

Multi-Cloud Engineering Program

Parte 19 — Google Cloud: arquitectura de datos 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	19 de 23
Clases	229–240
Evaluaciones	12
Horas estimadas	52

Índice

Alcance de este cuaderno	2
Índice	3
Parte 19 — Google Cloud: arquitectura de datos y operación en producción	4
229 — Resource Manager, folders, Shared VPC y guardrails	6
230 — Workload Identity Federation, IAM Conditions y PAM	17
231 — Red global, load balancing, PSC y Cloud DNS	28
232 — Terraform, Infrastructure Manager y policy validation	38
233 — Cloud Run, Functions, API Gateway y Workflows	49
234 — GKE Autopilot, Workload Identity y Config Sync	60
235 — Cloud SQL, Spanner, Firestore y Bigtable	71
236 — BigQuery, Dataflow, Dataproc y gobernanza de datos	82
237 — Pub/Sub, Eventarc y entrega exactamente-una-vez	92
238 — Cloud Operations, Trace y OpenTelemetry	103
239 — SCC, VPC Service Controls, KMS y FinOps	113
240 — Proyecto: CloudShop productivo en Google Cloud	123

Parte 19 — Google Cloud: arquitectura de datos y operación en producción

← Parte 18 · Índice completo · Parte 20 →

Descargar: Esta parte en PDF · Recorrido de Google Cloud en PDF · Manual integral

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

Operar CloudShop con la red global, servicios administrados, seguridad y plataforma de datos de Google Cloud.


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

Google Cloud combina una jerarquía estricta de recursos con una red global y servicios data-first; proyecto, cuota e IAM forman una unidad operativa.

Secuencia



Clases

ID	Clase	Laboratorio	Horas
229	Resource Manager, folders, Shared VPC y guardrails	governance	4
230	Workload Identity Federation, IAM Conditions y PAM	iam	4
231	Red global, load balancing, PSC y Cloud DNS	network	4
232	Terraform, Infrastructure Manager y policy validation	iac	4
233	Cloud Run, Functions, API Gateway y Workflows	serverless	4
234	GKE Autopilot, Workload Identity y Config Sync	kubernetes	4
235	Cloud SQL, Spanner, Firestore y Bigtable	data	4
236	BigQuery, Dataflow, Dataproc y gobernanza de datos	data	4
237	Pub/Sub, Eventarc y entrega exactamente-una-vez	messaging	4
238	Cloud Operations, Trace y OpenTelemetry	observability	4
239	SCC, VPC Service Controls, KMS y FinOps	security	4
240	Proyecto: CloudShop productivo en Google Cloud	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

- Google Cloud Architecture Framework — Google.
- Google Cloud Certified Professional Cloud Architect Study Guide — Dan Sullivan.
- Data Engineering with Google Cloud — Adi Wijaya.

229 — Resource Manager, folders, Shared VPC y guardrails

Parte: 19 — Google Cloud: arquitectura de datos y operación en producción Nivel: avanzado · Horas estimadas: 4
Laboratorio: governance · Estado: EXECUTABLECORE

Propósito

Diseñar la jerarquía de Google Cloud —organización, carpetas y proyectos— y su red compartida, con la advertencia que abre la parte: el mayor riesgo aquí no es lo que se desconoce, sino trasladar suposiciones de las dos nubes anteriores. La clase explica por qué el proyecto es una frontera más fuerte que una suscripción, qué controlan las políticas de organización frente a los permisos, y por qué la red compartida separa quién opera la red de quién la usa.

Resultados de aprendizaje

Al finalizar podrás:

1. Repartir cargas entre carpetas y proyectos con criterio.
2. Distinguir política de organización de permiso, y usar cada una.
3. Diseñar red compartida separando operación de uso.
4. Evitar los errores de trasladar suposiciones de otras nubes.
5. Corregir una jerarquía con demasiados o muy pocos proyectos.

Conceptos centrales


Concepto	Comprensión verificable
organización	Raíz de la jerarquía, ligada al dominio. Donde se aplican las políticas que nadie puede quitar desde abajo.
carpeta	Agrupación de proyectos y otras carpetas. Nivel intermedio donde se heredan políticas y permisos.
proyecto	Frontera de recursos, facturación, cuota, API habilitadas y red. Más fuerte que una suscripción.
política de organización	Restricción sobre qué se puede configurar. Distinta de un permiso: limita el qué, no el quién.
red compartida	Red de un proyecto anfitrión, usada por proyectos de servicio que no la administran.
cuota	Límite por proyecto, servicio y región. Se topa antes que la capacidad y se pide con antelación.

Modelo mental

Google Cloud combina una jerarquía estricta de recursos con una red global y servicios data-first; proyecto, cuota e IAM forman una unidad operativa.

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 el proyecto es fuerte

La estructura tiene tres niveles y el del medio es opcional, pero el de abajo tiene más peso que sus equivalentes en otras nubes.

ORGANIZACIÓN

raíz, ligada al dominio
aquí van las políticas de organización y los permisos que se heredan

CARPETA

agrupación de proyectos, anidable
nivel natural para políticas por entorno o por unidad

PROYECTO

frontera de
recursos
facturación
CUOTAS
API habilitadas ← esto no existe en otras nubes
red (salvo que use una compartida)
y ámbito natural de muchos permisos

Y la diferencia que hay que interiorizar:

UN PROYECTO ES MÁS BARATO Y MÁS FUERTE que una suscripción
crear uno es inmediato y gratis
las API se habilitan por proyecto: lo que no está
habilitado, no existe
y borrar un proyecto se lleva todo lo de dentro

→ y por eso el error frecuente aquí es el CONTRARIO al de Azure: demasiados proyectos, no demasiado pocos

Y el criterio de reparto, con la tensión que hay que resolver:

UN PROYECTO POR CARGA Y ENTORNO

+ aislamiento fuerte, cuota propia, facturación clara
- más proyectos que gestionar: políticas, permisos, presupuestos, conexiones de red

UN PROYECTO POR EQUIPO Y ENTORNO

+ menos objetos que gestionar
- las cargas comparten cuota y se afectan

CRITERIO

por carga y entorno para producción
agrupado para desarrollo, si el volumen no lo justifica
→ y con la entrega AUTOMATIZADA, para que crear uno cueste
minutos y no semanas ley 16

Y las carpetas, que casi siempre se organizan de una de dos formas:

POR ENTORNO producción · no producción · sandbox
+ las políticas por entorno son las que más varían
- las unidades de negocio quedan mezcladas

POR UNIDAD, y dentro por entorno
+ refleja la organización
- la empresa se reorganiza antes que la nube clase 183

→ por entorno arriba y por unidad debajo suele envejecer mejor

Y una advertencia de traslado, la primera de muchas:

X «esto se hereda como allí»
las políticas de organización se heredan, sí
pero su combinación tiene reglas propias: algunas se fusionan y otras se sustituyen
→ hay que leerlas, no suponerlas

2. Políticas de organización y permisos: dos cosas

Aquí hay una separación que en otras nubes está mezclada, y confundirla produce controles que no controlan.

POLÍTICA DE ORGANIZACIÓN
restringe QUÉ se puede configurar
ejemplos
prohibir direcciones IP externas en máquinas
restringir las regiones donde se puede crear
prohibir claves de cuenta de servicio
exigir que los recursos no sean públicos
restringir qué dominios pueden recibir permisos
→ se aplica en organización, carpeta o proyecto
→ y NO depende de quién lo intente: ni el dueño puede

PERMISO
decide QUIÉN puede hacer QUÉ sobre QUÉ recurso
→ y se hereda hacia abajo

→ la política de organización es la barrera; el permiso es la puerta
→ y una barrera bien puesta hace que el permiso amplio sea menos peligroso clase 169

Y las políticas que conviene tener desde el primer día:

prohibir claves de cuenta de servicio
→ obliga a usar federación e identidad de carga clase 230

prohibir IP externas salvo donde se declare
restringir regiones
prohibir que los recursos se hagan públicos
restringir a qué dominios se pueden dar permisos
→ impide dar acceso a una cuenta personal por error
prohibir el reenvío de puertos y el acceso directo
exigir el uso de la red compartida

Y la disciplina de implantación, que es la de siempre:

- 1 aplicar en modo de solo registro donde exista
- 2 medir el incumplimiento actual
- 3 corregir o exceptuar, con dueño y fecha
- 4 aplicar

→ y recordando que no actúa hacia atrás ley 27

Las API habilitadas, que son un control que sorprende:

un servicio no se puede usar si su API no está habilitada en el proyecto
→ es un control de superficie muy efectivo y gratuito
→ habilitar solo lo que se usa reduce el alcance de un

compromiso

clase 189

y la trampa

habilitar una API es fácil y nadie la deshabilita

→ inventario periódico de API habilitadas y sin uso

ley 25

Y las cuotas, con la lección de la clase 222:

son por proyecto, servicio y región

se topan antes que la capacidad

se piden con antelación y tardan

→ margen del 30 % sobre el máximo del escalado

→ alerta al 80 %

clase 262

→ y no actualizar ni escalar si el margen no da

3. Red compartida: separar operar de usar

La red compartida es la pieza que más distingue a esta nube en gobierno, y resuelve un problema real.

EL PROBLEMA

si cada proyecto tiene su red, hay que conectarlas todas

entre sí

→ y cada equipo administra su red, con lo que eso implica

LA RED COMPARTIDA

un PROYECTO ANFITRIÓN contiene la red y sus subredes

los PROYECTOS DE SERVICIO usan esas subredes

→ los recursos viven en el proyecto de servicio

→ la red la administra el equipo de plataforma

QUÉ SEPARA

quién OPERA la red: plataforma

quién la USA: los equipos

→ y un equipo no puede crear rutas, emparejamientos ni

reglas por su cuenta

Y las decisiones que hay que tomar:

¿UNA RED COMPARTIDA O VARIAS?

una por entorno es lo habitual

→ producción y no producción NUNCA en la misma

¿QUÉ SUBREDES SE CEDEN A QUIÉN?

se ceden subredes concretas a proyectos concretos

→ un proyecto de servicio solo ve las subredes cedidas

→ y eso es un control de alcance real

clase 199

¿QUIÉN PUEDE CREAR REGLAS DE CORTAFUEGOS?

plataforma, con etiquetas o cuentas de servicio como

selector

→ y los equipos piden, no crean

→ si pedir tarda días, crearán recursos con IP pública

ley 16

Y las particularidades de red que hay que conocer para no trasladar suposiciones:

LA RED ES GLOBAL, las subredes son regionales

→ una sola red puede abarcar todas las regiones

→ y por tanto no hace falta emparejar entre regiones

→ es distinto de las otras dos nubes

clase 231

LAS REGLAS DE CORTAFUEGOS SON DE LA RED, no de la subred

con prioridades y con selectores por etiqueta o por

cuenta de servicio

→ seleccionar por cuenta de servicio es mucho mejor que

por etiqueta: la etiqueta la puede poner cualquiera con

permiso de instancia

LA SALIDA A INTERNET ESTÁ PERMITIDA por defecto

→ y hay que cerrarla explícitamente

ley 26

Y el error de traslado más caro en esta parte:

✗ «cada proyecto tendrá su red, como cada cuenta la suya»

→ produce decenas de redes que hay que conectar

- y pierde la ventaja principal de esta nube
- la red compartida es la elección por defecto salvo razón concreta

4. Facturación, entrega y corrección

La facturación, que se organiza distinto:

- una CUENTA DE FACTURACIÓN se asocia a muchos proyectos
 - y el desglose por proyecto es directo y limpio
 - por eso la separación por proyecto es también una decisión de atribución clase 239

- y las etiquetas
 - aquí se llaman de otra forma y hay dos mecanismos
 - unas sirven para facturación y organización
 - otras para condiciones de permiso y políticas
 - y no son intercambiables: hay que saber cuál se usa para qué

La entrega de proyectos, que decide si el gobierno se cumple:

- UN PROYECTO ENTREGADO trae
 - colocado en la carpeta correcta
 - cuenta de facturación asociada
 - API habilitadas mínimas
 - subredes cedidas de la red compartida
 - permisos base y cuentas de servicio
 - destinos de registro configurados clase 238
 - presupuesto y alertas
 - y las políticas heredadas aplicando

- Y EL PLAZO
 - si tarda semanas, los equipos usarán proyectos personales o pedirán permisos amplios en los que ya tienen ley 16
 - automatizar la entrega es lo que hace cumplir el resto

Corregir una jerarquía, con el problema propio de esta nube:

- DEMASIADOS PROYECTOS
 - el síntoma: cientos de proyectos, muchos sin uso
 - y cada uno con su presupuesto, permisos y API
 - corrección
 - inventario con último uso y dueño
 - los sin actividad en 90 días, a retirar ley 25
 - y consolidar los de desarrollo por equipo

- PROYECTOS EN LA CARPETA EQUIVOCADA
 - mover es sencillo y las políticas empiezan a aplicar
 - pero lo ya creado sigue incumpliendo ley 27
 - hace falta remediación, no solo mover

- PROYECTOS SIN CARPETA, colgando de la organización
 - no reciben las políticas por entorno
 - es el hallazgo típico del primer inventario

Y lo que hay que vigilar:

- proyectos sin carpeta, sin dueño o sin presupuesto
- API habilitadas y sin uso
- cuotas frente al máximo del escalado
- políticas de organización con excepciones, y su antigüedad
- subredes cedidas y no usadas
- y recursos creados fuera de la red compartida

Y la lista de comprobación de la clase:

- hay carpetas por entorno, y proyectos por carga
- ningún proyecto cuelga directamente de la organización
- las políticas de organización están en organización o carpeta
- están las políticas mínimas: sin claves de cuenta de servicio, sin IP externas, regiones, no público, dominios
- se midió el incumplimiento antes de aplicar
- hay plan de remediación de lo existente

- solo están habilitadas las API que se usan
- hay red compartida por entorno, con subredes cedidas
- las reglas de cortafuegos seleccionan por cuenta de servicio, no por etiqueta
- la salida a internet está cerrada explícitamente
- las cuotas tienen margen y alerta al 80 %
- la entrega de un proyecto está automatizada y tarda minutos
- hay inventario de proyectos con último uso y dueño

Y el cierre que enlaza con la clase siguiente: con la jerarquía y la red repartidas, el control que decide el alcance real vuelve a ser la identidad, y aquí hay un elemento que no existe en las otras dos nubes: las condiciones en las asignaciones. Es la materia de la clase 230.

Ejemplo trabajado

CloudShop monta su organización en Google Cloud, con la experiencia de las dos nubes anteriores. Lo que sigue son los tres errores de traslado que cometió el equipo, el inventario que encontró 214 proyectos, y la red compartida que redujo 41 redes a dos.

El punto de partida, tras dos años de uso sin gobierno:

proyectos	214
colgando de la organización, sin carpeta	189
con dueño identificable	94
sin actividad en 90 días	71
sin presupuesto asociado	203
redes	41
una por proyecto que la necesitaba	
emparejamientos entre ellas	67
políticas de organización aplicadas	2
claves de cuenta de servicio	341
con más de 1 año	218

Los tres errores de traslado, cometidos en las primeras semanas:

ERROR 1 · «cada proyecto con su red»
 el equipo venía de un modelo de cuenta por carga con red propia
 creó 12 redes nuevas antes de que alguien preguntara
 → y la conexión entre ellas exigía emparejamientos, que no son transitivos

al descubrir la red compartida
 12 redes nuevas → 0
 41 redes existentes → 2 (producción y no producción)
 67 emparejamientos → 4
 y una diferencia que no habían previsto
 la red es GLOBAL: una sola red cubre las 3 regiones
 → no hacen falta emparejamientos entre regiones

ERROR 2 · «las reglas de cortafuegos son por subred»
 se crearon reglas asumiendo que aplicaban a la subred
 → aquí son de la RED, con selectores
 → y las primeras se escribieron con selectores por ETIQUETA
 → cualquiera con permiso sobre una instancia podía ponerle la etiqueta que abría el acceso a la base

corrección
 selectores por CUENTA DE SERVICIO
 → poner una cuenta de servicio a una instancia exige permiso sobre esa cuenta
 → y eso sí es un control clase 230

ERROR 3 · «los permisos amplios ya los limita la barrera»
 se asumió el modelo de la nube anterior
 → aquí la política de organización limita QUÉ se configura, no QUIÉN accede a los datos
 → una asignación amplia sobre almacenamiento seguía

dando acceso a los datos, con la barrera puesta

corrección

los dos controles, y no uno en lugar del otro
clase 230

Y la conclusión que el equipo escribió:

los tres errores fueron de SUPOSICIÓN, no de desconocimiento
cada uno venía de dar por válido algo de otra nube
→ y los tres se detectaron por casualidad, no por una comprobación
→ desde entonces, la primera tarea de cada servicio nuevo es leer qué se hereda, qué viene activado y qué se propaga
clase 228

La jerarquía nueva:

```
organización
■■■■ plataforma
■ ■■■■ red-compartida-prod      (proyecto anfitrión)
■ ■■■■ red-compartida-nopro    (proyecto anfitrión)
■ ■■■■ identidad
■ ■■■■ observabilidad
■ ■■■■ seguridad
■■■■ produccion
■ ■■■■ pedidos-prod
■ ■■■■ catalogo-prod
■ ■■■■ precios-prod
■ ■■■■ ... (14 proyectos, uno por carga)
■■■■ no-produccion
■ ■■■■ pedidos-pre, pedidos-dev
■ ■■■■ ... (28 proyectos)
■■■■ sandbox                    con caducidad de 60 días
```

Las políticas de organización, implantadas por orden:

política	incumplimiento inicial
sin claves de cuenta de servicio	341
sin IP externas en máquinas	118
regiones restringidas a la UE	41
sin recursos públicos	29
dominios permitidos para permisos	14
sin reenvío de puertos	62
uso obligatorio de red compartida	n/a (nuevo)

el orden que se siguió

- 1 dominios permitidos ← 14 casos, 2 días
y encontró 3 permisos concedidos a cuentas personales de ex empleados ley 25
- 2 sin recursos públicos ← 29 casos, 1 semana
de ellos, 4 almacenes con datos de clientes
- 3 regiones ← 41 casos, 3 semanas
- 4 sin IP externas ← 118 casos, 6 semanas
sustituidas por acceso mediante servicio de administración clase 256
- 5 sin claves de cuenta de servicio ← 341, 4 meses
el más largo, y el de más valor clase 230

y la remediación, que no vino sola

aplicar las políticas corrigió 0 recursos existentes
→ tareas de remediación planificadas aparte ley 27

El inventario de proyectos:

214 proyectos, con último uso y dueño

con actividad y dueño	94
con actividad y SIN dueño	49
→ 12 resultaron ser de equipos que ya no existen	
→ 3 tenían cargas en producción que nadie sabía que existían	ley 20
sin actividad en 90 días	71
→ apagados, y borrados 30 días después	

→ 2 reclamaciones, ambas restauradas en minutos

proyectos tras la limpieza	143
→ y consolidando los de desarrollo por equipo:	86

coste liberado	4.900 €/mes
de los cuales, en los 71 sin actividad	3.100 €

Y el hallazgo más incómodo:

uno de los 71 sin actividad tenía
una base de datos con una copia de la tabla de clientes
de 2023
sin cifrado con clave propia
sin registro de acceso
y con permisos de lectura para «todos los usuarios
autenticados» ← es decir, cualquier cuenta de Google

llevaba así	19 meses
lo encontró	el inventario, no una alerta ley 15

La red compartida, montada:

dos proyectos anfitriones: producción y no producción
red global por entorno; subredes por región
subredes cedidas a proyectos concretos
→ pedidos-prod ve su subred y nada más

reglas de cortafuegos
denegación por defecto en entrada y en SALIDA
selectores por cuenta de servicio
creadas por plataforma, pedidas por los equipos
→ y el plazo de una petición: 40 minutos, automatizado
con revisión

resultado	
redes	41 → 2
emparejamientos	67 → 4
reglas de cortafuegos	940 → 118
equipos que pueden crear rutas	41 → 1

La entrega de proyectos, automatizada:

antes petición por correo → 2 semanas
y 189 proyectos creados fuera del proceso
después plantilla que crea el proyecto con
carpeta, facturación, API mínimas, subred cedida,
permisos base, destinos de registro, presupuesto
plazo 14 min
proyectos creados fuera del proceso en 6 meses: 0

El resultado:

proyectos	214	86
sin carpeta	189	0
sin dueño	120	0
sin presupuesto	203	0
redes	41	2
claves de cuenta de servicio (las 12, con excepción registrada)	341	12
recursos públicos	29	0
permisos a cuentas fuera del dominio	14	0
coste mensual	28.700 €	21.400 €
plazo de entrega de un proyecto	2 semanas	14 min

La lección que esta clase deja: los tres errores del arranque no fueron por desconocer esta nube, sino por dar por válidas suposiciones de las otras dos, y ninguno lo detectó una comprobación: se descubrieron por casualidad. Y el inventario de proyectos —que no requería tecnología ninguna— encontró setenta y uno sin actividad, tres con cargas de producción que nadie conocía y una copia de la tabla de clientes legible por cualquier cuenta de Google desde hacía diecinueve meses.

Laboratorio guiado

Ejecuta desde la raíz:

```
python classes/part-19-gcp-production-architecture/229-resource-manager-folders-shared-vpc-y-guardrails/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 gcp-foundation 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 gcp-foundation 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
Aparecen decenas de redes que hay que conectar entre sí	Se trasladó el modelo de una red por cuenta o suscripción	Usa red compartida por entorno; la red es global y no hacen falta emparejamientos entre regiones.
Cualquiera puede abrir un acceso poniendo una etiqueta a su instancia	Las reglas de cortafuegos seleccionan por etiqueta	Selecciona por cuenta de servicio; asignarla exige permiso sobre esa cuenta.
Las barreras están puestas y siguen existiendo accesos amplios a los datos	Se confundió política de organización con permiso: la primera limita qué se configura, no quién accede	Usa los dos controles, no uno en lugar del otro.
Hay cientos de proyectos y nadie sabe cuáles sirven	Crear un proyecto es inmediato y nadie los retira	Inventario con último uso y dueño; apaga los inactivos, bórralos después y consolida los de desarrollo.
Mover proyectos a la carpeta correcta no corrige nada	Las políticas no actúan sobre lo ya creado	Planifica una tarea de remediación además del movimiento.
Los equipos crean recursos fuera del proceso	Conseguir un proyecto o una regla de cortafuegos tarda semanas	Automatiza la entrega de proyectos y las peticiones de reglas para que tarden minutos.

■ 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 hace que un proyecto sea una frontera más fuerte que una suscripción?
2. ¿Qué diferencia hay entre una política de organización y un permiso?
3. ¿Qué separa la red compartida y por qué importa?
4. ¿Por qué los selectores por cuenta de servicio son mejores que por etiqueta?
5. ¿Cuál es el error de reparto de proyectos característico de esta nube?

Referencias

- Google Cloud (2025). Resource hierarchy. <<https://cloud.google.com/resource-manager/docs/cloud-platform-resource-hierarchy>>
- Google Cloud (2025). Organization policy constraints. <<https://cloud.google.com/resource-manager/docs/organization-policy/org-policy-constraints>>
- Google Cloud (2025). Shared VPC overview. <<https://cloud.google.com/vpc/docs/shared-vpc>>
- Google Cloud (2025). VPC firewall rules and service account targets. <<https://cloud.google.com/firewall/docs/firewalls>>
- Google Cloud (2025). Landing zone design in Google Cloud. <<https://cloud.google.com/architecture/landing-zones>>
- Documentación oficial vigente del servicio implementado; registra URL y fecha de consulta.

Descargar: Parte 19 en PDF · Recorrido de Google Cloud en PDF · Manual integral

Anterior	Índice	Siguiente
← 228 · Proyecto: CloudShop productivo en Azure	Parte 19 · Programa	230 · Workload Identity Federation, IAM Conditions y PAM →

Evaluación — 229 Resource Manager, folders, Shared VPC y guardrails

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 gcp-foundation 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.

230 — Workload Identity Federation, IAM Conditions y PAM

Parte: 19 — Google Cloud: arquitectura de datos y operación en producción Nivel: avanzado · Horas estimadas: 4
Laboratorio: iam · Estado: EXECUTABLECORE

Propósito

Resolver la identidad en Google Cloud, donde el mecanismo tiene una pieza que no existe en las otras dos nubes: las condiciones en las asignaciones, que permiten conceder un permiso solo sobre ciertos recursos y durante cierto tiempo. La clase cubre la federación y las cuentas de servicio sin claves, la suplantación como sustituto de las credenciales guardadas, el ámbito de asignación —que vuelve a ser el error frecuente— y la elevación temporal con aprobación.

Resultados de aprendizaje

Al finalizar podrás:

1. Eliminar claves de cuenta de servicio con federación y suplantación.
2. Asignar permisos en el ámbito mínimo, con condiciones.
3. Distinguir quién actúa de qué identidad se usa, y auditarlo.
4. Configurar elevación temporal con aprobación y caducidad.
5. Detectar y reducir el alcance de las identidades más amplias.

Conceptos centrales


Concepto	Comprensión verificable
cuenta de servicio	Identidad de una carga. Puede usarse sin credenciales si se adjunta al recurso o se suplanta.
clave de cuenta de servicio	Credencial de larga duración en un fichero. Lo que hay que eliminar.
suplantación	Obtener un testigo de otra identidad con permiso para ello, sin credencial guardada.
federación de identidad de carga	Confianza en un emisor externo para que sus testigos suplanten una cuenta de servicio.
condición en la asignación	Expresión que limita cuándo y sobre qué recursos aplica un permiso.
identidad de carga del clúster	Vinculación entre una cuenta de servicio de Kubernetes y una de la nube, sin claves.

Modelo mental

Google Cloud combina una jerarquía estricta de recursos con una red global y servicios data-first; proyecto, cuota e IAM forman una unidad operativa.

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. Eliminar las claves

Una clave de cuenta de servicio es un fichero con una credencial que no caduca. Es lo que hay que eliminar, y aquí hay cuatro formas de no necesitarla.

- 1 **CUENTA DE SERVICIO ADJUNTA** – para lo que corre en la nube la máquina, la función o el servicio lleva una cuenta de servicio asociada
el código obtiene testigos del servicio de metadatos
→ sin credencial en ningún sitio

y la regla que se olvida
NO usar la cuenta de servicio POR DEFECTO del proyecto
→ tiene permisos amplios y la comparten todos los recursos del proyecto
→ una cuenta por carga, con sus permisos ley 26
- 2 **IDENTIDAD DE CARGA** – para lo que corre en un clúster una cuenta de servicio de Kubernetes se vincula con una de la nube
→ el pod obtiene testigos sin claves clase 234
- 3 **FEDERACIÓN** – para lo que corre fuera se declara confianza en un emisor externo (canalización, otra nube, otro clúster)
sus testigos suplantan una cuenta de servicio
→ mismo mecanismo y mismos errores que en la clase 206
- 4 **SUPLANTACIÓN** – para personas y para encadenar una identidad con permiso obtiene un testigo de otra
→ y el registro guarda QUIÉN suplantó a QUIÉN

Y la política que lo hace efectivo:

prohibir la creación de claves de cuenta de servicio, como política de organización clase 229
→ y las existentes, inventariadas, migradas y borradas
→ con excepción registrada, dueño y fecha para lo que no se pueda ley 25

La suplantación, que es la pieza que más cambia el día a día:

UNA PERSONA no necesita permisos de producción
tiene permiso para SUPLANTAR una cuenta de servicio que sí los tiene
→ obtiene un testigo de corta duración
→ y queda registrado quién lo hizo clase 238

Y LAS CANALIZACIONES ENCADENAN

la identidad federada suplanta una cuenta de despliegue

- y esa cuenta tiene los permisos, no el testigo externo
- así se cambian los permisos sin tocar la federación

Y el error que hay que evitar:

- dar a muchos el permiso de suplantar una cuenta muy permisiva
- es equivalente a darles esos permisos, y más difícil de ver en un inventario
- el permiso de suplantar se audita como si fuera el permiso suplantado

2. Ámbito y condiciones

El error frecuente vuelve a ser el mismo de las clases 206 y 218: el ámbito demasiado amplio. Aquí hay además una herramienta que no existe en las otras dos.

- LOS ÁMBITOS, de mayor a menor
 - organización → todos los proyectos
 - carpeta → todos los de esa rama
 - proyecto → todos sus recursos
 - RECURSO → solo ese

- y la costumbre
 - asignar «Editor» en el proyecto, porque funciona
 - esa identidad puede crear, modificar y borrar casi todo
 - incluida la base de datos clase 218

Las condiciones, que permiten afinar sin crear papeles a medida:

UNA CONDICIÓN es una expresión que limita cuándo aplica el permiso

- POR RECURSO
 - «solo sobre los almacenes cuyo nombre empiece por pedidos-»
 - un permiso de proyecto que en la práctica solo toca lo suyo

- POR TIEMPO
 - «solo hasta el 31 de marzo»
 - el acceso caduca solo ley 25
 - y esto resuelve el problema del acceso temporal sin infraestructura adicional

- POR ETIQUETA
 - «solo sobre recursos con entorno = desarrollo»

- POR TIPO DE RECURSO
 - «solo sobre conjuntos de datos, no sobre trabajos»

Y el uso que más aporta:

- el acceso concedido durante un incidente, con condición de tiempo
- nadie tiene que acordarse de quitarlo
- y el registro de decisión queda en la propia asignación

Y las limitaciones que hay que conocer:

- no todos los servicios soportan condiciones por recurso
 - hay que comprobarlo por servicio
- las condiciones complican la auditoría: un inventario que no las lee muestra permisos que en realidad no aplican
 - y al revés: un permiso que parece limitado puede no estarlo si el servicio ignora la condición
- comprobar con una prueba negativa, no suponer ley 22

Los papeles, con la disciplina de siempre:

- usar el papel PREDEFINIDO más específico que exista
 - no «Editor» sino «Escritor de objetos de almacenamiento»
- y papel PERSONALIZADO cuando ninguno encaje
 - con las acciones justas, y mantenido
- y los papeles que se conceden con elevación temporal

Propietario
Administrador de organización
Administrador de facturación
Administrador de seguridad
→ nunca permanentes

3. Elevación temporal y auditoría

La elevación temporal aquí se puede montar de dos formas, y conviene conocer las dos.

CON EL SERVICIO DE GESTIÓN DE ACCESO PRIVILEGIADO
la persona es ELEGIBLE; solicita, se aprueba, caduca
→ con justificación y registro

CON CONDICIONES DE TIEMPO
una asignación con condición de caducidad
→ más simple, sin aprobación integrada
→ útil para accesos acordados fuera de línea

Y EN AMBOS CASOS
activación rápida cuando no requiere aprobación
aprobadores con turnos cuando sí ley 16
y un camino de emergencia sin aprobación, con alerta
inmediata clase 218

Y la prueba obligatoria:

usar el acceso de emergencia y cronometrar
→ en la clase 179 estaba creado, documentado y no
funcionaba ley 22

La auditoría, con lo que hay que saber leer:

LOS REGISTROS DE ACTIVIDAD DE ADMINISTRACIÓN
siempre activos y sin coste
quién creó, modificó o borró qué

LOS REGISTROS DE ACCESO A DATOS
DESACTIVADOS por defecto, salvo unos pocos ley 26
→ quién leyó qué
→ y son los que hacen falta para investigar una fuga
→ y los que más volumen generan: hay que elegir
servicios y coste clase 238

Y EL CAMPO QUE HAY QUE MIRAR
cuando alguien suplanta, el registro guarda la identidad
ORIGINAL y la suplantada
→ sin leer las dos, la auditoría atribuye la acción a la
cuenta de servicio y no a la persona

Medir el alcance, que es lo que ordena el trabajo:

el analizador de políticas responde preguntas concretas
¿quién puede leer este almacén?
¿a qué recursos puede acceder esta identidad?
¿quién puede suplantar esta cuenta de servicio?

→ y esas tres preguntas, ejecutadas periódicamente, son la
medida de alcance de la clase 133

y las recomendaciones de permisos sobrantes
la plataforma sugiere reducir papeles poco usados
→ basadas en uso real de 90 días
→ se evalúan, no se aplican a ciegas clase 227

Y una fuente de alcance que se olvida:

LOS GRUPOS
los permisos se conceden a grupos, y la pertenencia se
gestiona en el directorio
→ alguien añadido a un grupo hereda permisos que nadie
revisó
→ hay que auditar la pertenencia efectiva clase 218

4. Lo que hay que comprobar

Las pruebas negativas de esta clase, que son las mismas de siempre con otras piezas:

- crear una clave de cuenta de servicio → debe fallar
- suplantar una cuenta desde una identidad sin permiso → debe fallar
- usar una identidad federada desde otro repositorio → debe fallar
- acceder a un recurso fuera de la condición → debe fallar
- usar un acceso cuya condición de tiempo ha caducado → debe fallar
- activar un papel privilegiado sin aprobación → debe fallar
- entrar con el acceso de emergencia → debe funcionar
- comprobar que el registro guarda la identidad original en una suplantación
- y que las tres preguntas de alcance devuelven lo esperado

Y las señales que hay que vigilar:

- claves de cuenta de servicio existentes → cero
- asignaciones en organización y carpeta → mínimas
- identidades con papeles de administración
- permisos concedidos y no usados en 90 días
- condiciones de tiempo que vencen este mes
- usos del acceso de emergencia → alerta
- cambios en asignaciones de papeles → auditados
- suplantaciones de cuentas privilegiadas → alerta

Y la disciplina de revisión:

- trimestral
- revisión de accesos por dueño
- pertenencia efectiva de grupos
- quién puede suplantar cada cuenta privilegiada
- y prueba del acceso de emergencia
- y la regla que la hace útil
- quien no responde a la revisión → se retira el acceso
- clase 218

Los errores de traslado, que esta parte vigila especialmente:

- ✗ «la barrera limita el acceso a los datos»
la política de organización limita qué se configura
→ el acceso a los datos lo decide el permiso
- clase 229
- ✗ «con quitar la clave ya está resuelto»
si la cuenta de servicio conserva permisos amplios, el problema sigue: solo cambia cómo se obtiene el testigo
- ✗ «la condición de recurso funciona en todos los servicios»
→ hay que comprobarlo por servicio, con una prueba

Y la lista de comprobación de la clase:

- la política prohíbe crear claves de cuenta de servicio
- no queda ninguna clave sin excepción registrada
- ningún recurso usa la cuenta de servicio por defecto
- lo que corre en la nube usa cuenta adjunta
- lo que corre fuera usa federación con sujeto exacto
- las personas acceden por suplantación, no con permisos propios de producción
- las asignaciones están en el ámbito del recurso
- se usan condiciones por recurso y por tiempo donde aportan
- se comprobó por servicio que la condición se respeta
- los papeles privilegiados requieren elevación temporal
- el acceso de emergencia se ha probado este trimestre
- los registros de acceso a datos están activados donde hacen falta
- la auditoría lee la identidad original en las suplantaciones

- se ejecutan las tres preguntas de alcance periódicamente

Y el cierre que enlaza con la clase siguiente: con jerarquía e identidad resueltas, queda la red, que aquí es global y tiene mecanismos de conectividad privada y de balanceo distintos de los de las otras dos nubes. Es la materia de la clase 231.

Ejemplo trabajado

CloudShop elimina las 341 claves de cuenta de servicio de su organización. Lo que sigue es el inventario, la migración por tipos, y el hallazgo de que quitar las claves no reducía el alcance.

El inventario de claves:

claves de cuenta de servicio	341
con más de 1 año	218
con más de 3 años	94
usadas en los últimos 90 días	127
NUNCA usadas	61
usadas desde fuera de la organización	14 ←

y las 14 usadas desde fuera

- 9 canalizaciones de un repositorio externo
- 3 herramientas de proveedores
- 1 un script en el portátil de un consultor que terminó su contrato en 2023 ley 25, 20
- 1 uso desde una dirección que nadie pudo explicar
 - se revocó inmediatamente y se investigó
 - resultó ser un entorno de pruebas de un socio, no declarado

La migración, por tipos:

tipo de uso	claves	migrado a
cargas en máquinas	88	cuenta adjunta
cargas en el clúster	64	identidad de carga
canalizaciones internas	41	federación
canalizaciones externas	9	federación
funciones y servicios	52	cuenta adjunta
scripts de personas	43	suplantación
herramientas de terceros	12	9 federadas, 3 con excepción
sin uso	32	borradas
total migrado	341 → 3 con excepción	registrada, dueño y fecha

duración 4 meses

Y los dos pasos que costaron más:

LAS 43 DE PERSONAS

cada una tenía su clave para «hacer cosas rápido»
y muchas con permisos de proyecto
→ sustituidas por suplantación de cuentas de servicio concretas
→ y aquí hubo resistencia: suplantar exige un comando más
→ se resolvió con un envoltorio que lo hace transparente ley 16

LAS 88 DE MÁQUINAS

al mirar cuál usaban, 71 usaban la CUENTA DE SERVICIO POR DEFECTO del proyecto
→ que tiene permisos amplios y la comparten todos los recursos ley 26
→ no bastaba quitar la clave: había que crear una cuenta por carga

El hallazgo: quitar las claves no redujo el alcance.

tras migrar las 341, se midió el alcance con las tres preguntas del analizador

¿a qué recursos llega cada identidad?

identidad	antes	después
cuenta por defecto de pedidos-prod	todo el proyecto	todo el proyecto
despliegue	organización	organización
cuenta de análisis	41 conjuntos	41 conjuntos

→ el alcance NO había cambiado
→ solo había cambiado cómo se obtiene el testigo

y la conclusión
eliminar credenciales resuelve el ROBO de credenciales
no resuelve el ALCANCE
→ son dos trabajos distintos, y el segundo es el que reduce el daño de un compromiso clases 189, 218

La reducción de alcance, con condiciones:

asignaciones inventariadas	2.410
en organización	18
en carpeta	140
en proyecto	1.870
en recurso	382

- las tres peores
- 1 la cuenta de despliegue con «Editor» en la organización
alcance: 86 proyectos, todo
corrección: 5 cuentas, una por propósito, con asignación en el proyecto y CONDICIÓN por prefijo de nombre de recurso
alcance: entre 4 y 40 recursos cada una
 - 2 el equipo de análisis con «Visor de datos» en la carpeta de producción
alcance: todos los conjuntos y tablas, incluidos los que contienen datos personales completos
corrección: asignación por conjunto, y para los sensibles, seudonimizados clases 236, 239
 - 3 17 personas con «Editor» en proyectos de producción
corrección: suplantación de cuentas concretas, con elevación temporal para lo privilegiado

Y el uso de las condiciones, con la comprobación que hizo falta:

se usaron condiciones en 61 asignaciones	
por prefijo de recurso	38
por tiempo (accesos temporales)	19
por etiqueta de entorno	4

y la prueba negativa, por servicio
se intentó acceder a un recurso FUERA de la condición en cada uno de los 9 servicios implicados

respetaron la condición	7
NO la respetaron	2 ←
→ dos servicios ignoraban la condición por recurso	
→ esas 2 asignaciones se sustituyeron por papeles personalizados y asignación en el recurso	

→ y sin esa prueba, dos permisos habrían parecido limitados y no lo estaban ley 22

La elevación temporal:

papeles privilegiados retirados como permanentes	
Propietario	14 → 0
Administrador de organización	6 → 0
Administrador de facturación	4 → 0
Administrador de seguridad	3 → 0

configurados como elegibles
con aprobación de 2 personas y caducidad de 4 h
emergencia: sin aprobación, con alerta inmediata

primeros tres meses

activaciones	186
de emergencia	2
· 1 incidente real	
· 1 porque el aprobador estaba de baja y nadie cubría	
→ turno de aprobadores corregido	

y la prueba de emergencia

primera ejecución: funcionó, en 90 segundos

segunda (trimestral): la cuenta había perdido un permiso al reorganizar la carpeta ley 27

→ corregido, y añadida comprobación automática mensual

La auditoría, con el campo que faltaba leer:

al investigar un borrado accidental de una tabla

el registro decía: «cuenta de servicio de análisis borró la tabla»

→ y el equipo buscó qué carga lo había hecho

al leer el campo de identidad ORIGINAL

una persona había suplantado esa cuenta y ejecutado el borrado a mano

→ 3 horas de investigación por no leer un campo

corrección

las consultas guardadas incluyen siempre la identidad original

y una alerta: «suplantación de una cuenta privilegiada»

El resultado:

claves de cuenta de servicio	341	3
usadas desde fuera sin explicar	1	0
recursos con cuenta de servicio por defecto	71	0
asignaciones en organización	18	4
asignaciones en carpeta	140	22
alcance de la cuenta de despliegue	86 proyectos	4-40 recursos
papeles privilegiados permanentes	27	0
asignaciones con condición	0	59
condiciones que un servicio ignoraba	—	0
tiempo de investigación de una acción	3 horas	4 min

La lección que esta clase deja: eliminar las trescientas cuarenta y una claves costó cuatro meses y no redujo el alcance ni un punto: solo cambió cómo se obtiene el testigo. Reducir el alcance fue un trabajo distinto y posterior, y ahí las condiciones por recurso hicieron el trabajo que en otras nubes exige papeles a medida. Y dos de los nueve servicios ignoraban la condición, lo que se descubrió con una prueba negativa y habría dejado dos permisos aparentemente limitados sin estarlo.

Laboratorio guiado

Ejecuta desde la raíz:

```
python classes/part-19-gcp-production-architecture/230-workload-identity-federation-iam-conditions-y-pam/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 gcp-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 gcp-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
Se eliminan las claves y el riesgo apenas baja	Quitar la credencial resuelve el robo, no el alcance de la identidad	Trata reducir alcance como un trabajo aparte: mide qué recursos alcanza cada identidad y baja el ámbito de las asignaciones.
Todos los recursos de un proyecto comparten una identidad muy permisiva	Usan la cuenta de servicio por defecto del proyecto	Una cuenta de servicio por carga, con sus permisos, y prohibición de usar la predeterminada.
Un permiso parece limitado por una condición y no lo está	El servicio no respeta las condiciones por recurso	Comprueba con una prueba negativa servicio por servicio; donde no se respeten, usa papeles personalizados y asignación en el recurso.
La auditoría atribuye una acción a una cuenta de servicio y no a la persona	No se lee el campo de identidad original en las suplantaciones	Incluye siempre la identidad original en las consultas y alerta sobre suplantaciones de cuentas privilegiadas.
Dar el permiso de suplantar parece inofensivo y no lo es	Equivale a conceder los permisos de la cuenta suplantada	Audita quién puede suplantar cada cuenta privilegiada como si fuera una asignación directa.
El acceso de emergencia funcionó una vez y luego no	Perdió un permiso al reorganizar la jerarquía y nadie lo comprobó	Prueba trimestral del acceso de emergencia y comprobación automática de sus permisos.

■ 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 las cuatro formas de no necesitar una clave de cuenta de servicio?
2. ¿Qué permiten las condiciones que no permite el ámbito por sí solo?
3. ¿Por qué el permiso de suplantar debe auditarse como el permiso suplantado?
4. ¿Qué registros están desactivados por defecto y por qué hacen falta?

5. ¿Qué campo hay que leer para saber quién ejecutó realmente una acción?

Referencias

- Google Cloud (2025). Best practices for using service accounts. <<https://cloud.google.com/iam/docs/best-practices-service-accounts>>
- Google Cloud (2025). Workload identity federation. <<https://cloud.google.com/iam/docs/workload-identity-federation>>
- Google Cloud (2025). IAM conditions overview. <<https://cloud.google.com/iam/docs/conditions-overview>>
- Google Cloud (2025). Privileged Access Manager. <<https://cloud.google.com/iam/docs/pam-overview>>
- Google Cloud (2025). Policy Analyzer and IAM recommender. <<https://cloud.google.com/policy-intelligence/docs/policy-analyzer-overview>>
- Documentación oficial vigente del servicio implementado; registra URL y fecha de consulta.

Descargar: Parte 19 en PDF · Recorrido de Google Cloud en PDF · Manual integral

Anterior	Índice	Siguiente
← 229 · Resource Manager, folders, Shared VPC y guardrails	Parte 19 · Programa	231 · Red global, load balancing, PSC y Cloud DNS →

Evaluación — 230 Workload Identity Federation, IAM Conditions y PAM

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 gcp-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.

231 — Red global, load balancing, PSC y Cloud DNS

Parte: 19 — Google Cloud: arquitectura de datos y operación en producción Nivel: avanzado · Horas estimadas: 4
Laboratorio: network · Estado: EXECUTABLECORE

Propósito

Montar la red de Google Cloud, que es la que más se diferencia de las otras dos: la red es global y una sola dirección puede servir desde todas las regiones. La clase explica qué implica eso para el balanceo, cómo funciona la conectividad privada hacia servicios propios y de terceros, y la resolución de nombres con su equivalente del problema de la clase 219: si la zona no está asociada a la red, el nombre resuelve a la dirección pública.

Resultados de aprendizaje

Al finalizar podrás:

1. Aprovechar la red global sin trasladar suposiciones regionales.
2. Elegir el balanceador adecuado entre global y regional.
3. Conectar a servicios propios y de terceros de forma privada.
4. Resolver nombres privados en todas las redes que los necesitan.
5. Controlar la salida a internet, que está abierta por defecto.

Conceptos centrales

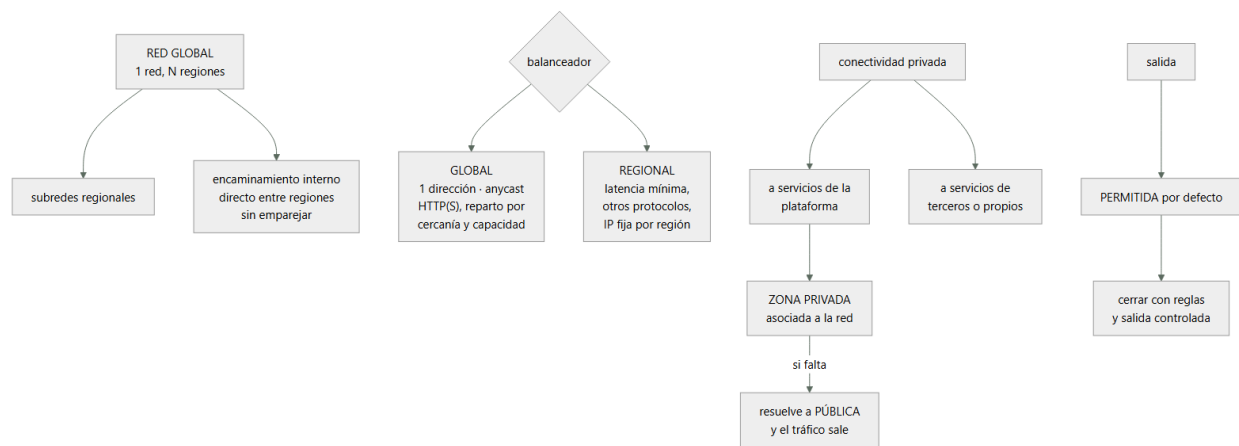
Concepto	Comprensión verificable
red global	Red virtual que abarca todas las regiones. Las subredes son regionales; el encaminamiento interno es directo.
balanceo global	Una dirección única que reparte a los grupos de la región más cercana con capacidad.
conexión de servicio privada	Mecanismo para alcanzar un servicio de la plataforma o de un tercero por una dirección de tu red.
acceso privado a servicios	Alternativa que permite alcanzar servicios de la plataforma sin dirección externa, por rutas privilegiadas.
zona privada de nombres	Zona asociada a redes concretas. Sin asociación, el nombre resuelve a la dirección pública.
salida controlada	Restricción del tráfico saliente, que está permitido por defecto y hay que cerrar.

Modelo mental

Google Cloud combina una jerarquía estricta de recursos con una red global y servicios data-first; proyecto, cuota e IAM forman una unidad operativa.

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 red global, y qué cambia

Esta es la diferencia estructural que más suposiciones invalida.

LA RED ES GLOBAL

- una sola red abarca todas las regiones
- las SUBREDES son regionales
- y los recursos de subredes distintas se alcanzan directamente, sin emparejar nada

QUÉ DESAPARECE

- emparejamientos entre regiones
- concentradores de tránsito para unir regiones propias
- y buena parte de la complejidad de encaminamiento de las clases 194 y 199

QUÉ NO DESAPARECE

- el coste del tráfico entre regiones, que sigue
- el coste del tráfico entre zonas, que también
- y la latencia física

Y las suposiciones que hay que desmontar:

- ✗ «hay que emparejar las redes de cada región»
no; es una sola red
- ✗ «una subred agotada solo afecta a su región»
cierto, pero el rango se decide en el plan global
clase 193
→ y las subredes se pueden AMPLIAR sin recrear, que es una ventaja real frente a otras nubes
- ✗ «las reglas de cortafuegos son por subred»
son de la RED, con selectores y prioridades clase 229
→ una regla mal puesta afecta a todas las regiones
- ✗ «el balanceador es regional»
hay de los dos, y el global cambia el diseño

Los rangos secundarios, que hacen falta para contenedores:

- una subred puede tener rangos SECUNDARIOS
- los pods y los servicios del clúster usan esos rangos
- y se dimensionan aparte del rango principal
clases 193, 234

- el plan de direcciones tiene que contarlos, y son los que más consumen

Y una decisión que conviene tomar pronto:

¿SUBREDES AUTOMÁTICAS O PERSONALIZADAS?

- automáticas la red crea una subred por región, con rangos fijos

- cómodo y garantiza solapamiento con cualquier otra red creada igual
- personalizadas se declaran los rangos del plan
- la elección correcta para cualquier organización

clase 193

→ y las redes automáticas se convierten en personalizadas, pero no al revés

2. Balanceo: global y regional

El balanceador global es la pieza que más cambia el diseño frente a las otras nubes.

BALANCEADOR GLOBAL DE APLICACIÓN

UNA dirección, anunciada desde muchos puntos
el usuario llega al punto más cercano
y desde ahí se reparte a la región con capacidad

qué da
una sola entrada para todas las regiones
conmutación entre regiones sin tocar nombres
→ y por tanto SIN el retraso del TTL ni de las cachés de cliente

clase 215

terminación TLS y certificados gestionados
caché integrada en el borde
y filtrado de aplicación delante

qué implica
la salud de los grupos por región decide el reparto
→ y hay que configurarla bien, con las lecciones de la clase 196

BALANCEADOR REGIONAL

para protocolos que no son HTTP
para latencia mínima dentro de una región
y cuando hace falta una IP fija por región para listas de terceros

clase 193

BALANCEADOR INTERNO

para el tráfico entre servicios propios
regional o global según el caso

Y la consecuencia sobre continuidad, que es notable:

con balanceo global, perder una región NO exige cambiar un registro de nombres
→ el reparto deja de enviar tráfico a esa región
→ y el tramo de «redirección» de la clase 215 casi desaparece

→ lo que NO desaparece
promover los datos

clase 235

escalar la capacidad en la región que queda

clase 233

y decidir

← sigue siendo el tramo que domina

Y una advertencia:

la capacidad de los grupos por región hay que dimensionarla para absorber el tráfico de la región perdida
→ si cada región está al 80 %, perder una no funciona
→ es la misma aritmética de la clase 186, aplicada a regiones en vez de a zonas

Y el caché del borde:

el balanceador global integra caché
→ las lecciones de la clase 197 aplican igual: clave de caché, contenido rancio, invalidación por etiqueta
→ y el ahorro de salida y de origen también

3. Conectividad privada y nombres

Aquí hay dos mecanismos que se confunden y una trampa idéntica a la de la clase 219.

ACCESO PRIVADO A SERVICIOS

- las máquinas sin dirección externa alcanzan las API de la plataforma por rutas privilegiadas
- + se activa por subred, sin crear recursos
- + gratuito
- el tráfico sale por las direcciones públicas del servicio, no por una dirección de tu red
- y por tanto el control por origen es más grueso

CONEXIÓN DE SERVICIO PRIVADA

- crea una dirección DE TU RED que representa el servicio
- + alcanzable desde el centro de datos y desde otras redes
- + permite política por origen fina
- + y sirve también para servicios de TERCEROS y para publicar los propios a otros clientes
- cuesta, y consume direcciones clase 193

CRITERIO

- ¿hace falta alcanzarlo desde fuera de la red o controlar por origen? → conexión privada
- ¿solo desde dentro y sin dirección externa? → acceso privado a servicios

La trampa de los nombres, que es la misma de siempre:

- la conexión privada crea una dirección
- y hace falta que el NOMBRE del servicio resuelva a ella
- eso lo hace una ZONA PRIVADA, asociada a las redes

- X si la zona no está asociada a una red
- el nombre resuelve a la dirección PÚBLICA
- el tráfico sale a internet
- y si el acceso público está cerrado, falla; y si no, funciona pagando salida y sin control clase 219, ley 26

- y con red compartida, la asociación se hace en el proyecto anfitrión, no en el de servicio
- es el error de configuración más frecuente aquí

Y la comprobación obligatoria:

- para cada servicio con conexión privada, resolver su nombre desde CADA red y comprobar que devuelve dirección privada
- función de aptitud, diaria clase 190

La resolución con el centro de datos, con lo suyo:

- políticas de reenvío entrante y saliente
- entrante el centro de datos resuelve nombres de la nube
- saliente la nube resuelve nombres del centro de datos
- y hay que montar las DOS
- el fallo clásico es montar una y descubrir la otra el día que un sistema corporativo tiene que llamar clase 195

Y los controles de perímetro, que aquí tienen forma propia:

- un PERÍMETRO DE SERVICIO agrupa proyectos y restringe qué API pueden usarse desde fuera y hacia fuera
- impide que una identidad válida copie datos a un proyecto de otra organización
- es el equivalente del perímetro de datos de la clase 200, y es lo que cierra el hueco que deja la conexión privada

4. Salida, cortafuegos y diagnóstico

La salida está permitida por defecto, como en las otras dos nubes, y hay que cerrarla.

LAS REGLAS DE CORTAFUEGOS

- son de la red, con prioridad, y con reglas implícitas al final
- entrada: denegar todo
- SALIDA: permitir todo ley 26

selectores

por etiqueta de red ← cualquiera con permiso sobre la instancia puede ponerla
por CUENTA DE SERVICIO ← exige permiso sobre la cuenta
→ usar cuenta de servicio siempre que se pueda
clase 229

CERRAR LA SALIDA

regla de denegación de salida con prioridad alta
y permisos explícitos hacia lo declarado
con las API de la plataforma alcanzadas por acceso
privado o conexión privada

Y EL PERÍMETRO DE SERVICIO

impide sacar datos a proyectos ajenos aunque la red lo permitiera
clase 200

Y los mecanismos de salida gestionada:

LA PASARELA DE TRADUCCIÓN DE DIRECCIONES

da salida a máquinas sin dirección externa
con direcciones fijas para listas de terceros
y hay que dimensionar los puertos por instancia
→ el agotamiento de puertos aparece igual que en la
clase 221

EL CORTAFUEGOS GESTIONADO

inspección de capa 7 y control por nombre de destino
→ lo que hace falta para la lista de destinos permitidos
clase 200

El diagnóstico, con las herramientas propias:

COMPROBADOR DE CONECTIVIDAD

dice, para un origen y un destino, si el tráfico llegaría
y qué regla o ruta lo permite o lo bloquea
→ responde en segundos lo que una captura tarda horas
clase 202

REGISTROS DE FLUJO

quién habla con quién, y qué se deniega
→ con muestreo configurable: al 100 % en lo crítico

ESPEJO DE PAQUETES

copia del tráfico hacia un destino de análisis
→ caro y con datos sensibles; con procedimiento

Y LOS REGISTROS DE REGLAS DE CORTAFUEGOS

desactivados por defecto, por regla ley 26
→ activarlos en las reglas de denegación es lo que
revela lo que se está bloqueando

Y la lista de comprobación de la clase:

- la red es personalizada, con rangos del plan
- los rangos secundarios están dimensionados
- no se han creado redes por región innecesariamente
- las reglas seleccionan por cuenta de servicio
- la salida está cerrada explícitamente
- hay perímetro de servicio para los proyectos con datos
- el balanceador global se usa donde aporta, y el regional donde hace falta IP fija u otro protocolo
- la capacidad por región absorbe la pérdida de una
- las zonas privadas están asociadas a todas las redes, en el proyecto anfitrión
- hay comprobación diaria de resolución a dirección privada
- el reenvío con el centro de datos está en los dos sentidos
- los registros de flujo están al 100 % en lo crítico
- los registros de las reglas de denegación están activados

Y el cierre que enlaza con la clase siguiente: con jerarquía, identidad y red resueltas, hace falta declararlo como código con validación previa de las políticas, para que el rechazo no llegue en el momento de desplegar. Es la materia de la clase 232.

Ejemplo trabajado

CloudShop monta la red de su organización en Google Cloud. Lo que sigue es lo que ahorró la red global, el problema de zonas privadas que se repitió pese a conocerlo, y la conmutación de región que resultó ser mucho más rápida que en las otras dos nubes.

Lo que ahorró la red global:

el diseño trasladado de las otras nubes preveía	
3 redes (una por región)	
emparejamientos entre ellas	3
o un concentrador de tránsito	1
reglas duplicadas por región	
el diseño real	
2 redes compartidas (producción y no producción)	
subredes regionales dentro de cada una	
emparejamientos	0
concentradores	0
reglas de cortafuegos, únicas para las 3 regiones	
ahorro estimado frente al diseño trasladado	
coste de concentrador y tránsito	1.900 €/mes
reglas que mantener	3× menos
y la complejidad de encaminamiento entre regiones, eliminada	

Y el hallazgo que no se esperaba:

- las subredes se pueden AMPLIAR sin recrear
 - en las otras dos nubes, ampliar exigía crear otra subred o reenumerar clase 193
 - aquí, dos subredes que se estaban agotando se ampliaron de /22 a /20 en minutos, sin cortar nada
 - y eso cambió la estrategia de dimensionado: se puede empezar ajustado y ampliar

El problema de las zonas privadas, otra vez.

se montaron conexiones privadas a 19 servicios
con zonas privadas para que los nombres resolvieran a dirección privada

y al comprobar, dos semanas después
proyectos de servicio desde los que resolvía correcto 4
proyectos desde los que resolvía a dirección PÚBLICA 38

causa
con red compartida, la zona privada debe asociarse a la red del PROYECTO ANFITRIÓN
el equipo la había asociado en cada proyecto de servicio, donde no tiene efecto
→ y funcionaba en los 4 proyectos donde alguien la había asociado bien por casualidad

lo incómodo
el equipo CONOCÍA el problema: lo habían sufrido en la clase 219, con Azure
→ y aun así lo repitieron, porque el sitio donde hay que asociarla es distinto
→ es exactamente el error de traslado de la clase 229

corrección
zonas asociadas a las redes de los proyectos anfitriones
comprobación diaria: resolver los 19 nombres desde una máquina de cada proyecto de servicio
→ 4 fallos en los 6 meses siguientes, todos en proyectos creados antes de que la automatización existiera
ley 27

El balanceo global, y lo que cambió en continuidad.

montaje
1 balanceador global de aplicación

El diagnóstico, con la herramienta que ahorró horas:

incidente el servicio de precios no alcanzaba la base desde la región secundaria

```
lo que se habría hecho antes
  revisar reglas a mano, capturar paquetes: horas
```

lo que se hizo
comprobador de conectividad: origen la instancia,
destino la base
→ respuesta en 12 segundos: «bloqueado por la regla
deny-egress-default; no hay regla que permita el
destino»
→ causa: la regla de permitido se había creado con
selector por etiqueta y las instancias nuevas usaban
cuenta de servicio

```
tiempo total          9 min
```

El resultado:

redes	41	2
emparejamientos	67	0
concentradores de tránsito	1	0
proyectos con resolución privada correcta	4/42	42/42
destinos externos alcanzables	ilimitado	48
salida a internet	41 TB	6 TB
coste de salida	3.900 €	610 €
tiempo de conmutación de región	sin medir	8 min 15
tiempo de diagnóstico de red	2-3 h	9 min
coste de conectividad	6.400 €	3.900 €

La lección que esta clase deja: la red global eliminó los emparejamientos, los concentradores y —en la conmutación— el tramo de redirección entero, que en las otras dos nubes era el que más se alargaba. Y el error de las zonas privadas se repitió pese a que el equipo lo había sufrido en la nube anterior: el mecanismo era el mismo y el sitio donde se asocia, distinto. Es la forma más pura del error de traslado.

Laboratorio guiado

Ejecuta desde la raíz:

```
python classes/part-19-gcp-production-architecture/231-red-global-load-balancing-psc-y-cloud-dns/lab.py
```

El laboratorio selecciona el motor de práctica network 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. Provoa el caso de `negativetest` y explica la señal observada.
4. Materializa `gcp-network` 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 topología con rutas, puertos y controles. Además, la entrega debe incluir el comando ejecutado, la salida estructurada y una conclusión que no exceda lo observado.

Reto verificable

Construye gcp-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
Se crean redes por región y emparejamientos entre ellas	Se trasladó el modelo regional de otras nubes	La red es global: una red por entorno con subredes regionales, sin emparejamientos internos.
El nombre de un servicio con conexión privada resuelve a dirección pública	Con red compartida, la zona privada debe asociarse a la red del proyecto anfitrión	Asocia en el anfitrión y comprueba a diario la resolución desde una máquina de cada proyecto de servicio.
Al perder una región el servicio se degrada mientras escala	Cada región estaba dimensionada solo para su propio tráfico	Dimensiona cada región para absorber el total con utilización por debajo del codo.
Una regla de cortafuegos se puede burlar poniendo una etiqueta	El selector es por etiqueta de red	Selecciona por cuenta de servicio, que exige permiso sobre esa cuenta.
Con la salida cerrada aún se pueden copiar datos fuera	La API de la plataforma se alcanza por rutas privilegiadas y llega a proyectos ajenos	Añade un perímetro de servicio sobre los proyectos con datos.
Diagnosticar por qué no llega el tráfico lleva horas	Se revisan reglas a mano en vez de usar la comprobación de conectividad	Usa el comprobador de conectividad primero y activa los registros de las reglas de denegación.

■ 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 desaparece y qué no al ser la red global?
2. ¿Qué tramo de la conmutación de región elimina el balanceo global?
3. ¿Dónde hay que asociar una zona privada cuando se usa red compartida?
4. ¿Qué diferencia hay entre el acceso privado a servicios y la conexión de servicio privada?
5. ¿Qué cierra el perímetro de servicio que no cierra el cortafuegos?

Referencias

- Google Cloud (2025). VPC network overview. <<https://cloud.google.com/vpc/docs/vpc>>
- Google Cloud (2025). Cloud Load Balancing: global external Application Load Balancer. <<https://cloud.google.com/load-balancing/docs/https>>
- Google Cloud (2025). Private Service Connect. <<https://cloud.google.com/vpc/docs/private-service-connect>>
- Google Cloud (2025). Cloud DNS private zones and forwarding. <<https://cloud.google.com/dns/docs/zones>>

- Google Cloud (2025). Connectivity Tests.
<<https://cloud.google.com/network-intelligence-center/docs/connectivity-tests/concepts/overview>>
- Documentación oficial vigente del servicio implementado; registra URL y fecha de consulta.

Descargar: Parte 19 en PDF · Recorrido de Google Cloud en PDF · Manual integral

Anterior	Índice	Siguiente
← 230 · Workload Identity Federation, IAM Conditions y PAM	Parte 19 · Programa	232 · Terraform, Infrastructure Manager y policy validation →

Evaluación — 231 Red global, load balancing, PSC y Cloud DNS

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 gcp-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.

232 — Terraform, Infrastructure Manager y policy validation

Parte: 19 — Google Cloud: arquitectura de datos y operación en producción Nivel: avanzado · Horas estimadas: 4
Laboratorio: iac · Estado: EXECUTABLECORE

Propósito

Declarar la infraestructura de Google Cloud como código con la pieza que faltaba en las partes anteriores: validar las políticas antes de desplegar, para que el rechazo no llegue en el momento de aplicar. La clase cubre la gestión del estado y sus riesgos, la estructura por ciclo de vida, la validación previa de restricciones, y la operación que resuelve el problema de la ley 27: qué hacer con lo que ya existe y no cumple.

Resultados de aprendizaje

Al finalizar podrás:

1. Gestionar el estado de forma segura y con bloqueo.
2. Estructurar el código por ciclo de vida y por ámbito.
3. Validar políticas y coste antes de aplicar, no después.
4. Importar lo existente al código sin recrearlo.
5. Retirar recursos de forma controlada y comprobada.

Conceptos centrales


Concepto	Comprensión verificable
estado	Registro de qué recursos gestiona el código. Contiene información sensible y debe protegerse y bloquearse.
bloqueo del estado	Mecanismo que impide dos aplicaciones simultáneas. Sin él, el estado se corrompe.
plan de cambios	Previsualización de lo que se creará, modificará, recreará y destruirá. Se lee antes de aplicar.
validación de políticas	Comprobación del plan contra las restricciones de la organización, antes de aplicar.
importación	Incorporación de un recurso existente al estado, sin recrearlo.
servicio gestionado de despliegue	Alternativa que ejecuta el despliegue en la nube, con el estado gestionado por la plataforma.

Modelo mental

Google Cloud combina una jerarquía estricta de recursos con una red global y servicios data-first; proyecto, cuota e IAM forman una unidad operativa.

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 estado, y cómo no perderlo

La diferencia principal frente a Bicep es que aquí hay un estado, y eso da capacidades y riesgos.

QUÉ DA EL ESTADO

saber exactamente qué gestiona el código
 detectar deriva: lo que cambió por fuera
 y destruir lo que deja de estar declarado
 → resuelve el problema de los huérfanos de la clase 220

QUÉ RIESGOS TRAE

contiene valores sensibles en claro

- contraseñas generadas, claves, cadenas de conexión
- un estado en un repositorio es una fuga
- se corrompe si dos personas aplican a la vez
- y si se pierde, el código deja de saber qué gestiona

Y la configuración mínima:

ESTADO REMOTO

- en un almacén de objetos, no en el portátil
- con VERSIONADO activado
- con cifrado
- con acceso restringido: quien lee el estado ve secretos
- y con registro de acceso clase 238

BLOQUEO

- automático al aplicar
- sin él, dos canalizaciones simultáneas corrompen el estado
- y un procedimiento para liberar un bloqueo atascado
- que hay que tener escrito ANTES de necesitarlo

UN ESTADO POR CICLO DE VIDA

- no uno gigante
- un estado enorme hace lentas todas las operaciones
- y un error afecta a todo

Y el error que más daño hace:

BORRAR O PERDER EL ESTADO

- el código deja de saber qué existe
- al aplicar, intenta CREAR lo que ya está
- y falla con errores de recurso duplicado, o peor: crea duplicados donde el nombre no es único

la recuperación

- restaurar la versión anterior del estado
- y por eso el versionado del almacén es obligatorio
- o importar todo de nuevo, que es lento y manual

Y la alternativa gestionada, que conviene conocer:

- el servicio gestionado de despliegue ejecuta el código en la nube y guarda el estado por ti
- + sin almacén que proteger, sin bloqueo que gestionar
- + con identidad de la plataforma, sin credenciales
- menos control sobre el proceso y sobre las versiones

- para equipos pequeños o que empiezan, suele ser mejor
- y para canalizaciones complejas, el modelo propio

2. Estructura y ámbitos

La estructura es la de siempre, con los ámbitos de esta nube.

SEPARADO POR CICLO DE VIDA Y POR ÁMBITO

- | | |
|---------------|---|
| organizacion/ | políticas, carpetas, permisos de organización |
| red/ | red compartida, subredes, cortafuegos, zonas privadas |
| proyectos/ | creación y configuración base |
| datos/ | bases, conjuntos, almacenes |
| | → con protección contra destrucción |
| cargas/ | servicios, trabajos, colas |

- cada uno con su estado
- y las dependencias entre ellos por salidas y fuentes de datos, no por variables copiadas

Y las reglas que evitan los problemas frecuentes:

PROTECCIÓN CONTRA DESTRUCCIÓN

- los recursos con datos llevan la marca que impide destruirlos
- y entonces un plan que los destruiría FALLA en el plan, no en el aplicar
- es la protección más barata que existe

SIN SECRETOS EN VARIABLES

- referencias al gestor de secretos
- y aun así, el valor acaba en el estado: por eso el estado se protege como un secreto

VERSIONES FIJADAS

- la del proveedor y las de los módulos
- sin fijar, el mismo código produce cosas distintas en momentos distintos ley 25

MÓDULOS DEL CATÁLOGO OFICIAL

- con los valores por defecto revisados
- misma idea que en la clase 220, contra la ley 26

Y los ámbitos de despliegue, que aquí importan:

lo que se crea en la ORGANIZACIÓN

- carpetas, políticas de organización, permisos de organización
- exige permisos muy altos
- y por eso ese estado y esa canalización van aparte, con aprobación clase 229

lo que se crea en el PROYECTO

- casi todo lo demás
- con la identidad federada del proyecto

Y una advertencia de traslado:

- ✗ «una carpeta de módulos por entorno»
produce código duplicado que diverge
- ✓ un módulo, y ficheros de variables por entorno
- y la diferencia entre entornos, visible en un solo sitio

3. Validar antes de aplicar

Esta es la pieza que las partes 17 y 18 echaban de menos: comprobar que el cambio cumplirá las políticas antes de intentarlo.

EL PROBLEMA SIN VALIDACIÓN PREVIA

- el despliegue llega a producción y la política lo rechaza
- el cambio queda a medias
- y el equipo descubre la restricción en el peor momento

LA VALIDACIÓN PREVIA

- se genera el PLAN
- se convierten los recursos previstos a su forma final
- se evalúan contra las restricciones de la organización
- y la canalización FALLA ahí, con un mensaje que dice qué restricción y qué falta

Y lo que se puede validar:

- las restricciones de organización clase 229
- las políticas propias de la empresa
- «ningún almacén sin cifrado con clave propia»
- «ninguna base sin copia de seguridad»
- «ningún recurso sin etiquetas obligatorias»
- y las convenciones
- nombres, regiones, tamaños permitidos

Y las otras dos puertas que deben estar en la misma canalización:

ESTIMACIÓN DE COSTE

- a partir del plan, cuánto costará al mes
- publicada en la revisión clase 220
- y con umbral: por encima de X, aprobación

DESTRUCCIONES Y RECREACIONES

- el plan las lista
- y una recreación destruye y crea: para una base, es pérdida de datos
- puerta automática: si hay destrucciones en producción, aprobación explícita clase 220

Y el orden completo de la canalización:

- 1 formato y análisis estático
- 2 validación de sintaxis
- 3 PLAN, con identidad federada y solo lectura
- 4 validación de políticas sobre el plan
- 5 estimación de coste
- 6 publicación del resumen: qué se crea, cambia, RECREA y destruye
- 7 puerta si hay destrucciones o si el coste supera el umbral
- 8 aplicar, con identidad de despliegue
- 9 comprobar el resultado

Y una práctica que ahorra incidentes:

el PLAN se ejecuta con una identidad de SOLO LECTURA
→ y la de escritura solo se usa en el paso de aplicar
→ así una propuesta de cambio de cualquiera puede generar plan sin poder cambiar nada clase 230

4. Importar, detectar deriva y retirar

La importación es lo que permite poner bajo código lo que ya existe, que es el problema de la ley 27.

EL ESCENARIO HABITUAL

hay cientos de recursos creados a mano
el código nuevo describe lo que debería haber
→ aplicarlo intentaría crear lo que ya existe

LA IMPORTACIÓN

incorpora el recurso existente al estado
→ y a partir de ahí, el código lo gestiona
→ sin recrearlo ni cortar nada

y el trabajo real

hay que escribir el código que COINCIDA con lo que existe
→ y el plan posterior dice qué diferencias hay
→ esas diferencias son el inventario de lo que estaba mal

Y el orden que funciona:

- 1 generar el código a partir de lo existente, donde la herramienta lo permita
- 2 importar
- 3 ejecutar el plan: si sale vacío, el código describe la realidad
- 4 y si no, cada diferencia es una decisión: ¿se ajusta el código o se corrige el recurso?
- 5 corregir hacia el estado deseado, por lotes

La deriva, que es lo que ocurre después:

alguien cambia algo por la consola durante un incidente
→ el código deja de describir la realidad
→ y el siguiente despliegue lo revierte sin avisar

LA DETECCIÓN

ejecutar el plan periódicamente y alertar si no está vacío
→ un plan que no está vacío sin que nadie haya cambiado el código significa deriva
→ y esa alerta es la que detecta los cambios manuales ley 25, clase 219

La retirada, que es lo que el estado permite y casi nadie usa:

quitar el recurso del código y aplicar → se destruye
→ y por eso la protección contra destrucción en los datos

y para lo que hay que sacar del código sin borrarlo
se quita del estado, y el recurso queda huérfano
→ útil cuando pasa a gestionarlo otro equipo
→ y peligroso si se olvida: queda sin gobierno ley 20

Y las comprobaciones de esta clase:

- borrar el estado y comprobar que se puede restaurar
 - aplicar dos veces en paralelo y ver que el bloqueo lo impide
 - intentar destruir un recurso protegido
 - desplegar algo que incumple una política y ver que falla en la validación, no al aplicar
 - ejecutar el plan sin cambios y comprobar que está vacío
 - desplegar el entorno de cero en un proyecto vacío
- clase 220

Y la lista de comprobación de la clase:

- el estado es remoto, cifrado, versionado y con acceso restringido
- el bloqueo está activo y hay procedimiento para liberarlo
- hay un estado por ciclo de vida, no uno gigante
- los recursos con datos tienen protección contra destrucción
- las versiones del proveedor y de los módulos están fijadas
- se usan módulos del catálogo oficial donde existen
- la canalización valida políticas sobre el plan
- estima el coste y lo publica
- lista destrucciones y recreaciones, con puerta de aprobación
- el plan usa identidad de solo lectura
- lo existente está importado, y el plan sale vacío
- hay detección periódica de deriva, con alerta
- el entorno se despliega de cero periódicamente

Y el cierre que enlaza con la clase siguiente: con la base declarada y validada, quedan las cargas. Las opciones de cómputo gestionado de esta nube —y la que ha cambiado más el modelo de contenedores— son la materia de la clase 233.

Ejemplo trabajado

CloudShop pone su infraestructura de Google Cloud bajo código. Lo que sigue es la importación de 4.100 recursos creados a mano, el estado que se perdió una vez, y la validación previa que evitó 61 despliegues fallidos en producción.

El punto de partida:

recursos existentes	9.400	
declarados en algún código	410	4 %
creados a mano	8.990	
estados existentes	11	
en un almacén sin versionado	7	
EN EL REPOSITORIO	2	←
en portátiles	2	

y los 2 del repositorio contenían
 3 contraseñas de bases de datos en claro
 1 clave de cuenta de servicio
 → visibles para los 214 miembros de la organización
 → desde hacía 14 meses ley 15

Y la corrección inmediata:

estados retirados del repositorio y del historial
 contraseñas y clave rotadas
 almacén de estados: versionado, cifrado con clave propia,
 acceso restringido a 4 identidades, registro de acceso
 activado clase 238
 → y una función de aptitud: ningún fichero de estado en
 ningún repositorio clase 190

La importación, por lotes.

orden elegido	
1 red y cortafuegos	(más estable, menos riesgo)
2 proyectos y permisos	
3 datos	(con protección primero)
4 cargas	(las que más cambian)

el proceso por lote
generar el código desde lo existente
importar
ejecutar el plan
→ y aquí aparecía el trabajo real

lote de red: 210 recursos
plan tras importar: 118 diferencias
· 41 reglas de cortafuegos con descripción vacía
→ se ajustó el código
· 38 subredes sin registros de flujo activados
→ se corrigió el RECURSO
· 9 reglas con selector por etiqueta clase 229
→ se corrigieron
· 30 diferencias de campos irrelevantes
→ se ajustó el código

→ cada diferencia era una decisión, y 47 de las 118
revelaron configuraciones que estaban mal

Y el resultado global:

recursos importados	4.100
→ los otros 4.890 eran efímeros o de servicios gestionados que no se declaran	
diferencias encontradas al importar	1.240
ajustes al código	810
CORRECCIONES DE RECURSOS	430 ←

→ importar fue, además, una auditoría de configuración
→ y las 430 correcciones son la remediación que la ley 27
exige clase 228

El estado que se perdió.

qué pasó
una canalización mal configurada aplicó con la variable
de ruta del estado vacía
→ creó un estado nuevo, vacío, en la ruta por defecto
→ y el siguiente despliegue, con el estado bueno, entró
en conflicto

y el estado bueno se sobrescribió

qué salvó el caso
el almacén tenía versionado activado
→ se restauró la versión anterior en 4 minutos

qué habría pasado sin versionado
el código no habría sabido qué existía
→ habría intentado crear 4.100 recursos que ya estaban
→ y en los que el nombre no es único, habría creado
duplicados

correcciones
la ruta del estado, obligatoria y comprobada en la
canalización
copia diaria del estado a otro almacén
y una prueba: borrar el estado en un entorno inferior y
restaurarlo ley 22

La validación previa de políticas, que era lo que faltaba.

antes de montarla, en 3 meses	
despliegues rechazados por política EN EL MOMENTO DE APLICAR	61
de ellos, en producción	19
de ellos, que dejaron el cambio a medias	11
tiempo medio de resolución	2 h 20

tras montarla
la canalización convierte el plan a la forma final y lo
evalúa contra las restricciones
→ falla en la validación, con el mensaje

despliegues rechazados en el momento de aplicar
61 → 2
los 2, por restricciones que la validación no cubre
rechazados en la validación 74
→ antes de tocar nada, en 40 segundos
tiempo medio de resolución 2 h 20 → 9 min

Y las políticas propias que se añadieron a la validación:

ningún almacén sin cifrado con clave propia
ninguna base sin copia de seguridad configurada
ningún recurso sin las 5 etiquetas obligatorias
ninguna regla de cortafuegos con selector por etiqueta
ninguna cuenta de servicio con papel de proyecto
ningún recurso fuera de las regiones de la UE

→ y cada una con un mensaje que dice qué falta y enlaza el
módulo que ya lo cumple clase 217

La estimación de coste, que evitó dos sorpresas:

caso 1 una propuesta de cambio añadía un clúster con
nodos de 32 núcleos
estimación +8.400 €/mes
→ la revisión preguntó por qué; resultó ser un
valor copiado de otro entorno
→ corregido a nodos de 8: +1.100 €/mes

caso 2 una propuesta activaba registros de acceso a
datos en todos los servicios
estimación +3.900 €/mes
clase 238
→ se acotó a los servicios con datos sensibles:
+410 €/mes

La deriva, detectada:

plan ejecutado a diario, sin cambios de código
→ si no sale vacío, hay deriva

primeros 6 meses
detecciones 23
cambios hechos por consola durante incidentes 14
→ 9 de ellos deberían haberse revertido y no se
revirtieron ley 25
cambios de servicios gestionados que ajustan campos 6
→ se marcaron para ignorar
3 cambios que nadie pudo explicar
→ investigados; 2 eran automatismos de la
plataforma, 1 fue un script de un proveedor

→ y las 9 del primer grupo son exactamente lo que la deriva
sirve para encontrar

Las pruebas negativas, ejecutadas:

✓ borrar el estado y restaurarlo 4 min
✓ aplicar dos veces en paralelo bloqueado
✓ destruir un recurso protegido falla en el
plan
✓ desplegar algo que incumple una política falla en
validación

✗ plan sin cambios, vacío
→ 6 recursos con deriva permanente por campos que la
plataforma ajusta sola
→ marcados para ignorar; corregido
✓ desplegar el entorno de cero en proyecto vacío 61 min

El resultado:

recursos bajo código	4 %	97 %
estados en repositorios	2	0
secretos expuestos en estados	4	0
despliegues rechazados al aplicar	61/trim	2/trim
tiempo de resolución de un rechazo	2 h 20	9 min
configuraciones corregidas al importar	—	430

deriva detectada y corregida	no	23/6mes
sorpresas de coste en despliegues	2/trim	0
tiempo de despliegue de cero	imposible	61 min

La lección que esta clase deja: importar cuatro mil cien recursos fue además una auditoría, y produjo cuatrocientas treinta correcciones de configuración que ninguna herramienta de postura había señalado. La validación previa de políticas convirtió sesenta y un rechazos en producción en setenta y cuatro fallos de canalización de cuarenta segundos. Y el estado estuvo catorce meses en un repositorio con tres contraseñas de producción en claro, visible para doscientos catorce personas.

Laboratorio guiado

Ejecuta desde la raíz:

```
python classes/part-19-gcp-production-architecture/232-terraform-infrastructure-manager-y-policy-validation/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 gcp-iac-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 gcp-iac-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
El estado contiene secretos visibles para mucha gente	Está en un repositorio o en un almacén con acceso amplio	Estado remoto, cifrado, versionado y restringido a unas pocas identidades, con registro de acceso, y una función de aptitud que prohíba ficheros de estado en repositorios.
Se pierde el estado y el código intenta crear lo que ya existe	El almacén no tiene versionado o la ruta del estado no está fijada	Versionado obligatorio, copia diaria, ruta comprobada en la canalización y prueba de restauración.
Un despliegue se rechaza por política a mitad de aplicar	No se valida el plan contra las restricciones antes de aplicar	Convierte el plan a su forma final y evalúalo contra las políticas en la canalización, con mensajes que digan qué falta.
Una recreación destruye datos	El plan no se leyó y el recurso no estaba protegido	Marca los recursos con datos contra destrucción y pon puerta de aprobación cuando el plan liste destrucciones.
Un cambio hecho en la consola desaparece en el siguiente despliegue	Deriva no detectada entre el código y la realidad	Ejecuta el plan periódicamente sin cambios de código y alerta si no sale vacío.
Aparecen sorpresas de coste tras un despliegue	No se estima el coste del plan en la revisión	Añade estimación de coste a la canalización, con umbral que exija aprobación.

■ 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 capacidades da el estado y qué riesgos trae?
2. ¿Qué ocurre si se pierde el estado y cómo se recupera?
3. ¿Qué se gana validando las políticas sobre el plan en vez de al aplicar?
4. ¿Qué revela la importación de recursos existentes además de ponerlos bajo código?
5. ¿Cómo se detecta que alguien cambió algo por la consola?

Referencias

- HashiCorp (2025). Terraform state: remote backends and locking. <<https://developer.hashicorp.com/terraform/language/state>>
- Google Cloud (2025). Infrastructure Manager. <<https://cloud.google.com/infrastructure-manager/docs/overview>>
- Google Cloud (2025). Policy validation with Policy Library. <<https://cloud.google.com/docs/terraform/policy-validation>>
- Google Cloud (2025). Cloud Foundation Toolkit modules. <<https://cloud.google.com/foundation-toolkit>>
- HashiCorp (2025). Importing existing infrastructure. <<https://developer.hashicorp.com/terraform/cli/import>>
- Documentación oficial vigente del servicio implementado; registra URL y fecha de consulta.

Descargar: Parte 19 en PDF · Recorrido de Google Cloud en PDF · Manual integral

Anterior	Índice	Siguiente
← 231 · Red global, load balancing, PSC y Cloud DNS	Parte 19 · Programa	233 · Cloud Run, Functions, API Gateway y Workflows →

Evaluación — 232 Terraform, Infrastructure Manager y policy validation

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 gcp-iac-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.

233 — Cloud Run, Functions, API Gateway y Workflows

Parte: 19 — Google Cloud: arquitectura de datos y operación en producción Nivel: avanzado · Horas estimadas: 4
Laboratorio: serverless · Estado: EXECUTABLECORE

Propósito

Desplegar cargas sin gestionar servidores en Google Cloud, donde el modelo de contenedores gestionados es el que más ha cambiado la forma de trabajar: se despliega una imagen, escala a cero y se reparte tráfico por revisión, sin orquestador. La clase cubre la configuración que separa un servicio de demostración de uno de producción —concurrency, instancias mínimas, tiempos de espera y conexiones—, las funciones y la orquestación de pasos largos.

Resultados de aprendizaje

Al finalizar podrás:

1. Elegir entre servicio de contenedores, funciones y flujos de trabajo.
2. Configurar concurrency e instancias con criterio, no por defecto.
3. Conectar las cargas a la red privada, de entrada y de salida.
4. Desplegar con reparto por revisión y vuelta atrás inmediata.
5. Orquestar procesos de varios pasos sin escribir la coordinación.

Conceptos centrales


Concepto	Comprensión verificable
servicio de contenedores gestionado	Ejecuta una imagen con escalado automático, escala a cero y reparto de tráfico por revisión.
concurrency por instancia	Cuántas peticiones atiende una instancia a la vez. Es el ajuste que más cambia coste y latencia.
instancia mínima	Número de instancias siempre encendidas. Elimina el arranque en frío y se paga.
revisión	Versión inmutable del servicio. El tráfico se reparte entre revisiones por porcentaje.
conector de red	Mecanismo que hace que el tráfico saliente del servicio pase por la red privada.
flujo de trabajo	Orquestación declarativa de pasos con reintentos, esperas y compensaciones, sin código de coordinación.

Modelo mental

Google Cloud combina una jerarquía estricta de recursos con una red global y servicios data-first; proyecto, cuota e IAM forman una unidad operativa.

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 forma de ejecutar

Hay cuatro opciones y se diferencian por lo que ejecutan y cuánto duran.

SERVICIO DE CONTENEDORES

- una imagen que atiende peticiones
- + cualquier lenguaje y cualquier dependencia
- + escala a cero y escala por peticiones
- + reparto de tráfico por revisión, nativo
- + sin orquestador que operar
- arranque en frío si escala a cero

FUNCIONES

- código sin empaquetar, disparado por eventos o HTTP
- + más simple para pagamento
- menos control del entorno
- y en la práctica se ejecutan sobre la misma base que los servicios: la diferencia es de empaquetado

TRABAJO

- un contenedor que se ejecuta, termina y no atiende peticiones
- + para lotes, migraciones y procesos programados
- + con paralelismo por tareas

FLUJO DE TRABAJO

- orquestación declarativa de pasos
- + reintentos, esperas largas, ramas y compensaciones sin escribir código de coordinación
- no es para lógica compleja: para coordinar

Y el criterio:

¿atiende peticiones HTTP?	servicio
¿reacciona a un evento y es pequeño?	función
¿empieza, hace y termina?	trabajo
¿coordina varios pasos con esperas y reintentos?	flujo de trabajo
¿necesita operadores, GPU o planificación fina?	clúster
	clase 234

Y la diferencia principal frente a lo visto en las otras nubes:

aquí el servicio de contenedores cubre lo que en otras nubes se reparte entre varios productos

- aplicaciones web, APIs, trabajadores y funciones
 - con un solo modelo de despliegue y de escalado
 - y eso reduce mucho lo que hay que aprender y operar
- ley 23

Y una advertencia de traslado:

- X «escala a cero, así que es lo más barato»
- con tráfico continuo, un servicio con instancias mínimas puede salir más barato que uno que arranca y para
- y con concurrencia alta, mucho más ← ver abajo

2. Concurrencia: el ajuste que más cambia

Este es el parámetro que distingue este modelo y el que más se configura mal.

CONCURRENCIA POR INSTANCIA

cuántas peticiones atiende UNA instancia a la vez
valor por defecto: alto (80 en muchos casos)

ALTA

- + menos instancias para el mismo tráfico
- + mucho más barato
- + menos arranques en frío
- una petición pesada afecta a las otras 79
- y la memoria se comparte entre todas

BAJA (1)

- + aislamiento total: como una función
- + útil si el código no es seguro para concurrencia
- una instancia por petición: caro y con muchos arranques

Y el cálculo, que es el de la clase 186:

$\text{instancias} = \text{caudal} \times \text{latencia} / \text{concurrencia}$

$1.000 \text{ pet/s} \times 0,08 \text{ s} / 80 = 1 \text{ instancia}$
 $1.000 \text{ pet/s} \times 0,08 \text{ s} / 1 = 80 \text{ instancias}$

- el mismo tráfico, con 80 veces más instancias
- y por tanto, con 80 veces más conexiones a la base

Y de ahí la consecuencia que rompe sistemas:

LAS CONEXIONES A LA BASE

cada instancia abre su agrupación
instancias máximas $\times$ tamaño de agrupación = conexiones

con concurrencia 1 y máximo 100 instancias

$100 \times 5 = 500 \text{ conexiones}$

y la base admite 200

→ agotamiento, igual que en la clase 207

con concurrencia 80 y el mismo tráfico

$2 \text{ instancias} \times 5 = 10 \text{ conexiones}$

- subir la concurrencia es también la forma de reducir conexiones
- y donde no se pueda, hace falta un intermediario

Y cómo se elige el valor:

¿el código es seguro para atender varias peticiones a la vez?

no → concurrencia 1, y arreglarlo

sí → medir

y se mide

con la carga real, subiendo la concurrencia hasta que la latencia empeora

→ el punto donde el p99 empieza a subir es el codo
clase 186

→ y se elige algo por debajo

Las instancias mínimas, con la decisión de coste:

MÍNIMO 0

- + no se paga cuando no hay tráfico
- arranque en frío en la primera petición
- aceptable para lo asíncrono y lo interno

MÍNIMO ≥ 1

- + sin arranque en frío
- se paga siempre
- obligatorio en el camino crítico

Y EL TAMAÑO DE LA IMAGEN decide cuánto dura el arranque

- imagen mínima, dependencias justas clase 212
- y el trabajo de inicialización, fuera de la petición

3. Red, despliegue y tiempos

La red, con la misma separación de la clase 221:

ENTRADA

- pública, interna o solo desde el balanceador
- «interna» significa alcanzable desde la red, no desde internet
- y la autorización sigue siendo necesaria: la red no autoriza clase 189

SALIDA

- por defecto, el tráfico saliente NO pasa por tu red
- un conector o la salida directa a la red hacen que sí
- y solo entonces se alcanza lo privado y se pasa por el cortafuegos clases 221, 231

y hay que decidir

- ¿todo el tráfico saliente por la red, o solo el privado?
- para control de salida, todo clase 200

Y el error de traslado que se repite:

- X «tiene entrada interna, ya está en la red»
- la entrada y la salida se configuran por separado
- y sin conector, el servicio no alcanza la base privada

El despliegue por revisiones, que aquí es nativo y muy bueno:

cada despliegue crea una REVISIÓN inmutable
el tráfico se reparte por porcentaje entre revisiones

- desplegar sin tráfico 0 %
- comprobar con una etiqueta que da una URL propia
- desviar 5 %, 25 %, 100 %
- y volver atrás cambiando el porcentaje segundos

→ es el despliegue escalonado de la clase 102, sin montar nada

→ y la vuelta atrás no redespliega: cambia un número

Y lo que hay que cuidar:

LAS MIGRACIONES DE ESQUEMA

- dos revisiones sirviendo a la vez significa dos versiones del código contra la misma base
- expandir y contraer, siempre clase 188

LAS SESIONES

- las instancias son efímeras y no hay afinidad garantizada
- el estado va fuera clase 149

Los tiempos de espera y el ciclo de vida:

TIEMPO MÁXIMO DE PETICIÓN

- configurable, con un máximo alto
- y el mismo error de la clase 207: poner el máximo «por si acaso» significa pagar peticiones colgadas
- múltiplo pequeño del p99 ley 26

SEÑAL DE TERMINACIÓN

- la instancia recibe aviso antes de pararse

- hay que atenderla: terminar lo que se está haciendo
- si no, se cortan peticiones clase 212

TRABAJO EN SEGUNDO PLANO

- fuera de una petición, la CPU puede no estar asignada
- un hilo que sigue trabajando tras responder puede no avanzar
- o se activa la asignación continua de CPU, o el trabajo va a una cola clase 237

Y una advertencia sobre eso último, que sorprende:

- el patrón «responder rápido y seguir trabajando en segundo plano» NO funciona por defecto aquí
- y falla de forma intermitente, que es lo peor
- el trabajo diferido va a una cola, siempre

4. Flujos de trabajo y operación

Los flujos de trabajo resuelven la coordinación sin escribirla, y evitan uno de los antipatrones de la parte 09.

QUÉ RESUELVEN

- «llama a A; si falla, reintenta 3 veces con retroceso; luego espera a que llegue B; si tarda más de 2 horas, compensa A y avisa»
- escrito en un fichero declarativo
- con el estado de cada ejecución persistido

QUÉ EVITAN

- la coordinación escrita a mano en un servicio, que acumula estado y se convierte en un punto único
- y las esperas largas ocupando concurrencia

Y LOS LÍMITES

- no son para lógica de negocio compleja
- ni para volumen muy alto
- cada paso tiene coste, y con millones de ejecuciones suma

Y la disciplina que este programa exige y aquí también aplica:

- cada paso con efecto, **IDEMPOTENTE** clase 210
- el flujo reintenta, y un reintento no debe duplicar las compensaciones, explícitas y probadas
- y recordando que la compensación hace invisible el fallo ley 19
- y el estado del flujo, consultable
- «¿por qué este pedido lleva 3 horas?» debe tener respuesta sin abrir registros

Lo que hay que vigilar en estas cargas:

- peticiones, errores y latencia por percentil clase 238
- instancias activas frente al máximo
- tocar el máximo significa rechazo
- utilización de la concurrencia
- si está muy por debajo, se puede subir y ahorrar tiempo de arranque y peticiones que lo pagan
- conexiones a la base por instancia
- peticiones que agotan el tiempo de espera
- y en flujos: ejecuciones en curso, fallidas y su antigüedad ley 13

Y el coste, con las palancas propias:

- se factura por tiempo de instancia y por peticiones

las palancas, por efecto

- 1 SUBIR LA CONCURRENCIA ← la mayor, con diferencia
- 2 reducir la latencia (menos tiempo de instancia)
- 3 instancias mínimas solo donde hacen falta
- 4 memoria y CPU ajustadas, medidas
- 5 y la asignación continua de CPU solo si se usa

Y la lista de comprobación de la clase:

- la forma de ejecutar corresponde a la carga

- la concurrencia se eligió midiendo, no por defecto
- el código es seguro para concurrencia, comprobado
- las conexiones máximas a la base están calculadas
- las instancias mínimas cubren el camino crítico
- la imagen es mínima y el arranque está medido
- la entrada está restringida y la salida pasa por la red
- el despliegue usa revisiones con reparto por porcentaje
- los cambios de esquema usan expandir y contraer
- el tiempo de espera es múltiplo pequeño del p99
- el servicio atiende la señal de terminación
- no hay trabajo en segundo plano fuera de la petición
- los pasos de los flujos son idempotentes
- hay alerta de ejecuciones de flujo antiguas o fallidas

Y el cierre que enlaza con la clase siguiente: cuando la carga exige operadores, control fino o cargas heterogéneas, aparece el clúster gestionado, que aquí tiene un modo que quita casi toda la operación. Es la materia de la clase 234.

Ejemplo trabajado

CloudShop despliega su plataforma en Google Cloud. Lo que sigue es el ajuste de concurrencia que redujo el coste un 71 % y las conexiones a la base de 500 a 12, el trabajo en segundo plano que fallaba de forma intermitente, y el flujo de trabajo que sustituyó a un coordinador escrito a mano.

El montaje inicial, trasladado de la nube anterior:

```
11 servicios, todos con
  concurrencia                1
  motivo del equipo    «así se comporta como una función,
                        que es lo que teníamos»
  instancias mínimas      0
  máximo                  100
  tiempo de espera        300 s
  memoria                  512 Mi
  entrada                  interna
  salida                   sin conector
```

Y los cuatro problemas que aparecieron el primer mes:

- 1 la base agotó conexiones en el primer pico
- 2 el coste era 3,4 veces el estimado
- 3 los servicios no alcanzaban la base privada
- 4 el envío de correos fallaba de forma intermitente

Problema 1 y 2 · La concurrencia.

```
el cálculo, con la carga real del servicio de pedidos
caudal en el pico          900 pet/s
latencia p50                78 ms
```

```
con concurrencia 1
  instancias = 900 × 0,078 / 1 = 71 instancias
  conexiones = 71 × 7 = 497          > 200 de la base
```

```
con concurrencia 40
  instancias = 900 × 0,078 / 40 = 2 instancias
  conexiones = 2 × 7 = 14
```

Y la medición para elegir el valor:

se subió la concurrencia por escalones, midiendo el p99

concurrencia	p99	instancias en el pico
1	142 ms	71
10	148 ms	8
25	151 ms	3
40	156 ms	2
60	189 ms	2
80	410 ms	2 ← el codo

→ el p99 empieza a subir claramente entre 60 y 80
→ se eligió 40, con margen

y antes hubo que comprobar
¿el código es seguro para atender varias a la vez?

- 2 de los 11 servicios NO lo eran: usaban una variable global para el contexto de la petición
- corregidos; y hasta corregirlos, quedaron en concurrencia 1

Y el efecto:

concurrencia	1	40
instancias en el pico	71	2
conexiones a la base	497	14
coste de cómputo	4.100 €	1.180 €
p99	142 ms	156 ms
agotamientos de conexiones	3/mes	0

Problema 3 · La salida sin conector.

síntoma los servicios no alcanzaban la base privada
ni el almacén con conexión privada clase 231

causa entrada configurada como interna
→ el equipo asumió que eso los ponía «en la red»
→ la SALIDA es un ajuste distinto

corrección
conector de red, con subred dedicada dimensionada por el máximo de instancias
y encaminamiento de CUANTO tráfico salga, por la red
→ así pasa por el cortafuegos y se registra clase 200

y la comprobación que se añadió
desde el servicio, resolver el nombre de la base
→ debe devolver dirección privada
y comprobar la dirección de salida observada
→ debe ser la de la pasarela de traducción

Problema 4 · El trabajo en segundo plano.

síntoma entre el 2 % y el 11 % de los correos de confirmación no se enviaban
sin errores en los registros
sin patrón horario

causa
el servicio respondía al cliente y luego, en un hilo aparte, enviaba el correo
→ fuera de la petición, la CPU puede no estar asignada
→ el hilo se quedaba a medias y la instancia se apagaba
→ y no se registraba nada porque no llegaba a fallar

corrección
el envío pasa a una cola; un servicio consumidor lo procesa clase 237
→ y con idempotencia, porque hay reintentos

correos no enviados 2-11 % → 0

Y la observación del equipo:

este fallo es el más difícil de los cuatro
no daba error
no tenía patrón
y funcionaba en pruebas, donde el tráfico bajo mantenía las instancias vivas
→ y es una diferencia de modelo, no un error de configuración clase 229

El flujo de trabajo que sustituyó al coordinador.

el proceso de devolución tenía 7 pasos
validar → autorizar reembolso → esperar recepción del paquete (hasta 14 días) → inspeccionar → reembolsar → actualizar inventario → notificar

la implementación anterior
un servicio que guardaba el estado en una tabla
un trabajo programado cada 10 min que buscaba

devoluciones pendientes y las avanzaba
reintentos escritos a mano
compensaciones escritas a mano
→ 1.400 líneas de coordinación
→ y 3 incidentes en el año por estados inconsistentes

la implementación con flujo de trabajo
fichero declarativo de 120 líneas
reintentos con retroceso, declarados
espera de hasta 14 días, nativa
compensación declarada
estado de cada ejecución, consultable

resultado
líneas de coordinación 1.400 → 120
incidentes por estado inconsistente 3/año → 0
«¿por qué esta devolución lleva 3 días?»
antes abrir registros: 20-40 min
después consultar la ejecución: 30 s
coste +18 €/mes

Y la disciplina que hizo falta:

los 7 pasos, idempotentes
→ el flujo reintentaba, y reembolsar dos veces cuesta dinero
→ clave de idempotencia por devolución e intento clase 210
y la compensación, probada
→ se ejecutó a propósito 20 veces en preproducción
→ 2 de 20 dejaron el inventario mal: corregido ley 19, 22

El despliegue por revisiones, y lo que evitó:

214 despliegues en 6 meses
desplegados sin tráfico y comprobados con URL propia
desviados al 5 %, luego al 100 %
revisiones que no llegaron al 100 % 9
· 6 detectadas en el 5 % por tasa de error
· 3 detectadas al comprobar con la URL propia
tiempo de vuelta atrás 12 s
peticiones afectadas por despliegue defectuoso
~340 (en el 5 %)

y lo que habría pasado sin reparto por porcentaje
las 9 habrían llegado al 100 % del tráfico

El resultado:

coste de cómputo	4.100 €	1.180 €
conexiones máximas a la base	497	14
agotamientos de conexiones	3/mes	0
correos no enviados	2-11 %	0
servicios que alcanzan la base privada	0/11	11/11
líneas de coordinación de devoluciones	1.400	120
incidentes por estado inconsistente	3/año	0
despliegues defectuosos que llegaron a todo el tráfico	n/d	0

La lección que esta clase deja: un solo parámetro —la concurrencia, puesta en 1 por trasladar el modelo de funciones— costaba dos mil novecientos euros al mes y agotaba las conexiones de la base. Subirlo a 40 redujo las instancias de setenta y una a dos. Y el fallo más difícil de los cuatro no dio ningún error: el trabajo en segundo plano fuera de la petición no avanza, y eso no es un error de configuración sino una diferencia de modelo que hay que conocer antes de trasladar código.

Laboratorio guiado

Ejecuta desde la raíz:

```
python classes/part-19-gcp-production-architecture/233-cloud-run-functions-api-gateway-y-workflows/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 gcp-serverless 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 gcp-serverless 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
La base agota conexiones con poco tráfico	Concurrencia por instancia baja, que multiplica el número de instancias y de agrupaciones	Mide el codo subiendo la concurrencia y elige un valor por debajo; calcula las conexiones máximas resultantes.
El coste es varias veces el estimado	Se factura tiempo de instancia y hay muchas instancias por concurrencia baja	Subir la concurrencia es la palanca de coste con más efecto; después, reducir latencia y ajustar recursos.
El servicio no alcanza recursos privados pese a tener entrada interna	Entrada y salida se configuran por separado	Añade el conector o la salida directa a la red y comprueba la dirección de salida observada.
Un trabajo diferido falla de forma intermitente y sin errores	Fuera de la petición, la CPU puede no estar asignada y el hilo no avanza	Envía el trabajo diferido a una cola con un consumidor propio, o activa la asignación continua de CPU.
Se paga tiempo de peticiones que ya no interesan a nadie	El tiempo de espera está en el máximo por si acaso	Fíjalo en un múltiplo pequeño del p99 esperado.
Dos revisiones sirviendo a la vez rompen la base	Un cambio de esquema incompatible entre versiones	Aplica expandir y contraer: el código tolera las dos formas durante la transición.

■ 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. ¿Cómo se relacionan concurrencia, número de instancias y conexiones a la base?
2. ¿Cómo se elige el valor de concurrencia y qué hay que comprobar antes?
3. ¿Por qué tener entrada interna no basta para alcanzar recursos privados?
4. ¿Qué le ocurre al trabajo que sigue tras responder a la petición?
5. ¿Qué resuelve un flujo de trabajo y qué sigue siendo responsabilidad del código?

Referencias

- Google Cloud (2025). Cloud Run: concurrency and instance settings. <<https://cloud.google.com/run/docs/about-concurrency>>
- Google Cloud (2025). Cloud Run: traffic management and revisions. <<https://cloud.google.com/run/docs/managing/revisions>>
- Google Cloud (2025). Cloud Run: CPU allocation and background activity. <<https://cloud.google.com/run/docs/configuring/cpu-allocation>>
- Google Cloud (2025). Connecting to a VPC network from Cloud Run. <<https://cloud.google.com/run/docs/configuring/connecting-vpc>>
- Google Cloud (2025). Workflows. <<https://cloud.google.com/workflows/docs/overview>>
- Documentación oficial vigente del servicio implementado; registra URL y fecha de consulta.

Descargar: Parte 19 en PDF · Recorrido de Google Cloud en PDF · Manual integral

Anterior	Índice	Siguiente
← 232 · Terraform, Infrastructure Manager y policy validation	Parte 19 · Programa	234 · GKE Autopilot, Workload Identity y Config Sync →

Evaluación — 233 Cloud Run, Functions, API Gateway y Workflows

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 gcp-serverless 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.

234 — GKE Autopilot, Workload Identity y Config Sync

Parte: 19 — Google Cloud: arquitectura de datos y operación en producción Nivel: avanzado · Horas estimadas: 4
Laboratorio: kubernetes · Estado: EXECUTABLECORE

Propósito

Operar Kubernetes gestionado en Google Cloud, donde existe un modo que quita casi toda la operación de nodos y cambia la decisión de la clase 213: si el motivo para no usar clúster era el coste de mantenerlo, ese motivo se reduce mucho. La clase compara los dos modos con lo que cada uno permite y prohíbe, cubre la identidad de carga y el consumo de direcciones, y la reconciliación desde el repositorio con su alerta imprescindible.

Resultados de aprendizaje

Al finalizar podrás:

1. Elegir entre el modo gestionado y el estándar con criterios.
2. Decidir si el clúster compensa frente al servicio de contenedores.
3. Dar identidad a las cargas sin claves, atada al espacio de nombres.
4. Dimensionar los rangos de direcciones que consume el clúster.
5. Operar con reconciliación, políticas y actualizaciones planificadas.

Conceptos centrales


Concepto	Comprensión verificable
modo gestionado	El proveedor administra los nodos: se paga por lo que piden los pods y no hay conjunto que mantener.
modo estándar	Grupos de nodos administrados por el equipo. Más control y más trabajo.
identidad de carga	Vinculación entre una cuenta de servicio de Kubernetes y una de la nube, sin claves.
rango secundario	Rango de la subred del que salen las direcciones de pods y servicios. Es el que más consume.
canal de versión	Política de actualización automática del plano de control y de los nodos.
sincronización de configuración	Bucle gestionado que aplica el estado declarado en el repositorio y corrige la deriva.

Modelo mental

Google Cloud combina una jerarquía estricta de recursos con una red global y servicios data-first; proyecto, cuota e IAM forman una unidad operativa.

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. Dos modos, y qué cambia cada uno

La decisión más importante al crear el clúster es el modo, y aquí hay uno que no existe en las otras nubes.

MODO GESTIONADO

- no hay grupos de nodos que administrar
- se paga por CPU, memoria y disco que PIDEN los pods

- el proveedor decide y mantiene los nodos
- + sin parchear, sin escalar el conjunto, sin drenar
- + la petición de recursos es el contrato: si pides bien, pagas bien
- + configuración segura por defecto: política de red, nodos endurecidos, identidad de carga activada
- ley 26
- no se puede tocar el nodo: nada de agentes con acceso privilegiado ni configuraciones del sistema
- menos control sobre el empaquetado
- y ciertas capacidades quedan restringidas

MODO ESTÁNDAR

- grupos de nodos propios
- + control total: agentes, configuración, tipos de máquina
- + coste por unidad menor si el empaquetado es alto
- hay que mantener el conjunto
- ley 23
- y hay que activar a mano lo que el otro trae puesto

Y el efecto sobre la decisión de la clase 213:

- el motivo principal para NO usar clúster era el coste de operarlo
- actualizaciones, complementos, nodos, parches
- el modo gestionado reduce mucho ese coste
- y por tanto la frontera se mueve: hay casos que antes no compensaban y ahora sí
- lo que NO cambia
- sigue habiendo actualizaciones de versión
- siguen los complementos que se instalan a mano
- y sigue haciendo falta saber Kubernetes

Y el criterio actualizado:

- ¿es un servicio HTTP o un trabajo?
- servicio de contenedores; más simple
- clase 233
- ¿hacen falta operadores, recursos propios o planificación fina?
- clúster
- ¿hacen falta agentes con acceso al nodo o configuración del sistema?
- clúster en modo estándar
- ¿ninguna de las dos?
- clúster en modo gestionado

Y una advertencia de coste que sorprende:

- en el modo gestionado se paga lo que PIDEN los pods
- una petición de recursos generosa «por si acaso» se paga entera, use lo que use
- y por tanto las peticiones bien puestas dejan de ser buena práctica y pasan a ser una línea de la factura
- clase 213

2. Identidad y direcciones

La identidad de carga es el mecanismo estándar aquí y conviene que esté activada desde el principio.

CÓMO FUNCIONA

- una cuenta de servicio de Kubernetes se anota con una cuenta de servicio de la nube
- el pod obtiene testigos de esa identidad
- sin claves, sin secretos montados

Y EL ENLACE

- se concede a la cuenta de Kubernetes el permiso de suplantar la de la nube
- atado a espacio de nombres Y nombre de la cuenta
- el mismo error de las clases 218 y 222: si se ata solo al proyecto, cualquier cuenta de servicio del clúster la obtiene

Y LO QUE HAY QUE DESACTIVAR

- el acceso de los pods al servicio de metadatos del nodo

- si no, obtienen la identidad del NODO, que suele tener más permisos
- en el modo gestionado viene desactivado; en el estándar, hay que hacerlo ley 26

Y la prueba obligatoria:

- desde un pod de otro espacio de nombres, intentar obtener la identidad
- debe fallar
- y desde un pod, leer las credenciales del nodo
- debe estar bloqueado ley 22

Las direcciones, que es la decisión que más consume:

LOS TRES RANGOS

nodos	del rango principal de la subred
PODS	de un rango secundario
SERVICIOS	de otro rango secundario

EL CÁLCULO

- el rango de pods se dimensiona por
- nodos máximos × pods por nodo × factor de reserva
- y el factor no es 1: se reservan bloques por nodo
- un clúster de 100 nodos con 110 pods por nodo puede necesitar un /17

Y LA TRAMPA

- el número de pods por nodo se fija al crear
- y el rango de pods NO se puede cambiar sin recrear
- es la misma decisión irreversible de la clase 222 ley 14

Y las opciones que reducen el consumo:

- reducir los pods por nodo, si no hacen falta 110
- usar rangos no enrutables para pods, donde el modelo lo permita clase 193
- y reutilizar rangos secundarios entre clústeres, donde esté soportado
- y en cualquier caso, calcularlo ANTES, con el plan de direcciones delante

Y el uso de red compartida:

- el clúster vive en un proyecto de servicio y usa subredes de la red compartida clase 229
- los rangos secundarios los cede el proyecto anfitrión
- y por tanto los pide plataforma, no el equipo

3. Operar desde el repositorio

La reconciliación es la misma idea de las clases 213 y 222, con una variante gestionada.

SINCRONIZACIÓN DE CONFIGURACIÓN GESTIONADA

- un componente del proveedor aplica lo declarado en el repositorio y corrige la deriva
- + menos que operar
- + con políticas de admisión integradas
- menos control sobre versiones y extensiones

O UN CONTROLADOR PROPIO

- + control total y portable
- hay que operarlo ley 23

Y la alerta que no puede faltar, por tercera vez:

- «la sincronización lleva N minutos sin completarse»
- o «el estado real difiere del declarado desde hace N»
- un bucle parado no da error: deja de aplicar ley 13
- y en la clase 179 esa prueba negativa falló porque la alerta iba a un canal sin nadie

Las políticas de admisión, que aquí se integran con el gobierno:

- lo que hay que impedir

y la disciplina
modo de aviso primero, con medición
mensajes que digan qué falta y cómo arreglarlo
y el carril fácil que cumpla solo ley 16

en el modo gestionado viene activada
 en el estándar hay que activarla, y por defecto todos los
 pods hablan con todos ley 26, clase 222
 → denegación por defecto entre espacios de nombres, y
 reglas explícitas

CANALES DE VERSIÓN
rápido · regular · estable
→ el plano de control y los nodos se actualizan solos dentro del canal
→ con VENTANAS Y EXCLUSIONES de mantenimiento declaradas

LO QUE SIGUE SIENDO MANUAL

- las versiones mayores
- los complementos instalados a mano
- y los operadores propios

el aviso de interfaces retiradas: la plataforma detecta
manifiestos que usan API que van a desaparecer
→ conviene revisarlo antes de cada canal, no después
→ y añadirlo a la canalización

MODO GESTIONADO
se paga lo pedido por los pods
palancas
 peticiones ajustadas al p95 real clase 213
 clases de cómputo adecuadas a la carga
 y pods de baja prioridad para lotes tolerantes
→ y no hay empaquetado que optimizar: eso lo hace el
 proveedor

Y EN AMBOS
el clúster tiene un coste fijo de plano de control
→ varios clústeres pequeños cuestan más que uno con
espacios de nombres separados
→ salvo que el aislamiento lo justifique

- + una dirección para varias regiones clase 231
- + certificados gestionados y caché en el borde
- + filtrado de aplicación delante

CONTROLADOR DE ENTRADA PROPIO

- + control y portabilidad clase 158
- hay que operarlo

Y LA PUERTA DE ENLACE declarativa

- el modelo más nuevo, con separación entre quien opera la entrada y quien declara las rutas
- encaja con la separación de la clase 229

Y las comprobaciones de esta clase:

- obtener la identidad desde otro espacio de nombres
→ debe fallar
- leer credenciales del nodo desde un pod
→ debe estar bloqueado
- desplegar una imagen de un registro ajeno
→ debe rechazarse
- desplegar un pod sin peticiones de recursos
→ debe rechazarse
- desplegar un pod con privilegios
→ debe rechazarse
- hablar entre dos espacios de nombres no permitidos
→ debe fallar
- parar la sincronización y esperar la alerta
- perder una zona y comprobar el reparto de réplicas
clase 227

Y la lista de comprobación de la clase:

- la decisión de usar clúster está justificada frente al servicio de contenedores
- el modo elegido corresponde a lo que hace falta
- la identidad de carga está activada y atada a espacio de nombres y cuenta
- el acceso al servicio de metadatos está bloqueado
- los rangos secundarios se calcularon antes de crear
- los pods por nodo están ajustados a lo necesario
- el clúster usa la red compartida
- la política de red está activada, con denegación por defecto
- hay políticas de admisión con mensajes útiles
- la reconciliación está montada, con alerta por antigüedad
- el canal de versión y las ventanas están decididos
- se revisan las interfaces retiradas antes de actualizar
- las peticiones de recursos están medidas, no copiadas
- las réplicas se reparten entre zonas

Y el cierre que enlaza con la clase siguiente: con el cómputo resuelto, quedan los datos, que en esta nube ofrecen una familia amplia y una base distribuida con una propiedad que no tiene equivalente. Es la materia de la clase 235.

Ejemplo trabajado

CloudShop revisa su uso de Kubernetes en Google Cloud. Lo que sigue es la decisión de modo que cambió respecto a la de la clase 222, el cálculo de direcciones que evitó recrear el clúster, y el ahorro de ajustar las peticiones de recursos.

La decisión de modo:

- lo que se necesitaba
 - 2 cargas con GPU del equipo de datos
 - un operador de base vectorial
 - trabajos por lotes con prioridades
 - el buscador, con imagen propia

- lo que NO se necesitaba
 - agentes con acceso privilegiado al nodo
 - configuración del sistema operativo
 - tipos de máquina exóticos

→ modo GESTIONADO para todo salvo las cargas con GPU

y la comparación de esfuerzo, frente al clúster de Azure	
actualizaciones al año	3 planificadas → 1
mantenimiento de complementos	18 días/año → 4
soporte a equipos	44 días/año → 38
incidentes de plataforma	11 días/año → 3
██	
total	82 días/año → 46
	0,4 → 0,22 personas

el modo gestionado reduce a la mitad el coste de operación
→ y eso mueve la frontera de la clase 213: hay dos cargas
que se habían quedado fuera del clúster por el coste de
operarlo y que ahora entrarían
→ decisión: no moverlas de todos modos; funcionan donde
están clase 216

```

el equipo iba a aceptar los valores por defecto
    pods por nodo                                110
    rango de pods sugerido                       /14

el cálculo real
    nodos máximos previstos                      38
    pods por nodo REALES observados en el clúster de
        Azure                                     máx. 31
    → 110 era el valor por defecto y no correspondía a nada

con 32 pods por nodo
    rango de pods necesario                       /19
    rango de servicios                           /22

frente a
con 110 pods por nodo
    rango de pods                                /17

```

y la decisión irreversible
el número de pods por nodo se fija al crear
→ cambiarlo exige recrear el clúster lev 14

identidad de carga activada
7 cuentas de servicio de la nube, una por carga
enlace atado a espacio de nombres y nombre de cuenta

→ y es el mismo fallo que en la clase 222, con el mismo
componente: el que se instala a mano y no pasa por la
plantilla clase 229. lev 27

en el modo gestionado se paga lo PEDIDO

las peticiones estaban copiadas del clúster anterior

carga	pedido	uso p95 real
buscador	2 CPU / 4 Gi	0,7 CPU / 2,1 Gi
indexador	4 CPU / 8 Gi	2,9 CPU / 5,8 Gi
operador vect.	1 CPU / 2 Gi	0,1 CPU / 0,6 Gi
api interna	1 CPU / 2 Gi	0,2 CPU / 0,9 Gi
trabajos lote	2 CPU / 4 Gi	1,8 CPU / 3,6 Gi

ajuste a p95 con margen del 25 %

buscador	0,9 CPU / 2,7 Gi
indexador	3,6 CPU / 7,3 Gi
operador vect.	0,2 CPU / 0,8 Gi
api interna	0,3 CPU / 1,2 Gi
trabajos lote	2,3 CPU / 4,5 Gi

coste del clúster gestionado 3.400 € → 1.640 €/mes

→ y aquí el ajuste de peticiones no es higiene: es
directamente la factura clase 213

Y un efecto que no se buscaba:

al bajar las peticiones, más pods caben por nodo

→ y el proveedor usa menos nodos

→ pero como se paga por lo pedido, el ahorro es directo y
no depende del empaquetado

La reconciliación y las políticas:

sincronización gestionada desde el repositorio

con alerta de antigüedad, a canal con guardia

→ y probada parándola: alerta en 4 minutos ley 22

políticas de admisión, en modo aviso 3 semanas

incumplimientos medidos

imágenes de registros ajenos	41
→ 38 eran imágenes públicas de herramientas	
→ se copiaron al registro propio y se firmaron	
pods sin peticiones de recursos	62
→ todos, de un equipo que desplegaba a mano	
contenedores con privilegios	4
→ 3 legítimos (agentes de red), 1 innecesario	
sin etiquetas obligatorias	88

tras corregir, modo bloqueo

rechazos en el primer mes 6

todos, incumplimientos reales

tiquetes de soporte 0

→ porque el mensaje decía qué faltaba clase 217

Las actualizaciones, con el canal:

canal	regular
ventanas	martes y jueves, 02:00-06:00
exclusiones	del 15 de noviembre al 5 de enero (campana) y las 2 semanas de cierre trimestral

en 12 meses

actualizaciones automáticas aplicadas	9
que causaron incidencia	0
actualizaciones mayores planificadas	1
con revisión previa de interfaces retiradas	
→ 11 manifiestos corregidos antes	
duración de la mayor	2 h

El resultado:

coste del clúster	3.400 €	1.640 €
direcciones consumidas por pods	8.192	2.048
(con el valor por defecto)		
capacidad de equipo dedicada	0,4 pers.	0,22 pers.
actualizaciones planificadas al año	3	1
enlaces de identidad mal atados	1	0
pods sin peticiones de recursos	62	0
imágenes de registros ajenos	41	0

La lección que esta clase deja: el modo gestionado redujo a la mitad el coste de operar el clúster, lo que mueve la frontera de cuándo compensa usarlo. El valor por defecto de ciento diez pods por nodo no correspondía a nada —el uso real era treinta y uno— y aceptarlo habría consumido el proyecto entero de direcciones de forma irreversible. Y el único fallo de identidad estaba, otra vez, en el componente instalado a mano: el que no pasa por la plantilla.

Laboratorio guiado

Ejecuta desde la raíz:

```
python classes/part-19-gcp-production-architecture/234-gke-autopilot-workload-identity-y-config-sync/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 gcp-gke-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 gcp-gke-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 el rango de direcciones del proyecto entero	Se aceptó el valor por defecto de pods por nodo sin medir el uso real	Calcula nodos por pods reales antes de crear; el valor se fija al crear y cambiarlo exige recrear el clúster.
La factura del clúster gestionado es alta pese a poco uso	Se paga lo que piden los pods y las peticiones estaban copiadas	Ajusta las peticiones al p95 real con margen; aquí es directamente la factura, no higiene.
Cualquier cuenta de servicio del clúster obtiene una identidad privilegiada	El enlace de identidad se ató solo al proyecto	Ata a espacio de nombres y nombre de cuenta, y compruébalo desde un pod de otro espacio.
Los pods obtienen permisos que no les corresponden	Pueden alcanzar el servicio de metadatos del nodo	Bloquéalo; en modo gestionado viene bloqueado, en estándar hay que hacerlo.
Los cambios del repositorio dejan de aplicarse sin aviso	El bucle de sincronización se detuvo en silencio	Alerta por antigüedad de la sincronización, con destino a guardia, y pruébala parándola.
Una actualización automática ocurre en plena campaña	No hay exclusiones de mantenimiento declaradas	Declara ventanas y exclusiones para los periodos críticos, y revisa las interfaces retiradas antes de cambiar de canal.

■ 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 permite y qué prohíbe el modo gestionado, y cómo cambia la decisión de usar clúster?
2. ¿Por qué las peticiones de recursos son directamente la factura en modo gestionado?
3. ¿Qué rangos consume un clúster y cuál es la decisión irreversible?
4. ¿A qué debe atarse el enlace de identidad de carga?
5. ¿Qué sigue siendo manual pese a tener canal de versión?

Referencias

- Google Cloud (2025). GKE Autopilot overview.
<<https://cloud.google.com/kubernetes-engine/docs/concepts/autopilot-overview>>
- Google Cloud (2025). Workload Identity Federation for GKE.
<<https://cloud.google.com/kubernetes-engine/docs/concepts/workload-identity>>
- Google Cloud (2025). IP address planning for GKE clusters.
<<https://cloud.google.com/kubernetes-engine/docs/concepts/alias-ips>>
- Google Cloud (2025). Config Sync and Policy Controller.
<<https://cloud.google.com/kubernetes-engine/enterprise/config-sync/docs/overview>>
- Google Cloud (2025). GKE release channels and maintenance windows.
<<https://cloud.google.com/kubernetes-engine/docs/concepts/release-channels>>
- Documentación oficial vigente del servicio implementado; registra URL y fecha de consulta.

Descargar: Parte 19 en PDF · Recorrido de Google Cloud en PDF · Manual integral

Anterior	Índice	Siguiente
← 233 · Cloud Run, Functions, API Gateway y Workflows	Parte 19 · Programa	235 · Cloud SQL, Spanner, Firestore y Bigtable →

Evaluación — 234 GKE Autopilot, Workload Identity y Config Sync

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 gcp-gke-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.

235 — Cloud SQL, Spanner, Firestore y Bigtable

Parte: 19 — Google Cloud: arquitectura de datos y operación en producción Nivel: avanzado · Horas estimadas: 4
Laboratorio: data · Estado: EXECUTABLECORE

Propósito

Elegir el almacén de datos en Google Cloud, donde hay cuatro familias con propósitos claramente distintos y una que no tiene equivalente en las otras nubes: una base relacional que escala horizontalmente y da consistencia fuerte global, a cambio de un coste y unas reglas de modelado propias. La clase da el criterio de elección, las decisiones que no se pueden cambiar en cada una, y la advertencia de siempre sobre la clave.

Resultados de aprendizaje

Al finalizar podrás:

1. Elegir entre las cuatro familias con criterios comprobables.
2. Modelar para la base distribuida evitando los puntos calientes.
3. Decidir si la consistencia fuerte global compensa su coste.
4. Dimensionar capacidad y detectar el estrangulamiento.
5. Combinar el camino operativo con el analítico sin forzar ninguno.

Conceptos centrales


Concepto	Comprensión verificable
base relacional gestionada	Motor tradicional gestionado. Escala vertical, transacciones y consultas ad hoc.
base relacional distribuida	Escala horizontal con transacciones y consistencia fuerte global. Con reglas de modelado propias.
base de documentos	Almacén sin esquema con sincronización a clientes. Cómoda y con límites de escritura por documento.
base de tabla ancha	Almacén de altísimo volumen y baja latencia, con una sola clave ordenada.
punto caliente	Clave que concentra escrituras contiguas. En estas familias, la causa principal de mala escala.
entrelazado	Colocación física de filas hijas junto a su padre, para que la transacción no cruce servidores.

Modelo mental

Google Cloud combina una jerarquía estricta de recursos con una red global y servicios data-first; proyecto, cuota e IAM forman una unidad operativa.

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. Cuatro familias, cuatro propósitos

Aquí las familias están más diferenciadas que en las otras nubes, y elegir mal se paga pronto.

RELACIONAL GESTIONADA

- motor tradicional, gestionado
- + SQL completo, transacciones, consultas ad hoc
- + migración desde lo heredado casi directa
- escala vertical con techo
- y las conexiones son un recurso limitado clase 233
- para la mayoría de los sistemas de tamaño normal

RELACIONAL DISTRIBUIDA

- escala horizontal CON transacciones y consistencia fuerte global
- + no hay que elegir entre SQL y escala
- + disponibilidad muy alta y multirregión real
- coste base alto: hay un mínimo de capacidad
- reglas de modelado propias, y la clave manda
- para volúmenes que una relacional no aguanta, o cuando se necesita consistencia fuerte entre regiones

DOCUMENTOS

- almacén sin esquema, con sincronización a clientes
- + cómodo, con consultas por campo y tiempo real
- + integración directa con aplicaciones móviles
- límite de escrituras por documento
- índices automáticos que se pagan en cada escritura
- para perfiles, catálogos, estado de aplicaciones cliente

TABLA ANCHA

- altísimo volumen, latencia de milisegundos, una sola clave ordenada
- + escala a petabytes con latencia estable
- sin consultas por otros campos: solo por la clave
- coste base alto (nodos)
- para series temporales, telemetría, perfiles de usuario a gran escala

Y el criterio, en preguntas:

¿el volumen cabe en una máquina grande y crecerá poco?
→ relacional gestionada; y no compliques

¿hace falta SQL y no cabe, o hace falta consistencia fuerte entre regiones?
→ relacional distribuida, midiendo el coste base

¿es estado de aplicación cliente con sincronización?

→ documentos

¿son millones de escrituras por segundo con una clave conocida?

→ tabla ancha

¿son informes y exploración?

→ ninguna de las cuatro: almacén analítico clase 236

Y la advertencia de coste que decide muchas elecciones:

la relacional distribuida y la de tabla ancha tienen COSTE
BASE ALTO

hay un mínimo de capacidad que se paga aunque no se use

→ para volúmenes pequeños salen mucho más caras

→ y por eso «empezar por la que escala» suele ser un error
de coste clase 216

2. La clave, otra vez

En las tres familias distribuidas, el error de diseño es el mismo y tiene el mismo nombre: la clave que concentra.

EL PROBLEMA

estas bases reparten los datos por RANGOS de clave

→ claves contiguas van al mismo servidor

→ y una clave que crece de forma monótona hace que TODAS
las escrituras nuevas caigan en el mismo sitio

LAS CLAVES QUE PRODUCEN PUNTOS CALIENTES

identificador autoincremental

marca de tiempo como primer componente

y cualquier secuencia ordenada

→ y es distinto del problema de la clase 208: allí la clave
se distribuía por resumen y el problema era la
concentración de TRÁFICO; aquí el problema es el ORDEN

Y las soluciones:

IDENTIFICADOR ALEATORIO

el más simple y el que mejor reparte

- se pierde el orden natural de inserción

INVERTIR LOS BITS de un valor creciente

reparte y conserva unicidad

PREFIJO CALCULADO

un valor derivado del resto de la clave, como primer
componente

→ reparte, y sigue permitiendo consultas por el resto si
se recorre cada prefijo

CLAVE COMPUESTA con algo que reparta primero

cliente + fecha, en vez de fecha + cliente

→ y sirve para las consultas por cliente clase 208

El entrelazado, que es propio de la relacional distribuida:

las filas hijas se colocan FÍSICAMENTE junto a su padre
pedido y sus líneas, juntos

→ leer un pedido con sus líneas es una sola lectura local

→ y la transacción no cruza servidores

y sin entrelazar

la transacción coordina entre servidores

→ latencia mucho mayor y más conflictos

→ es la decisión de modelado que más cambia el rendimiento

→ y hay que tomarla al crear la tabla

Y las transacciones, con lo que hay que saber:

la relacional distribuida da transacciones globales con
consistencia fuerte

→ y eso cuesta coordinación

las de SOLO LECTURA no bloquean y son mucho más baratas
→ declararlas como tales, siempre

y las de lectura con obsolescencia acotada
«lee de hace 10 segundos»
→ sirven la mayoría de las consultas y evitan la
coordinación clase 223

→ y la mayoría de los sistemas que usan transacciones
fuertes para todo están pagando coordinación que no
necesitan ley 26

3. Capacidad, límites y coste

La relacional distribuida se dimensiona por unidades de proceso.

LA CAPACIDAD

se mide en unidades; hay un mínimo por instancia
y cada unidad da un tope de almacenamiento y de caudal

→ y la regla operativa
mantener la utilización de CPU por debajo del 65 % en
una región y del 45 % en multirregión
→ por encima, la latencia se dispara clase 186

EL ESTRANGULAMIENTO

se manifiesta como latencia alta y transacciones
abortadas
→ y las abortadas hay que reintentar, lo que empeora
→ la señal directa es la CPU y la de operaciones por
servidor

Y LAS ESTADÍSTICAS DE ACCESO

la plataforma indica qué rangos de clave concentran
→ es la herramienta que encuentra el punto caliente
→ y hay que mirarla, no suponer ley 15

La base de documentos, con sus límites característicos:

UNA ESCRITURA POR SEGUNDO Y DOCUMENTO

→ un contador global en un documento no funciona
→ hay que repartirlo en varios y sumar al leer

ÍNDICES AUTOMÁTICOS

por defecto se indexa cada campo
→ cada escritura paga por todos clase 223
→ y hay que EXCLUIR lo que no se consulta

CONSULTAS LIMITADAS

no hay uniones ni agregaciones complejas
→ y las consultas compuestas exigen índices declarados

Y LAS REGLAS DE SEGURIDAD

si los clientes acceden directamente, las reglas son el
control de acceso
→ y una regla mal escrita expone todo
→ se prueban con el simulador, siempre ley 22

La tabla ancha, con lo suyo:

UNA SOLA CLAVE, ORDENADA

las consultas son por clave o por rango de claves
→ no hay índices secundarios
→ el diseño de la clave ES el diseño

GRUPOS DE COLUMNAS

separar lo que se lee junto
→ leer un grupo no trae los demás

CADUCIDAD POR CELDA

las versiones antiguas se retiran solas
→ imprescindible en series temporales

Y EL COSTE

por nodo y por almacenamiento

→ con un mínimo por instancia

Y la decisión de continuidad, que aquí es sencilla y cara:

la relacional distribuida en configuración multirregión da
consistencia fuerte y disponibilidad muy alta
→ y cuesta del orden del triple

y la relacional gestionada
réplicas de lectura, y conmutación con su plazo medido
clase 215

4. Combinar operativo y analítico

El patrón que este programa repite desde la clase 150 aquí es especialmente directo.

LO OPERATIVO en la familia que corresponda
LO ANALÍTICO en el almacén de análisis clase 236

y la conexión
flujo de cambios hacia el almacén analítico
o consulta federada desde el almacén hacia la base
o réplica gestionada, donde exista

→ y ninguna de las cuatro familias se fuerza para hacer
informes

Y las tres cosas que hay que decidir al montarlo:

¿CUÁNTO RETRASO SE ACEPTA?
segundos, minutos u horas
→ y hay que declararlo y vigilarlo ley 13

¿QUÉ DATOS NO CRUZAN?
los personales completos, seudonimizados o excluidos
clases 230, 239

¿QUIÉN ES EL ESCRITOR?
el almacén analítico es de solo lectura desde el punto de
vista del negocio
→ si alguien escribe ahí y luego vuelve al operativo, hay
dos escritores ley 21

El caché, que en muchos sistemas es lo que evita cambiar de familia:

un caché en memoria delante de la relacional gestionada
resuelve la mayoría de los problemas de lectura
→ y es mucho más barato que migrar a una distribuida
→ con las cautelas de la clase 111: el caché portante y
la avalancha

→ antes de cambiar de familia por rendimiento de lectura,
medir qué resuelve un caché

Y las comprobaciones de esta clase:

- escribir 10.000 filas con clave secuencial y observar el reparto
- consultar las estadísticas de acceso y comprobar que no hay rango caliente
- ejecutar una transacción que cruce servidores y medir
- escribir el mismo documento 10 veces por segundo
- probar las reglas de acceso con el simulador
- conmutar la base y cronometrar clase 215
- y comprobar el retraso del flujo hacia lo analítico

Y la lista de comprobación de la clase:

- la familia elegida corresponde a los patrones y al volumen
- se comparó el coste base antes de elegir una que escala
- la clave no es monótona creciente
- las tablas hijas están entrelazadas donde procede
- las lecturas usan transacciones de solo lectura
- se usa obsolescencia acotada donde basta
- la utilización se mantiene por debajo del umbral
- se revisan las estadísticas de acceso por rango

- Y el cierre que enlaza con la clase siguiente: con los datos operativos resueltos, queda la plataforma analítica, que en esta nube es la pieza más madura y la que más problemas de gobierno y de coste produce. Es la materia de la clase 236.

CloudShop elige sus almacenes en Google Cloud. Lo que sigue es la decisión que evitó pagar una base distribuida sin necesitarla, el punto caliente que apareció igualmente en otra tabla, y el contador de un documento que no escalaba.

carga pedidos	volumen 41 M filas, 900 escrituras/s	elección relacional gestionada
catálogo sesiones	4,1 M productos 2 M activas, sincronización con la app	relacional gestionada documentos
telemetría de la web	41.000 eventos/s	tabla ancha
inventario global	120 M filas, consistencia fuerte entre 2 regiones	RELACIONAL DISTRIBUIDA
informes	—	almacén analítico clase 236

→ y pedidos con 41 M de filas y 900 escrituras/s cabe holgadamente en una relacional gestionada

→ ahorro 2.880 €/mes

lo que pasó en la prueba de carga

a partir de 1.200 escrituras/s
latencia p99 de 12 ms a 890 ms
transacciones abortadas 14 %
CPU media de la instancia 31 % ← engañosa

las estadísticas de acceso por rango decían
el 96 % de las escrituras caían en el ÚLTIMO rango
→ todas las claves nuevas eran contiguas
→ un solo servidor las atendía

corrección
clave primaria: identificador aleatorio
y para las consultas por producto y almacén, clave
compuesta (producto, almacén) que reparte por producto

resultado
latencia p99 a 1.200 escrituras/s 890 ms → 14 ms
transacciones abortadas 14 % → 0,2 %
caudal máximo probado 1.200 → 9.400/s

Y el entrelazado, que faltaba:

las tablas de movimientos de inventario no estaban
entrelazadas con la de inventario
→ cada transacción de ajuste coordinaba entre servidores
→ latencia de la transacción 48 ms

con movimientos entrelazados bajo inventario
→ la transacción es local
→ latencia 9 ms

→ y esta decisión se toma AL CREAR la tabla; cambiarla
exige recrear y migrar ley 14

El contador del documento.

la aplicación móvil mantenía un contador de artículos en
el carrito, en un documento por usuario
→ funcionaba

y para el panel de operaciones se añadió un contador
GLOBAL de carritos activos, en un solo documento

síntoma en campaña, el contador se quedaba atrás y
aparecían errores de contención
causa un documento admite del orden de una escritura
por segundo sostenida
y había hasta 340 modificaciones por segundo

corrección
el contador se reparte en 100 documentos
cada escritura elige uno al azar
el panel suma los 100 al leer

→ y para el panel, un valor agregado cada 30 s desde el
almacén analítico habría bastado y habría sido más
barato clase 236
→ se hizo así al final

Y los índices, recortados:

los documentos de sesión tenían 34 campos
indexados automáticamente 34
consultados 4

tras excluir los 30 no consultados
coste de escritura por documento -71 %
coste mensual de documentos 1.240 € → 380 €

Las reglas de acceso, probadas:

la aplicación móvil accede directamente a los documentos
de sesión
→ las reglas son el control de acceso, no hay servidor en
medio

el simulador de reglas, con 12 casos

- ✓ usuario lee su propio documento
- ✓ usuario escribe su propio documento
- ✗ usuario lee el documento de OTRO usuario
 - la regla comparaba el identificador del documento, no el del usuario autenticado
 - cualquiera con un identificador podía leer
- ✓ usuario sin autenticar denegado
- ✗ usuario escribe un campo que no debería
 - la regla no validaba qué campos se modifican
- ✓ el resto correcto

→ 2 de 12, y las dos exponían datos de otros usuarios

→ y sin el simulador no se habrían visto hasta que alguien las probara ley 22

La telemetría en tabla ancha:

clave de fila invertida(marca de tiempo) + sesión
 → el componente invertido reparte; sin él, todas las escrituras nuevas caerían juntas

grupos de columnas
 «evento» y «contexto» separados
 → el proceso en tiempo real lee solo «evento»

caducidad por celda 30 días
 → y el histórico va al almacén analítico clase 236

coste 610 €/mes
 frente a 3.900 € estimados con el bus de mensajes clase 224

El resultado:

coste mensual de datos (según la propuesta inicial)	6.200 €	3.320 €
latencia p99 del inventario	890 ms	14 ms
caudal máximo del inventario	1.200/s	9.400/s
transacciones abortadas	14 %	0,2 %
coste de documentos	1.240 €	380 €
reglas de acceso con fallos	2/12	0/12
contadores con contención	1	0

La lección que esta clase deja: la propuesta de poner todo en la base que escala habría costado casi el doble sin resolver ningún problema, porque el coste base de esas familias es alto y la mayoría de las cargas cabían en una relacional normal. Y el punto caliente apareció donde siempre: una clave autoincremental trasladada de la base relacional, que en un almacén repartido por rangos concentra el noventa y seis por ciento de las escrituras en un solo servidor.

Laboratorio guiado

Ejecuta desde la raíz:

```
python classes/part-19-gcp-production-architecture/235-cloud-sql-spanner-firestore-y-bigtable/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 gcp-operational-data 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 gcp-operational-data 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
Latencia altísima y transacciones abortadas con la CPU baja	Clave monótona creciente: todas las escrituras nuevas caen en el mismo rango	Usa identificador aleatorio, invierte los bits o pon delante un componente que reparta; revisa las estadísticas de acceso por rango.
Las transacciones son lentas aunque toquen pocas filas	Cruzan servidores porque las tablas hijas no están entrelazadas con el padre	Entrelaza las hijas al crear la tabla; cambiarlo después exige recrear y migrar.
Se paga mucho por una carga pequeña	Se eligió una familia con coste base alto por si escala en el futuro	Compara el coste base antes de elegir; empieza en la relacional gestionada y registra qué señal justificaría migrar.
Un contador global da errores de contención	Un documento admite del orden de una escritura por segundo	Reparte el contador en varios documentos y suma al leer, o agrega el valor en el almacén analítico.
El coste de escritura de los documentos es desproporcionado	Se indexan automáticamente todos los campos	Excluye del índice los campos que no se consultan.
Un usuario puede leer los datos de otro	Las reglas de acceso comparan el identificador equivocado o no validan los campos modificados	Prueba las reglas con el simulador para todos los casos, incluidos los de acceso ajeno.

■ 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 cuatro familias?
2. ¿Por qué una clave autoincremental produce puntos calientes en un almacén repartido por rangos?
3. ¿Qué aporta entrelazar las tablas hijas y cuándo se decide?
4. ¿Qué límite tiene la escritura sobre un mismo documento y cómo se resuelve?
5. ¿Por qué no conviene empezar por la familia que más escala?

Referencias

- Google Cloud (2025). Spanner schema design and hotspot avoidance. <<https://cloud.google.com/spanner/docs/schema-design>>
- Google Cloud (2025). Spanner: interleaved tables and transactions. <<https://cloud.google.com/spanner/docs/schema-and-data-model>>
- Google Cloud (2025). Firestore: best practices and limits. <<https://cloud.google.com/firestore/docs/best-practices>>
- Google Cloud (2025). Bigtable schema design. <<https://cloud.google.com/bigtable/docs/schema-design>>
- Google Cloud (2025). Cloud SQL: read replicas and high availability. <<https://cloud.google.com/sql/docs/mysql/high-availability>>
- Documentación oficial vigente del servicio implementado; registra URL y fecha de consulta.

Descargar: Parte 19 en PDF · Recorrido de Google Cloud en PDF · Manual integral

Anterior	Índice	Siguiente
← 234 · GKE Autopilot, Workload Identity y Config Sync	Parte 19 · Programa	236 · BigQuery, Dataflow, Dataproc y gobernanza de datos →

Evaluación — 235 Cloud SQL, Spanner, Firestore y Bigtable

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 gcp-operational-data 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.

236 — BigQuery, Dataflow, Dataproc y gobernanza de datos

Parte: 19 — Google Cloud: arquitectura de datos y operación en producción Nivel: avanzado · Horas estimadas: 4
Laboratorio: data · Estado: EXECUTABLECORE

Propósito

Operar la plataforma analítica de Google Cloud, que es la pieza más madura de esta nube y la que más problemas produce de dos tipos concretos: coste, porque una consulta mal escrita puede costar cientos de euros en segundos, y gobierno, porque el acceso a datos personales se concede en la primera semana y nadie lo revisa después. La clase cubre el modelo de facturación, el diseño de tablas, el procesamiento por lotes y continuo, y el control de acceso a nivel de columna y de fila.

Resultados de aprendizaje

Al finalizar podrás:

1. Elegir el modelo de facturación adecuado y evitar las sorpresas.
2. Diseñar tablas particionadas y agrupadas para reducir lo que se lee.
3. Elegir entre procesamiento continuo, por lotes y gestionado.
4. Controlar el acceso a columnas y filas con datos sensibles.
5. Gobernar el linaje, la calidad y la retención de los datos.

Conceptos centrales


Concepto	Comprensión verificable
facturación por consulta	Se paga por bytes leídos. Una consulta sin filtro sobre una tabla grande cuesta mucho.
capacidad reservada	Modelo de precio por capacidad de proceso contratada, con coste previsible.
partición	División física de una tabla, normalmente por fecha. Permite leer solo lo necesario.
agrupación	Ordenación física por columnas dentro de la partición. Reduce lo leído en filtros por esas columnas.
enmascaramiento de columna	Transformación del valor según quién consulta, sin duplicar la tabla.
linaje	Registro de de dónde viene cada tabla y qué la consume. Necesario para retirar y para auditar.

Modelo mental

Google Cloud combina una jerarquía estricta de recursos con una red global y servicios data-first; proyecto, cuota e IAM forman una unidad operativa.

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 coste, que es lo primero

Aquí el coste no es un asunto de fin de mes: una consulta puede costar cientos de euros en segundos, y por eso se aborda antes que el diseño.

POR CONSULTA

- se paga por BYTES LEÍDOS, no por filas devueltas
- «select * from tabla limit 10» sobre 40 TB lee 40 TB
- el límite no reduce lo leído
- + sin coste cuando no se consulta
- impredecible; una consulta mal escrita cuesta mucho

CAPACIDAD RESERVADA

- se paga por capacidad de proceso, con compromiso
- + coste previsible y consultas «gratis» dentro de la capacidad
- hay que dimensionarla, y las consultas compiten entre sí

CRITERIO

- uso irregular o bajo → por consulta, CON LÍMITES
- uso alto y continuo → capacidad reservada
- y lo habitual: capacidad para lo productivo y por consulta para exploración, con límites

Y los límites que hay que poner el primer día:

LÍMITE DE BYTES POR CONSULTA

- «ninguna consulta puede leer más de X»
- rechaza antes de ejecutar
- y es lo único que impide el susto de una consulta

CUOTA DIARIA POR USUARIO Y POR PROYECTO

Y LA COSTUMBRE DE ESTIMAR ANTES

- la herramienta dice cuántos bytes leerá una consulta
- ANTES de ejecutarla
- y esa estimación debe estar en la formación de cualquiera que consulte

ley 26

Y las tres causas de coste que se repiten:

- SELECCIONAR TODAS LAS COLUMNAS**
el almacenamiento es por columnas: leer 3 de 80 cuesta una fracción
→ «select *» es el error más caro y el más común
- NO FILTRAR POR LA COLUMNA DE PARTICIÓN**
una consulta sin filtro de fecha lee la tabla entera
→ se puede EXIGIR el filtro en la definición de la tabla
- CONSULTAS PROGRAMADAS QUE NADIE REVISA**
un panel que refresca cada 5 minutos sobre una tabla grande
→ y nadie mira su coste

ley 15

2. Diseñar para leer menos

Todo el rendimiento y el coste dependen de cuántos bytes se leen. Hay dos mecanismos.

PARTICIÓN

divide la tabla, normalmente por fecha
→ una consulta con filtro de fecha lee solo esas particiones

y la opción que evita sustos
exigir el filtro de partición en la tabla
→ una consulta sin él FALLA en vez de leer todo

AGRUPACIÓN

ordena físicamente por hasta cuatro columnas dentro de la partición
→ filtrar por la primera columna de agrupación reduce mucho lo leído
→ el orden importa: se agrupa por lo que más se filtra

→ y las dos juntas son lo que convierte una tabla de 40 TB en consultas de 2 GB

Y el resto de decisiones de modelado:

DESNORMALIZAR

las uniones cuestan; repetir datos suele salir más barato
→ aquí, al contrario que en una base transaccional

CAMPOS ANIDADOS Y REPETIDOS

guardar las líneas de un pedido dentro del pedido
→ evita la unión y reduce lo leído

VISTAS MATERIALIZADAS

agregados precalculados que se refrescan solos
→ las consultas los usan automáticamente
→ y reducen mucho el coste de los paneles

TABLAS EXTERNAS

consultar ficheros del almacén sin cargarlos
→ cómodo, y más lento y más caro por consulta
→ para datos poco consultados

El almacenamiento, con su propia palanca:

las particiones que no se modifican pasan a un precio de almacenamiento menor, solas
→ y la RETENCIÓN por partición retira lo antiguo
→ sin retención, la tabla crece indefinidamente ley 25

y una decisión que hay que tomar
¿cuántos años de histórico hacen falta de verdad?
→ casi siempre menos de los que se guardan
→ y lo que haga falta por norma, en almacenamiento barato clase 239

Y la carga de datos, con lo que decide el coste:

CARGA POR LOTES	gratuita o muy barata
INSERCIÓN CONTINUA	se paga por fila, y suma
ESCRITURA POR FLUJO	el mecanismo moderno, más barato

→ si el retraso aceptable es de minutos, la carga por lotes cada pocos minutos es mucho más barata que la inserción fila a fila
→ y esa es una decisión de arquitectura, no de implementación clase 242

3. Procesar: continuo, por lotes y gestionado

Hay tres formas de transformar datos y se eligen por lo que hay que hacer, no por preferencia.

CONSULTAS PROGRAMADAS Y VISTAS MATERIALIZADAS

la transformación se escribe en SQL, dentro del almacén
+ lo más simple; sin infraestructura
+ y el linaje se registra solo
- limitado a lo que SQL puede hacer
→ y es lo que resuelve la mayoría de los casos

PROCESAMIENTO UNIFICADO (Dataflow)

- el mismo código para lotes y para flujo continuo
- + gestiona ventanas, datos que llegan tarde y estado
- + escala solo
- más que operar, y hay que entender el modelo
- para transformaciones complejas o continuas de verdad

MOTOR DE CÓDIGO ABIERTO GESTIONADO (Dataproc)

- para trabajos existentes que ya están escritos
- + migración directa de lo que ya hay
- hay que gestionar clústeres, aunque sean efímeros
- y para trabajos nuevos, rara vez es la elección

Y el criterio:

- ¿se puede escribir en SQL y el retraso de minutos vale?
 - consulta programada o vista materializada
- ¿hace falta procesamiento continuo con ventanas y estado?
 - procesamiento unificado
- ¿hay trabajos que ya existen y funcionan?
 - motor gestionado, con fecha de revisión ley 25

Y lo que hay que resolver en el procesamiento continuo, que es lo mismo de la clase 116:

DATOS QUE LLEGAN TARDE

- una ventana cerrada y un dato de hace 3 horas
- decidir: descartar, reprocesar o corregir
- y declararlo clase 242

EXACTAMENTE UNA VEZ

- se consigue con identificadores y deduplicación
- no viene gratis clase 237

Y EL RETRASO

- vigilado, con alerta ley 13
- «el flujo lleva N minutos de retraso» es la señal que dice que algo va mal antes de que falte un dato

Y la orquestación:

- los trabajos dependen unos de otros
- hace falta un orquestador que sepa el orden, reintente y avise clase 243
- y no un conjunto de trabajos programados por hora esperando que el anterior haya terminado

4. Gobierno: acceso, linaje y retención

El acceso a datos sensibles es donde este tipo de plataformas produce los hallazgos más incómodos.

LOS NIVELES DE CONTROL

- por conjunto de datos y por tabla
 - el habitual, y el más grueso
- POR COLUMNA
 - las columnas se etiquetan; el acceso se concede por etiqueta
 - «quien no tenga la etiqueta de datos personales no ve esas columnas»
- POR FILA
 - políticas que filtran según quién consulta
 - «cada país ve sus propias filas»
- ENMASCARAMIENTO
 - la columna se transforma según quién consulta
 - un analista ve el correo con formato pero sin valor
 - sin duplicar la tabla

Y el problema que resuelven, que es el de la clase 230:

- sin control por columna, dar acceso a una tabla es dar acceso a CUANTO contiene
- y por eso el acceso se concede al conjunto entero
- y por eso los equipos de análisis acaban viendo datos personales completos que no necesitan

- con etiquetas de columna
- el acceso a la tabla no incluye las columnas etiquetadas
- y la mayoría de los análisis funcionan igual

Y la disciplina:

- 1 CLASIFICAR las columnas: la plataforma puede detectar datos personales automáticamente
- 2 ETIQUETAR las sensibles
- 3 QUITAR el acceso amplio y conceder por etiqueta
- 4 y REVISAR trimestralmente quién la tiene clase 230

El linaje, que hace posible retirar y auditar:

qué tablas alimentan a cuáles
qué consultas y paneles consumen cada tabla
y de dónde vino cada dato

→ sin linaje, retirar una tabla es imposible: nadie sabe quién la usa ley 20

→ y ante una petición de borrado de datos personales, tampoco se sabe dónde se copiaron clases 139, 251

Y lo que hay que vigilar en esta plataforma:

coste por consulta, por usuario y por panel
consultas que leen más de X bytes
tablas sin partición ni agrupación
tablas sin retención
tablas sin consumidores en 90 días → candidatas a retirar

acceso a columnas sensibles, por identidad
retraso de los flujos continuos
y trabajos que fallan sin que nadie lo mire ley 13

Y la lista de comprobación de la clase:

- hay límite de bytes por consulta
- hay cuota diaria por usuario y por proyecto
- las tablas grandes están particionadas
- se exige el filtro de partición donde procede
- están agrupadas por las columnas de filtro habituales
- los paneles usan vistas materializadas
- hay retención por tabla
- la ingesta usa lotes o escritura por flujo, no inserción fila a fila
- las columnas sensibles están clasificadas y etiquetadas
- el acceso se concede por etiqueta, no al conjunto entero
- hay políticas de fila donde aplica
- el linaje está activado y se consulta
- hay alerta de retraso de los flujos y de trabajos fallidos
- se revisan las tablas sin consumidores

Y el cierre que enlaza con la clase siguiente: con datos operativos y analíticos resueltos, queda la mensajería que los conecta, que en esta nube tiene una propiedad que se anuncia mucho y conviene entender bien. Es la materia de la clase 237.

Ejemplo trabajado

CloudShop monta su plataforma analítica en Google Cloud. Lo que sigue son las tres consultas que costaban 4.100 € al mes, el acceso a datos personales que tenían 41 personas, y el rediseño de tablas que redujo el coste un 88 %.

La factura, al revisar:

coste mensual del almacén analítico	7.900 €	
consultas	6.200 €	
almacenamiento	1.400 €	
inserción continua	300 €	
las consultas, por origen		
paneles programados	4.100 €	←
exploración de analistas	1.400 €	
transformaciones programadas	700 €	

Y el desglose de los paneles:

panel	refresco	bytes/ejec.	€/mes
ventas en tiempo real	5 min	2,1 TB	2.900

ocupación por almacén	15 min	0,9 TB	810
embudo de conversión	1 h	3,4 TB	390

- tres consultas, 4.100 €/mes
- y los tres paneles los abría alguien 2 o 3 veces al día

Y el diagnóstico de la primera:

la consulta del panel de ventas
 select * from pedidos p join lineas l ... where
 fecha >= current_date() - 30

la tabla pedidos 14 TB
 la tabla lineas 26 TB
 ninguna estaba particionada
 → el filtro de fecha no reducía nada: se leía todo
 → y «select *» traía 80 columnas de las que se usaban 6

bytes leídos por ejecución 2,1 TB
 ejecuciones al mes 8.640

El rediseño de tablas:

pedidos
 partición por fecha de pedido, diaria
 agrupación por país, canal, estado
 filtro de partición EXIGIDO

lineas
 partición por fecha del pedido (heredada)
 agrupación por producto
 o mejor: las líneas ANIDADAS dentro de pedidos
 → se eligió anidarlas: elimina la unión

y las consultas reescritas
 columnas explícitas, no «select *»
 filtro de fecha, obligatorio

bytes por ejecución del panel de ventas 2,1 TB → 1,4 GB

Y las vistas materializadas:

los tres paneles consultaban agregados diarios
 → vista materializada con el agregado, refrescada sola
 → los paneles la usan automáticamente

bytes por ejecución 1,4 GB → 12 MB

coste de los tres paneles 4.100 € → 41 €/mes

Los límites, puestos después del susto:

un analista ejecutó una consulta exploratoria sin filtro
 sobre la tabla de eventos de 61 TB

bytes leídos	61 TB
coste de esa consulta	310 €
duración	94 s

→ y no había nada que lo impidiera

límites puestos

bytes máximos por consulta	200 GB
→ salvo excepción con aprobación	
cuota diaria por usuario	2 TB
cuota diaria por proyecto de exploración	20 TB

y formación
 la estimación previa de bytes, en la guía de
 incorporación
 → y un aviso en la herramienta cuando la estimación
 supera 50 GB

consultas rechazadas por límite, primer mes	61
de ellas, errores reales del analista	57
con excepción aprobada	4

El acceso a datos personales.

al inventariar
personas con acceso al conjunto de datos de clientes 41
de ellas, que necesitaban ver datos personales
completos 3

→ los otros 38 hacían análisis agregados y no
necesitaban el correo, el teléfono ni la dirección
→ pero el acceso se concede al conjunto, y el conjunto
los incluye clase 230

y la clasificación automática encontró
columnas con datos personales 61
en tablas donde nadie sabía que los había 9
· una tabla de análisis de campañas con correos
· dos tablas temporales de una migración de 2023
que nunca se borraron ley 25

Y la corrección:

clasificación y etiquetado de las 61 columnas
etiquetas jerárquicas
personal-directo (nombre, correo, teléfono,
dirección)
personal-indirecto (identificador, dispositivo)
financiero

acceso concedido por etiqueta, no por conjunto
personal-directo 3 personas
personal-indirecto 12 personas
financiero 6 personas
el resto del conjunto 41 personas

y enmascaramiento para los casos intermedios
el correo se ve como «a***@dominio.com»
→ suficiente para verificar y sin exponer el valor

y las políticas de fila
el equipo de cada país ve solo las filas de su país

y las 3 tablas con datos que nadie sabía
2 borradas (temporales de la migración)
1 seudonimizada

Y la comprobación:

prueba negativa
un analista sin la etiqueta consulta la columna de
correo
→ la consulta falla, indicando qué etiqueta falta
un analista de España consulta filas de Portugal
→ devuelve 0 filas
→ y ambas se ejecutan en cada despliegue del gobierno
ley 22

El procesamiento, ajustado:

antes
inserción continua fila a fila desde la aplicación
41.000 eventos/s → 300 €/mes de inserción
y transformaciones en un motor gestionado con un clúster
siempre encendido 410 €/mes

después
los eventos van al servicio de mensajería y de ahí en
lotes cada 60 s clase 237
coste de ingesta 300 € → 18 €
las transformaciones que caben en SQL, como consultas
programadas 9
las que no, en procesamiento unificado 2
clúster gestionado retirado 410 € → 140 €

y el retraso declarado
eventos disponibles para consulta ≤ 90 s

con alerta si supera 5 min

ley 13

La retención y el linaje:

retención por tabla	
eventos brutos	90 días
agregados diarios	5 años
tablas de trabajo	7 días
almacenamiento	1.400 € → 310 €
linaje activado	
tablas sin consumidores en 90 días	34
→ 28 borradas tras avisar	
→ 6 resultaron alimentar informes trimestrales	
y ante la primera petición de borrado de datos de un cliente	
tablas donde aparecía, según el linaje	7
tablas que el equipo creía	2
	clases 139, 251

El resultado:

coste mensual del almacén	7.900 €	610 €
paneles	4.100 €	41 €
exploración	1.400 €	120 €
almacenamiento	1.400 €	310 €
ingesta	300 €	18 €
bytes por ejecución del panel de ventas	2,1 TB	12 MB
personas con acceso a datos personales	41	3
columnas sensibles sin clasificar	61	0
tablas con datos personales desconocidos	3	0
tablas sin consumidores	34	6
consultas que pueden leer la tabla entera	cualquiera	0

La lección que esta clase deja: tres paneles que alguien abría dos veces al día costaban cuatro mil cien euros al mes, y el problema no era la plataforma sino tablas sin particionar consultadas con «select». Y cuarenta y una personas tenían acceso a datos personales completos porque el acceso se concede al conjunto y el conjunto los incluye; solo tres los necesitaban, y el resto siguió trabajando igual con las columnas enmascaradas.

Laboratorio guiado

Ejecuta desde la raíz:

```
python classes/part-19-gcp-production-architecture/236-bigquery-dataflow-dataproc-y-gobernanza-de-datos/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 gcp-analytics-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 gcp-analytics-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
Una consulta cuesta cientos de euros en segundos	Se paga por bytes leídos y no hay límite ni filtro de partición	Pon límite de bytes por consulta y cuota por usuario, particiona las tablas y exige el filtro de partición.
Los paneles dominan la factura	Refrescan consultas pesadas sobre tablas grandes muchas veces al día	Usa vistas materializadas con los agregados y revisa el coste por panel.
El filtro de fecha no reduce el coste	La tabla no está particionada por esa columna	Particiona por la columna de filtro habitual y agrupa por las siguientes más usadas.
Todo el equipo de análisis ve datos personales completos	El acceso se concede al conjunto de datos, que los incluye	Clasifica y etiqueta las columnas sensibles, concede por etiqueta y usa enmascaramiento para los casos intermedios.
La ingesta continua cuesta más que el proceso	Se inserta fila a fila cuando el retraso aceptable es de minutos	Agrupar en lotes o usa la escritura por flujo; decide el retraso aceptable como decisión de arquitectura.
No se puede retirar una tabla porque nadie sabe quién la usa	No hay linaje registrado	Activa el linaje y revisa periódicamente las tablas sin consumidores.

■ 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 un límite de filas no reduce el coste de una consulta?
2. ¿Qué diferencia hay entre partición y agrupación, y para qué sirve cada una?
3. ¿Qué problema resuelve el control de acceso por columna?
4. ¿Cuándo conviene procesamiento unificado frente a consultas programadas?
5. ¿Para qué hace falta el linaje además de para auditar?

Referencias

- Google Cloud (2025). BigQuery: controlling costs. <<https://cloud.google.com/bigquery/docs/best-practices-costs>>
- Google Cloud (2025). Partitioned and clustered tables. <<https://cloud.google.com/bigquery/docs/partitioned-tables>>
- Google Cloud (2025). Column-level and row-level security. <<https://cloud.google.com/bigquery/docs/column-level-security-intro>>
- Google Cloud (2025). Dataflow: unified batch and streaming. <<https://cloud.google.com/dataflow/docs/concepts>>

- Google Cloud (2025). Dataplex and data lineage. <<https://cloud.google.com/dataplex/docs/about-data-lineage>>
- Documentación oficial vigente del servicio implementado; registra URL y fecha de consulta.

Descargar: Parte 19 en PDF · Recorrido de Google Cloud en PDF · Manual integral

Anterior	Índice	Siguiente
← 235 · Cloud SQL, Spanner, Firestore y Bigtable	Parte 19 · Programa	237 · Pub/Sub, Eventarc y entrega exactamente-una-vez →

Evaluación — 236 BigQuery, Dataflow, Dataproc y gobernanza de datos

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 gcp-analytics-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.

237 — Pub/Sub, Eventarc y entrega exactamente-una-vez

Parte: 19 — Google Cloud: arquitectura de datos y operación en producción Nivel: avanzado · Horas estimadas: 4
Laboratorio: messaging · Estado: EXECUTABLECORE

Propósito

Montar la mensajería de Google Cloud, cuyo servicio principal anuncia entrega exactamente una vez, y conviene entender con precisión qué significa y qué sigue siendo responsabilidad del código. La clase separa el servicio de mensajería del enrutador de eventos, explica los mecanismos de entrega y sus parámetros, y sostiene lo que este programa lleva demostrando: la garantía del transporte no elimina la necesidad de idempotencia en el efecto.

Resultados de aprendizaje

Al finalizar podrás:

1. Elegir entre suscripción de entrega y de extracción, y el enrutador de eventos.
2. Configurar plazos, reintentos y destino de fallidos coherentemente.
3. Entender qué garantiza la entrega exactamente una vez y qué no.
4. Ordenar mensajes por clave cuando el orden importa.
5. Operar los fallidos con alerta, diagnóstico y reproceso probado.

Conceptos centrales


Concepto	Comprensión verificable
tema	Punto de publicación. Los consumidores se conectan mediante suscripciones independientes.
suscripción de extracción	El consumidor pide mensajes. Controla su propio ritmo.
suscripción de entrega	El servicio llama a un punto del consumidor. Más simple y con menos control de ritmo.
plazo de confirmación	Tiempo que el mensaje queda retenido tras entregarse. Si vence, se reentrega.
entrega exactamente una vez	Garantía de que un mensaje confirmado no se reentrega dentro de la ventana de confirmación.
clave de ordenación	Campo que agrupa mensajes para entregarlos en orden. Limita el caudal por clave.

Modelo mental

Google Cloud combina una jerarquía estricta de recursos con una red global y servicios data-first; proyecto, cuota e IAM forman una unidad operativa.

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 tema, muchas suscripciones

El modelo aquí es más simple que el de las otras nubes: hay un servicio principal y un enrutador.

SERVICIO DE MENSAJERÍA

un TEMA donde se publica
N SUSCRIPCIONES independientes, cada una con su propio
ritmo, sus reintentos y su destino de fallidos
→ uno a muchos, sin configurar nada más
→ y añadir un consumidor es crear una suscripción: el
productor no se entera clase 148

ENRUTADOR DE EVENTOS

entrega eventos de la propia plataforma y de fuentes
propias a destinos, con filtros
→ «cuando se suba un fichero a este almacén, llama a este
servicio»
→ y por debajo usa el servicio de mensajería

Y los dos tipos de suscripción, que se eligen mal a menudo:

EXTRACCIÓN

- el consumidor pide mensajes cuando puede
- + controla su ritmo: no le llega más de lo que aguanta
- + amortigua picos de forma natural
- hay que ejecutar un proceso que extraiga

ENTREGA (a un punto HTTP)

- el servicio llama al consumidor
- + más simple: no hay proceso extractor
- + encaja con servicios que escalan por peticiones
clase 233
- el ritmo lo marca el servicio, no el consumidor
- y por tanto puede escalar el consumidor sin control

Y LA DECISIÓN

- si el consumidor tiene un recurso limitado detrás (una base), la extracción da control
- si escala bien y es idempotente, la entrega es más simple
- y en cualquier caso hay que poner un límite de concurrencia
clase 233

Y los otros destinos, que ahorran código:

SUSCRIPCIÓN HACIA EL ALMACÉN ANALÍTICO

- los mensajes se escriben directamente en una tabla
- sin consumidor que mantener
- y con esquema validado
clase 236

SUSCRIPCIÓN HACIA ALMACENAMIENTO

- vuelca por lotes a ficheros
- el histórico, sin escribir nada
clase 224

2. Exactamente una vez: qué significa

Esta es la propiedad que más se malinterpreta, y conviene ser preciso.

LO QUE GARANTIZA

- un mensaje CONFIRMADO no se vuelve a entregar dentro de la ventana de confirmación
- elimina los duplicados que produce el plazo vencido cuando el consumidor sí había terminado

LO QUE NO GARANTIZA

- que el PRODUCTOR no publique el mismo hecho dos veces
- un reintento del productor crea dos mensajes distintos
- que el efecto no se produzca dos veces si el consumidor falla DESPUÉS de actuar y ANTES de confirmar
- que el reproceso desde el tema de fallidos no repita
- ni que dos suscripciones no procesen lo mismo

→ es decir: elimina una de las cinco fuentes de duplicado de la clase 210, no las cinco

Y la conclusión, que es la de siempre:

LA IDEMPOTENCIA EN EL EFECTO SIGUE SIENDO OBLIGATORIA

- clave del suceso, generada por el productor
- registro de claves procesadas, en dos estados
- y escritura condicionada antes del efecto
clase 210

→ lo que la garantía da es que se necesitan MENOS reintentos y menos reproceso, no que se pueda prescindir de la comprobación

Y el coste, que conviene conocer:

- la entrega exactamente una vez tiene un coste
- el caudal por suscripción es menor
- la latencia es algo mayor
- y hay restricciones de configuración

→ activarla donde el duplicado cuesta dinero

→ y no en la telemetría, donde no aporta y limita el caudal

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

PLAZO DE CONFIRMACIÓN

tiempo que el mensaje queda retenido tras entregarse
si vence antes de confirmar, se reentrega

y la extensión automática

las bibliotecas extienden el plazo mientras se procesa
→ activarla es lo que evita el problema
→ y hay un máximo total: procesos muy largos no encajan

CONCURRENCIA DEL CONSUMIDOR

cuántos mensajes procesa a la vez
→ si es alta y el proceso es lento, se acumulan mensajes
retenidos y algunos vencen
→ es la misma relación de prebúsqueda de la clase 224

REINTENTOS Y RETROCESO

con retroceso exponencial declarado
→ sin retroceso, un consumidor caído recibe una avalancha
en cuanto vuelve

3. Orden, filtros y fallidos

El orden se consigue con clave, y tiene su coste.

CLAVE DE ORDENACIÓN

los mensajes con la misma clave se entregan en orden
→ y en la misma suscripción, al mismo consumidor

coste

el caudal por clave lo limita un solo consumidor
y si un mensaje falla, los siguientes de esa clave
ESPERAN
→ un mensaje venenoso bloquea su clave entera

y hay que decidir

¿qué se hace con el veneno? ¿se aparta y se sigue, o se
para?
→ misma decisión que en la clase 224

Y la pregunta previa, que evita el problema:

¿de verdad hace falta orden, o basta con que las
operaciones sean conmutativas?

«-1 unidad» no necesita orden

«estado = ENVIADO» tampoco, si lleva versión

«stock = 4» sí

→ y modelar para no necesitar orden es más barato que
garantizarlo clases 203, 224

Los filtros, que reducen trabajo y coste:

una suscripción puede filtrar por atributos del mensaje

→ el consumidor solo recibe lo suyo

→ y no se paga por entregar lo que se iba a descartar

y por eso conviene que los atributos lleven lo necesario
para filtrar

tipo de suceso, entidad, entorno, versión de esquema

El tema de fallidos, con la disciplina de siempre:

tras N intentos, el mensaje va a otro tema

→ y hay que crear una suscripción sobre él, o los
mensajes caducan sin que nadie los vea ley 13

LAS ALERTAS

«hay mensajes sin confirmar con más de 1 hora de
antigüedad» ← la que sirve

«el número de mensajes sin confirmar crece de forma
sostenida»

y en el tema de fallidos, las dos ley 15

EL DIAGNÓSTICO

guardar el motivo del fallo con el mensaje

→ veneno, dependencia o error de código clase 210

EL REPROCESO
procedimiento escrito, con límite de ritmo y por lotes
y probado por alguien que no lo escribió ley 22

Y una capacidad que evita reprocesos:

RETROCESO EN EL TIEMPO
una suscripción puede volver a un momento anterior o a una instantánea
→ y reprocesar desde ahí sin mover mensajes
→ útil cuando un consumidor procesó mal durante un rato
→ y exige que el consumidor sea idempotente, otra vez

4. Operar y medir

Lo que hay que vigilar, con las señales que dicen algo:

MENSAJES SIN CONFIRMAR
número y ANTIGÜEDAD del más viejo
→ la antigüedad es la que detecta el consumidor parado

PLAZOS VENCIDOS
señal directa de plazo mal puesto o proceso lento

RETRASO DE PUBLICACIÓN A CONSUMO
el tiempo entre que ocurre el hecho y se procesa
→ es la medida que le importa al negocio clase 238

MENSAJES EN EL TEMA DE FALLIDOS, y su antigüedad

ENTREGAS REPETIDAS del mismo mensaje
→ si la entrega exactamente una vez está activa y aun así hay repeticiones, algo no está confirmando

Y EL COSTE
se paga por volumen publicado, entregado y almacenado
→ una suscripción que nadie consume acumula y factura
→ suscripciones sin consumidor: inventario periódico ley 25

Y una advertencia de coste que se repite:

los mensajes se retienen hasta que se confirman o caducan
→ una suscripción abandonada retiene todo hasta la caducidad
→ y factura almacenamiento
→ y por eso las suscripciones sin consumidor son un hallazgo típico del primer inventario

Las comprobaciones de esta clase:

- enviar el mismo mensaje 50 veces y comprobar un efecto
- parar el consumidor y esperar la alerta de antigüedad
- dejar un mensaje en el tema de fallidos y esperar alerta
- reprocesar 10.000 mensajes con límite de ritmo
- publicar un mensaje con esquema inválido
- retroceder una suscripción y comprobar el reproceso
- y comprobar que un mensaje venenoso con clave de ordenación no bloquea indefinidamente

Y los errores de traslado, que esta parte vigila:

- X «como garantiza exactamente una vez, no hace falta idempotencia»
→ cubre una de las cinco fuentes de duplicado
- X «la suscripción de entrega es como una cola con consumidor»
→ el ritmo lo marca el servicio; hay que limitar la concurrencia del consumidor
- X «un tema por consumidor»
→ un tema, N suscripciones; crear un tema por consumidor obliga al productor a saber quién escucha clase 148

Y la lista de comprobación de la clase:

- hay un tema y una suscripción por consumidor
- el tipo de suscripción corresponde al consumidor
- la concurrencia del consumidor está limitada
- el plazo de confirmación supera el proceso, o se extiende
- los reintentos tienen retroceso declarado
- la entrega exactamente una vez está donde el duplicado cuesta
- toda operación con efecto es idempotente igualmente
- el orden por clave se usa solo donde hace falta
- está decidido qué hacer con un veneno en una clave ordenada
- los filtros reducen lo que llega a cada consumidor
- hay tema de fallidos CON suscripción
- hay alerta por antigüedad, no solo por número
- el motivo del fallo se guarda con el mensaje
- el reproceso está escrito y probado
- no hay suscripciones sin consumidor

Y el cierre que enlaza con la clase siguiente: con datos, cómputo y mensajería en pie, falta saber qué ocurre cuando algo va mal. La observabilidad de esta nube, con el estándar abierto, es la materia de la clase 238.

Ejemplo trabajado

CloudShop monta la mensajería de su plataforma en Google Cloud. Lo que sigue es el malentendido sobre la entrega exactamente una vez, la suscripción abandonada que acumuló 41 millones de mensajes, y la clave de ordenación que bloqueó un cliente durante 6 horas.

El malentendido, semana 2.

el equipo activó la entrega exactamente una vez en las 6
suscripciones
y retiró la comprobación de idempotencia de los
consumidores
motivo «ya no hace falta: el servicio lo garantiza»

lo que pasó en la primera campaña	
correos de confirmación duplicados	214
descuentos de stock duplicados	88

el diagnóstico
la garantía cubre: un mensaje CONFIRMADO no se reentrega
no cubría lo que estaba pasando

caso 1 (correos)
el consumidor enviaba el correo y fallaba al confirmar
por una desconexión
→ el mensaje se reentregaba, correctamente
→ y el correo se enviaba otra vez
→ la garantía funcionó: el problema es que el EFECTO ya
se había producido

caso 2 (stock)
el productor reintentaba al no recibir confirmación de
publicación
→ publicaba DOS mensajes distintos, con contenido igual
→ dos mensajes distintos, entregados una vez cada uno
→ la garantía no aplica: son mensajes distintos

corrección
idempotencia restaurada, con clave del suceso generada
por el PRODUCTOR y estable entre reintentos clase 210
→ y la entrega exactamente una vez se dejó activa donde
el duplicado cuesta, y se desactivó en telemetría,
donde limitaba el caudal

duplicados tras la corrección	0
-------------------------------	---

Y la frase que el equipo escribió en el registro de decisión:

«la garantía del transporte reduce los duplicados de
transporte; el efecto lo protege el consumidor»
→ y es la misma conclusión de las clases 117, 210 y 224,
con otro producto ley 18

La suscripción abandonada.

al revisar el coste, mes 4
coste de mensajería 1.840 €/mes
esperado ~200 €

desglose
publicación 140 €
entrega 180 €
ALMACENAMIENTO DE MENSAJES SIN CONFIRMAR 1.520 € ←

causa
una suscripción creada para una prueba en el mes 1
su consumidor se apagó al terminar la prueba
la suscripción siguió recibiendo CUANTO se publicaba
mensajes retenidos 41 millones
antigüedad del más antiguo 94 días
→ y la retención estaba en 7 días... en OTRA suscripción

la abandonada tenía retención de 31 días y los mensajes
se acumulaban hasta caducar y volver a acumularse

corrección
suscripción borrada
inventario de suscripciones sin actividad de consumo
→ 4 más encontradas
alerta: «suscripción sin consumo en 24 h»
y caducidad automática de suscripciones inactivas 30 días
ley 25

coste 1.840 € → 190 €/mes

La clave de ordenación que bloqueó un cliente.

el flujo de integración con socios usaba clave de
ordenación = identificador de socio
motivo los eventos de un socio deben procesarse en orden

qué pasó
un socio envió un evento con un campo con un carácter que
el consumidor no manejaba
→ el consumidor fallaba al procesarlo
→ reintentaba con retroceso
→ y todos los eventos siguientes de ESE socio esperaban

duración 6 h 10
eventos acumulados de ese socio 4.100
otros socios sin afectación

cómo se detectó
el socio llamó
→ la alerta de antigüedad existía pero con umbral de
24 h ley 15

correcciones
1 umbral de antigüedad a 30 minutos
2 decisión escrita sobre el veneno en clave ordenada
tras 5 intentos, el mensaje se aparta al tema de
fallidos y la clave AVANZA
→ se pierde el orden estricto para esa clave, y se
registra como incidencia de datos
→ la alternativa (parar) era peor para el negocio
3 validación de esquema en la publicación
→ el mensaje con el carácter problemático se habría
rechazado al publicar clase 188

La configuración final:

consumidor	tipo	plazo	concurr.	orden
notificaciones	entrega	60 s	50	no
inventario	extracción	600 s	20	no
facturación	extracción	600 s	10	no
integración socios	extracción	300 s	5	Sí
analítica	hacia el almacén analítico, directa			

histórico hacia almacenamiento, por lotes

entrega exactamente una vez
 activa en inventario, facturación e integración
 inactiva en notificaciones y telemetría

filtros
 cada suscripción filtra por tipo de suceso
 → la de inventario recibía 41.000 mensajes/día y ahora
 2.100
 → y no se paga por los 38.900 que descartaba

temas de fallidos
 uno por suscripción, CON suscripción propia
 con el motivo guardado como atributo

Y las dos suscripciones directas, que ahorraron trabajo:

ANALÍTICA
 antes un consumidor que leía y escribía en el almacén
 analítico: 340 líneas y un servicio que mantener
 después suscripción directa hacia la tabla, con esquema
 validado clase 236
 → servicio retirado ley 23

HISTÓRICO
 antes un trabajo que exportaba cada noche
 después suscripción hacia almacenamiento, por lotes de
 5 minutos
 → trabajo retirado

Las comprobaciones, ejecutadas:

- ✓ mismo mensaje 50 veces 1 efecto
- ✓ parar el consumidor → alerta de antigüedad 3 min
- ✓ mensaje en tema de fallidos → alerta 41 s
- ✓ reprocesar 10.000 con límite de ritmo 2 min
- ✗ publicar un mensaje con esquema inválido
 → se aceptó: la validación de esquema no estaba
 activada en 2 de los 6 temas
 → activada
- ✓ retroceder una suscripción y reprocesar
- ✗ veneno con clave de ordenación
 → bloqueó indefinidamente en la primera prueba
 → corregido con la decisión de apartar y avanzar

El resultado:

coste de mensajería	1.840 €	190 €
duplicados por campaña	302	0
suscripciones sin consumidor	5	0
mensajes retenidos	41 M	<10 k
bloqueo por veneno en clave ordenada	6 h 10	6 min
tiempo de detección de consumidor parado	24 h	3 min
servicios de integración retirados	—	2
mensajes entregados y descartados	38.900/día	0

La lección que esta clase deja: la garantía de entrega exactamente una vez es real y cubre una de las cinco fuentes de duplicado; quitar la idempotencia porque existe produjo trescientos dos duplicados en una campaña. Y el mayor coste del capítulo no fue de proceso ni de entrega: fue mil quinientos veinte euros al mes de almacenamiento de una suscripción que nadie consumía desde hacía tres meses.

Laboratorio guiado

Ejecuta desde la raíz:

```
python classes/part-19-gcp-production-architecture/237-pub-sub-eventarc-y-entrega-exactamente-una-vez/
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 `gcp-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 `gcp-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
Aparecen duplicados pese a tener entrega exactamente una vez	La garantía cubre la reentrega tras confirmar, no el reintento del productor ni el fallo tras producir el efecto	Mantén la idempotencia en el consumidor con clave del suceso generada por el productor y estable entre reintentos.
La factura de mensajería es diez veces lo previsto	Una suscripción sin consumidor retiene todo lo publicado y paga almacenamiento	Inventaría suscripciones sin consumo, alerta cuando una lleve 24 h sin consumir y caduca las inactivas.
Los eventos de un cliente se detienen durante horas	Un mensaje venenoso bloquea su clave de ordenación	Decide y escribe qué ocurre con el veneno: apartarlo y avanzar, o parar; valida el esquema al publicar.
El consumidor recibe más carga de la que aguanta	Suscripción de entrega, donde el ritmo lo marca el servicio	Limita la concurrencia del consumidor o usa suscripción de extracción si hay un recurso limitado detrás.
Vencen los plazos y se reentregan mensajes que sí se estaban procesando	El plazo de confirmación es menor que el proceso y no se extiende	Activa la extensión automática del plazo y reduce la concurrencia; vigila los plazos vencidos.
Los mensajes fallidos caducan sin que nadie los vea	El tema de fallidos no tiene suscripción ni alerta	Crea suscripción sobre él, alerta por antigüedad y guarda el motivo del fallo como atributo.

■ 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 exactamente la entrega exactamente una vez y qué no?
2. ¿Cuándo conviene suscripción de extracción y cuándo de entrega?
3. ¿Qué coste tiene usar clave de ordenación y qué hay que decidir?
4. ¿Por qué una suscripción sin consumidor genera coste?
5. ¿Qué dos suscripciones directas evitan escribir un consumidor?

Referencias

- Google Cloud (2025). Pub/Sub: exactly-once delivery. <<https://cloud.google.com/pubsub/docs/exactly-once-delivery>>
- Google Cloud (2025). Pub/Sub subscription types and delivery. <<https://cloud.google.com/pubsub/docs/subscriber>>
- Google Cloud (2025). Message ordering. <<https://cloud.google.com/pubsub/docs/ordering>>
- Google Cloud (2025). Dead-letter topics and retry policies. <<https://cloud.google.com/pubsub/docs/handling-failures>>
- Google Cloud (2025). Eventarc. <<https://cloud.google.com/eventarc/docs/overview>>
- Documentación oficial vigente del servicio implementado; registra URL y fecha de consulta.

Descargar: Parte 19 en PDF · Recorrido de Google Cloud en PDF · Manual integral

Anterior	Índice	Siguiente
← 236 · BigQuery, Dataflow, Dataproc y gobernanza de datos	Parte 19 · Programa	238 · Cloud Operations, Trace y OpenTelemetry →

Evaluación — 237 Pub/Sub, Eventarc y entrega exactamente-una-vez

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 gcp-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.

238 — Cloud Operations, Trace y OpenTelemetry

Parte: 19 — Google Cloud: arquitectura de datos y operación en producción Nivel: avanzado · Horas estimadas: 4
Laboratorio: observability · Estado: EXECUTABLECORE

Propósito

Montar la observabilidad de Google Cloud, donde los registros de auditoría son la pieza distintiva y a la vez la que más coste y más sorpresas produce: el registro de acceso a datos está desactivado por defecto, y activarlo sin acotar dispara la factura. La clase cubre el enrutado y los filtros de exclusión, la instrumentación estándar, los objetivos de nivel de servicio como recurso declarado, y las alertas que este programa exige siempre.

Resultados de aprendizaje

Al finalizar podrás:

1. Enrutar registros con filtros de inclusión y exclusión, y controlar su coste.
2. Decidir qué registros de auditoría activar y sobre qué servicios.
3. Instrumentar con el estándar abierto para no quedar atado.
4. Declarar objetivos de nivel de servicio y alertar por ritmo de consumo.
5. Correlacionar desde la alerta hasta la causa sin eslabones rotos.

Conceptos centrales


Concepto	Comprensión verificable
receptor de registros	Regla que enruta registros a un destino: almacén de registros, almacenamiento, almacén analítico o mensajería.
filtro de exclusión	Regla que descarta registros antes de almacenarlos. La palanca de coste más directa.
registro de auditoría de administración	Quién creó, modificó o borró qué. Siempre activo y sin coste.
registro de acceso a datos	Quién leyó o escribió datos. Desactivado por defecto y muy voluminoso.
objetivo de nivel de servicio	Recurso declarado con su indicador, su objetivo y su presupuesto de error.
alerta por ritmo de consumo	Se dispara cuando el presupuesto de error se gasta demasiado rápido. La que debe despertar.

Modelo mental

Google Cloud combina una jerarquía estricta de recursos con una red global y servicios data-first; proyecto, cuota e IAM forman una unidad operativa.

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. Enrutar y excluir

El modelo aquí es un enrutador: todo pasa por él y se decide qué va a dónde.

LOS DESTINOS

almacén de registros	consultable, con retención
almacenamiento	barato, para conservar por norma
almacén analítico	para consultar mucho volumen
	clase 236
mensajería	para procesar en tiempo real

Y EL RECEPTOR

un filtro decide qué se envía a cada destino
 → y se pueden crear en la organización, para que apliquen
 a todos los proyectos clase 229

Los filtros de exclusión, que son la palanca de coste más directa:

se descartan ANTES de almacenar y no se pagan

lo que casi siempre se excluye

comprobaciones de salud del balanceador
 peticiones correctas de servicios muy hablados, con
 muestreo parcial
 registros de nivel de información de componentes ruidosos
 y las lecturas de metadatos de los agentes

y con MUESTREO

«excluye el 95 % de las peticiones con código 200»
 → conserva una muestra y descarta el resto
 → y hay que tenerlo en cuenta al contar clase 225

Y el receptor a la organización, que resuelve un problema de gobierno:

un receptor en la organización envía los registros de
 AUDITORÍA de todos los proyectos a un destino centralizado
 en un proyecto de seguridad
 al que los equipos NO tienen acceso de escritura ni de
 borrado
 → y eso es lo que hace la auditoría creíble clase 141
 → sin ello, quien compromete un proyecto borra sus huellas

Y la retención, por destino:

almacén de registros de aplicación	30 días
almacén de auditoría	400 días

almacenamiento para conservación lo que exija la norma
→ y hay que fijarla: los valores por defecto no corresponden a nada ley 26

2. Los registros de auditoría

Esta es la pieza distintiva y la que hay que entender antes de activarla.

ADMINISTRACIÓN

quién creó, modificó o borró un recurso
SIEMPRE activo y sin coste
→ y es el que responde «¿quién cambió esto?»

ACCESO A DATOS

- quién leyó o escribió datos
- DESACTIVADO por defecto, salvo unos pocos ley 26
- y es el que responde «¿quién leyó esta tabla?»
- es decir, el que hace falta para investigar una fuga

y su volumen

- cada lectura de cada objeto genera una entrada
- en un almacén con mucho tráfico, es enorme
- activarlo en todos los servicios dispara la factura

EVENTOS DE SISTEMA

```
acciones que hace la propia plataforma
siempre activo
```

DENEGACIÓN DE POLÍTICA

intentos rechazados por una política
→ muy útil y de poco volumen

Y la decisión que hay que tomar servicio por servicio:

¿ACTIVAR ACCESO A DATOS AQUÍ?

```

sí    donde hay datos sensibles: almacenes con datos
      personales, conjuntos analíticos, gestor de secretos
sí    en el gestor de claves, siempre
no    en almacenes de artefactos, registros y datos
      públicos

```

y dentro de los activados

distinguir LECTURA de ESCRITURA

la escritura es poco voluminosa y muy valiosa
la lectura es lo que dispara el volumen
→ activar escritura en muchos, lectura en pocos

y excluir las identidades que generan ruido

los propios agentes, los procesos de copia
→ con una exclusión, no desactivando el servicio entero

Y la comprobación de que sirve:

«¿quién leyó la tabla de clientes en las últimas 24 h?»
→ si no se puede contestar, el registro de acceso a datos
no está donde hace falta
→ y esa pregunta llega el día de un incidente, no antes

clase 226

Y el acceso a los propios registros:

- quien puede leer los registros de auditoría ve mucho
 - acceso restringido y auditado
 - y quien puede BORRARLOS o cambiar el enrutado, menos aún
 - con política de organización que lo impida clase 229

3. Instrumentar y declarar objetivos

La instrumentación, con la decisión de la clase 225:

ESTÁNDAR ABIERTO

- trazas, métricas y registros con la API común
- el destino es configuración
- cambiar de proveedor de análisis no toca el código

→ y la misma instrumentación vale en las tres nubes
clase 158

y aquí hay un detalle a favor
los servicios gestionados ya emiten trazas y métricas
→ y el contexto se propaga si la aplicación lo respeta
→ una petición que cruza balanceador, servicio de
contenedores y base aparece como una sola traza

Y lo que hay que cuidar, que es lo de siempre:

el contexto de traza viaja también por la mensajería
→ dentro del mensaje clase 237
dimensiones de baja cardinalidad clase 211
registros estructurados con traza, servicio, versión y
entorno
y sin secretos ni datos personales completos

Los objetivos de nivel de servicio, que aquí son un recurso declarado:

se declara
el SERVICIO
el INDICADOR: disponibilidad o latencia, con su fuente
el OBJETIVO: 99,5 % en 28 días
→ y la plataforma calcula el presupuesto de error y su
consumo

y se puede declarar como código, junto al servicio
clase 232

Y LA ALERTA QUE IMPORTA
por RITMO DE CONSUMO del presupuesto
«se está gastando 14 veces más rápido de lo normal»
→ esa es la que despierta clase 211
→ y no «hubo un error»

con dos ventanas
corta, para lo que arde
larga, para la degradación lenta

Y la disciplina que este programa exige:

el objetivo se define por FLUJO DE USUARIO, no por
componente clase 123
«el 99,5 % de las confirmaciones de pedido en menos de
800 ms, medidas en el borde»
→ y medido donde el usuario lo sufre clase 126

Y las alertas que faltan siempre:

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

POR ANTIGÜEDAD
mensajes sin confirmar, temas de fallidos, sincronización
certificados, retraso de replicación
clases 237, 234, 235

Y POR NEGOCIO
«pedidos confirmados por minuto por debajo del mínimo»
→ detecta lo que ninguna métrica técnica ve ley 15

4. Consultar, correlacionar y pagar

Las consultas preparadas, que ahorran minutos durante un incidente:

«todo lo de esta traza»
«errores de este servicio en la última hora, por tipo»
«qué cambió en los recursos en la última hora»
→ del registro de auditoría de administración
«quién accedió a estos datos»
→ del registro de acceso a datos
«peticiones más lentas y qué tramo domina»

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

La cadena de diagnóstico, con el eslabón que aquí es directo:

alerta por ritmo de consumo del presupuesto
→ panel del servicio
→ trazas del periodo
→ registros de esas trazas
→ REGISTRO DE AUDITORÍA: ¿qué se cambió?

→ y ese último eslabón es el que suele faltar en otras plataformas y aquí está siempre activo y gratis

Y el perfilado, que resuelve una categoría de problemas:

el perfilador continuo muestra dónde se va el tiempo y la memoria en producción, con muestreo y coste bajo
→ y resuelve las preguntas que ni las trazas ni los registros contestan: «¿por qué esta función consume el 40 % de la CPU?»
→ conviene tenerlo activo antes de necesitarlo

El coste, con las palancas:

- 1 FILTROS DE EXCLUSIÓN ← la mayor
- 2 activar acceso a datos solo donde hace falta
- 3 retención por almacén, no global
- 4 destino según uso: consultable, barato o analítico
- 5 muestreo en la aplicación
- 6 y dimensiones de baja cardinalidad

y la revisión trimestral
¿cuánto cuesta la observabilidad frente al cómputo?
→ en la clase 211 costaba el doble
→ y aquí, con acceso a datos mal acotado, puede costar más
clase 239

Y la lista de comprobación de la clase:

- hay receptor en la organización para los registros de auditoría
- el destino de auditoría está en un proyecto sin acceso de escritura desde producción
- hay filtros de exclusión para lo ruidoso
- el acceso a datos está activado donde hay datos sensibles, y solo ahí
- se distingue lectura de escritura al activarlo
- la retención está fijada por almacén
- el acceso a los registros está restringido y auditado
- una política impide cambiar el enrutado de auditoría
- la instrumentación de las aplicaciones es estándar
- el contexto de traza viaja por la mensajería
- hay objetivos declarados por flujo de usuario
- hay alerta por ritmo de consumo, con dos ventanas
- hay alertas por ausencia, por antigüedad y de negocio
- las consultas de diagnóstico están guardadas
- el perfilador continuo está activo
- se puede contestar quién leyó unos datos concretos

Y el cierre que enlaza con la clase siguiente: con la observabilidad en pie, quedan la seguridad operativa y el coste, que aquí tienen herramientas propias y un mecanismo de perímetro que ya ha aparecido varias veces. Es la materia de la clase 239.

Ejemplo trabajado

CloudShop monta la observabilidad de su organización en Google Cloud. Lo que sigue es la activación del acceso a datos que multiplicó la factura por seis, la pregunta que no se podía contestar durante un incidente, y los objetivos declarados que sustituyeron a 71 alertas técnicas.

El punto de partida:

coste mensual de observabilidad	1.100 €
registros	740 €

métricas	240 €
trazas	120 €
registros de auditoría	
de administración	activos (gratis)
DE ACCESO A DATOS	desactivados
destino	el proyecto de cada equipo
→ cada equipo podía borrar sus propios registros de auditoría	clase 141

El incidente que reveló el hueco.

seguridad recibió un aviso: un correo de un cliente aparecía en una lista de contactos de un tercero

la pregunta
«¿quién ha leído la tabla de clientes en los últimos 90 días?»

la respuesta
no se podía contestar
el registro de acceso a datos estaba desactivado
el de administración decía quién había concedido permisos, no quién había leído

lo que se pudo hacer
reconstruir con los registros de consulta del almacén analítico, que sí guardaban las consultas
→ 41 identidades habían consultado la tabla
→ y de ellas, 9 no debían tener acceso clase 236

tiempo de investigación 3 días
y la conclusión
la respuesta se obtuvo por casualidad, porque el almacén analítico registra sus consultas
→ sobre el almacén de objetos no habría habido nada

La activación, y la factura.

primer intento
se activó el acceso a datos en TODOS los servicios, con lectura y escritura

factura del mes siguiente	
registros	740 € → 6.400 €

desglose	
almacén de objetos, lecturas	4.100 €
→ cada descarga de una imagen del catálogo generaba una entrada; 41 M al día	
almacén analítico, lecturas	980 €
bases de datos, lecturas	710 €
resto	610 €

Y la corrección, servicio por servicio:

servicio	lectura	escritura	motivo
almacén con datos de clientes	SÍ	SÍ	datos personales
almacén de imágenes del catálogo	no	SÍ	público
almacén analítico	SÍ	SÍ	datos personales
gestor de secretos	SÍ	SÍ	siempre
gestor de claves	SÍ	SÍ	siempre
base de pedidos	no	SÍ	volumen; y el acceso va por la API
almacén de artefactos	no	SÍ	no sensible
registros	no	SÍ	

y las exclusiones dentro de los activados
identidades de los agentes de copia
identidad del proceso de replicación

→ ninguna había detectado un problema que los objetivos no detectaran antes

La prueba de las alertas:

condición provocada en las 45
no llegaron 7
4 por umbral mal puesto
2 por destino sin destinatarios
1 porque el objetivo estaba mal declarado: el
indicador medía en el servidor, no en el borde
clase 126, ley 22

El perfilador, que resolvió algo que las trazas no:

síntoma el servicio de búsqueda consumía el doble de CPU
que hacía tres meses, con el mismo tráfico
las trazas no mostraban ningún tramo lento

el perfilador continuo
el 41 % de la CPU en una función de normalización de
texto
→ un cambio de tres meses antes había añadido una
expresión regular compilada EN CADA LLAMADA

corrección compilar una vez
CPU -38 %
instancias necesarias 9 → 6

El resultado:

coste de observabilidad	1.100 €	1.640 €
(con auditoría de datos activada donde hace falta)		
frente a 6.400 € con todo activado		
volumen de registros	1,9 TB	450 GB
«¿quién leyó estos datos?»	incontestable	40 s
registros de auditoría borrables por		
los equipos	sí	no
alertas configuradas	98	45
accionables	61 (8 %)	61 (90 %)
objetivos declarados	0	6
alertas que no llegaban	n/d	0 (de 7 corregidas)

La lección que esta clase deja: activar el registro de acceso a datos en todos los servicios multiplicó la factura por seis, y acotarlo a donde hay datos sensibles la dejó en menos de la cuarta parte sin perder la capacidad que importaba. La pregunta que un incidente hizo —quién leyó una tabla— no se podía contestar, y solo se respondió por casualidad porque el almacén analítico registra sus consultas. Y setenta y una alertas técnicas se retiraron sin perder nada: ninguna había detectado un problema antes que los objetivos.

Laboratorio guiado

Ejecuta desde la raíz:

```
python classes/part-19-gcp-production-architecture/238-cloud-operations-trace-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 gcp-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 gcp-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
No se puede saber quién leyó unos datos durante un incidente	El registro de acceso a datos está desactivado por defecto	Actívalo en los servicios con datos sensibles, distinguiendo lectura de escritura, y guarda la consulta que responde esa pregunta.
La factura de registros se multiplica al activar la auditoría de datos	Se activó la lectura en todos los servicios, incluidos los de mucho volumen y datos públicos	Acota por servicio, activa escritura en muchos y lectura en pocos, y excluye las identidades de agentes y procesos de copia.
Un equipo puede borrar los registros que lo incriminan	La auditoría se guarda en el proyecto del propio equipo	Receptor en la organización hacia un proyecto de seguridad sin escritura desde producción, y política que impida modificarlo.
Hay decenas de alertas y ninguna dice si el usuario está sufriendo	Son umbrales técnicos y no objetivos por flujo de usuario	Declara objetivos por flujo, alerta por ritmo de consumo del presupuesto y retira las técnicas que no aporten.
Un objetivo declarado no detecta un problema real	El indicador se mide en el servidor y no donde el usuario lo sufre	Mide en el borde y comprueba el objetivo provocando la condición.
Un servicio consume más CPU y las trazas no muestran nada	El coste está dentro del proceso, no en las llamadas	Activa el perfilador continuo antes de necesitarlo; muestra dónde se va el tiempo en producción.

■ 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 registro de administración y el de acceso a datos?
2. ¿Por qué el destino de la auditoría debe estar fuera del alcance de producción?
3. ¿Cuál es la palanca de coste más directa en el enrutado de registros?
4. ¿Qué alerta debe despertar a alguien y por qué no el error suelto?

5. ¿Qué resuelve el perfilador continuo que no resuelven trazas ni registros?

Referencias

- Google Cloud (2025). Cloud Logging: routing and storage. <<https://cloud.google.com/logging/docs/routing/overview>>
- Google Cloud (2025). Cloud Audit Logs. <<https://cloud.google.com/logging/docs/audit>>
- Google Cloud (2025). Service monitoring: SLOs and burn rate alerts. <<https://cloud.google.com/stackdriver/docs/solutions/slo-monitoring>>
- Google Cloud (2025). Cloud Trace and OpenTelemetry. <<https://cloud.google.com/trace/docs/setup>>
- Google Cloud (2025). Cloud Profiler. <<https://cloud.google.com/profiler/docs/about-profiler>>
- Documentación oficial vigente del servicio implementado; registra URL y fecha de consulta.

Descargar: Parte 19 en PDF · Recorrido de Google Cloud en PDF · Manual integral

Anterior	Índice	Siguiente
← 237 · Pub/Sub, Eventarc y entrega exactamente-una-vez	Parte 19 · Programa	239 · SCC, VPC Service Controls, KMS y FinOps →

Evaluación — 238 Cloud Operations, Trace 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 gcp-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.

239 — SCC, VPC Service Controls, KMS y FinOps

Parte: 19 — Google Cloud: arquitectura de datos y operación en producción Nivel: avanzado · Horas estimadas: 4
Laboratorio: security · Estado: EXECUTABLECORE

Propósito

Cerrar la operación de Google Cloud con la seguridad y el coste, que aquí tienen dos piezas propias: el perímetro de servicio, que es el control que impide sacar datos aunque los permisos lo permitan, y el modelo de descuentos automáticos, que cambia el cálculo de los compromisos. La clase cubre la postura y la detección con la disciplina de la clase 226, y el control de coste con la de la 214.

Resultados de aprendizaje

Al finalizar podrás:

1. Priorizar los hallazgos de seguridad por alcance y por camino de ataque.
2. Aplicar perímetros de servicio y entender qué cierran.
3. Gestionar claves de cifrado propias donde aportan.
4. Atribuir el coste y aprovechar los descuentos automáticos.
5. Comprometer capacidad solo tras retirar y redimensionar.

Conceptos centrales


Concepto	Comprensión verificable
perímetro de servicio	Frontera que restringe qué API pueden usarse hacia dentro y hacia fuera de un grupo de proyectos.
camino de ataque	Secuencia de pasos desde un punto expuesto hasta un dato valioso. Ordena la prioridad.
clave gestionada por el cliente	Clave de cifrado bajo control propio. Permite revocar el acceso a los datos por completo.
descuento por uso sostenido	Rebaja automática por mantener recursos encendidos, sin compromiso.
compromiso de uso	Descuento a cambio de un compromiso de gasto o de capacidad durante uno o tres años.
etiqueta de facturación	Etiqueta que aparece en el desglose de costes. Distinta de las que se usan en condiciones de permiso.

Modelo mental

Google Cloud combina una jerarquía estricta de recursos con una red global y servicios data-first; proyecto, cuota e IAM forman una unidad operativa.

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 y caminos de ataque

La disciplina es la de la clase 226 y aquí hay una herramienta que la hace directa.

LO QUE PRODUCE LA EVALUACIÓN CONTINUA
 hallazgos de configuración: público, sin cifrar, sin copias, versión antigua
 hallazgos de identidad: permisos amplios, claves
 hallazgos de vulnerabilidades

Y LO QUE ORDENA EL TRABAJO
 no la gravedad declarada
 sino los CAMINOS DE ATAQUE
 «desde esta máquina expuesta, con esta cuenta de servicio, se llega a este conjunto con datos de clientes»
 → con la puntuación de exposición calculada

→ y esos caminos concentran más riesgo que cientos de hallazgos sueltos clase 226

Y el orden de trabajo, ya conocido:

- 1 cerrar los caminos que terminan en datos
- 2 reducir el alcance de las identidades más amplias clase 230
- 3 impedir por política que lo arreglado vuelva clase 229
- 4 remediar el resto por lotes ley 27
- 5 aceptar por escrito lo que no compensa clase 189

Y los hallazgos que se repiten en esta nube:

cuentas de servicio con papel de proyecto clase 230
 claves de cuenta de servicio sin caducidad
 almacenes con acceso a «todos los usuarios autenticados»
 → que significa cualquier cuenta de Google, no solo la organización
 → y es el hallazgo que más sorprende
 reglas de cortafuegos con selector por etiqueta clase 229
 conjuntos analíticos con acceso al conjunto entero clase 236
 y proyectos sin carpeta, que no reciben políticas

Y la comprobación de la detección:

simular técnicas conocidas y medir qué proporción se detecta
 → es la única medida real clase 226
 → y las que no se detecten son la lista de trabajo

2. El perímetro de servicio

Este es el control propio de esta nube y el que cierra el hueco que dejan los permisos.

EL PROBLEMA QUE RESUELVE
 una identidad con permiso legítimo sobre unos datos puede copiarlos a un proyecto de otra organización
 → el permiso lo autoriza
 → la red no lo impide, porque va por la API de la plataforma clase 200, 231

EL PERÍMETRO

agrupa proyectos y restringe qué API pueden usarse
desde fuera hacia dentro ← quién puede leer
desde dentro hacia fuera ← a dónde se puede escribir
→ y una identidad de dentro NO puede escribir en un
recurso de fuera del perímetro

Y lo que hay que hacer para que funcione sin romper nada:

- 1 DEFINIR el perímetro: qué proyectos y qué servicios
- 2 MODO DE SIMULACIÓN: registra lo que bloquearía
- 3 MEDIR semanas
- 4 DECLARAR los accesos legítimos que cruzan
reglas de entrada y de salida, por identidad, por
proyecto y por servicio
- 5 APLICAR

→ activar sin simular corta integraciones legítimas
→ y es la misma disciplina de las clases 200, 209 y 217

Y lo que suele aparecer en la simulación:

herramientas de terceros que leen datos
canalizaciones de otro proyecto
copias hacia un proyecto de análisis
el propio equipo consultando desde su portátil
→ y eso obliga a decidir: ¿se declara o se prohíbe?

Las claves gestionadas por el cliente, con lo que aportan de verdad:

QUÉ APORTAN

el control de la clave: revocarla hace los datos
inaccesibles, incluso para el proveedor
→ y eso es lo que exigen algunos requisitos
clase 177
rotación bajo control propio
y registro de cada uso de la clave
clase 238

QUÉ CUESTAN

operación: rotación, permisos, disponibilidad de la clave
y si la clave se pierde o se revoca por error, los datos
son irre recuperables
→ esa es una consecuencia real, no teórica

DÓNDE APLICARLAS

donde haya requisito o datos sensibles
no en todo
ley 26

Y una advertencia operativa:

la clave vive en una región
→ si esa región no está disponible, los datos cifrados con
ella tampoco
→ y eso entra en el cálculo del techo de disponibilidad
clase 185

3. Coste: los descuentos que ya se aplican

Aquí hay una diferencia que cambia el cálculo de los compromisos.

DESCUENTO POR USO SOSTENIDO

se aplica AUTOMÁTICAMENTE por mantener recursos
encendidos durante el mes
→ sin compromiso, sin contratar nada
→ y llega a ser apreciable

Y LA CONSECUENCIA

el compromiso de uso añade descuento SOBRE lo ya
descontado
→ el ahorro incremental es menor de lo que sugiere el
porcentaje anunciado
→ y hay que calcularlo con las cifras propias, no con el
porcentaje del catálogo
clase 227

Y los tipos de compromiso:

POR GASTO

- se compromete una cantidad por hora
- + flexible: se aplica a lo que haya
- descuento menor

POR RECURSO

- se compromete una cantidad de CPU y memoria en una región
- + descuento mayor
- rígido: si se cambia de región o de familia, se pierde

→ y el orden de la clase 227 sigue valiendo
retirar → redimensionar → apagar → y ENTONCES comprometer

La atribución, con la particularidad de las etiquetas:

HAY DOS MECANISMOS DE ETIQUETADO

- uno aparece en el desglose de FACTURACIÓN
- otro sirve para CONDICIONES de permiso y para políticas
clases 229, 230

- y no son intercambiables
- usar el equivocado hace que el gasto no se atribuya

Y LA JERARQUÍA AYUDA

- el desglose por PROYECTO es directo y limpio
- y por eso la separación por proyecto de la clase 229
es también una decisión de atribución

Y el resto del método, que es el de la clase 214:

- etiquetas obligatorias en la creación, por política
- presupuestos por proyecto, sobre previsión, con acción en
no producción
- detección de anomalías por servicio y por dueño
- retirada automática de lo ocioso: apagar antes de borrar
- y coste por unidad de negocio

Y las partidas que sorprenden en esta nube:

consultas del almacén analítico	clase 236
registros de acceso a datos	clase 238
almacenamiento de mensajes sin confirmar	clase 237
tráfico entre zonas y entre regiones	
mínimos de capacidad de las bases distribuidas	clase 235
y los proyectos sin uso que nadie retira	ley 25

4. El ritmo, y lo que se degrada solo

Coste y seguridad comparten la propiedad de degradarse sin intervención, y esta clase cierra la parte con el mismo calendario de la 227.

SEMANAL

- anomalías de coste abiertas
- hallazgos críticos nuevos
- recursos ociosos retirados

MENSUAL

- coste por unidad de negocio y su tendencia
- cobertura y utilización de compromisos
- proyectos sin uso
- y hallazgos por camino de ataque

TRIMESTRAL

- simulación de técnicas y proporción detectada clase 226
- prueba del acceso de emergencia clase 230
- revisión de accesos y de exenciones
- y un experimento de resiliencia clase 227

ANUAL

- ejercicio de pérdida de región clase 215
- revisión de las decisiones registradas clase 190

Y las señales que dicen si está sano:

SEGURIDAD

- caminos de ataque que terminan en datos → cero
- proporción de técnicas simuladas detectadas
- claves de cuenta de servicio → cero

proyectos sin carpeta → cero
y perímetros con reglas de excepción sin fecha → cero

COSTE

gasto atribuido	> 90 %
coste por unidad de negocio	tendencia
utilización de compromisos	> 95 %
proyectos sin uso	tendencia a cero

Y una comprobación honesta, la misma de la clase 226:

¿cuántos incidentes detectó el centro y cuántos se detectaron por otra vía?
→ y las vías de siempre: una factura, un tercero, un inventario, una persona

Y la lista de comprobación de la clase:

- los hallazgos se ordenan por camino de ataque
- no hay caminos que terminen en datos sensibles
- no hay almacenes con acceso a todos los usuarios autenticados
- hay perímetros de servicio sobre los proyectos con datos
- los perímetros se simulaban antes de aplicar
- las reglas de excepción del perímetro tienen dueño y fecha
- las claves propias están donde hay requisito, y su región entra en el cálculo de disponibilidad
- las etiquetas de facturación son las correctas
- el gasto atribuido supera el 90 %
- se retiró y redimensionó antes de comprometer
- el descuento incremental del compromiso se calculó sobre el ya aplicado
- hay presupuestos con acción y detección de anomalías
- se simulan técnicas y se publica la proporción detectada
- existe el 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, compararlo con las otras dos nubes y cerrar la parte. Es la materia de la clase 240.

Ejemplo trabajado

CloudShop cierra la operación de Google Cloud. Lo que sigue son los almacenes accesibles por cualquier cuenta de Google, el perímetro que cortó una integración legítima, y el cálculo de compromiso que resultó dar mucho menos de lo anunciado.

La postura, ordenada por camino de ataque:

- | | |
|---|-----------|
| hallazgos abiertos | 2.140 |
| puntuación de exposición: los 5 caminos principales | |
| 1 máquina con IP externa y puerto de administración abierto | |
| → su cuenta de servicio tiene papel de proyecto | |
| → alcanza el almacén de copias y la base de pedidos | |
| pasos: 3 · datos al final: 2,3 M de registros | |
| 2 almacén de exportaciones con acceso a «todos los usuarios autenticados» | |
| → cualquier cuenta de Google del mundo podía listarlo y descargarlo | |
| → contenía extractos diarios de pedidos desde 2023 | |
| pasos: 1 · datos: 41 meses de extractos | |
| 3 cuenta de servicio de la canalización con papel de organización | clase 230 |
| 4 conjunto analítico con acceso al conjunto entero para 41 personas | clase 236 |
| 5 clave de cuenta de servicio de un consultor externo, activa desde 2023 | ley 25 |

Y el segundo merece detalle:

«todos los usuarios autenticados» NO significa «todos los de la organización»

significa cualquiera con una cuenta de Google

→ el equipo lo había configurado creyendo lo primero

→ y la política de organización que lo impide existía desde la clase 229, pero el almacén se había creado ANTES
ley 27

cuánto llevaba así 19 meses

accesos externos registrados no se sabía

→ el registro de acceso a datos no estaba activo en ese almacén clase 238

→ se activó, y en 30 días: 0 accesos externos

→ lo cual no dice nada de los 19 meses anteriores

El perímetro de servicio, con su simulación.

definición

proyectos: los 14 de producción con datos

servicios restringidos: almacenamiento, almacén

analítico, bases, gestor de secretos y claves

modo de simulación, 4 semanas

accesos que se bloquearían 41.200

legítimos 610

del propio perímetro 40.400

NO IDENTIFICADOS 190 ←

los 610 legítimos

- canalización de despliegue desde el proyecto de plataforma

- herramienta de visualización de un tercero

- exportación nocturna al proyecto de análisis

- 4 personas consultando desde su portátil

los 190 no identificados

- 140 de una cuenta de servicio de un proyecto que se creía retirado en 2024 ley 25

- 38 de una herramienta de un proveedor cuyo contrato había terminado

- 12 de una dirección que resultó ser un entorno de pruebas de un socio, no declarado

→ los 190 se cortaron a propósito

→ y los 610 se declararon como reglas de entrada y salida, con dueño y fecha de revisión

Y el corte que ocurrió igualmente:

al aplicar, una integración se rompió

el equipo de finanzas exportaba un informe mensual desde una hoja de cálculo conectada

→ esa conexión no había aparecido en las 4 semanas de simulación porque es MENSUAL y cayó fuera de la ventana

→ duración del corte 2 días

→ corrección: regla declarada

→ y lección: la ventana de simulación debe cubrir el ciclo completo de negocio clase 167

Las claves propias, decididas por caso:

dónde se aplicaron

almacén con datos de clientes

conjunto analítico con datos personales

copias de seguridad

→ los tres con requisito contractual del mayor cliente

dónde NO

almacenes de imágenes y artefactos

registros de aplicación

→ sin requisito y con coste de operación

y el efecto sobre disponibilidad, calculado
la clave vive en una región
→ se configuró con réplica en la segunda región
→ sin eso, el techo del flujo habría bajado clase 185

y la prueba negativa
revocar el acceso a la clave en preproducción
→ los datos pasaron a ser inaccesibles, correctamente
→ y la restauración tardó 11 minutos
→ procedimiento escrito y probado ley 22

El cálculo de compromiso, que dio menos de lo anunciado.

gasto de cómputo 8.400 €/mes

el descuento por uso sostenido YA aplicado
precio de lista 11.900 €
descuento automático -3.500 €
gasto real 8.400 €

la oferta de compromiso a 1 año
descuento anunciado sobre lista 37 %
→ parecía un ahorro de 4.400 €/mes

el cálculo real
con compromiso, sobre lista 7.500 €
ahorro frente a los 8.400 actuales 900 €/mes
→ no 4.400 €

→ porque el descuento automático ya estaba aplicado
→ y comparar con el precio de lista es el error
clase 227

Y el orden que se siguió antes de comprometer:

- 1 RETIRAR 71 proyectos sin actividad clase 229
-3.100 €/mes
- 2 REDIMENSIONAR peticiones de recursos del clúster
clase 234
-1.760 €/mes
- 3 APAGAR entornos no productivos por horario
-1.900 €/mes
- 4 y ENTONCES comprometer, sobre la base estable
-610 €/mes

→ y el compromiso se hizo POR GASTO, no por recurso
→ motivo: el clúster iba a cambiar de familia

El coste, atribuido:

al empezar
gasto atribuido 64 %
y el 36 % restante
recursos con el tipo de etiqueta EQUIVOCADO 2.100 €
→ se habían puesto las de condiciones de permiso,
que no aparecen en el desglose
servicios compartidos 1.900 €
tráfico entre zonas 1.400 €

tras corregir el tipo de etiqueta y repartir lo compartido
gasto atribuido 95 %

La detección, medida:

simulación de 14 técnicas
detectadas la primera vez 9 de 14
las 5 que no
• exfiltración al almacén de otra organización
→ la detectó el PERÍMETRO, no la regla
→ y se aceptó así
• suplantación de una cuenta privilegiada
→ regla escrita
• creación de una clave de cuenta de servicio

- la impide la política; regla añadida igualmente
- acceso a datos desde una identidad inusual
 - dependía del registro de acceso a datos, ahora activo
- enumeración de proyectos
 - umbral corregido

segunda simulación

13 de 14

El resultado:

caminos de ataque que terminan en datos	5	0
almacenes accesibles por cualquier cuenta	3	0
perímetros de servicio	0	2
accesos no identificados que cruzaban	190	0
claves de cuenta de servicio	12	3
gasto atribuido	64 %	95 %
coste mensual	21.400 €	14.030 €
utilización del compromiso	—	97 %
técnicas simuladas detectadas	9/14	13/14

La lección que esta clase deja: un almacén con extractos de pedidos de cuarenta y un meses era descargable por cualquier persona con una cuenta de Google, porque «todos los usuarios autenticados» no significa lo que parece, y la política que lo impedía se creó después que el almacén. Y el compromiso que prometía un 37 % de descuento daba novecientos euros al mes y no cuatro mil cuatrocientos, porque el descuento automático ya estaba aplicado: comparar con el precio de lista es el error.

Laboratorio guiado

Ejecuta desde la raíz:

```
python classes/part-19-gcp-production-architecture/239-scc-vpc-service-controls-kms-y-finops/lab.py
```

El laboratorio selecciona el motor de práctica security 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 gcp-security-finops 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 gcp-security-finops 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 almacén resulta accesible desde fuera de la organización	Se concedió a «todos los usuarios autenticados», que significa cualquier cuenta del proveedor	Prohíbelo por política, revisa lo existente porque la política no actúa hacia atrás, y activa el registro de acceso a datos allí.
Una identidad legítima copia datos a otra organización	El permiso lo autoriza y la red no lo impide porque va por la API	Aplica perímetros de servicio sobre los proyectos con datos, simulando antes y declarando los accesos legítimos.
Aplicar el perímetro corta una integración que no apareció en la simulación	La ventana de simulación no cubrió un proceso mensual	Simula durante un ciclo completo de negocio antes de aplicar.
El ahorro del compromiso es mucho menor de lo anunciado	Se comparó con el precio de lista y el descuento automático ya estaba aplicado	Calcula el ahorro incremental sobre el gasto real actual, no sobre la tarifa de catálogo.
Parte del gasto no aparece atribuido pese a etiquetar	Se usó el tipo de etiqueta que sirve para condiciones de permiso y no el de facturación	Comprueba qué mecanismo aparece en el desglose y usa ese; los dos no son intercambiables.
Los datos cifrados con clave propia dejan de estar disponibles	La clave vive en una región que no está disponible	Replica la clave y cuenta su disponibilidad en el cálculo del techo del flujo.

■ 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 ordena la prioridad de los hallazgos de seguridad?
2. ¿Qué cierra un perímetro de servicio que no cierra ni el permiso ni el cortafuegos?
3. ¿Qué hay que comprobar antes de aplicar un perímetro y durante cuánto tiempo?
4. ¿Por qué el descuento por compromiso da menos de lo que anuncia el porcentaje?
5. ¿Qué efecto tiene sobre la disponibilidad usar claves de cifrado propias?

Referencias

- Google Cloud (2025). Security Command Center: attack path simulation. <<https://cloud.google.com/security-command-center/docs/attack-exposure-learn>>
- Google Cloud (2025). VPC Service Controls: dry run mode. <<https://cloud.google.com/vpc-service-controls/docs/dry-run-mode>>
- Google Cloud (2025). Customer-managed encryption keys. <<https://cloud.google.com/kms/docs/cmek>>
- Google Cloud (2025). Sustained use and committed use discounts. <<https://cloud.google.com/compute/docs/sustained-use-discounts>>
- Google Cloud (2025). Billing labels and cost breakdown. <<https://cloud.google.com/billing/docs/how-to/bq-examples>>
- Documentación oficial vigente del servicio implementado; registra URL y fecha de consulta.

Descargar: Parte 19 en PDF · Recorrido de Google Cloud en PDF · Manual integral

Anterior	Índice	Siguiente
← 238 · Cloud Operations, Trace y OpenTelemetry	Parte 19 · Programa	240 · Proyecto: CloudShop productivo en Google Cloud →

Evaluación — 239 SCC, VPC Service Controls, KMS y FinOps

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 gcp-security-finops 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.

240 — Proyecto: CloudShop productivo en Google Cloud

Parte: 19 — Google Cloud: arquitectura de datos y operación en producción Nivel: avanzado · Horas estimadas: 8
Laboratorio: capstone · Estado: EXECUTABLECORE

Propósito

Poner en producción el sistema completo de CloudShop en Google Cloud, compararlo con las otras dos nubes y cerrar la parte 19. La clase da el orden, el entregable y las pruebas negativas; corrige las cinco predicciones de la clase 228 —tres acertadas, una incompleta y una fallada—, actualiza el recuento de leyes, añade la ley 28 y escribe la hipótesis de la parte 20.

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 las tres nubes con cifras y sacar conclusiones defendibles.
4. Corregir las cinco predicciones de la clase 228 con evidencia.
5. Escribir la hipótesis de la parte 20 en forma refutable.

Conceptos centrales


Concepto	Comprensión verificable
ley 28	Donde se paga por uso, cada valor por defecto es una factura; y nadie lo revisa porque no parece una decisión.
error de traslado	Fallo que viene de dar por válida una suposición de otra nube. La causa dominante de esta parte.
coste de operar varias nubes	Suma de modelos de gobierno, permisos, red, observabilidad y calendarios. No es proporcional al número.
equivalencia conceptual	Correspondencia de ideas entre proveedores. Alta; la operativa es la que difiere.
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

Google Cloud combina una jerarquía estricta de recursos con una red global y servicios data-first; proyecto, cuota e IAM forman una unidad operativa.

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 las pruebas

El encargo. Llevar a producción la plataforma de pedidos de CloudShop en Google Cloud, con usuarios reales, guardia, presupuesto y continuidad comprobada.

El orden, por coste de cambio:

- 1 JERARQUÍA Y RED COMPARTIDA clase 229
carpetas por entorno, proyectos por carga
políticas de organización en auditoría antes de aplicar
→ y con plan de remediación de lo existente ley 27
- 2 IDENTIDAD clase 230
sin claves de cuenta de servicio
asignaciones en el ámbito del recurso, con condiciones
- 3 RED GLOBAL clase 231
una red por entorno, salida cerrada, zonas privadas
asociadas en el proyecto anfitrión
- 4 CÓDIGO clase 232
estado protegido, validación de políticas y coste antes
de aplicar
- 5 DATOS clase 235
familia por patrones y por coste base; clave que reparte
- 6 CÓMPUTO clases 233, 234
servicio de contenedores por defecto; clúster donde hace
falta
- 7 MENSAJERÍA clase 237
un tema, una suscripción por consumidor, idempotencia
- 8 ANALÍTICA clase 236
particionado, límites de consulta y acceso por columna
- 9 OBSERVABILIDAD clase 238
instrumentación estándar, objetivos declarados,
auditoría acotada
- 10 SEGURIDAD Y COSTE clase 239
perímetros, caminos de ataque, compromisos tras retirar

Las pruebas negativas de la parte:

- crear un recurso sin etiquetas obligatorias
- crear una clave de cuenta de servicio
- suplantar una cuenta sin permiso
- acceder fuera de una condición de recurso o de tiempo
- activar un papel privilegiado sin aprobación
- entrar con el acceso de emergencia
- resolver un nombre con conexión privada desde cada
proyecto
- sacar datos a un proyecto de otra organización
- desplegar algo que incumple una política
- borrar el estado y restaurarlo
- ejecutar el plan sin cambios y comprobar que sale vacío
- escribir con clave secuencial y observar el reparto
- consultar una tabla grande sin filtro de partición
- consultar una columna sensible sin la etiqueta
- enviar el mismo mensaje 50 veces
- dejar un mensaje en el tema de fallidos y esperar alerta
- obtener la identidad desde otro espacio de nombres
- perder una región y cronometrar
- provocar la condición de cada alerta
- desplegar el entorno de cero en un proyecto vacío

Y los criterios de evaluación, con el peso donde importa:

- 1 ningún proyecto sin carpeta ni sin dueño 2
- 2 cero claves de cuenta de servicio sin excepción 3
- 3 el alcance de cada identidad está medido 3
- 4 las zonas privadas resuelven desde todos los proyectos 3
- 5 hay perímetro de servicio sobre los proyectos con datos 3
- 6 la clave de las tablas distribuidas reparte 2
- 7 hay límite de bytes por consulta 3
- 8 el acceso a datos personales es por columna 3
- 9 la instrumentación es estándar 2
- 10 hay objetivos declarados con alerta por ritmo 2
- 11 la lista de valores por defecto cambiados es explícita 3

2. Cierre de la parte 19: corrección de las cinco predicciones

Las cinco predicciones de la clase 228, corregidas con la evidencia de las clases 229 a 239.

1. «la tercera nube confirmará la equivalencia conceptual y diferirá en lo operativo; y lo que más costará no será aprender lo distinto sino DESAPRENDER lo de las dos anteriores»

CORRECTA, y con cinco casos documentados. Crear una red por proyecto; asumir que las reglas de cortafuegos son por subred; confundir la barrera con el permiso; poner la concurrencia en 1 por trasladar el modelo de funciones; y usar una clave autoincremental en un almacén repartido por rangos. El más puro fue el de las zonas privadas: el equipo HABÍA SUFRIDO ese problema en la nube anterior, lo conocía, y lo repitió porque el sitio donde se asocia la zona es distinto.

2. «la jerarquía de proyectos y la red compartida volverán a condicionar todo, y el error frecuente será el CONTRARIO: demasiados proyectos»

CORRECTA y literal. 214 proyectos, 189 colgando de la organización sin carpeta, 71 sin actividad en 90 días, 120 sin dueño. Y uno de los inactivos contenía una copia de la tabla de clientes legible por cualquier cuenta, desde hacía 19 meses.

3. «la identidad volverá a ser el eje y el error más frecuente volverá a ser el ámbito amplio»

CORRECTA E INCOMPLETA, y lo que falta es lo más útil. El ámbito amplio estaba: 18 asignaciones en la organización y 140 en carpetas. Pero el hallazgo mayor fue otro: eliminar 341 claves de cuenta de servicio costó cuatro meses y NO redujo el alcance ni un punto. Quitar credenciales y reducir alcance son dos trabajos distintos, y confundirlos hace creer que el primero resuelve el segundo. Esa distinción no estaba en la predicción.

4. «los valores por defecto volverán a estar mal elegidos, y aquí fallarán sobre todo en RED»

FALLADA en la segunda mitad, y el patrón del fallo importa. Los valores por defecto de red estaban mal –la salida permitida, el selector por etiqueta–, pero los que costaron dinero de verdad fueron otros: consultar sin filtro de partición y con todas las columnas, 4.100 €/mes; activar la auditoría de acceso a datos en todo, *6 la factura de registros; el indexado automático de documentos; la concurrencia; y una suscripción abandonada reteniendo 41 millones de mensajes. Es la SEGUNDA VEZ que fallamos en dónde fallarán los valores por defecto: en la clase 228 predijimos identidad para Azure y era coste y observabilidad; aquí predijimos red y era analítica y auditoría. El patrón que no habíamos visto es que los valores por defecto caros están donde se factura por uso, no donde la nube es característica.

5. «los problemas serán otra vez de las leyes 25, 15 y 22. Lo refutable: la proporción de hallazgos que detecte una comprobación automática y periódica será MAYOR que en las partes 17 y 18»

CORRECTA, y medible. En esta parte, las comprobaciones automáticas detectaron: 4 proyectos con zonas sin asociar, 23 casos de deriva, 74 despliegues que incumplían política, 190 accesos no identificados que

cruzaban el perímetro, 5 caminos de ataque y 5 técnicas no detectadas. Frente a las partes anteriores, donde casi todo lo grave lo encontraron inventarios o facturas. PERO el matiz cualitativo se mantiene: los tres hallazgos más graves de esta parte –el almacén público de 19 meses, la suscripción de 41 millones de mensajes y las 41 personas con acceso a datos personales– los encontraron un inventario, una factura y otro inventario. Las comprobaciones detectan más cosas; las peores siguen apareciendo al mirar.

Marcador: tres correctas, una incompleta, una fallada.

3. Recuento de leyes, ley 28 e hipótesis de la parte 20

El recuento de leyes, cerrada la parte 19.

ley 13	lo que no se mira deja de funcionar en silencio	55
ley 15	la señal existe y nadie la mira	44
ley 22	un procedimiento nunca ejecutado no funciona	39
ley 14	el coste se decide al crear, no al pagar	34
ley 16	un control que estorba se rodea	32
ley 20	lo que no tiene dueño se filtra y se desperdicia	31
ley 21	el acoplamiento vive en quién escribe	25
ley 25	lo provisional sobrevive a su motivo	24
ley 26	el valor por defecto sirve a la demostración	19
ley 23	la capacidad la limita lo que ya se mantiene	19
ley 24	lo que no está en el diagrama no se analiza	13
ley 17	se optimiza la medida, no el objetivo	13
ley 19	la compensación hace invisible el fallo	10
ley 27	un control solo actúa sobre lo que cambia	9
ley 18	lo asíncrono traslada la garantía, no la elimina	9

Y la parte 19 obliga a escribir la ley que explica el fallo de la predicción 4:

LEY 28

donde se paga por uso, cada valor por defecto es una factura; y nadie lo revisa porque no parece una decisión

apariciones en esta parte	5
clase 236	consultar sin filtro de partición y con todas las columnas: 4.100 €/mes en tres paneles
clase 238	auditoría de acceso a datos activada en todo: la factura de registros x6
clase 237	una suscripción sin consumidor reteniendo 41 M de mensajes: 1.520 €/mes de almacenamiento
clase 235	indexado automático de todos los campos de un documento
clase 233	conurrencia 1 por instancia: 2.900 €/mes

y lo que la distingue de la ley 26

la 26 dice que el valor inicial está elegido para que la demostración funcione

la 28 dice DÓNDE duele: en los servicios que facturan por uso, un valor por defecto no es una configuración: es una decisión de gasto continuo

→ y por eso pasa desapercibida: nadie revisa una casilla de un asistente pensando en la factura del año que viene

ley 14

La hipótesis de la parte 20 (clases 241 a 252, plataformas de datos e IA), escrita antes de estudiarla:

1. la parte 20 volverá a demostrar lo de la clase 175: en las cargas de datos e IA el problema dominante no será el modelo ni el cómputo, será el DATO –su origen, su permiso, su forma y quién lo escribe–; y las leyes dominantes serán la 21 y la 14
2. de todo lo que se monte, lo que más problemas producirá no será entrenar ni servir modelos, sino la ORQUESTACIÓN y la calidad: trabajos que fallan sin que nadie los mire y datos que llegan mal sin que nada lo detecte

leyes 13, 15

3. los contratos de datos fracasarán por la misma razón que los controles: si publicar un dato con contrato cuesta más que publicarlo sin él, se publicará sin él ley 16
4. en la parte de IA, la evaluación será lo que más se omita: se medirá la calidad del modelo en el laboratorio y no en producción, y la deriva se descubrirá por una queja, no por una señal ley 22
5. y una refutable con cifra: **el coste de las cargas de IA estará dominado por la inferencia y no por el entrenamiento, en una proporción de al menos tres a uno**;
y dentro de la inferencia, por peticiones que no necesitaban un modelo

Y el cierre de la parte 19: de once clases, los tres hallazgos más graves los encontraron un inventario, una factura y otro inventario, y ninguno una alerta. La parte 20 sube una capa —a las plataformas de datos e inteligencia artificial, por encima de cualquier proveedor concreto— y empieza por la arquitectura de datos y sus contratos. Es la clase 241.

4. Comparar las tres nubes

Con el mismo sistema montado tres veces, se pueden defender conclusiones.

LO QUE RESULTÓ EQUIVALENTE EN LAS TRES

el techo de disponibilidad y su aritmética	clase 185
la teoría de colas y la concurrencia	clase 186
la consistencia decidida por operación	clase 187
la idempotencia y los mensajes fallidos	clase 210
el despliegue escalonado con vuelta atrás	
la estructura del código por ciclo de vida	
el orden de implantar un control: medir, avisar, aplicar	
y las pruebas negativas, una a una	

LO QUE NO

el modelo de gobierno y su alcance	
el modelo de permisos y sus ámbitos	
la red: regional frente a global	
la observabilidad y qué viene activado	
y lo que cada una factura por uso	ley 28

Y la comparación medida:

p99 del flujo de compra	412 ms	438 ms	395 ms
disponibilidad observada	99,86 %	99,84 %	99,88 %
coste mensual	16.700 €	17.400 €	15.900 €
coste por pedido	0,046 €	0,051 €	0,044 €
valores por defecto cambiados	24	19	21
pruebas negativas fallidas	7/19	8/19	6/20
tiempo hasta producción	9 semanas	7 semanas	6 semanas
líneas de infraestructura	~4.100	~3.800	~3.400
conmutación de región	12 min 40	10 min 40	8 min 15
equipo dedicado	2,1	2,4	1,9

Y las cuatro conclusiones que se pueden defender:

- 1 EL COSTE DE UN SISTEMA EQUIVALENTE ES PARECIDO
la diferencia entre la más cara y la más barata es del 9 %, dentro de lo que cambia una decisión de diseño
→ elegir nube por precio de lista es un error
clases 216, 228
- 2 EL TIEMPO HASTA PRODUCCIÓN BAJA CON CADA REPETICIÓN
9, 7 y 6 semanas
→ y no por la nube: por el método
→ lo que se traslada bien es el ORDEN, no la configuración
- 3 LO QUE MÁS DIFIERE ES LO QUE MÁS CUESTA APRENDER
el modelo operativo: gobierno, permisos, red y observabilidad
→ tres meses en cada nube nueva
→ y ese es el coste real de la multinube clase 157
- 4 EL ERROR DOMINANTE AL AÑADIR UNA NUBE NO ES LA

- cinco casos documentados en esta parte
- y la contramedida es un procedimiento, no un curso:
al empezar con un servicio, comprobar explícitamente
qué se hereda, qué viene activado y qué se propaga

- 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
- los perímetros están simulados un ciclo completo
- las 20 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 %
- hay comparación con las otras nubes, con cifras
- está escrito lo que no se hace

Ejemplo trabajado

La lista de valores por defecto cambiados:

Multi-Cloud Engineering Program · Parte 19 · Google Cloud: arquitectura de datos y operación en producción

Las veinte pruebas negativas: seis fallaron.

✓ crear recurso sin etiquetas	rechazado
✓ crear clave de cuenta de servicio	rechazado
✓ suplantar sin permiso	denegado
X acceder fuera de una condición de recurso	
→ 2 de 11 servicios ignoraban la condición	clase 230
✓ activar papel privilegiado sin aprobación	denegado
✓ acceso de emergencia	90 s
X resolver nombre con conexión privada desde cada proyecto	
→ 3 proyectos creados el mes anterior sin zonas asociadas: la automatización llegó después	ley 27
✓ sacar datos a otra organización	perímetro lo impide
✓ desplegar incumpliendo política	falla en validación
✓ borrar el estado y restaurarlo	4 min
X plan sin cambios, vacío	
→ 6 recursos con deriva permanente por campos que la plataforma ajusta; marcados para ignorar	
✓ escribir con clave secuencial	reparto correcto
✓ consultar sin filtro de partición	rechazado
X consultar columna sensible sin etiqueta	
→ 1 vista materializada creada antes del etiquetado exponía la columna sin control	ley 27
✓ mismo mensaje 50 veces	1 efecto
✓ mensaje en tema de fallidos → alerta	38 s
✓ identidad desde otro espacio de nombres	denegado
X perder una región	
→ 8 min 15 s, dentro de lo previsto, pero la clave de cifrado propia vivía en una sola región y 2 almacenes quedaron inaccesibles	clase 239
X provocar la condición de cada alerta	
→ 7 de 45 no llegaron; 4 por umbral, 2 por destino y 1 por objetivo medido en el servidor	clase 238
✓ desplegar el entorno de cero	61 min

Y el análisis de las seis:

tres por la ley 27: recursos creados antes de que existiera la comprobación o el etiquetado que los cubriría
dos por controles que no cubrían lo que se creía (condiciones ignoradas por 2 servicios, alerta con el indicador en el sitio equivocado)
una por una dependencia no contada en el cálculo (la región de la clave de cifrado)

→ y el diagnóstico es el mismo de las clases 216 y 228:
el sistema creció y las comprobaciones no crecieron con él
→ con el añadido de que aquí ya existían las comprobaciones y lo que faltó fue ejecutarlas sobre lo creado después

Las cifras del sistema, tras tres meses:

p99 del flujo de compra	< 500 ms	395 ms
disponibilidad observada	99,8 %	99,88 %
coste mensual	15.000 €	15.900 €
coste por pedido	0,050 €	0,044 €
conmutación de región	15 min	8 min 15
coste atribuido	90 %	95 %
alertas por turno	< 2	0,6
técnicas simuladas detectadas	> 90 %	13/14
despliegue del entorno de cero	—	61 min

La comparación final de las tres nubes, con lo que costó de verdad:

coste mensual	16.700 €	17.400 €	15.900 €
coste por pedido	0,046 €	0,051 €	0,044 €
p99 del flujo	412 ms	438 ms	395 ms
conmutación de región	12 min 40	10 min 40	8 min 15
valores por defecto cambiados	24	19	21
pruebas fallidas	7/19	8/19	6/20
tiempo hasta producción	9 semanas	7 semanas	6 semanas

meses para aprender el modelo operativo	—	3	3
equipo dedicado	2,1	2,4	1,9

Y OPERAR LAS TRES A LA VEZ

equipo dedicado sumado	6,4
equipo real necesario	7,8

→ un 22 % más que la suma, por los cambios de contexto y por mantener tres modelos operativos al día

clase 157

Y las decisiones que se tomaron con esta comparación:

no migrar nada entre nubes: los tres sistemas funcionan
 no operar los tres a la vez para la misma carga
 → CloudShop mantiene AWS como principal, Azure por el contrato corporativo y Google para las cargas de datos y de IA

clase 157

y el criterio escrito
 «cada nube por un motivo declarado; ninguna por preferencia»

La lección que este proyecto deja: veintidós valores por defecto cambiados, todos los cuales funcionaban, y los cinco más caros estaban en servicios que facturan por uso. De las seis pruebas negativas fallidas, tres fueron por recursos creados después de que existiera la comprobación. Y comparando las tres nubes con el mismo sistema montado bien, la diferencia de coste es del nueve por ciento: la nube no decide el coste; lo deciden las decisiones de diseño y los valores por defecto que nadie revisa.

Laboratorio guiado

Ejecuta desde la raíz:

```
python classes/part-19-gcp-production-architecture/240-proyecto-cloudshop-productivo-en-google-cloud/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-gcp 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-gcp 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
Al añadir una nube nueva fallan cosas que en las anteriores funcionaban	Se trasladaron suposiciones del modelo operativo anterior	Al empezar con cada servicio, comprueba explícitamente qué se hereda, qué viene activado y qué se propaga; es un procedimiento, no un curso.
Los valores por defecto caros pasan desapercibidos	En los servicios que facturan por uso, un valor por defecto es una decisión de gasto que no parece una decisión	Revisa primero los valores por defecto de todo lo que se factura por uso, y estima su coste antes de aceptar el asistente.
Las comprobaciones pasan y aparecen huecos en lo creado después	La automatización llegó más tarde que los recursos	Toda automatización nueva se acompaña de una tarea de remediación y de una comprobación periódica sobre lo existente.
Se elige nube comparando precios de lista	El coste lo deciden el diseño y los valores por defecto, no el proveedor	Compara el coste del mismo sistema montado bien; la diferencia suele estar dentro del ruido.
Operar varias nubes consume más equipo que la suma de las partes	Se cuentan las tecnologías y no los modelos operativos ni los cambios de contexto	Justifica cada nube por un motivo declarado y cuenta el coste operativo real, que es superior a la suma.
Una clave de cifrado propia deja datos inaccesibles al perder una región	La clave vive en una región y no entró en el cálculo del techo	Replica la clave y cuenta su disponibilidad como una dependencia dura más.

■ 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 228 falló y qué patrón revela su fallo?
2. ¿Qué dice la ley 28 y en qué se distingue de la ley 26?
3. ¿Qué distinción faltaba en la predicción sobre identidad?
4. ¿Qué resultó equivalente entre las tres nubes y qué no?
5. ¿Por qué operar tres nubes cuesta más que la suma de operar cada una?

Referencias

- Google Cloud (2025). Architecture Framework. <<https://cloud.google.com/architecture/framework>>
- Google Cloud (2025). Enterprise foundations blueprint. <<https://cloud.google.com/architecture/security-foundations>>
- Google Cloud (2025). Landing zone design. <<https://cloud.google.com/architecture/landing-zones>>
- Beyer, B. y otros (2018). The Site Reliability Workbook. <<https://sre.google/workbook/table-of-contents/>>
- Forsgren, N. y otros (2018). Accelerate — medir antes y después con las mismas definiciones. <<https://itrevolution.com/product/accelerate/>>
- Documentación oficial vigente del servicio implementado; registra URL y fecha de consulta.

Descargar: Parte 19 en PDF · Recorrido de Google Cloud en PDF · Manual integral

Anterior	Índice	Siguiente
← 239 · SCC, VPC Service Controls, KMS y FinOps	Parte 19 · Programa	241 · Lakehouse, warehouse, mesh y contratos de datos →

Evaluación — 240 Proyecto: CloudShop productivo en Google Cloud

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-gcp 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.