             |
| técnica                                       | ¿detectada? |
| fuerza bruta contra identidad                 | sí          |
| inicio de sesión desde país inhabitual        | sí          |
| creación de identidad con permisos altos      | sí          |
| exfiltración a almacén externo                | NO ←        |
| desactivación de registro de auditoría        | sí          |
| acceso a secretos desde identidad inusual     | NO ←        |
| enumeración de recursos                       | NO ←        |
| uso de credencial de emergencia               | sí          |
| movimiento lateral por identidad administrada | NO ←        |
| borrado masivo de recursos                    | sí          |
| cambio de política de seguridad               | sí          |
| consultas de nombres anómalas                 | NO ←        |
| ejecución en contenedor con privilegios       | NO ←        |
| persistencia por credencial federada nueva    | NO ←        |
| detectadas                                    | 7 de 14     |

## Y el análisis de las siete que no:

- 3 la regla existía y no se disparaba
  - umbral demasiado alto (enumeración: exigía 500 llamadas en 1 min; el ataque hizo 80 en 10 min)
  - consulta con un error de campo
  - regla en estado deshabilitado desde su creación
- 3 no había regla
  - movimiento lateral por identidad administrada
  - persistencia por credencial federada nueva
  - ejecución en contenedor con privilegios
- 1 la señal NO SE INGERÍA
  - consultas de nombres: el conector estaba desactivado por coste  
clase 200

## Y las correcciones:

umbrales ajustados con datos reales  
reglas escritas para las 3 técnicas sin cobertura  
conector de nombres activado, con plan básico para el volumen y regla sobre un resumen agregado  
→ coste 340 €/mes en vez de 2.100 €  
y simulación trimestral, con la cifra publicada  
segunda simulación, 3 meses después 13 de 14

```

class 200

```

|                                   |     |
|-----------------------------------|-----|
| al activar las 61 reglas de golpe |     |
| incidentes el primer día          | 890 |
| reales                            | 2   |

```

modo observación durante 3 semanas
exclusiones legítimas
  · el escáner de vulnerabilidades propio
  · la cuenta de copias, que accede a todo por diseño
  · los rangos de las 11 oficinas
  · una integración de un socio
reglas retiradas por no accionables

```

|                                |         |
|--------------------------------|---------|
| incidentes al día              | 890 → 6 |
| que resultan ser algo          | 1,4     |
| tiempo hasta la primera acción | 8 min   |

[illegible]

|                                                      |           |
|------------------------------------------------------|-----------|
| incidentes reales detectados por el centro           | 9         |
| incidentes detectados por OTRA vía                   | 4         |
| · una factura anómala (una prueba de carga olvidada) |           |
| · un socio que avisó de un correo sospechoso         |           |
| · un inventario de destinos de salida                | clase 200 |
| · un usuario que reportó un comportamiento raro      |           |

La lección que esta clase deja: ordenar por puntuación habría hecho al equipo cifrar cuatrocientos doce discos de desarrollo mientras un camino de cuatro pasos llevaba de internet a dos millones trescientos mil registros de clientes. Y la simulación reveló que siete de catorce técnicas no se detectaban, aunque las reglas existían: tres tenían umbrales o errores, tres no existían y una dependía de una señal que se había desactivado por coste.

1. Lee `exercise.steps` y formula una predicción antes de ejecutar.
2. Ejecuta la práctica y verifica todos los elementos de checks.
3. Provoca el caso de `negativetest` y explica la señal observada.
4. Materializa `azure-security-operations` en `evidence/` usando la plantilla indicada.
5. Para proveedor real, sigue `sandbox.requires`, registra costo y ejecuta `destroy`.

## Evidencia esperada

El artefacto principal es un control con amenaza, mitigación y evidencia. Además, la entrega debe incluir el comando ejecutado, la salida estructurada y una conclusión que no exceda lo observado.

## Reto verificable

Construye azure-security-operations para el caso CloudShop. Incluye una alternativa descartada, un supuesto que pueda falsarse, una prueba de fallo y una decisión de rollback.

### ■ Criterio de aceptación

- [ ] lab.py termina con código 0 y genera JSON válido.
- [ ] La entrega conecta al menos tres requisitos con mecanismos verificables.
- [ ] Existe una prueba positiva y una prueba negativa con evidencia.
- [ ] Seguridad, costo y operación aparecen como decisiones, no como anexos.
- [ ] Se declara una limitación y una condición que obligaría a revisar el diseño.
- [ ] Otra persona puede repetir el recorrido sin conocimiento tácito.

### ■ Errores frecuentes

| Síntoma                                                               | Causa probable                                                                               | Corrección                                                                                                                                |
|-----------------------------------------------------------------------|----------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------|
| El equipo trabaja mucho en seguridad y el riesgo real no baja         | Las recomendaciones se priorizan por la puntuación agregada                                  | Ordena por alcance desde el punto comprometido y usa los caminos de ataque calculados.                                                    |
| Una recomendación resuelta reaparece meses después                    | Se corrigió el recurso pero nada impide crearlo mal otra vez                                 | Tras remediar, impide por política que vuelva a ocurrir.                                                                                  |
| El informe dice que se cumple el 94 % y la auditoría encuentra huecos | El porcentaje incluye controles manuales sin evidencia y oculta los no cumplidos             | Presenta el desglose por tipo de control, con dueño y evidencia, y un plan con fecha para los no cumplidos.                               |
| Las reglas de detección existen y el ataque no se detecta             | Umbral mal puesto, consultas con errores o reglas deshabilitadas                             | Simula técnicas conocidas periódicamente y publica qué proporción se detecta; es la única medida real.                                    |
| El centro genera cientos de incidentes al día y nadie los mira        | Las reglas se activaron sin calibrar ni excluir lo legítimo                                  | Despliega en modo observación, excluye lo conocido, retira lo no accionable y mide la proporción que resulta ser algo.                    |
| La factura de seguridad es enorme                                     | Protección activada en todos los recursos e ingesta de señales voluminosas en plan analítico | Protege donde hay datos o exposición, ingiere en plan analítico solo lo que alimenta reglas y usa resúmenes agregados para lo voluminoso. |

### ■ Seguridad, ética y costo

Trabaja con cuentas propias o sandboxes autorizados. No publiques secretos, identificadores reales ni datos personales. Antes de crear recursos pagos define presupuesto, etiquetas y comando de destrucción; después verifica que no queden recursos huérfanos. Los ejemplos locales enseñan contratos, pero no certifican cumplimiento ni disponibilidad de producción.

### ■ Preguntas de comprobación

1. ¿Qué pregunta responde cada una de las tres herramientas y cómo se relacionan?
2. ¿Por qué la puntuación de seguridad es mala guía de prioridad?
3. ¿Qué debe acompañar a cada control de cumplimiento para que la medida sea honesta?
4. ¿Qué mide de verdad si una detección funciona?

5. ¿Qué acciones de respuesta conviene automatizar y cuáles no?

## Referencias

- Microsoft (2025). Microsoft Defender for Cloud: secure score and attack paths. <<https://learn.microsoft.com/en-us/azure/defender-for-cloud/secure-score-security-controls>>
- Microsoft (2025). Regulatory compliance in Defender for Cloud. <<https://learn.microsoft.com/en-us/azure/defender-for-cloud/regulatory-compliance-dashboard>>
- Microsoft (2025). Microsoft Sentinel: data connectors and analytics rules. <<https://learn.microsoft.com/en-us/azure/sentinel/overview>>
- MITRE (2025). ATT&CK for cloud. <<https://attack.mitre.org/matrices/enterprise/cloud/>>
- Microsoft (2025). Sentinel cost optimization and data tiers. <<https://learn.microsoft.com/en-us/azure/sentinel/billing>>
- Documentación oficial vigente del servicio implementado; registra URL y fecha de consulta.

Descargar: Parte 18 en PDF · Recorrido de Azure en PDF · Manual integral

| Anterior                                                                    | Índice              | Siguiente                                                                    |
|-----------------------------------------------------------------------------|---------------------|------------------------------------------------------------------------------|
| <a href="#">← 225 · Azure Monitor, Application Insights y OpenTelemetry</a> | Parte 18 · Programa | <a href="#">227 · Cost Management, Advisor, resiliencia y Chaos Studio →</a> |

## Evaluación — 226 Defender for Cloud, Policy y Sentinel

### Preguntas

1. Explica el problema que resuelve esta capacidad sin mencionar un proveedor.
2. Identifica una frontera de responsabilidad y su propietario.
3. Compara dos alternativas mediante confiabilidad, seguridad, costo y operación.
4. ¿Qué demuestra el laboratorio y qué no puede demostrar?
5. Propón un caso límite o una prueba de fallo.

### Reto verificable

Entrega azure-security-operations con diagrama o configuración, evidencia de ejecución, alternativa descartada, riesgo residual y criterio de rollback.

### Criterio de aceptación

- [ ] Resultado reproducible por una segunda persona.
- [ ] Evidencia vinculada a cada afirmación técnica.
- [ ] Prueba negativa o de fallo incluida.
- [ ] Costos y permisos expresados con unidades y alcance.
- [ ] Limitaciones declaradas sin presentar la simulación como producción.

## Escala

| Nivel             | Evidencia                                                |
|-------------------|----------------------------------------------------------|
| A — competente    | Cumple todo y defiende trade-offs con datos.             |
| B — en desarrollo | Cumple lo esencial; falta profundidad en una dimensión.  |
| C — inicial       | Artefacto parcial o conclusión sin evidencia suficiente. |
| 0                 | Sin entrega reproducible.                                |

# 227 — Cost Management, Advisor, resiliencia y Chaos Studio

Parte: 18 — Azure: arquitectura empresarial y operación en producción Nivel: avanzado · Horas estimadas: 4  
Laboratorio: finops · Estado: EXECUTABLECORE

## Propósito

Cerrar la operación de Azure con las dos cosas que se dejan para el final y deciden si el sistema es sostenible: el control del coste y la comprobación de la resiliencia. La clase aplica el método de la clase 214 con las herramientas de esta nube, evalúa las recomendaciones automáticas con escepticismo —el asesor propone reservas sobre cargas que había que retirar—, y usa la inyección controlada de fallos para comprobar lo que la clase 215 exige comprobar.

## Resultados de aprendizaje

Al finalizar podrás:

1. Atribuir el coste con etiquetas impuestas en la creación.
2. Evaluar las recomendaciones automáticas antes de aplicarlas.
3. Comprometer capacidad solo sobre la base estable y vigilar su uso.
4. Inyectar fallos de forma controlada para comprobar la resiliencia.
5. Cerrar el ciclo: cada hallazgo, una acción con dueño y fecha.

## Conceptos centrales


| Concepto                 | Comprensión verificable                                                                       |
|--------------------------|-----------------------------------------------------------------------------------------------|
| ámbito de facturación    | Nivel al que se agrega el gasto: cuenta de facturación, perfil, sección y suscripción.        |
| etiqueta heredada        | Etiqueta que se propaga del grupo de recursos al recurso. No todos los servicios la respetan. |
| reserva de capacidad     | Compromiso de uso a uno o tres años a cambio de descuento. Se aplica a la base estable.       |
| plan de ahorro           | Compromiso de gasto por hora, más flexible que la reserva y con menos descuento.              |
| experimento de caos      | Inyección controlada de un fallo, con hipótesis, alcance limitado y forma de parar.           |
| recomendación automática | Sugerencia de la plataforma sobre coste, fiabilidad o rendimiento. Se evalúa, no se aplica.   |

## Modelo mental

La arquitectura Azure nace del tenant y las políticas heredables, y llega al workload mediante identidades administradas y redes privadas.

Aplicado a esta clase, separa siempre cuatro planos: intención (qué necesita el usuario), configuración (qué declaramos), estado observado (qué existe de verdad) y evidencia (cómo sabemos que cumple). Confundirlos produce diseños que se ven correctos en un diagrama pero fallan al operar.

## ■ Flujo de razonamiento



## Desarrollo

### 1. Atribuir el coste en esta nube

El método es el de la clase 214 y aquí hay particularidades que hay que conocer.

#### LA JERARQUÍA DE FACTURACIÓN

cuenta de facturación → perfil → sección → suscripción  
→ el gasto se agrega por ahí, y por eso la separación  
por suscripción de la clase 217 es también una  
decisión de facturación

#### LAS ETIQUETAS

obligatorias en la creación, con valores cerrados, por  
política clase 217  
→ y la herencia del grupo de recursos NO la respetan  
todos los servicios  
→ hay que comprobar cuáles, y para esos, etiquetar el  
recurso directamente

Y el gasto que no se puede etiquetar, que aquí es apreciable:

transferencia entre zonas y regiones  
servicios compartidos: centro de red, cortafuegos,  
resolutor, área de observabilidad  
y los recursos gestionados por la plataforma

→ se reparten por regla escrita y acordada  
→ y hay que decir cuánto se reparte y con qué criterio

Las cinco vistas de la clase 214, con lo que suele aparecer en Azure:

|                       |                                                          |
|-----------------------|----------------------------------------------------------|
| POR SERVICIO          | el 80 % en 3 o 4 líneas                                  |
| POR DUEÑO             | y cuánto no lo tiene                                     |
| POR ENTORNO           | preproducción por encima del 25 % de producción es señal |
| POR TIPO DE USO       | dentro de cada servicio grande                           |
| POR UNIDAD DE NEGOCIO | la única cifra comparable                                |

y las partidas que sorprenden en esta nube  
 unidades de petición de la base distribuida clase 223  
 ingesta de observabilidad y de seguridad clases 225, 226  
 puntos privados e inspección del cortafuegos clase 219  
 transferencia entre zonas  
 y los planes de servicio con instancias encendidas y sin tráfico clase 221

Y los presupuestos con acción, igual que antes:

por suscripción y por servicio, sobre previsión  
 en entornos no productivos, con acción real  
 en producción, solo aviso  
 y detección de anomalías por servicio y por dueño  
 clase 214

## 2. Las recomendaciones automáticas, con escepticismo

La plataforma propone mejoras de coste, fiabilidad, rendimiento y seguridad. Son útiles y no se aplican sin evaluar.

LAS DE COSTE, y su trampa  
 «compra una reserva para estas máquinas»  
 → calcula el ahorro suponiendo que ESAS máquinas seguirán existiendo tres años  
 → y no sabe que estaban en la lista de retirada  
 → comprometerse con lo que hay que apagar es la peor compra posible ley 25  
  
 «redimensiona esta máquina infrautilizada»  
 → mira el uso medio, no el pico ni la estacionalidad  
 → hay que comprobar el percentil alto antes clase 212  
  
 «retira este recurso ocioso»  
 → suele ser correcta, y aun así: apagar antes de borrar  
 clase 214

Y el orden correcto, que evita comprar lo que hay que tirar:

- 1 RETIRAR lo que no se usa
- 2 REDIMENSIONAR lo sobredimensionado
- 3 APAGAR por horario lo no productivo
- 4 Y SOLO ENTONCES comprometer capacidad

→ comprometer primero congela el desperdicio durante años

Los compromisos, con la decisión entre los dos tipos:

RESERVA DE CAPACIDAD  
 se compromete un tipo y tamaño concreto  
 + descuento mayor  
 – rígida: si se cambia de familia, el descuento se pierde o hay que intercambiarla

PLAN DE AHORRO  
 se compromete un gasto por hora  
 + flexible: se aplica a lo que haya  
 – descuento menor

CRITERIO  
 infraestructura estable y previsible → reserva  
 cargas que van a cambiar de forma → plan de ahorro  
 y en ambos casos, SOLO sobre la base estable medida con meses de histórico clase 143

Y lo que hay que vigilar después:

COBERTURA      qué proporción del uso está cubierta  
UTILIZACIÓN    qué proporción de lo comprometido se usa  
→ por debajo del 95 %, es dinero tirado  
→ y baja sola cuando se apaga algo o se cambia de familia  
  
→ alerta si la utilización cae por debajo del umbral  
→ y revisión antes de cada renovación

Y las recomendaciones de fiabilidad, que merecen más atención que las de coste:

«esta base no tiene redundancia de zona»  
«este recurso no tiene copias de seguridad»  
«esta configuración no sobrevive a la pérdida de una zona»  
  
→ estas se leen con la aritmética de la clase 185: ¿cambian el techo de disponibilidad del flujo crítico?  
→ y si sí, se aplican; si no, se aceptan por escrito

### 3. Inyectar fallos de forma controlada

La clase 215 exige comprobar la resiliencia. La inyección controlada de fallos es la forma de hacerlo sin esperar a un incidente.

QUÉ PERMITE INYECTAR  
apagar o reiniciar máquinas y nodos  
presión de CPU, memoria o disco  
latencia y pérdida en la red  
bloqueo del acceso a un servicio dependiente  
conmutación forzada de una base  
caída de una zona completa  
y fallos de una dependencia de la plataforma

Y la disciplina, que es la de la clase 215:

HIPÓTESIS ESCRITA, antes  
«al perder una zona, el flujo de compra seguirá funcionando con latencia menor de 600 ms y sin errores; la búsqueda quedará degradada»  
→ lo valioso es dónde falla la hipótesis

ALCANCE LIMITADO  
un porcentaje de instancias, una zona, un servicio  
→ y el experimento debe poder pararse en segundos

VENTANA Y OBSERVACIÓN  
con negocio avisado y con alguien tomando notas  
→ y con tráfico real, no de madrugada la primera vez

ESCALA  
1 en papel: recorrer el procedimiento  
2 en preproducción  
3 en producción con alcance pequeño  
4 en producción completo

Los experimentos que más encuentran, por orden:

- 1 PÉRDIDA DE UNA ZONA  
→ comprueba que las réplicas están repartidas de verdad  
→ y que la capacidad restante aguanta      clases 185, 212
- 2 DEPENDENCIA QUE RESPONDE LENTO, no que cae  
→ el fallo gris; la mayoría de los diseños no lo resisten      clase 185  
→ y es donde se descubre que una dependencia declarada blanda es dura      clase 201
- 3 CONMUTACIÓN DE BASE DE DATOS  
→ cronometra y mide la pérdida real      clase 223
- 4 PRESIÓN DE RECURSOS  
→ descubre límites de memoria mal puestos      clase 213
- 5 PÉRDIDA DE UN SERVICIO DE PLATAFORMA

- el almacén de secretos, el resolutor, el registro de imágenes
- y estos son los que nadie prueba y los que paran todo  
clase 215

Y la disciplina posterior, que es lo que hace útil el ejercicio:

cada hallazgo → una acción con dueño y fecha  
el procedimiento se corrige EN EL MOMENTO  
y el experimento se repite hasta que pase entero

- un experimento que encuentra problemas y no se repite ha  
servido para la mitad  
clase 215

Y una advertencia sobre el permiso y el alcance:

- la herramienta necesita permisos para romper cosas
- y esos permisos son peligrosos si quedan permanentes
- elevación temporal para ejecutar experimentos  
clase 218
- y el alcance del experimento, restringido por etiqueta o  
por grupo de recursos

#### 4. Cerrar el ciclo

Coste y resiliencia comparten una propiedad: son las dos cosas que se degradan solas si nadie las mira.

EL COSTE SE DEGRADA PORQUE

- se crean recursos y no se retiran  
ley 25
- se sobredimensiona por si acaso
- se acumulan entornos y copias
- y nadie tiene el gasto entre sus señales

LA RESILIENCIA SE DEGRADA PORQUE

- el sistema crece y las comprobaciones no  
clase 216
- se añaden dependencias sin recalcular el techo  
clase 185
- y los procedimientos envejecen  
ley 22

Y el ritmo que este programa propone:

##### SEMANAL

revisión de anomalías de coste abiertas  
recursos ociosos detectados y retirados

##### MENSUAL

coste por unidad de negocio y su tendencia  
cobertura y utilización de compromisos  
cumplimiento de las iniciativas  
clase 217

##### TRIMESTRAL

un experimento de resiliencia, ejecutado  
simulación de técnicas de ataque  
clase 226  
prueba del acceso de emergencia  
clase 218  
revisión de accesos  
y revisión de exenciones vencidas

##### ANUAL

ejercicio de pérdida de región completo  
clase 215  
y revisión de las decisiones registradas  
clase 190

Y las señales que dicen si el sistema está sano:

##### COSTE

proporción de gasto atribuido > 90 %  
coste por unidad de negocio tendencia  
utilización de compromisos > 95 %  
recursos ociosos vivos tendencia a cero

##### RESILIENCIA

proporción de pruebas negativas que pasan  
plazo de recuperación MEDIDO, no declarado  
proporción de técnicas simuladas detectadas  
clase 226  
y experimentos ejecutados frente a planificados

Y la lista de comprobación de la clase:

- las etiquetas obligatorias se imponen en la creación

- se comprobó qué servicios no heredan etiquetas
- el coste no etiquetable se reparte por regla escrita
- hay presupuestos con acción en entornos no productivos
- hay detección de anomalías por servicio y por dueño
- se retiró y redimensionó ANTES de comprometer capacidad
- los compromisos cubren solo la base estable medida
- se vigilan cobertura y utilización, con alerta
- las recomendaciones automáticas se evalúan, no se aplican
- las de fiabilidad se leen con la aritmética del techo
- hay experimentos de caos con hipótesis y forma de parar
- el alcance de los experimentos está restringido
- los permisos para inyectar fallos son temporales
- cada hallazgo tiene dueño y fecha, y el experimento se repite
- existe un calendario semanal, mensual, trimestral y anual

Y el cierre que enlaza con la clase siguiente: con todo lo de esta parte montado, queda ponerlo junto en un sistema productivo y comprobarlo. Es la materia de la clase 228, que además cierra la parte 18.

## Ejemplo trabajado

CloudShop cierra la operación de su plataforma en Azure. Lo que sigue es la reserva que casi se compra sobre máquinas que había que retirar, y el experimento de pérdida de zona que encontró seis problemas, ninguno de infraestructura.

El coste, al revisar:

|                                 |          |      |
|---------------------------------|----------|------|
| total mensual                   | 31.400 € |      |
| por servicio                    |          |      |
| base distribuida                | 5.740    | 18 % |
| cómputo (planes y contenedores) | 4.900    | 16 % |
| observabilidad y seguridad      | 4.780    | 15 % |
| transferencia y red             | 4.210    | 13 % |
| bases relacionales              | 3.100    | 10 % |
| almacenamiento                  | 2.840    | 9 %  |
| resto                           | 5.830    | 19 % |
| por dueño                       |          |      |
| atribuido                       | 19.100   | 61 % |
| sin atribuir                    | 12.300   | 39 % |

Y el detalle de lo no atribuido:

|                                                                                     |       |
|-------------------------------------------------------------------------------------|-------|
| transferencia y servicios compartidos                                               | 6.100 |
| recursos sin etiqueta                                                               | 3.240 |
| → de ellos, 1.870 € en servicios que NO HEREDAN las etiquetas del grupo de recursos |       |
| → el equipo creía que las heredaban todos                                           |       |
| recursos ociosos                                                                    | 2.960 |

Y el hallazgo de la herencia:

|                                                                                               |           |
|-----------------------------------------------------------------------------------------------|-----------|
| se comprobó servicio por servicio cuáles heredan                                              |           |
| heredan                                                                                       | 61 %      |
| NO heredan                                                                                    | 39 %      |
| · cuentas de almacenamiento en algunas operaciones                                            |           |
| · discos creados por conjuntos de escalado                                                    |           |
| · direcciones públicas creadas automáticamente                                                |           |
| · instantáneas y copias                                                                       |           |
| corrección                                                                                    |           |
| política de tipo MODIFICAR que añade las etiquetas al crear, en vez de confiar en la herencia | clase 217 |
| → 3.240 € pasaron a estar atribuidos en 3 semanas                                             |           |

La reserva que no se compró.

|                                                     |                |
|-----------------------------------------------------|----------------|
| la recomendación automática decía                   |                |
| «reserva a 3 años para 22 máquinas de la familia D» |                |
| ahorro estimado                                     | 4.100 €/mes    |
| coste del compromiso                                | 38 % del total |

lo que el equipo comprobó antes de comprar

14 nodos del clúster antiguo, en la lista de retirada  
del trimestre siguiente

5 máquinas del sistema heredado de facturación, con  
migración planificada a 18 meses clase 223

3 máquinas de un proyecto terminado en 2024, que  
nadie había apagado ley 25

→ comprar la reserva habría congelado el desperdicio durante tres

ahorro total -5.920 €/mes  
frente a los 4.100 € de la recomendación, y sin  
comprometerse con lo que había que tirar

15:04:00 la base distribuida siguió sirviendo  
✓ (redundancia de zona activada)

15:04:20 el almacén de SECRETOS dejó de responder para 2 servicios  
X no estaba en la hipótesis  
causa esos 2 servicios cacheaban el secreto al arrancar; las instancias nuevas no pudieron obtenerlo porque el punto privado del almacén estaba en la zona 3  
clase 219

15:09:00 el equipo decide parar

15:09:40 zona restaurada

15:10-15:24 la recuperación NO fue automática  
X predicción 5  
2 servicios quedaron con instancias marcadas como no sanas y hubo que reiniciarlas a mano

#### Los seis hallazgos:

| # | hallazgo                                                     | tipo      | acción                          |
|---|--------------------------------------------------------------|-----------|---------------------------------|
| 1 | sin margen para perder una zona                              | capacidad | 6 → 9 instancias                |
| 2 | las 3 réplicas del buscador en la misma zona                 | reparto   | restricción de reparto          |
| 3 | punto privado del almacén de secretos en una sola zona       | red       | 3 puntos, uno por zona          |
| 4 | 2 servicios cachean el secreto y no lo renuevan              | código    | renovación periódica            |
| 5 | recuperación no automática                                   | proceso   | comprobación de salud corregida |
| 6 | nadie sabía qué hacer al ver los 503: no había procedimiento | proceso   | escrito y probado               |
|   | de infraestructura                                           |           | 0                               |
|   | de configuración, reparto, código y proceso                  |           | 6                               |

#### Y la segunda ejecución, dos meses después:

|                            |            |   |
|----------------------------|------------|---|
| latencia p99 máxima        | 380 ms     | ✓ |
| errores para el usuario    | 0          | ✓ |
| búsqueda                   | degradada  | ✓ |
| almacén de secretos        | disponible | ✓ |
| recuperación               | automática | ✓ |
| duración total del impacto | 0 min      |   |

#### El calendario que quedó:

|            |                                                                        |           |
|------------|------------------------------------------------------------------------|-----------|
| semanal    | anomalías de coste; ociosos retirados                                  |           |
| mensual    | coste por pedido; cobertura y utilización; cumplimiento de iniciativas |           |
| trimestral | 1 experimento de resiliencia                                           |           |
|            | simulación de técnicas de ataque                                       | clase 226 |
|            | prueba de acceso de emergencia                                         | clase 218 |
|            | revisión de accesos y de exenciones                                    |           |
| anual      | ejercicio de pérdida de región                                         | clase 215 |
|            | revisión de decisiones registradas                                     | clase 190 |

#### El resultado, seis meses después:

|                                 |          |          |
|---------------------------------|----------|----------|
| coste mensual                   | 31.400 € | 23.100 € |
| coste atribuido                 | 61 %     | 94 %     |
| coste por pedido                | 0,071 €  | 0,049 €  |
| utilización del compromiso      | —        | 98 %     |
| recursos ociosos                | 2.960 €  | 0 €      |
| réplicas repartidas entre zonas | parcial  | total    |
| experimentos ejecutados         | 0        | 3        |
| hallazgos con dueño y fecha     | —        | 14       |

La lección que esta clase deja: la recomendación automática proponía comprometerse tres años con veintidós máquinas de las que diecisiete no iban a existir en uno, y hacer las cosas en el orden correcto —retirar, redimensionar, apagar, y solo entonces comprometer— dio un ahorro mayor sin atarse a nada. Y el experimento de pérdida de zona encontró seis problemas, ninguno de infraestructura: los tres más graves fueron réplicas mal repartidas, un punto privado en una sola zona y dos servicios que cacheaban un secreto y no lo renovaban.

## Laboratorio guiado

Ejecuta desde la raíz:

```
python classes/part-18-azure-production-architecture/227-cost-management-advisor-resiliencia-y-chaos-studio/lab.py
```

El laboratorio selecciona el motor de práctica finops y produce labresult.json. El escenario, sus comprobaciones y el artefacto esperado corresponden a esta clase; no requiere credenciales y deja explícito qué debe revalidarse en un sandbox real.

1. Lee exercise.steps y formula una predicción antes de ejecutar.
2. Ejecuta la práctica y verifica todos los elementos de checks.
3. Provoca el caso de negativetest y explica la señal observada.
4. Materializa azure-optimization en evidence/ usando la plantilla indicada.
5. Para proveedor real, sigue sandbox.requires, registra costo y ejecuta destroy.

## Evidencia esperada

El artefacto principal es un cálculo trazable con unidad, supuesto y sensibilidad. Además, la entrega debe incluir el comando ejecutado, la salida estructurada y una conclusión que no exceda lo observado.

## Reto verificable

Construye azure-optimization para el caso CloudShop. Incluye una alternativa descartada, un supuesto que pueda falsarse, una prueba de fallo y una decisión de rollback.

## ■ Criterio de aceptación

- [ ] lab.py termina con código 0 y genera JSON válido.
- [ ] La entrega conecta al menos tres requisitos con mecanismos verificables.
- [ ] Existe una prueba positiva y una prueba negativa con evidencia.
- [ ] Seguridad, costo y operación aparecen como decisiones, no como anexos.
- [ ] Se declara una limitación y una condición que obligaría a revisar el diseño.
- [ ] Otra persona puede repetir el recorrido sin conocimiento tácito.

## ■ Errores frecuentes

| Síntoma                                                                | Causa probable                                                                            | Corrección                                                                                                                  |
|------------------------------------------------------------------------|-------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------|
| Parte del gasto sigue sin atribuir pese a tener etiquetas obligatorias | Se confía en la herencia del grupo de recursos y hay servicios que no la respetan         | Comprueba qué servicios heredan y usa una política de tipo modificar que etiquete al crear.                                 |
| Se compra un compromiso y la utilización cae a los pocos meses         | Se comprometió capacidad sobre cargas que iban a retirarse o a cambiar de forma           | Retira, redimensiona y apaga primero; compromete solo la base estable medida y usa plan de ahorro si la forma va a cambiar. |
| Aplicar una recomendación de redimensionado degrada el servicio        | La recomendación usa el uso medio y no el pico ni la estacionalidad                       | Comprueba el percentil alto y el comportamiento en campaña antes de aplicar.                                                |
| Al perder una zona el servicio se degrada más de lo previsto           | No hay margen de capacidad para perder una zona de tres                                   | Dimensiona para que la capacidad restante quede por debajo del codo, y comprueba con un experimento.                        |
| Todas las réplicas de un servicio están en la misma zona               | No hay restricción de reparto y el planificador las agrupó                                | Declara restricciones de reparto por zona y compruébalo inyectando la pérdida de una.                                       |
| Un experimento de caos se convierte en un incidente                    | Alcance amplio, sin hipótesis ni forma de parar, y permisos permanentes para romper cosas | Hipótesis escrita, alcance restringido por etiqueta, parada en segundos y permisos por elevación temporal.                  |

## ■ Seguridad, ética y costo

Trabaja con cuentas propias o sandboxes autorizados. No publiques secretos, identificadores reales ni datos personales. Antes de crear recursos pagos define presupuesto, etiquetas y comando de destrucción; después verifica que no queden recursos huérfanos. Los ejemplos locales enseñan contratos, pero no certifican cumplimiento ni disponibilidad de producción.

## ■ Preguntas de comprobación

1. ¿Por qué no todas las etiquetas se heredan y qué hacer al respecto?
2. ¿En qué orden hay que actuar antes de comprometer capacidad?
3. ¿Cuándo conviene una reserva y cuándo un plan de ahorro?
4. ¿Qué cinco experimentos de resiliencia encuentran más problemas?
5. ¿Qué ritmo de revisión propone esta clase y qué se hace en cada periodo?

## Referencias

- Microsoft (2025). Azure Cost Management and Billing.  
<<https://learn.microsoft.com/en-us/azure/cost-management-billing/>>
- Microsoft (2025). Azure Advisor recommendations.  
<<https://learn.microsoft.com/en-us/azure/advisor/advisor-overview>>
- Microsoft (2025). Azure savings plans and reservations.  
<<https://learn.microsoft.com/en-us/azure/cost-management-billing/savings-plan/savings-plan-compute-overview>>
- Microsoft (2025). Azure Chaos Studio.  
<<https://learn.microsoft.com/en-us/azure/chaos-studio/chaos-studio-overview>>
- Microsoft (2025). Reliability and availability zones in Azure.  
<<https://learn.microsoft.com/en-us/azure/reliability/availability-zones-overview>>
- Documentación oficial vigente del servicio implementado; registra URL y fecha de consulta.

Descargar: Parte 18 en PDF · Recorrido de Azure en PDF · Manual integral

| Anterior                                      | Índice              | Siguiente                                       |
|-----------------------------------------------|---------------------|-------------------------------------------------|
| ← 226 · Defender for Cloud, Policy y Sentinel | Parte 18 · Programa | 228 · Proyecto: CloudShop productivo en Azure → |

## Evaluación — 227 Cost Management, Advisor, resiliencia y Chaos Studio

### Preguntas

1. Explica el problema que resuelve esta capacidad sin mencionar un proveedor.
2. Identifica una frontera de responsabilidad y su propietario.
3. Compara dos alternativas mediante confiabilidad, seguridad, costo y operación.
4. ¿Qué demuestra el laboratorio y qué no puede demostrar?
5. Propón un caso límite o una prueba de fallo.

### Reto verificable

Entrega azure-optimization con diagrama o configuración, evidencia de ejecución, alternativa descartada, riesgo residual y criterio de rollback.

### Criterio de aceptación

- ☐ Resultado reproducible por una segunda persona.
- ☐ Evidencia vinculada a cada afirmación técnica.
- ☐ Prueba negativa o de fallo incluida.
- ☐ Costos y permisos expresados con unidades y alcance.
- ☐ Limitaciones declaradas sin presentar la simulación como producción.

### Escala

| Nivel             | Evidencia                                                |
|-------------------|----------------------------------------------------------|
| A — competente    | Cumple todo y defiende trade-offs con datos.             |
| B — en desarrollo | Cumple lo esencial; falta profundidad en una dimensión.  |
| C — inicial       | Artefacto parcial o conclusión sin evidencia suficiente. |
| 0                 | Sin entrega reproducible.                                |

## 228 — Proyecto: CloudShop productivo en Azure

Parte: 18 — Azure: arquitectura empresarial y operación en producción Nivel: avanzado · Horas estimadas: 8  
Laboratorio: capstone · Estado: EXECUTABLECORE

### Propósito

Poner en producción el sistema completo de CloudShop en Azure con lo de las once clases anteriores, y comprobarlo con las pruebas negativas de toda la parte. La clase da el orden, el entregable y los criterios. Y cierra la parte 18: corrige las cinco predicciones de la clase 216 —tres acertadas y dos a medias—, actualiza el recuento de leyes, añade la ley 27 y escribe la hipótesis de la parte 19, contestando además la pregunta incómoda que la clase 216 se dejó planteada.

### Resultados de aprendizaje

Al finalizar podrás:

1. Construir el sistema completo en el orden que evita rehacer.
2. Comprobar con las pruebas negativas de toda la parte.
3. Comparar el resultado con el equivalente en AWS, con cifras.
4. Corregir las cinco predicciones de la clase 216 con evidencia.
5. Escribir la hipótesis de la parte 19 en forma refutable.

### Conceptos centrales


| Concepto                 | Comprensión verificable                                                                                    |
|--------------------------|------------------------------------------------------------------------------------------------------------|
| ley 27                   | Un control solo actúa sobre lo que cambia; lo que ya existe sigue incumpliendo hasta que alguien lo toque. |
| remediación              | Tarea que corrige recursos existentes que incumplen. Es lo único que cierra la brecha que deja la ley 27.  |
| equivalencia entre nubes | Correspondencia de conceptos. Alta en lo técnico, baja en el modelo operativo.                             |
| coste de traslado        | Lo que cuesta llevar la misma arquitectura a otra nube. Se paga más en operación que en código.            |
| prueba negativa de parte | Comprobación acumulada de las once clases, ejecutada sobre el sistema entero.                              |
| hipótesis de parte       | Afirmación refutable escrita antes de estudiar, que la parte siguiente corrige con evidencia.              |

### Modelo mental

La arquitectura Azure nace del tenant y las políticas heredables, y llega al workload mediante identidades administradas y redes privadas.

Aplicado a esta clase, separa siempre cuatro planos: intención (qué necesita el usuario), configuración (qué declaramos), estado observado (qué existe de verdad) y evidencia (cómo sabemos que cumple). Confundirlos produce diseños que se ven correctos en un diagrama pero fallan al operar.

### ■ Flujo de razonamiento



## Desarrollo

### 1. El encargo, el orden y el entregable

El encargo. Llevar a producción la plataforma de pedidos de CloudShop en Azure, con usuarios reales, guardia, presupuesto y continuidad comprobada.

El orden, por coste de cambio:

- 1 JERARQUÍA Y POLÍTICAS clase 217  
grupos de administración, suscripciones por carga y  
entorno, iniciativas en auditoría antes de denegar  
→ lo que llega tarde deja recursos incumpliendo  
ley 27
- 2 IDENTIDAD clase 218  
identidades administradas y federadas, sin secretos  
asignaciones en el ámbito del recurso  
elevación temporal y acceso de emergencia probado
- 3 RED clase 219  
centro y radios, salida centralizada  
puntos privados con zonas DNS enlazadas a TODAS las  
redes
- 4 CÓDIGO clase 220  
separado por ciclo de vida y ámbito, con módulos  
verificados y pilas de despliegue
- 5 DATOS clase 223  
familia por patrones, consistencia por operación,  
índices recortados
- 6 CÓMPUTO clases 221, 222  
la opción gestionada que corresponda; clúster solo donde  
hace falta
- 7 MENSAJERÍA clase 224  
el servicio que garantiza lo que hace falta, con  
idempotencia y fallidos vigilados
- 8 OBSERVABILIDAD clase 225  
diagnóstico por política, instrumentación estándar
- 9 SEGURIDAD clase 226  
postura por alcance, detección comprobada con simulación
- 10 COSTE Y RESILIENCIA clase 227  
atribución, compromisos tras retirar, experimentos

El entregable, con las piezas propias de esta parte:

- 1 el problema, con su cifra
- 2 jerarquía y iniciativas, con el estado de cumplimiento
- 3 inventario de identidades y su ALCANCE medido
- 4 topología de red, con las zonas DNS y su enlace
- 5 el código, con lo que gestiona cada pila
- 6 patrones de acceso y niveles de consistencia por  
operación
- 7 la lista de VALORES POR DEFECTO cambiados
- 8 observabilidad: qué se ingiere, en qué plan y qué cuesta
- 9 detección: qué técnicas se simulan y cuáles se detectan
- 10 coste atribuido y por unidad de negocio
- 11 experimentos de resiliencia y sus hallazgos
- 12 pruebas negativas, con los fallos publicados
- 13 lo que NO se hace, y por qué

Las pruebas negativas de la parte:

- quitar una política heredada desde una suscripción
- crear un recurso sin etiquetas obligatorias
- crear un recurso en una región no permitida
- obtener la identidad de otro espacio de nombres
- asumir una identidad federada desde otro repositorio
- activar un papel privilegiado sin aprobación
- entrar con la cuenta de acceso de emergencia
- alcanzar un radio desde otro radio
- resolver un nombre con punto privado desde cada red
- alcanzar un servicio con punto privado desde internet
- sacar datos a un destino no declarado
- desplegar quitando un recurso de la plantilla
- borrar la pila y comprobar que los datos sobreviven
- enviar el mismo mensaje 50 veces

- dejar un mensaje en la cola de fallidos y esperar la alerta
- perder una zona completa
- simular 14 técnicas de ataque
- provocar la condición de cada alerta
- desplegar el entorno de cero en una suscripción vacía

Y los criterios de evaluación, con el peso donde importa:

|    |                                                             |   |
|----|-------------------------------------------------------------|---|
| 1  | las políticas están en grupos de administración             | 3 |
| 2  | se midió el cumplimiento antes de denegar                   | 2 |
| 3  | ninguna asignación amplia sin justificar                    | 3 |
| 4  | no quedan secretos de cliente sin excepción                 | 3 |
| 5  | las zonas DNS están enlazadas a todas las redes             | 3 |
| 6  | la consistencia se decide por operación                     | 2 |
| 7  | la lista de valores por defecto cambiados es explícita      | 3 |
| 8  | la instrumentación es estándar                              | 2 |
| 9  | se simulan técnicas y se publica la proporción              | 3 |
| 10 | el coste atribuido supera el 90 %                           | 2 |
| 11 | hay experimentos de resiliencia ejecutados                  | 3 |
| 12 | las pruebas negativas se ejecutaron y hay fallos publicados | 3 |

## 2. Cierre de la parte 18: corrección de las cinco predicciones

Las cinco predicciones de la clase 216, corregidas con la evidencia de las clases 217 a 227.

1. «los valores por defecto de Azure estarán mal elegidos en proporción parecida a los de AWS, pero fallarán en otro sitio: los de AWS son permisivos en red y almacenamiento; los de Azure lo serán en identidad y ámbito de permisos»

PRIMERA MITAD CORRECTA: la lista de valores por defecto que hubo que cambiar es comparable a la de AWS. SEGUNDA MITAD FALLADA. Los peores valores por defecto de Azure no fueron de identidad: fueron de COSTE y de OBSERVABILIDAD. La consistencia fuerte del asistente costaba 1.720 €/mes; la política que indexa todos los campos, otros 1.020; y el 93 % de los recursos no enviaba ningún registro porque la configuración de diagnóstico no existe si no se crea. El problema de identidad fue real y grave, pero no era un valor por defecto: era un error de configuración que alguien tomó por comodidad.

2. «la jerarquía será el equivalente del plan de direcciones: se decide en una tarde, condiciona una década, y reenumerarla costará meses»

A MEDIAS, y la diferencia importa. Se decidió mal –47 suscripciones colgando de la raíz– y condicionó todo, como el plan de direcciones. Pero el mecanismo del coste es OTRO: mover las 61 suscripciones al grupo correcto fue instantáneo y gratis. Lo que costó cuatro meses fue corregir los recursos que ya existían, porque las políticas de denegación no actúan hacia atrás. En redes, lo caro es reenumerar; aquí, lo caro es que el control nuevo no toca lo viejo. Y eso es una ley distinta.

3. «la identidad será el eje; el error más frecuente será un ámbito de asignación demasiado amplio, el equivalente del comodín de la clase 206»

CORRECTA, y de forma casi literal. De 1.940 asignaciones, 820 estaban en la suscripción y 31 en grupos de administración; una sola identidad de canalización alcanzaba 14.200 recursos. Y en el clúster, la credencial federada atada solo al emisor permitía a cualquier cuenta de servicio de cualquier espacio de nombres obtenerla. El mecanismo cambia de nombre en cada nube y produce el mismo resultado.

4. «la mayoría de los conceptos se corresponderán uno a uno; lo que no se corresponderá es el modelo operativo, y trasladar la misma arquitectura costará más en operación

que en código»

CORRECTA. Se correspondieron: federación de identidad, puntos privados, centro y radios, infraestructura como código, contenedores, mensajería, observabilidad y coste. NO se correspondieron: el modelo de políticas, que aquí es mucho más fuerte y no actúa hacia atrás; el modelo de ámbitos de asignación; los cinco niveles de consistencia, que no tienen equivalente; los modos de despliegue; y la necesidad de crear el diagnóstico recurso a recurso. El código se tradujo en semanas; entender esas cinco diferencias operativas costó los tres primeros meses.

5. «los problemas volverán a ser de las leyes 25, 15 y 22; y si acierta por cuarta vez consecutiva, dejará de tener mérito y habrá que preguntarse por qué, sabiéndolo, sigue ocurriendo»

CORRECTA por cuarta vez, y toca contestar la pregunta. La evidencia: cuatro políticas quitadas por equipos sin que nadie se enterara; zonas DNS enlazadas a 4 de 43 redes durante siete meses; una configuración sin marcar como específica de ranura; el 93 % de los recursos sin diagnóstico; siete de catorce técnicas sin detectar con las reglas creadas; tres máquinas de un proyecto terminado en 2024.

Y la respuesta a la pregunta, que es lo que esta clase debe a la anterior:

las leyes 25, 15 y 22 no describen ERRORES  
describen el ESTADO POR DEFECTO de cualquier sistema que cambia

|                              |                                                 |
|------------------------------|-------------------------------------------------|
| lo provisional se queda      | porque retirar es trabajo y nadie lo pide       |
| la señal no se mira          | porque mirar es trabajo continuo y no urgente   |
| el procedimiento no funciona | porque ejecutarlo es trabajo y no hay incidente |

→ no hace falta que nadie se equivoque para que se cumplan  
→ hace falta que nadie haga algo, y eso ocurre siempre

y por eso saberlas no basta  
el equipo de este programa las conocía en las cuatro partes y las cuatro veces volvieron a ocurrir  
→ lo único que las contrarresta es que la comprobación sea AUTOMÁTICA y PERIÓDICA  
→ una persona que conoce la ley 15 sigue sin mirar el panel  
→ una alerta de antigüedad, no

Marcador: tres correctas, dos a medias.

### 3. Recuento de leyes, ley 27 e hipótesis de la parte 19

El recuento de leyes, cerrada la parte 18.

|        |                                                  |    |
|--------|--------------------------------------------------|----|
| ley 13 | lo que no se mira deja de funcionar en silencio  | 50 |
| ley 15 | la señal existe y nadie la mira                  | 39 |
| ley 22 | un procedimiento nunca ejecutado no funciona     | 34 |
| ley 14 | el coste se decide al crear, no al pagar         | 31 |
| ley 16 | un control que estorba se rodea                  | 29 |
| ley 20 | lo que no tiene dueño se filtra y se desperdicia | 28 |
| ley 21 | el acoplamiento vive en quién escribe            | 23 |
| ley 25 | lo provisional sobrevive a su motivo             | 18 |
| ley 23 | la capacidad la limita lo que ya se mantiene     | 16 |
| ley 26 | el valor por defecto sirve a la demostración     | 12 |
| ley 24 | lo que no está en el diagrama no se analiza      | 12 |
| ley 17 | se optimiza la medida, no el objetivo            | 12 |
| ley 19 | la compensación hace invisible el fallo          | 10 |
| ley 18 | lo asíncrono traslada la garantía, no la elimina | 8  |

Y la parte 18 obliga a escribir una ley nueva, que explica el fallo de la predicción 2:

## LEY 27

un control solo actúa sobre lo que cambia;  
lo que ya existe sigue incumpliendo hasta que alguien  
lo toque

apariciones en esta parte

5

clase 217 mover 61 suscripciones al grupo correcto  
corrigió CERO recursos existentes; 14.200  
siguieron incumpliendo  
clase 219 la automatización de zonas DNS no enlazó las  
creadas antes; 39 radios quedaron fuera  
clase 220 el despliegue incremental nunca borra lo que  
deja de estar declarado: 1.140 huérfanos  
clase 222 activar la política de red no cambia lo ya  
desplegado, y en algunas configuraciones  
exige recrear el clúster  
clase 226 cerrar una recomendación no impide que el  
recurso siguiente nazca igual

y lo que la distingue

la ley 25 dice que lo provisional se queda  
la ley 26 dice que el valor inicial está mal elegido  
la 27 dice algo distinto: que ARREGLAR LA REGLA no  
arregla lo que ya se hizo con la regla anterior

→ y el remedio no es una política mejor: es una TAREA DE  
REMEDIACIÓN, que es trabajo, y hay que planificarlo  
→ toda implantación de un control necesita dos planes:  
el de lo nuevo y el de lo viejo

La hipótesis de la parte 19 (clases 229 a 240, Google Cloud en producción), escrita antes de estudiarla:

1. la tercera nube confirmará la equivalencia conceptual y  
volverá a diferir en el modelo operativo; y esta vez lo  
que más costará no será aprender lo distinto sino  
DESAPRENDER lo de las dos anteriores: los errores serán  
de trasladar suposiciones que aquí no valen
2. la jerarquía de proyectos y la red compartida serán otra  
vez la decisión que condiciona todo, con un matiz: aquí  
el proyecto es una frontera más fuerte que la suscripción,  
y eso hará que el error frecuente sea el CONTRARIO –  
demasiados proyectos, no demasiado pocos
3. la identidad volverá a ser el eje, y el error más  
frecuente volverá a ser el ámbito amplio: una asignación  
en la organización o en la carpeta en vez de en el  
recurso ley 27, 218
4. los valores por defecto volverán a estar mal elegidos para  
producción, y aquí fallarán sobre todo en RED: la red  
global y los servicios con acceso público por defecto  
serán la fuente principal ley 26
5. y la predicción que ya no tiene mérito, con su corolario:  
los problemas del proyecto serán otra vez de las leyes  
25, 15 y 22. Lo que sí es refutable es esto: \*\*la  
proporción de hallazgos que detecte una comprobación  
automática y periódica será mayor que en las partes 17 y  
18\*\*, porque en esas dos aprendimos a montarlas. Si no lo  
es, el aprendizaje no se está trasladando

Y el cierre de la parte 18: de once clases, lo que más dinero movió no fue ninguna decisión de arquitectura sino dos  
casillas de un asistente de creación —el nivel de consistencia y la política de índices—, y lo que más riesgo concentró  
fue una sola asignación de permisos con el ámbito demasiado alto. La parte 19 hace el mismo recorrido en Google  
Cloud, empezando por su jerarquía de recursos y su red compartida. Es la clase 229.

## 4. Comparar las dos nubes, con cifras

Con el mismo sistema montado en dos nubes, se puede comparar de verdad. Y conviene, porque es la única forma de  
separar lo que es propio del proveedor de lo que es propio del método.

LO QUE RESULTÓ EQUIVALENTE

el techo de disponibilidad se calcula igual      clase 185  
 la aritmética de colas y concurrencia              clase 186  
 la decisión de consistencia por operación          clase 187  
 la idempotencia y la cola de fallidos              clases 210, 224  
 la disciplina de despliegue escalonado  
 la estructura del código por ciclo de vida  
 y las pruebas negativas, una a una

#### LO QUE NO

el modelo de gobierno: en Azure las políticas se heredan  
 y son fuertes; en AWS las barreras y los controles  
 están más repartidos  
 el modelo de permisos: papel más ámbito frente a política  
 con condiciones  
 la observabilidad: aquí hay que crear el diagnóstico  
 recurso a recurso  
 y la consistencia configurable, que no tiene equivalente

#### Y la comparación de esfuerzo, medida:

|                                                            | AWS       | Azure     |
|------------------------------------------------------------|-----------|-----------|
| tiempo hasta el primer despliegue productivo               | 9 semanas | 7 semanas |
| → más rápido la segunda vez, por el método, no por la nube |           |           |
| líneas de infraestructura como código                      | ~4.100    | ~3.800    |
| valores por defecto que hubo que cambiar                   | 24        | 19        |
| pruebas negativas ejecutadas que fallaron la primera vez   | 19<br>7   | 19<br>8   |
| coste mensual del mismo sistema                            | 16.700 €  | 17.400 €  |
| → diferencia del 4 %, dentro del ruido                     |           |           |
| tiempo dedicado a aprender el modelo OPERATIVO             | —         | 3 meses   |
| → y esto es lo que la predicción 4 acertaba                |           |           |

#### Y las dos conclusiones que se pueden defender:

- 1 el coste de un sistema equivalente es parecido  
 → elegir nube por precio de lista es un error  
 → lo que cambia el coste son las decisiones de diseño,  
 no el proveedor                                              clases 216, 227
- 2 el coste de OPERAR dos nubes no es el doble: es más  
 dos modelos de gobierno, dos de permisos, dos de  
 observabilidad, dos calendarios de actualización  
 → y por eso la multinube se justifica por requisitos,  
 no por preferencia                                              clase 157

#### Y una advertencia sobre el traslado:

las suposiciones de la nube anterior son el mayor riesgo  
 «esto se hereda» — aquí no  
 «esto ya viene activado» — aquí no  
 «el borrado no se propaga» — aquí sí  
 → y por eso el orden de la parte empieza otra vez por lo  
 que condiciona todo, en vez de por lo que ya se sabe

#### Y la lista de comprobación de la clase:

- el sistema se construyó en el orden por coste de cambio
- hay lista explícita de valores por defecto cambiados
- el alcance de cada identidad está medido
- las zonas DNS están enlazadas a todas las redes
- la consistencia está decidida por operación
- la instrumentación es estándar
- se simulan técnicas y se publica la proporción detectada
- hay plan de remediación de lo existente, no solo de lo nuevo

- las 19 pruebas negativas se ejecutaron y hay fallos publicados
- el entorno se despliega de cero desde el código
- el coste está atribuido por encima del 90 %
- está escrito lo que no se hace

Y el cierre que enlaza con la clase siguiente: la parte 19 repite el recorrido en Google Cloud, con el riesgo añadido de trasladar suposiciones que allí no valen. Empieza por la jerarquía de recursos y la red compartida, en la clase 229.

## Ejemplo trabajado

El sistema de CloudShop en producción en Azure. Lo que sigue es la lista de valores por defecto cambiados, el resultado de las diecinueve pruebas negativas —de las que fallaron ocho— y la comparación con el mismo sistema en AWS.

La lista de valores por defecto cambiados:

| servicio                       | por defecto                        | cambiado a                                  |
|--------------------------------|------------------------------------|---------------------------------------------|
| base distribuida               | consistencia fuerte                | acotada 5 s, sesión y eventual por petición |
| base distribuida               | indexa todos los campos            | 7 de 61                                     |
| base distribuida               | 1 región                           | 2 (lectura)                                 |
| grupo de seguridad             | salida a internet permitida        | ruta al cortafuegos                         |
| recursos                       | sin diagnóstico                    | por política                                |
| registros                      | retención global                   | por tabla                                   |
| registros                      | plan analítico                     | básico donde procede                        |
| app service                    | acceso público                     | punto privado                               |
| app service                    | salida pública                     | integración de red                          |
| app service                    | config no específica de ranura     | marcada por ranura                          |
| clúster                        | política de red desactivada        | activada                                    |
| clúster                        | red plana (asistente)              | superpuesta                                 |
| bus                            | bloqueo 30 s                       | 120-300 s                                   |
| bus                            | sin renovación de bloqueo          | activada                                    |
| flujo                          | retención 1 día                    | 3 días                                      |
| flujo                          | posición antes de procesar         | después                                     |
| despliegue                     | modo incremental sin ciclo de vida | pilas de despliegue                         |
| políticas                      | asignadas en suscripción           | en grupos de administración                 |
| alertas                        | grupos por equipo                  | uno por turno                               |
| total                          |                                    | 19                                          |
| que funcionaban sin cambiarlos |                                    | 19                                          |

Las diecinueve pruebas negativas: ocho fallaron.

- ✓ quitar una política heredada desde suscripción imposible
- ✓ crear recurso sin etiquetas rechazado
- ✓ crear en región no permitida rechazado
- ✗ obtener la identidad de otro espacio de nombres
  - 1 de 7 credenciales federadas ataba solo el emisor: la del operador de base vectorial, añadida después de la revisión clase 222
- ✓ asumir identidad federada desde otro repositorio denegado
- ✗ activar papel privilegiado sin aprobación
  - 2 papeles se habían añadido como elegibles sin exigir aprobación, al crear un equipo nuevo
- ✓ entrar con la cuenta de emergencia 45 s
- ✓ alcanzar un radio desde otro radio denegado
- ✗ resolver nombre con punto privado desde cada red
  - 2 radios creados el mes anterior no tenían las zonas enlazadas: la automatización se había desplegado DESPUÉS de crearlos ley 27, 219

- ✓ alcanzar servicio con punto privado desde internet  
denegado
- ✗ sacar datos a un destino no declarado  
→ funcionó desde el clúster: la política de red restringía entre pods, no la salida a internet  
clase 222
- ✓ desplegar quitando un recurso de la plantilla borrado
- ✗ borrar la pila y comprobar los datos  
→ una cuenta de almacenamiento de un servicio nuevo no tenía bloqueo de borrado ni estaba en la pila de datos
- ✓ mismo mensaje 50 veces 1 efecto
- ✓ mensaje en cola de fallidos → alerta 38 s
- ✗ perder una zona completa  
→ 12 min 40 s de degradación: dos servicios añadidos tras el último experimento no tenían restricción de reparto  
clase 227
- ✗ simular 14 técnicas de ataque 13 de 14  
→ la que falta, aceptada por escrito
- ✗ provocar la condición de cada alerta  
→ 4 de 58 no llegaron; 3 por umbral y 1 en estado de error  
clase 225
- ✓ desplegar el entorno de cero 94 min

Y el análisis de las ocho:

seis por elementos AÑADIDOS después de la última revisión

- una credencial federada
- dos papeles elegibles
- dos radios sin zonas enlazadas
- una cuenta de almacenamiento sin bloqueo
- dos servicios sin restricción de reparto

dos por un control que no cubría lo que se creía

- política de red que no restringe la salida
- umbrales de alerta

- y es el mismo diagnóstico de la clase 216: el sistema creció y las comprobaciones no crecieron con él
- con un matiz nuevo: cuatro de los seis casos son de la ley 27, porque la automatización llegó después que el recurso

Y la corrección de método que salió:

toda automatización nueva se acompaña de una TAREA DE REMEDIACIÓN sobre lo existente  
y una comprobación periódica que compare el estado real con el esperado, no solo en el momento de crear

- y esa comprobación encontró, en los tres meses siguientes
  - 5 radios sin zonas enlazadas
  - 3 recursos sin bloqueo de borrado
  - 2 credenciales federadas mal atadas
- todos, creados después de la automatización correspondiente

Las cifras del sistema en producción, tras tres meses:

|                                  |          |           |
|----------------------------------|----------|-----------|
| p99 del flujo de compra          | < 500 ms | 438 ms    |
| disponibilidad observada         | 99,8 %   | 99,84 %   |
| coste mensual                    | 15.000 € | 17.400 €  |
| coste por pedido                 | 0,050 €  | 0,051 €   |
| pérdida de una zona: degradación | 0 min    | 12 min 40 |
| (tras corregir)                  |          | 0 min     |
| coste atribuido                  | 90 %     | 94 %      |
| alertas por turno                | < 2      | 0,9       |
| técnicas simuladas detectadas    | > 90 %   | 13/14     |
| despliegue del entorno de cero   | —        | 94 min    |

La comparación con AWS, del mismo sistema:

|                          |          |          |
|--------------------------|----------|----------|
| p99 del flujo de compra  | 412 ms   | 438 ms   |
| disponibilidad observada | 99,86 %  | 99,84 %  |
| coste mensual            | 16.700 € | 17.400 € |
| coste por pedido         | 0,046 €  | 0,051 €  |

|                                                                  |           |           |
|------------------------------------------------------------------|-----------|-----------|
| valores por defecto cambiados                                    | 24        | 19        |
| pruebas negativas fallidas                                       | 7         | 8         |
| tiempo hasta producción                                          | 9 semanas | 7 semanas |
| líneas de infraestructura                                        | ~4.100    | ~3.800    |
| equipo dedicado a la plataforma                                  | 2,1       | 2,4       |
| → la diferencia está en el modelo operativo, no en la tecnología |           |           |

Y las tres cosas que se decidió no hacer:

no operar las dos nubes en activo-activo: el coste de  
operar dos modelos de gobierno no compensa clase 157  
no migrar las cargas de AWS: funcionan  
no unificar la observabilidad en un solo proveedor  
todavía: se revisa cuando el volumen lo justifique

La lección que este proyecto deja: los diecinueve valores por defecto cambiados funcionaban todos sin cambiarlos, y dos de ellos —dos casillas de un asistente— costaban dos mil setecientos euros al mes. De las ocho pruebas negativas fallidas, cuatro fueron por recursos creados antes de que existiera la automatización que los cubriría, que es la ley 27 en su forma más directa. Y comparado con AWS, el mismo sistema costó un 4 % más y necesitó un 14 % más de equipo: la diferencia está en operar dos modelos, no en la tecnología.

## Laboratorio guiado

Ejecuta desde la raíz:

```
python classes/part-18-azure-production-architecture/228-proyecto-cloudshop-productivo-en-azure/lab.py
```

El laboratorio selecciona el motor de práctica capstone y produce labresult.json. El escenario, sus comprobaciones y el artefacto esperado corresponden a esta clase; no requiere credenciales y deja explícito qué debe revalidarse en un sandbox real.

1. Lee exercise.steps y formula una predicción antes de ejecutar.
2. Ejecuta la práctica y verifica todos los elementos de checks.
3. Provoca el caso de negativetest y explica la señal observada.
4. Materializa cloudshop-azure en evidence/ usando la plantilla indicada.
5. Para proveedor real, sigue sandbox.requires, registra costo y ejecuta destroy.

## Evidencia esperada

El artefacto principal es un incremento integrado, demostrable y documentado. Además, la entrega debe incluir el comando ejecutado, la salida estructurada y una conclusión que no exceda lo observado.

## Reto verificable

Construye cloudshop-azure para el caso CloudShop. Incluye una alternativa descartada, un supuesto que pueda falsarse, una prueba de fallo y una decisión de rollback.

## ■ Criterio de aceptación

- [ ] lab.py termina con código 0 y genera JSON válido.
- [ ] La entrega conecta al menos tres requisitos con mecanismos verificables.
- [ ] Existe una prueba positiva y una prueba negativa con evidencia.
- [ ] Seguridad, costo y operación aparecen como decisiones, no como anexos.
- [ ] Se declara una limitación y una condición que obligaría a revisar el diseño.
- [ ] Otra persona puede repetir el recorrido sin conocimiento tácito.

## ■ Errores frecuentes

| Síntoma                                                                              | Causa probable                                                                              | Corrección                                                                                                                         |
|--------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------|
| Se implanta un control y los recursos existentes siguen incumpliendo                 | Los controles actúan sobre creaciones y modificaciones, no hacia atrás                      | Toda implantación necesita dos planes: el de lo nuevo y una tarea de remediación de lo existente.                                  |
| Una automatización cubre unos recursos y no otros                                    | Los recursos anteriores a la automatización no pasaron por ella                             | Ejecuta la automatización sobre lo existente y añade una comprobación periódica que compare el estado real con el esperado.        |
| Al trasladar la arquitectura a otra nube fallan cosas que en la anterior funcionaban | Se trasladaron suposiciones del modelo operativo anterior                                   | Empieza por lo que condiciona todo en la nube nueva y comprueba explícitamente qué se hereda, qué viene activado y qué se propaga. |
| Las pruebas negativas pasan y aparecen huecos nuevos                                 | El sistema creció y las comprobaciones no crecieron con él                                  | Añade una prueba negativa por cada capacidad nueva y ejecútalas periódicamente, no solo al terminar.                               |
| Se elige la nube por precio de lista y no se ahorra                                  | El coste lo deciden las decisiones de diseño, no el proveedor                               | Compara el coste del mismo sistema montado bien en ambas; la diferencia suele estar dentro del ruido.                              |
| Operar dos nubes consume mucho más equipo del previsto                               | Se contó el código y no los modelos de gobierno, permisos, observabilidad y actualizaciones | Justifica la multinube por requisitos y no por preferencia, contando el coste operativo real.                                      |

## ■ Seguridad, ética y costo

Trabaja con cuentas propias o sandboxes autorizados. No publiques secretos, identificadores reales ni datos personales. Antes de crear recursos pagos define presupuesto, etiquetas y comando de destrucción; después verifica que no queden recursos huérfanos. Los ejemplos locales enseñan contratos, pero no certifican cumplimiento ni disponibilidad de producción.

## ■ Preguntas de comprobación

1. ¿Cuál de las cinco predicciones de la clase 216 falló y en qué mitad?
2. ¿Qué dice la ley 27 y en qué se distingue de las leyes 25 y 26?
3. ¿Por qué saber las leyes 25, 15 y 22 no basta para evitar que se cumplan?
4. ¿Qué se correspondió entre las dos nubes y qué no?
5. ¿Cuántas de las pruebas negativas fallidas se deben a la ley 27?

## Referencias

- Microsoft (2025). Azure Well-Architected Framework. <<https://learn.microsoft.com/en-us/azure/well-architected/>>
- Microsoft (2025). Cloud Adoption Framework: Azure landing zones. <<https://learn.microsoft.com/en-us/azure/cloud-adoption-framework/ready/landing-zone/>>
- Microsoft (2025). Azure Policy remediation tasks. <<https://learn.microsoft.com/en-us/azure/governance/policy/how-to/remediate-resources>>
- Beyer, B. y otros (2018). The Site Reliability Workbook. <<https://sre.google/workbook/table-of-contents/>>
- Basiri, A. y otros (2016). Chaos engineering. <<https://ieeexplore.ieee.org/document/7503833>>
- Documentación oficial vigente del servicio implementado; registra URL y fecha de consulta.

Descargar: Parte 18 en PDF · Recorrido de Azure en PDF · Manual integral

| Anterior                                                     | Índice              | Siguiente                                                  |
|--------------------------------------------------------------|---------------------|------------------------------------------------------------|
| ← 227 · Cost Management, Advisor, resiliencia y Chaos Studio | Parte 18 · Programa | 229 · Resource Manager, folders, Shared VPC y guardrails → |

## Evaluación — 228 Proyecto: CloudShop productivo en Azure

### Preguntas

1. Explica el problema que resuelve esta capacidad sin mencionar un proveedor.
2. Identifica una frontera de responsabilidad y su propietario.
3. Compara dos alternativas mediante confiabilidad, seguridad, costo y operación.
4. ¿Qué demuestra el laboratorio y qué no puede demostrar?
5. Propón un caso límite o una prueba de fallo.

### Reto verificable

Entrega cloudshop-azure con diagrama o configuración, evidencia de ejecución, alternativa descartada, riesgo residual y criterio de rollback.

### Criterio de aceptación

- ☐ Resultado reproducible por una segunda persona.
- ☐ Evidencia vinculada a cada afirmación técnica.
- ☐ Prueba negativa o de fallo incluida.
- ☐ Costos y permisos expresados con unidades y alcance.
- ☐ Limitaciones declaradas sin presentar la simulación como producción.

### Escala

| Nivel             | Evidencia                                                |
|-------------------|----------------------------------------------------------|
| A — competente    | Cumple todo y defiende trade-offs con datos.             |
| B — en desarrollo | Cumple lo esencial; falta profundidad en una dimensión.  |
| C — inicial       | Artefacto parcial o conclusión sin evidencia suficiente. |
| 0                 | Sin entrega reproducible.                                |