



Guía de tenencia múltiple para ISVs ejecutar bases de datos de Amazon Neptune

AWS Guía prescriptiva



AWS Guía prescriptiva: Guía de tenencia múltiple para ISVs ejecutar bases de datos de Amazon Neptune

Copyright © 2026 Amazon Web Services, Inc. and/or its affiliates. All rights reserved.

Las marcas comerciales y la imagen comercial de Amazon no se pueden utilizar en relación con ningún producto o servicio que no sea de Amazon, de ninguna manera que pueda causar confusión entre los clientes y que menosprecie o desacredite a Amazon. Todas las demás marcas registradas que no son propiedad de Amazon son propiedad de sus respectivos propietarios, que pueden o no estar afiliados, conectados o patrocinados por Amazon.

Table of Contents

Introducción	1
Modelos de particionamiento de datos	3
Modelo silo	5
Clúster por inquilino	5
Guía de implementación del modelo de silo	7
Modelo de grupo	9
Modelo de piscina para LPGs	10
Estrategia inmobiliaria	10
Estrategia de etiquetas con prefijo	13
Estrategia de etiquetas múltiples	15
Implicaciones de rendimiento para los modelos de GLP	18
Modelo de piscina para RDF	19
Opciones de consulta de SPARQL mediante el protocolo HTTP Graph Store	20
Aislamiento de inquilinos para RDF	20
Prepárese para el crecimiento	21
Limitaciones de los escenarios de tenencia múltiple	22
Modelo híbrido	23
Prácticas recomendadas	24
Actualiza tu cúmulo de Neptune con las versiones más recientes	24
Use deltas en lugar de eliminar y reemplazar para la ingesta de datos	24
Demuestre cómo evolucionarán los costos de Neptune con sus inquilinos	25
Amplíe sus clústeres según la demanda de los clientes	25
Siguientes pasos	27
Recursos	28
Colaboradores	29
Historial de documentos	30
Glosario	31
#	31
A	32
B	35
C	37
D	40
E	45
F	47

G	49
H	50
I	51
L	54
M	55
O	60
P	62
Q	65
R	66
S	69
T	73
U	74
V	75
W	75
Z	77
.....	lxxviii

Guía de tenencia múltiple para ISVs ejecutar bases de datos de Amazon Neptune

Amazon Web Services ([colaboradores](#))

Agosto de 2024 (historial [del documento](#))

La multitenencia es una arquitectura de sistemas informáticos en la que una sola instancia de una aplicación sirve a varios clientes. Cada cliente se denomina inquilino. En una arquitectura de varios inquilinos, estas instancias de la aplicación funcionan en un entorno compartido en el que cada inquilino está ubicado físicamente en la misma infraestructura, pero separados de forma lógica.

Como proveedor de software independiente (ISV), puede usar Amazon Neptune para impulsar aplicaciones que requieren navegación a través de datos altamente conectados. Es posible que esté administrando una aplicación de software como servicio (SaaS) basada en la nube en su cuenta y proporcionando suscripciones a los inquilinos. Luego, los inquilinos pueden acceder al servicio a través de Internet o de forma privada. AWS PrivateLink La economía de este modelo funciona para ambas partes, ya que el inquilino tiene acceso a un software que es más económico de lo que le costaría comprar, construir y mantener. Como proveedor independiente de software, puede cobrar más por la suscripción de lo que cuesta crear y mantener el software. La pregunta es cómo puede ampliar su negocio a varios inquilinos.

La multitenencia ofrece ISVs importantes beneficios económicos y operativos. La arquitectura multiusuario proporciona a su organización un mejor retorno de la inversión (ROI). La multitenencia también simplifica los requisitos operativos para que su organización pueda avanzar con mayor rapidez y reducir el costo de entregar el software a sus inquilinos.

Este documento proporciona orientación sobre la ejecución eficaz de una aplicación ISV multiusuario mediante Amazon Neptune. Esta guía se basa en las mejores prácticas adquiridas durante años respaldando ISVs la entrega exitosa de soluciones SaaS a sus clientes. La evaluación de esta guía en el contexto de los objetivos y los principios arquitectónicos de su organización le ayudará a encontrar formas de optimizar su solución.

Note

Este documento no proporciona una lista exhaustiva de las mejores prácticas. Complementa el documento Applying [the AWS Well-Architected Framework for Amazon Neptune](#) al

proporcionar orientación específica adicional para las cargas de trabajo de ISV de varios arrendatarios. Recomendamos revisar las consideraciones de ambos documentos al diseñar la solución.

Modelos de particionamiento de datos de SaaS

Uno de los desafíos para los desarrolladores de SaaS es diseñar patrones arquitectónicos para representar y organizar datos en un entorno multiinquilino. [Estos mecanismos y patrones de almacenamiento multiusuario suelen denominarse particionamiento de datos.](#)

[En un entorno SaaS multiusuario, es importante distinguir entre la partición de datos y el aislamiento de inquilinos.](#) Estos conceptos, si bien están relacionados, no son sinónimos. El particionamiento de datos se refiere al método de almacenamiento de los datos de cada inquilino. Sin embargo, la división por sí sola no garantiza el aislamiento de los inquilinos. Se necesitan medidas adicionales para garantizar que los datos de un inquilino permanezcan inaccesibles para otro.

Los tres modelos comunes de particionamiento de datos en los sistemas [SaaS multiusuario](#) [son silos](#), agrupados e híbridos. La elección de cualquier modelo depende de factores como los siguientes:

- Conformidad
- [Vecinos ruidosos](#)
- Estrategia de niveles
- Requisitos operativos
- Necesidades de aislamiento de los inquilinos

Además, cada tipo de base de datos disponible en AWS normalmente ofrece una colección única de modelos de partición de datos y aislamiento de inquilinos. Al analizar cómo se pueden organizar los gráficos de inquilinos para satisfacer las diversas necesidades de su solución, tenga en cuenta los modelos que proporciona Amazon Neptune.

Muchos ISVs comienzan su diseño en Neptune con una de las siguientes afirmaciones:

- La ISV solución requiere la separación física de los clientes en clústeres separados.
- La ISV solución requiere construcciones como bases de datos con nombre o esquemas que se encuentran en los sistemas tradicionales de administración de bases de datos relacionales.

Tras considerarlo, tenga en ISVs cuenta que estas afirmaciones no son ciertas porque, en casi todas las cargas de trabajo, cada uno de sus clientes tiene un gráfico desconectado en su base de datos.

La implementación de la guía de acceso y modelado de datos que se describe en este documento evita que se crucen esos límites de datos y mantiene la privacidad de los datos de los clientes.

Esta guía describe tanto el modelo de [silo como el modelo](#) de [piscina](#), pero la mayoría ISVs elige el modelo de piscina por su rentabilidad y eficiencia operativa. La guía analiza brevemente un modelo híbrido que combina aspectos de los modelos de silo y piscina. Algunos ISVs utilizan un modelo híbrido para sus clientes más importantes a fin de adaptarse a los requisitos normativos o de cumplimiento del tamaño de un gráfico.

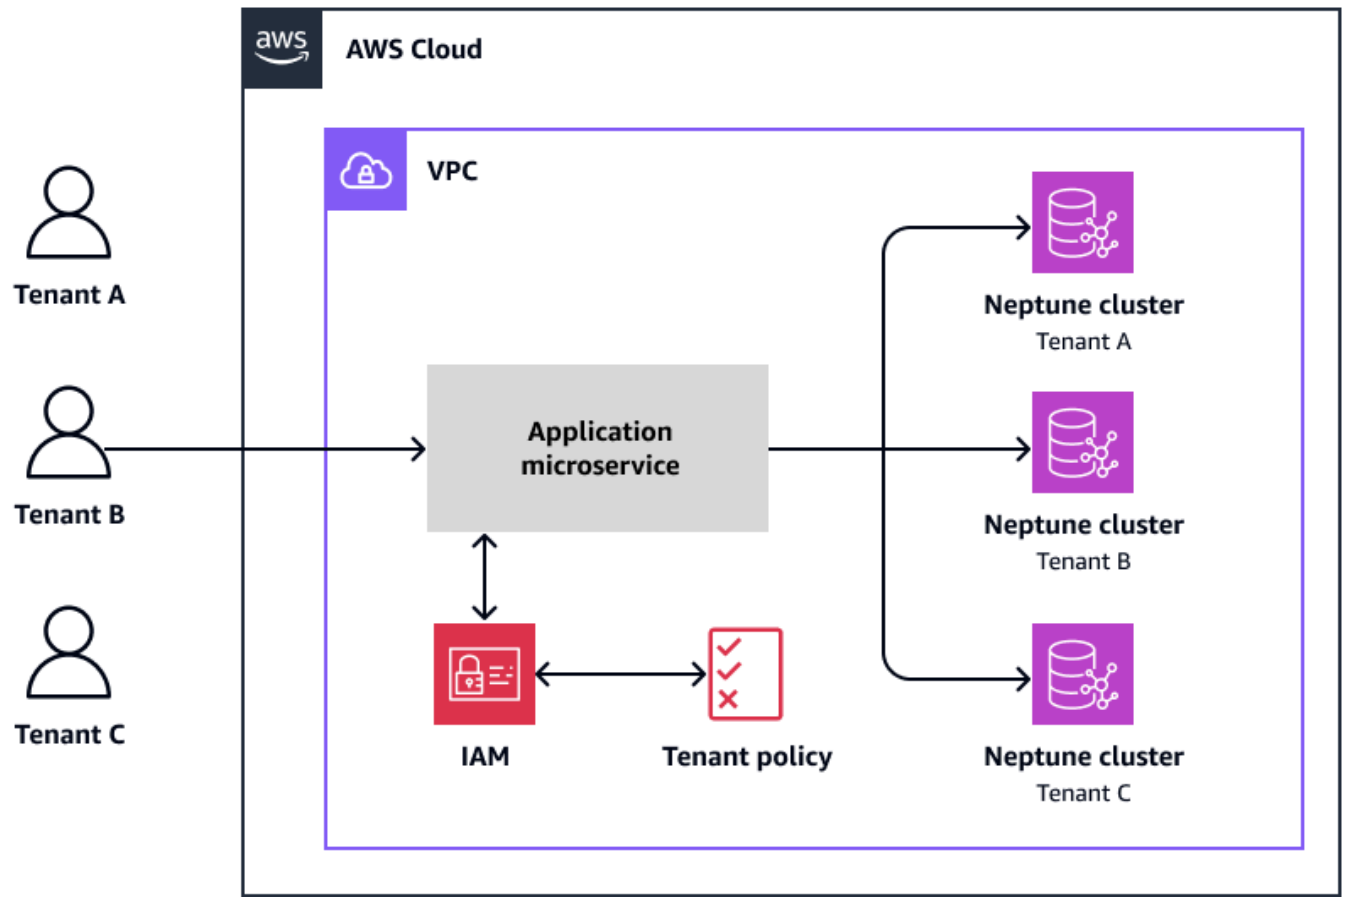
Modelo silo multiinquilino

Algunos entornos SaaS multiusuario pueden requerir que los datos de los inquilinos se desplieguen en recursos completamente separados debido a los requisitos normativos y de cumplimiento. En algunos casos, los grandes clientes necesitan clústeres dedicados para reducir el impacto del ruido en los vecinos. En esas situaciones, puede aplicar el modelo de silo.

En el modelo de silo, el almacenamiento de los datos de los inquilinos está completamente aislado de cualquier otro dato de los inquilinos. Todas las estructuras que se utilizan para representar los datos del arrendatario se consideran exclusivas de ese cliente desde el punto de vista físico, lo que significa que cada arrendatario, por lo general, dispondrá de un almacenamiento, una supervisión y una gestión diferenciados. Cada inquilino también tendrá una clave AWS Key Management Service (AWS KMS) independiente para el cifrado. En Amazon Neptune, un silo es un clúster por inquilino.

Clúster por inquilino

Puede implementar un modelo de silo con Neptune si tiene un inquilino por clúster. El siguiente diagrama muestra a tres inquilinos que acceden a un microservicio de aplicaciones en una nube privada virtual (VPC), con un clúster independiente para cada inquilino.



Cada clúster tiene su [punto final individual](#) para ayudar a garantizar puntos de acceso distintos para una gestión e interacción de datos eficientes. Al colocar a cada inquilino en su propio clúster, se crea un límite bien definido entre los inquilinos, lo que garantiza a los clientes que sus datos se aíslan correctamente de los datos de otros inquilinos. Este aislamiento también es atractivo para las soluciones SaaS que tienen estrictas restricciones regulatorias y de seguridad. Además, cuando cada inquilino tiene su propio clúster, no tiene que preocuparse por el ruido de un vecino, ya que uno de los inquilinos impone una carga que podría afectar negativamente a la experiencia de los demás inquilinos.

Si bien el modelo de cluster-per-tenant silos tiene ventajas, también presenta desafíos de gestión y agilidad. La naturaleza distribuida de este modelo hace que sea más difícil agregar y evaluar la actividad de los inquilinos y el estado operativo de todos los inquilinos. La implementación también se vuelve más difícil porque la configuración de un nuevo inquilino ahora requiere el aprovisionamiento de un clúster independiente. La actualización se hace más difícil en entornos con una capa de clientes compartida cuando las actualizaciones y versiones de los clientes están estrechamente vinculadas a la actualización de la base de datos.

Neptune admite clústeres aprovisionados y [sin servidor](#). Evalúe si la carga de trabajo de su aplicación se gestiona mejor con instancias aprovisionadas o sin servidor. En general, si su carga de trabajo tiene un nivel de demanda constante, las instancias aprovisionadas serán más rentables. La tecnología Serverless está optimizada para cargas de trabajo exigentes y muy variables, con un uso intensivo de las bases de datos durante períodos cortos, seguidos de períodos prolongados de actividad ligera o nula.

Cuando utilices un clúster aprovisionado por Neptune por inquilino, debes seleccionar un tamaño de instancia que se aproxime a la carga máxima de la demanda de tu inquilino. Esta dependencia de un servidor también tiene un impacto en cascada en la eficiencia de escalado y el costo de su entorno SaaS. Si bien el objetivo del SaaS es dimensionar el tamaño de forma dinámica en función de la carga real de los inquilinos, un clúster aprovisionado por Neptune requiere un aprovisionamiento excesivo para tener en cuenta los períodos de uso más intensos y los picos de carga. El aprovisionamiento excesivo aumenta el coste por inquilino. Además, dado que el uso de los inquilinos cambia con el tiempo, la ampliación o reducción del clúster debe aplicarse por separado para cada inquilino.

El equipo de Neptune generalmente desaconseja un modelo de silo debido al mayor costo que representan los recursos inactivos y a las complejidades operativas adicionales. Sin embargo, en el caso de cargas de trabajo delicadas o muy reguladas que requieran este aislamiento adicional, los clientes podrían estar dispuestos a pagar el coste adicional.

Guía de implementación del modelo de silo

[Para implementar un modelo de cluster-per-tenant aislamiento de silos, cree políticas de acceso a los datos AWS Identity and Access Management \(IAM\)](#). Estas políticas controlan el acceso a los clústeres de Neptune de los inquilinos al garantizar que los inquilinos solo puedan acceder al clúster de Neptune que contiene sus propios datos. Adjunte la política de IAM de cada inquilino a una función de IAM. A continuación, el microservicio de la aplicación utiliza la función de IAM para generar [credenciales temporales](#) detalladas mediante el método de `()`. `AssumeRole` AWS Security Token Service AWS STS Estas credenciales, que solo tienen acceso al clúster de Neptune de ese inquilino, se utilizan para conectarse al clúster de Neptune del inquilino.

El siguiente fragmento de código muestra un ejemplo de política de IAM basada en datos:

```
{
  "Version": "2012-10-17",
  "Statement": [
```

```
{
  "Effect": "Allow",
  "Action": [
    "neptune-db:ReadDataViaQuery",
    "neptune-db:WriteDataViaQuery"
  ],
  "Resource": "arn:aws:neptune-db:us-east-1:123456789012:tenant-1-cluster/*",
  "Condition": {
    "ArnEquals": {
      "aws:PrincipalArn": "arn:aws:iam::123456789012:role/tenant-role-1"
    }
  }
}
```

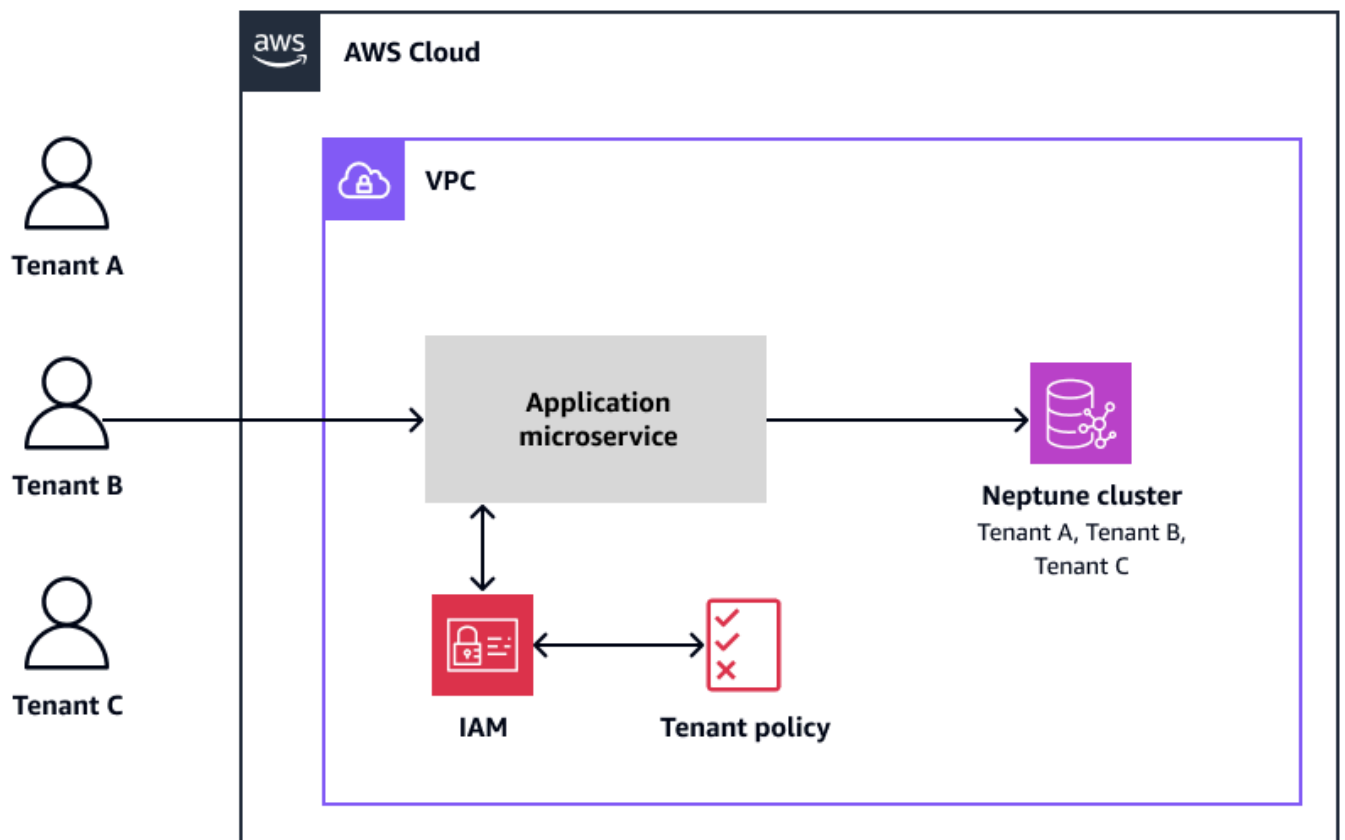
El código proporciona un ejemplo de `inquilino-tenant-1`, con acceso de consulta de lectura y escritura a su respectivo clúster de Neptune. El `Condition` elemento garantiza que solo la entidad que realiza la llamada (la principal), que ha asumido la función de `tenant-1 IAM (tenant-role-1)`, pueda acceder al clúster `tenant-1` de Neptune.

Multiarrendamiento modelo piscina

A veces, no es necesario o factible implementar el modelo de silo debido a los costos o a los gastos operativos:

- Es posible que no tenga los recursos para mantener un clúster individual por inquilino.
- Puede que no sea necesario separar físicamente los datos de cada inquilino, y una separación lógica es suficiente para satisfacer sus necesidades y requisitos de conformidad.

El siguiente diagrama muestra el modelo de grupo, en el que los datos de los inquilinos se colocan en un único clúster de Amazon Neptune y todos los inquilinos comparten una base de datos común.



Este [modelo de aislamiento](#) de grupos reduce la sobrecarga de administración y puede mejorar la eficiencia operativa porque hay menos clústeres que administrar. Además, los recursos informáticos se pueden compartir entre varios clientes en lugar de permanecer inactivos durante los períodos de inactividad de los clientes.

Cuando se utiliza el modelo de grupo, hay dos formas de modelar los datos. Su enfoque depende de si está creando un [gráfico de propiedades etiquetadas \(LPG\)](#) o un gráfico con el [marco de descripción de recursos \(RDF\)](#).

Modelo de conjunto para gráficos de propiedades etiquetadas

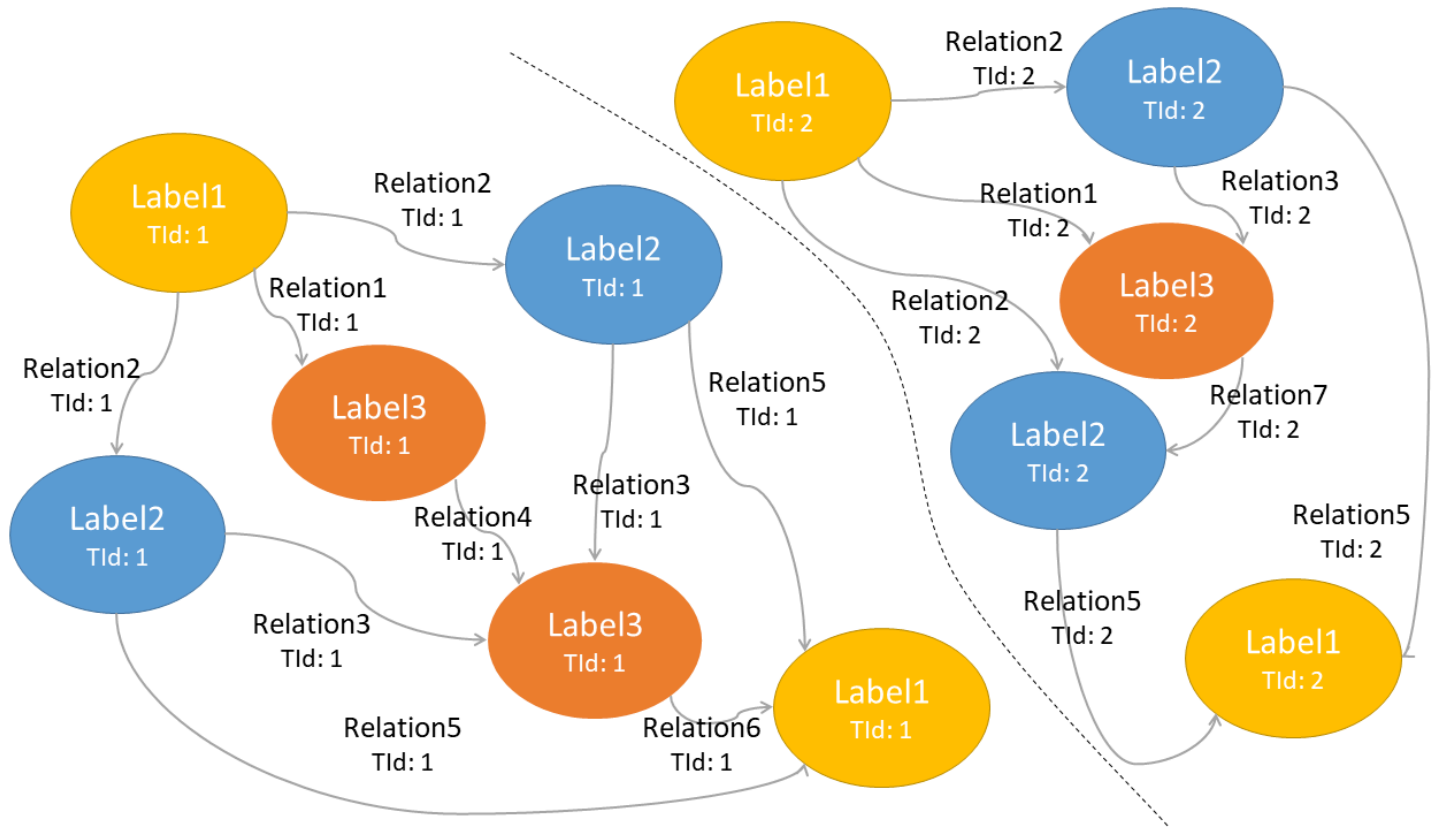
Existen tres enfoques diferentes del modelo de piscina para LPGs Amazon Neptune:

- Estrategia de propiedades: elija la estrategia de propiedades cuando necesite priorizar el uso de componentes de biblioteca establecidos, como el lenguaje Apache TinkerPop Gremlin, por encima del rendimiento. [PartitionStrategy](#)
- Estrategia de etiquetas de prefijo: recomendamos la estrategia de etiquetas de prefijo para la mayoría de los escenarios, en función del rendimiento y la limitación de los efectos de proximidad ruidosa.
- Estrategia de etiquetas múltiples: la estrategia de etiquetas múltiples tiene el rendimiento mejorado de la estrategia de etiquetas de prefijo. También permite ejecutar consultas que abarquen a todos los inquilinos de un clúster (por ejemplo, consultas ISV para generar informes o supervisar a todos los inquilinos).

Estrategia inmobiliaria

Con ella LPGs, los usuarios pueden añadir propiedades de pares clave-valor a los nodos, vértices y aristas. Para lograr una separación lógica, la mayoría de los clientes la modelan intuitivamente como una propiedad única en cada nodo y periferia con una clave de propiedad arrendataria común. La clave de propiedad del inquilino representa a todos los inquilinos propietarios del nodo. El identificador del inquilino es un valor único que identifica a un inquilino individual.

El siguiente diagrama muestra este modelo. Los dos subgrafos desconectados tienen varios nodos y aristas etiquetados, con la clave de propiedad del inquilino representada por TId. Cada nodo y borde de un subgrafo tiene un TId valor de. 1 En el otro subgrafo, cada nodo y borde tiene un TId valor de. 2



En los gráficos de propiedades etiquetadas, hay dos formas de gestionar esto. El lenguaje de consultas Gremlin ofrece la biblioteca [PartitionStrategy](#) transversal para ayudar a gestionar el particionamiento de los datos. El código del siguiente ejemplo espera que cada nodo y borde tenga una propiedad llamada: TId

```
strategy1 = new PartitionStrategy(partitionKey: "TId", writePartition: "1",
  readPartitions: ["1"])
strategy2 = new PartitionStrategy(partitionKey: "TId", writePartition: "2",
  readPartitions: ["2"])
```

Cuando se escriben nuevos nodos o aristas, la propiedad "TId" se añade con un valor de "1" o "2", en función de si `strategy2` se ha seleccionado `strategy1` o no. Para el cliente con "TId" o "1", usa `strategy1`. En el siguiente ejemplo, se muestran los datos de escritura para ese cliente:

```
g.withStrategies(strategy1).addV("Label1").property("Value", "123456").property(id,
  "Item_1")
```

En el caso de las consultas de lectura, "TId == '2'" se añade "TId == '1'" o se añade un filtro para cada recorrido de nodo o borde mediante `strategy1` o `strategy2`, respectivamente.

Estas estrategias de partición simplifican el código, pero no son necesarias. La ventaja de usar la estrategia es que se puede inyectar en un nivel de autorización y pasarla al código de nivel inferior que forma la consulta. Esto separa el código que determina el identificador del cliente (TId) de la lógica de la consulta.

El siguiente código de ejemplo muestra una consulta de Gremlin para leer datos:

```
g.withStrategies(strategy1).V().hasLabel("Label1")
```

El código anterior equivale al siguiente ejemplo:

```
g.V().hasLabel("Label1").has("TId", "1")
```

Del mismo modo, al escribir datos mediante Gremlin, puede utilizar la siguiente consulta:

```
g.withStrategies(strategy1).addV("Label1").property("Value").property(id, "Item_1")
```

El código anterior equivale al ejemplo siguiente, que no utiliza la estrategia de partición y, por lo tanto, requiere que la "TId" propiedad se escriba de forma explícita:

```
g.addV("Label1").property("TId", "1").property("Value").property(id, "Item_1")
```

En OpenCypher, estas bibliotecas no existen. Usted es responsable de escribir y modificar las consultas para añadir el identificador del inquilino como una propiedad en los nodos y los bordes. Por ejemplo:

```
CREATE (n:Item {`~id`: 'Item_1', Value: '123456', TId: '1'})
CREATE (n:Item {`~id`: 'Item_2', Value: '123456', TId: '2'})
```

Tenga en cuenta la similitud entre el código de Gremlin sin la estrategia de partición. A continuación, puede leer el nodo escrito a partir de la primera CREATE sentencia utilizando el siguiente código:

```
MATCH (n:Item {TId: '1'})
RETURN n
--or
MATCH (n:Item)
WHERE n.TId == '1'
```

```
RETURN n
```

Puede elegir la estrategia inmobiliaria cuando desee utilizar construcciones nativas de TinkerPop Gremlin, como. PartitionStrategy Sin embargo, este modelo presenta inconvenientes de rendimiento en Amazon Neptune en comparación con la estrategia de etiquetas de prefijo. Para obtener información sobre estos inconvenientes de rendimiento, consulte la sección [Implicaciones en el rendimiento de los modelos a GLP](#).

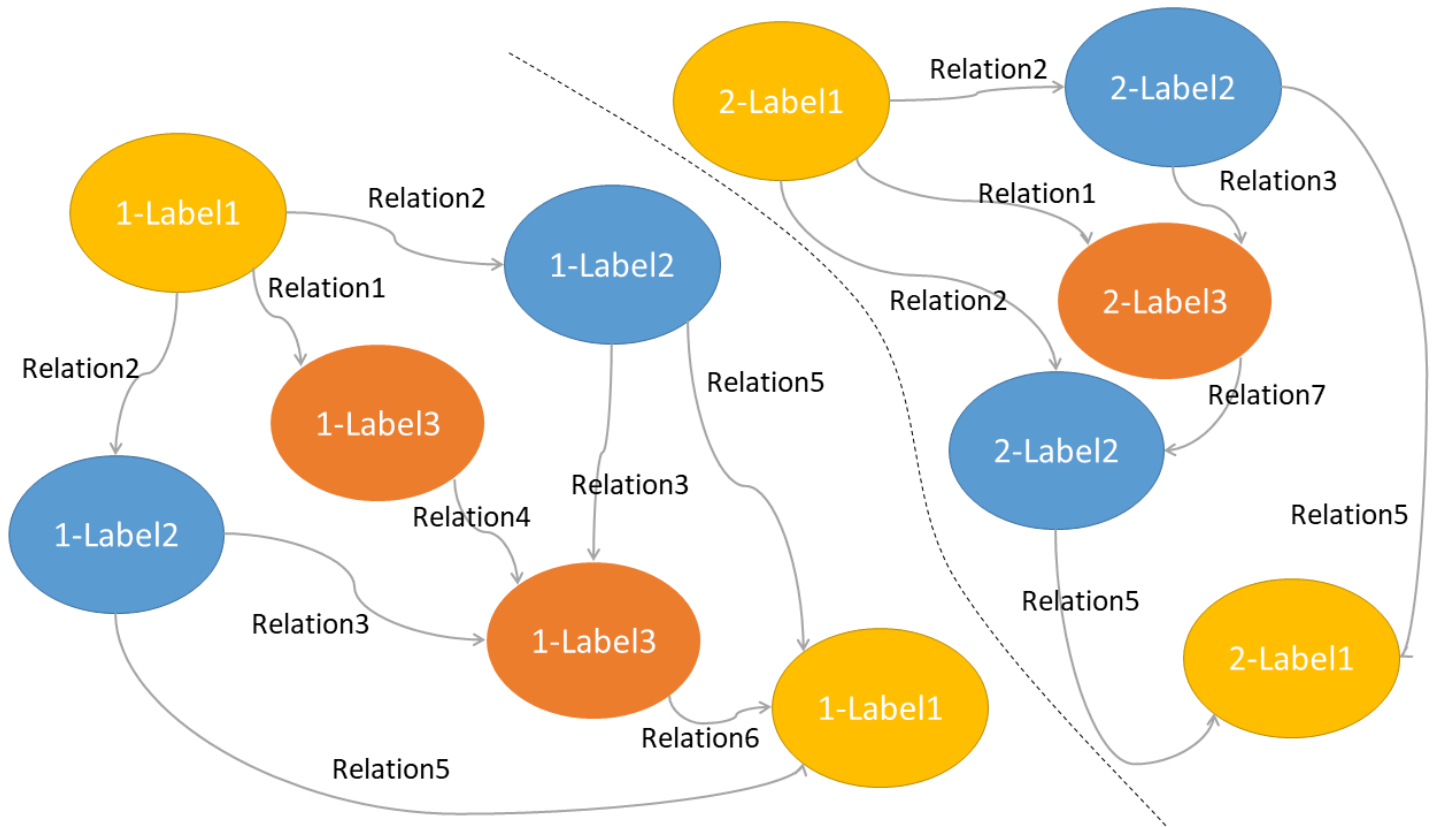
Si se cumplen las siguientes condiciones, considere la posibilidad de modelar la estrategia de propiedades solo en los nodos, no en los bordes:

- El gráfico tiene muchos más bordes que etiquetas.
- Cada inquilino es un gráfico desconectado.
- Para acceder al gráfico, solo se utilizan nodos como punto de partida, no etiquetas.

Estrategia de etiquetas con prefijo

Si el rendimiento es una de las principales preocupaciones, te recomendamos encarecidamente que consideres la estrategia de etiquetas con prefijos en lugar de la estrategia de propiedades.

En la estrategia de etiquetas de prefijo, se etiqueta cada nodo con una combinación de identificador de inquilino y etiqueta de nodo. Por ejemplo, si el inquilino tiene un identificador de "1" y la etiqueta del nodo es "Label1", especifique la etiqueta del nodo como "1-Label1" El siguiente diagrama muestra dos subgráficos desconectados que utilizan este modelo.



Al escribir datos en Gremlin, puedes añadir un número de identificación a la etiqueta de cualquier nodo:

```
g.addV("1-Label1")
g.addV("2-Label16")
```

Al consultar este gráfico, puedes comprobar la existencia de este prefijo en un nodo:

```
g.V().hasLabel("1-Label1")
```

En OpenCypher puedes escribir datos usando una sentencia: CREATE

```
CREATE (n:`1-Label1` {`~id`: 'Item_1', Value: 'XYZ123456'})
```

Para consultar los datos que escribió en OpenCypher, utilice el siguiente código:

```
MATCH n= (:`1-Label1`)
RETURN n
```

La estrategia de etiquetas de prefijo supone que todos los nodos están asignados a uno o más inquilinos y que los permisos no se asignan en el ámbito perimetral. Evite utilizar esta estrategia en las etiquetas de borde, ya que provocará una gran cantidad de predicados y tendrá un impacto negativo en el rendimiento de Neptune.

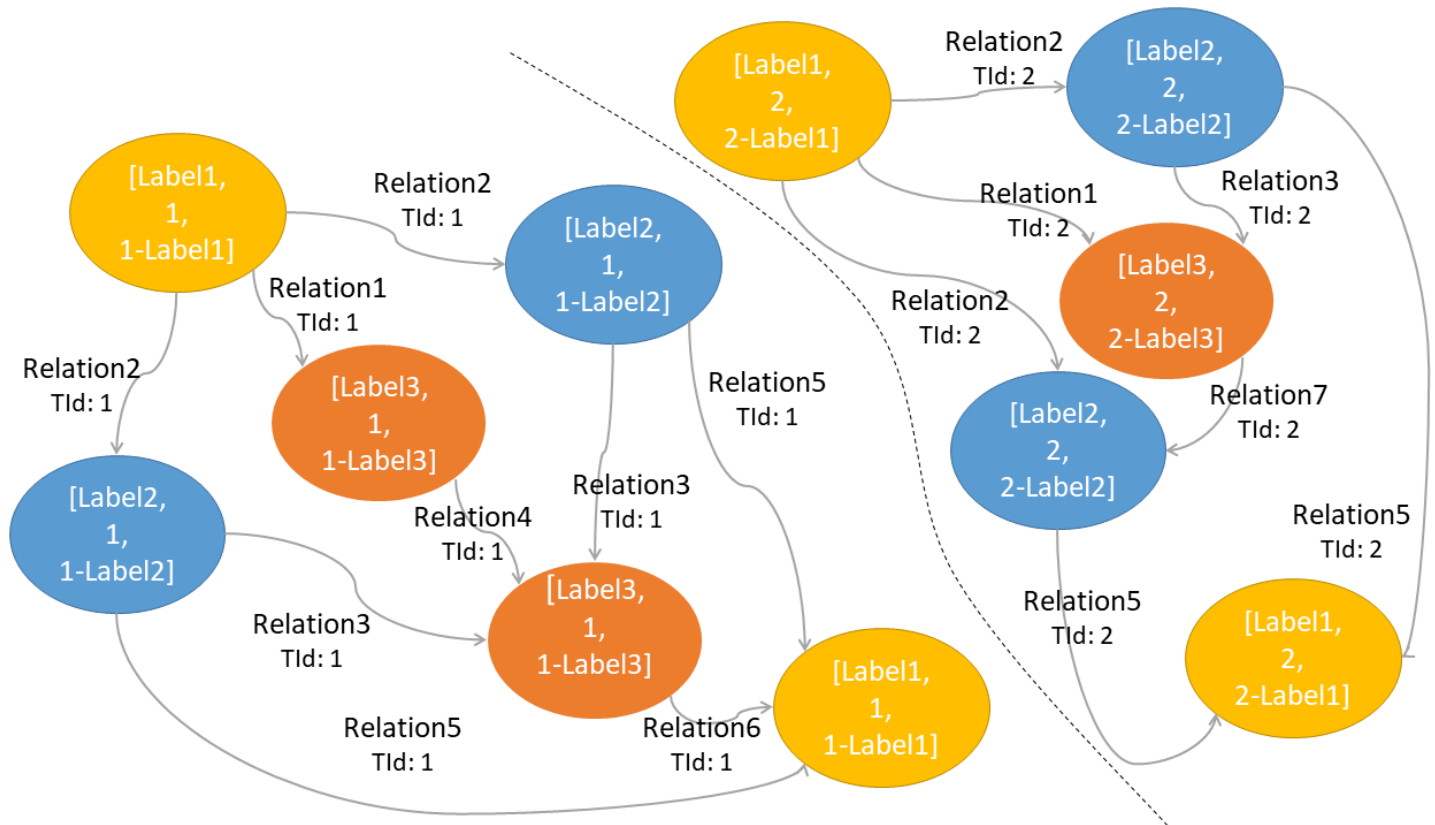
El enfoque de las etiquetas de prefijo presenta dos inconvenientes principales. En primer lugar, es difícil ejecutar consultas que abarquen a todos los inquilinos. Un ejemplo es una consulta que cuenta todos los nodos de una etiqueta determinada para la generación de informes o la supervisión. Si este es su caso de uso, considere la posibilidad de combinar esta estrategia con la estrategia de etiquetas múltiples. Para obtener más información sobre la combinación de estrategias, consulte la sección sobre [modelos híbridos](#).

En segundo lugar, la estrategia de etiquetas de prefijo requiere controles que impongan la aplicación adecuada del prefijo adecuado en cada consulta para evitar la filtración de datos. Sin embargo, esta estrategia es la opción más eficaz para las cargas de trabajo que requieren consultas de baja latencia, y la recomendamos encarecidamente. La sección [Implicaciones en el rendimiento de los modelos de GLP](#) proporciona ejemplos de por qué esta es la estrategia más eficiente.

Estrategia de etiquetas múltiples

La tercera opción es utilizar una estrategia de etiquetas múltiples. Para este enfoque, se añaden etiquetas adicionales a cada nodo del gráfico. Por ejemplo, si necesita filtrar todos los datos de un arrendatario determinado, añada la etiqueta de identificador del arrendatario. Si necesita filtrar todos los datos de una etiqueta determinada, independientemente del inquilino, añada esa etiqueta. El siguiente diagrama muestra la estrategia de etiquetas múltiples aplicada mediante el uso de tres etiquetas para cada nodo.

Ahora puede acceder al gráfico mediante tres patrones diferentes:



- Filtre para obtener todos Label1 los nodos con todos los inquilinos. Label1
- Active el filtro 1 para obtener todos los nodos del inquilino 1.
- Active el filtro 1-Label1 para mostrar todos los nodos solo para el inquilino 1 con la etiqueta Label1.

Pues LPGs, hay dos formas de implementar esto.

En Gremlin, puedes usar la estrategia transversal llamada [SubgraphStrategy](#) para limitar el alcance de todas las consultas solo a los vértices con una etiqueta específica, como: "Label1"

```
g.withStrategies(
  new SubgraphStrategy(
    vertices=hasLabel("Label1")
  )
)
```

Por el contrario PartitionStrategy, SubgraphStrategy afecta solo a la lectura de los datos, no a la escritura de los datos. Para escribir los datos, asigne manualmente las etiquetas en cada consulta:

```
g.addV("Label1").property("Value","XYZ123456")
.addV("Label2").property("Value","XYZ123456")
```

Al leer los datos, puedes utilizarlos SubgraphStrategy para consultar todos los nodos con "Label1":

```
g.withStrategies(
  new SubgraphStrategy(vertices=.hasLabel("Label1"))
).
V().has("Value","XYZ123456")
```

Neptune devuelve solo el primer registro, que tiene "Label1" un valor de "XYZ123456" Es equivalente a la siguiente consulta, que no utiliza SubgraphStrategy:

```
g.V().hasLabel("Label1").hasValue("XYZ123456")
```

En esta consulta básica, parece que SubgraphStrategy es más compleja de usar. Tenga en cuenta que sus bibliotecas pueden proporcionar una instancia g con la estrategia ya definida. Los desarrolladores no tienen que asegurarse de aplicar los filtros adecuados:

```
def getGraphTraversal():
  return g.withStrategies(new SubgraphStrategy(vertices=.hasLabel("Label1")))

getGraphTraversal().has("Value","XYZ123456")
```

Las bibliotecas OpenCypher no tienen estas construcciones, por lo que debes crear varias etiquetas para cada nodo:

```
CREATE (n:`1`:`Label1`:`1-Label1` {`~id`: 'Item_1', Value: '12345'})
```

Al utilizar estas etiquetas para filtrar un subgrafo, puede devolver los nodos que tienen la etiqueta de cliente que busca o que comparten una relación con otro nodo que tiene esa etiqueta:

```
MATCH n=( :Label1: `1` )
// or
MATCH n=( : `1-Label1` )
```

La estrategia de etiquetas múltiples le brinda la mayor flexibilidad para consultar los nodos por tipo (Label1) o inquilino (1), o para usar la estrategia de etiquetas de prefijo, que es más eficiente, cuando el rendimiento es lo más importante (). 1-Label1

El principal inconveniente de esta estrategia es que cada etiqueta es un objeto adicional almacenado en el gráfico. Un objeto es un nodo, una arista o una propiedad de un nodo o borde interno LPGs. La velocidad de ingesta se mide y se limita a objetos por segundo, y los costes de almacenamiento dependen de la cantidad de gigabytes consumidos. Esto significa que los objetos adicionales pueden tener un impacto medible a gran escala.

Implicaciones de rendimiento para los modelos de GLP

El curso [Data Modeling for Amazon Neptune](#), de AWS Skill Builder, describe en profundidad los aspectos internos del modelo de datos de Neptune y las implicaciones del modelado, pero aquí resumiremos las consideraciones importantes para estos diseños. Considere la posibilidad de tener tres inquilinos (T1, T2, T3) en un solo cúmulo de Neptune. Estos inquilinos tienen los siguientes atributos:

- El arrendatario 1 (T1) tiene un total de 100 millones de nodos y 10 millones son del tipo Item.
- El arrendatario 2 (T2) tiene un total de 10 millones de nodos y 1 millón son del tipo Item.
- El arrendatario 3 (T3) tiene un total de 100 millones de nodos y 1 millón son del tipo Item.

Ejecute una consulta que recupere los elementos del inquilino 3 utilizando la estrategia de propiedades. Neptune inspecciona las estadísticas de dos llamadas a índices:

- ¿Dónde `tenant property key=T3` tiene 100 millones de resultados?
- ¿Dónde `label = Item` tiene 12 millones de resultados (10 millones de la T1 + 1 millón de la T2 + 1 millón de la T3)

El optimizador de consultas de Neptune determina que es mejor aplicar primero la última consulta (12 millones de resultados) y, a continuación, inspecciona cada elemento. `tenant property key=T3` Recupera 12 millones de elementos para encontrar el millón de resultados.

Observe el impacto de esta consulta en los vecinos ruidosos. Si tuviera 100 millones de nodos de Item por usuario, la primera consulta tendría 300 millones de resultados en lugar de 12 millones (esto está demasiado simplificado a efectos ilustrativos). El optimizador de Neptune puede haber aplicado un orden de operaciones diferente).

A continuación, considere la estrategia de etiquetas de prefijo. Haga una sola llamada de índice `Where label=T3-Item`, que devolverá 1 millón de resultados. Con esto se obtiene el mismo

resultado que con la estrategia inmobiliaria, pero se recuperan 11 millones de registros menos. Además, ya no tiene problemas de vecinos ruidosos porque la etiqueta no se superpone en el índice.

La estrategia de etiquetas múltiples no mejora directamente el rendimiento de las consultas en comparación con la estrategia de propiedades. Filtrar por valor de propiedad es comparable a filtrar por valor de etiqueta cuando el espacio de búsqueda también es comparable. En cambio, la estrategia de etiquetas múltiples permite una mayor flexibilidad. La estrategia de etiquetas múltiples proporciona un rendimiento equivalente al de la estrategia de etiquetas con prefijo para la etiqueta. `label=T3` `Item` La estrategia de etiquetas múltiples proporciona un rendimiento equivalente al de la estrategia de propiedades para. `label=Item` La ventaja es que admite una variedad de patrones de acceso.

Modelo de piscina para RDF

El marco de descripción de recursos (RDF) tiene un concepto de gráficos con nombre, que proporciona una forma lógica de separar los datos. En Amazon Neptune, tiene un gráfico con nombre predeterminado y gráficos con nombre definidos por el usuario. Puede crear tantos gráficos con nombre como desee. En conjunto, se denominan conjunto de datos RDF. Todos los gráficos con nombre, predeterminados o definidos por el usuario, se definen mediante un identificador de recursos internacionalizado (IRI) dentro del conjunto de datos RDF. En Neptune, a menos que un usuario haya declarado un gráfico con nombre al escribir datos, todos los [triples](#) se consideran parte del gráfico con nombre predeterminado.

Existen varios casos de uso para los gráficos con nombre asignado:

- Particionamiento y aislamiento de datos
- Procedencia de los datos
- Control de versiones
- Inferencia

Esta guía se centra en el caso de uso de la partición de datos. Recomendamos crear un gráfico con nombre definido por el usuario para cada inquilino.

Opciones de consulta de SPARQL mediante el protocolo HTTP Graph Store

Las consultas de ejemplo siguientes utilizan el protocolo SPARQL, el lenguaje de consulta RDF (SPARQL) y el protocolo HTTP Graph Store para consultar o crear un gráfico con nombre para un inquilino.

- HTTP GET– Para recuperar un gráfico específico de un inquilino:

```
curl --request GET 'https://your-neptune-endpoint:port/sparql/gsp/?graph=http%3A//www.example.com/named/tenant1'
```

- HTTP PUT– Para crear o sustituir un gráfico con nombre específico por una carga útil especificada en la solicitud:

```
curl --request PUT -H "Content-Type: text/turtle" \ --data-raw "@prefix ex: http://example.com/ . ex:subject ex:predicate ex:object ." \ 'https://your-neptune-endpoint:port/sparql/gsp/?graph=http%3A//www.example.com/named/tenant1'
```

En RDF, un objeto es un triple.

- HTTP POST– Para crear una nueva gráfica con nombre si no existe ninguna, o para fusionarla con una gráfica existente:

```
curl --request POST -H "Content-Type: text/turtle" \ --data-raw "@prefix ex: http://example.com/ . ex:subject ex:predicate ex:object ." \ 'https://your-neptune-endpoint:port/sparql/gsp/?graph=http%3A//www.example.com/named/tenant1'
```

Aislamiento de inquilinos para RDF

Para el aislamiento lógico de los datos con las barandillas necesarias en la capa de aplicación, cree un mapeo entre el inquilino y los gráficos con nombre definidos por el usuario. [Cuando diseñe la multitenencia para un conjunto de datos RDF, tenga en cuenta los siguientes aspectos de RDF y SPARQL:](#)

- En Neptune, cuando se consulta sin especificar un gráfico con nombre, se recuperan todos los triples que coinciden con el patrón en todos los gráficos con nombre asignado de la base de datos.
- En RDF, no hay restricciones en cuanto a las conexiones entre los nodos de gráficos con distintos nombres. Por ejemplo, en el diagrama anterior, un nodo en se :G1 puede conectar a un nodo en: a G2 través de un borde.

Por ejemplo, si un usuario final de un arrendatario concreto envía una consulta a la API, la API debe validar los siguientes requisitos antes de enviar la consulta a la base de datos de Neptune:

- Cualquier consulta dirigida a un único inquilino debe especificar un gráfico con nombre. De lo contrario, corre el riesgo de filtrar datos entre los inquilinos.
- Las consultas de actualización o eliminación siempre deben especificar un gráfico con nombre.
- Los nodos situados a ambos lados de una arista o relación siempre deben pertenecer al gráfico con el nombre correcto.

Para obtener información adicional sobre las prácticas recomendadas, consulte la documentación de [Neptune](#).

Prepárese para el crecimiento

Cuando se utiliza correctamente el modelo de grupo, al final se supera el tamaño de un único cúmulo de Neptune. Los inquilinos aumentan, o el número de inquilinos aumenta, y la tasa de ingesta de datos necesaria para todos sus clientes supera la capacidad del clúster. Cuando esto ocurra, tendrá que dividir a sus clientes en varios clústeres. Diseñe esta configuración por adelantado en lugar de intentar adaptarla más adelante. Incluso si su escala inicial consiste en utilizar un solo clúster, simule los componentes que necesitará para enrutar a los inquilinos entre varios clústeres en el futuro cuando alcance esa escala.

Si su solución requiere más recursos en función del tamaño del inquilino, prepárese también para su crecimiento. Si varios de los clientes de un solo clúster crecen de forma significativa, es posible que ese clúster deje de satisfacer sus necesidades. Diseñe una estrategia para mover a los inquilinos a otro clúster o dividir un clúster existente en dos mediante la función de [clonación de Amazon Neptune DB](#).

Familiarícese con el [Copy-on-Write Protocolo](#) de Neptune, que puede ahorrarle dinero al implementar la clonación de bases de datos. Si divide un clúster debido a los cuellos de botella en la ingesta,

podría ser más eficiente no eliminar los datos de los clústeres, siempre que sus políticas lo permitan. Los dos clústeres compartirán una página de datos si no ha cambiado, pero no si la página de datos se ha modificado (porque se han eliminado algunos de sus datos).

Note

Esta guía se aplica a la versión más reciente de Neptune en el momento de escribir este artículo, que es la versión 1.3.1 de Neptune. Esta guía podría cambiar en futuras versiones a medida que evolucione la capa de almacenamiento de Neptune.

Limitaciones de los escenarios de tenencia múltiple

Tenga en cuenta que algunas funciones de Neptune no están diseñadas para escenarios de tenencia múltiple. Los inquilinos no deberían tener acceso directo a los puntos finales de Neptune en un modelo de grupo porque estas estrategias de tenencia múltiple no se aplican a nivel de base de datos. Mantenga siempre algún tipo de intermediario entre sus clientes y el terminal Neptune que haga cumplir los diseños descritos en este documento. Entre los ejemplos de un proxy de este tipo se incluyen los siguientes:

- Añadir los filtros de etiquetas a la capa de clientes
- Tener una API que asigne el token de autenticación a un ID de inquilino e inyecte este filtro en la consulta

[Esta guía también se aplica a la hora de ofrecer a los clientes acceso directo a funciones como las libretas gráficas Neptune, el explorador gráfico Neptune o Neptune Streams.](#)

Multitenencia múltiple

Las soluciones SaaS suelen utilizar una combinación de modelos de silos y grupos. Varios factores influyen en la decisión de cuándo y cómo emplear los modelos de silo y de piscina en el mismo entorno.

Uno de esos factores es la estratificación, en la que una solución SaaS ofrece experiencias únicas a cada nivel de inquilinos. Por ejemplo, si sus niveles son gratuito, estándar y premium, los datos de los inquilinos del nivel gratuito podrían almacenarse en un clúster de Neptune compartido mediante un modelo de grupo. Para los inquilinos de los niveles Estándar y Premium, puede utilizar un modelo de cluster-per-tenant silos.

Además, algunos proveedores de SaaS tienen la capacidad de crear su solución de pool en un clúster compartido de Amazon Neptune como base. Posteriormente, pueden crear un clúster de Neptune independiente para los inquilinos que requieren almacenamiento en silos, a menudo debido a los requisitos normativos y de cumplimiento.

Si bien esto puede añadir un nivel de complejidad a la capa de acceso a los datos y al perfil de administración, también puede ofrecer a su empresa una forma de organizar su oferta en niveles para cumplir con los requisitos de los clientes.

Mejores prácticas operativas para ISVs

Muchas de las pautas de esta sección son prácticas recomendadas para todos los clientes, pero también tienen una importancia adicional para ellos. ISVs

Actualiza tu cúmulo de Neptune con las versiones más recientes

En las [notas de la versión](#) de Amazon Neptune, puede ver que cada versión incluye una serie de correcciones de errores, mejoras de rendimiento y nuevas funciones. Mantenga sus cúmulos de Neptune en la última versión tanto como sea posible.

Si encuentra un error no descubierto anteriormente en su carga de trabajo y su clúster tiene la última versión, los ingenieros de Neptune pueden crear un parche privado para su clúster (si lo desea y lo justifica). El parche puede funcionar hasta la próxima versión, cuando la corrección esté disponible para el público en general. Para ayudarte a actualizar tus clústeres a la versión más reciente, usa la solución [Neptune Azul/Green](#).

Use deltas en lugar de eliminar y reemplazar para la ingesta de datos

Puede utilizar varias técnicas para ingerir o escribir datos en Neptune. Muchos clientes intentan simplificar la ingesta de datos borrando y volviendo a insertar su gráfico cada vez que reciben un cambio en el feed. Pueden añadir una `last-modified` propiedad a cada nodo y buscar periódicamente los nodos que no se hayan modificado desde una fecha específica y eliminarlos. Si bien estas técnicas simplifican el proceso de ingesta de datos, tienen implicaciones de escalabilidad y salud a largo plazo para su clúster de Neptune.

En primer lugar, Neptune usa la [codificación de cadenas en un diccionario](#). A menos que especifique explícitamente IDs los nodos y los bordes, Neptune genera un GUID representado como una cadena para el ID y almacena esa cadena en el diccionario. Si borras y añades objetos constantemente, los que se generen automáticamente IDs provocarán una sobrecarga en el diccionario.

En segundo lugar, Neptune escala hasta ingerir unos 120 K de objetos por segundo como máximo. Si eliminas y añades objetos de forma continua, consumirás gran parte de ese ancho de banda en objetos que, en esencia, no cambian. Esto limita el número de inquilinos que puede alojar

en un clúster, requiere instancias de escritura más grandes en los clústeres y requiere más I/O operaciones. Todos estos factores aumentan sus costos.

Le recomendamos encarecidamente que desarrolle una forma de calcular el delta real de lo que ha cambiado en lugar de utilizar los métodos de eliminar y añadir. Sin embargo, algunas fuentes de datos no lo permiten (por ejemplo, las llamadas a la API que devuelven el estado actual o los eventos que no registran exactamente lo que ha cambiado). Si la fuente de datos sin procesar no permite identificar los cambios, utilice los procesos de extracción, transformación y carga (ETL) para calcular el delta. Por ejemplo, puede mantener las instantáneas de cada captura de datos anterior en formato Parquet, utilizarlas AWS Glue para calcular las diferencias entre esas instantáneas y enviar solo las diferencias a Neptune.

Demuestre cómo evolucionarán los costos de Neptune con sus inquilinos

Ya sea que utilice un silo, una piscina o un modelo híbrido, los costes de la nube se ampliarán en función del tamaño de sus inquilinos. Los inquilinos que requieren más conexiones simultáneas necesitan instancias más grandes o más réplicas de lectura que aquellos con menos conexiones simultáneas. Lo mismo se aplica a los inquilinos que requieren una ingesta de datos más rápida.

Los tres componentes del costo del clúster de Neptune son el tamaño (y el número) de la instancia, el tamaño de los datos (GB-mes) y I/O las operaciones (por millón). Si bien estos costos suelen ser específicos de la carga de trabajo, aumentan según el tamaño y el volumen de datos, y se pueden medir mediante el uso de herramientas. AWS Realice un seguimiento y comprenda las economías de escala comparándolas con los indicadores clave del tamaño de sus inquilinos, incluida la forma en que varían sus tamaños a lo largo del tiempo. Si la imprevisibilidad de sus I/O cargos afecta sus márgenes, considere la posibilidad de elegir el almacenamiento [optimizado para E/S de Neptune](#) por un costo más predecible.

Amplíe sus clústeres según la demanda de los clientes

No existe una fórmula probada o verdadera para ajustar el tamaño de la instancia de Neptune. La [documentación de Neptune](#) proporciona orientación, pero hay demasiadas variables como para recomendar un mapeo directo. Estas variables incluyen, entre otras, las siguientes:

- Modelo de datos
- Forma de datos

- Simultaneidad de consultas
- Complejidad de la consulta.

Planifique las pruebas para determinar el tamaño óptimo para sus cargas de trabajo y perfiles de inquilinos. En general, recomendamos usar instancias aprovisionadas para lograr una mayor rentabilidad y previsibilidad. Si sus objetivos de experiencia de cliente dan prioridad a un escalado óptimo por encima de los costes, considere la posibilidad de utilizar [instancias Neptune Serverless](#) para garantizar una experiencia más coherente, independientemente de las fluctuaciones de la carga de trabajo.

[Si las cargas de trabajo de lectura de su inquilino tienen una variabilidad significativa en sus picos y mínimos, combine las instancias Neptune Serverless con el autoscaling de Neptune.](#) Por lo general, una nueva réplica de lectura tarda entre 10 y 15 minutos en ponerse en línea una vez inicializada. Esto significa que el autoscalamiento por sí solo puede gestionar cambios prolongados en el tráfico, pero no es suficiente para los picos de actividad que cambian rápidamente. Al combinar Neptune Serverless y el autoscalado de Neptune, puede escalar las instancias hacia arriba o hacia abajo y escalar el número de réplicas de lectura entrantes y salientes.

Si sus inquilinos tienen perfiles de carga de trabajo o acuerdos de nivel de servicio muy diferentes (SLAs), considere la posibilidad de utilizar [terminales personalizados](#) y réplicas de lectura dedicadas para dirigir el tráfico a las instancias que estén optimizadas para ese tráfico. La optimización puede incluir un tamaño diferente de la instancia, patrones de consulta específicos o precalentar la caché del búfer.

Siguientes pasos

Si acaba de empezar a implementar Amazon Neptune para su ISV aplicación de arrendamiento múltiple, piense más en el modelo que desee. Cambiar el modelo le resultará más costoso más adelante en el proceso.

Si se encuentra en una fase temprana de su viaje, compruebe que está utilizando el modelo que mejor se adapta a sus necesidades y que sigue las instrucciones de dicho modelo.

Planificar. Cuando se encuentra en una fase temprana del proceso, resulta tentador aplazar las tareas de segmentación de los clientes por clústeres o de optimizar los ETL procesos para adaptarlos al delta de los cambios, en lugar de eliminar y volver a añadir vértices y aristas. A medida que vaya escalando, esas decisiones pueden tener un impacto negativo en el rendimiento y los costes.

Por último, si ya ha avanzado bastante, esta guía podría asegurarle que su arquitectura es óptima o podría proporcionarle cambios para mejorarla.

Si tiene preguntas sobre esta guía o necesita más ayuda, póngase en contacto con su Cuenta de AWS equipo y solicite una sesión con un especialista en Neptune.

Recursos

- [Documentación de Amazon Neptune](#)
- [Modelado de datos para Amazon Neptune \(curso\)](#)
- [Aplicación del marco AWS Well-Architected para Amazon Neptune](#)
- [Enfoque del Well-Architected](#)
- [Guía para arquitecturas multiusuario sobre AWS](#)
- [Estrategias de aislamiento de inquilinos de SaaS: aislamiento de recursos en un entorno de múltiples inquilinos](#)
- [TinkerPop Documentación de Apache](#)
- [SPARQL](#)

Colaboradores

Los colaboradores de esta guía son:

- Brian O'Keefe, director de WW NeptuneSSA, AWS
- Veeresham Gande, mánager técnico sénior de cuentas AWS
- Dana Owens, arquitecta de soluciones para empresas emergentes, AWS
- Nima Seifi, arquitecta de soluciones para empresas emergentes, AWS

Historial del documento

En la siguiente tabla, se describen cambios significativos de esta guía. Si quiere recibir notificaciones de futuras actualizaciones, puede suscribirse a las [RSSnotificaciones](#).

Cambio	Descripción	Fecha
Publicación inicial	—	3 de septiembre de 2024

AWS Glosario de orientación prescriptiva

Los siguientes son términos de uso común en las estrategias, guías y patrones proporcionados por la Guía AWS prescriptiva. Para sugerir entradas, utilice el enlace [Enviar comentarios](#) al final del glosario.

Números

Las 7 R

Siete estrategias de migración comunes para trasladar aplicaciones a la nube. Estas estrategias se basan en las 5 R que Gartner identificó en 2011 y consisten en lo siguiente:

- **Refactorizar/rediseñar:** traslade una aplicación y modifique su arquitectura mediante el máximo aprovechamiento de las características nativas en la nube para mejorar la agilidad, el rendimiento y la escalabilidad. Por lo general, esto implica trasladar el sistema operativo y la base de datos. Ejemplo: Migrar la base de datos de Oracle en las instalaciones a Amazon Aurora PostgreSQL-Compatible Edition.
- **Redefinir la plataforma (transportar y redefinir):** traslade una aplicación a la nube e introduzca algún nivel de optimización para aprovechar las capacidades de la nube. Ejemplo: Migrar la base de datos Oracle en las instalaciones a Amazon Relational Database Service (Amazon RDS) para Oracle en la nube de Nube de AWS.
- **Recomprar (readquirir):** cambie a un producto diferente, lo cual se suele llevar a cabo al pasar de una licencia tradicional a un modelo SaaS. Ejemplo: Migrar el sistema de administración de las relaciones con los clientes (CRM) a Salesforce.com.
- **Volver a alojar (migrar mediante lift-and-shift):** traslade una aplicación a la nube sin realizar cambios para aprovechar las capacidades de la nube. Ejemplo: Migrar la base de datos de Oracle en las instalaciones a Oracle en una instancia de EC2 en la Nube de AWS.
- **Reubicar:** (migrar el hipervisor mediante lift and shift): traslade la infraestructura a la nube sin comprar equipo nuevo, reescribir aplicaciones o modificar las operaciones actuales. Los servidores se migran de una plataforma en las instalaciones a un servicio en la nube para la misma plataforma. Ejemplo: migrar una Microsoft Hyper-V aplicación a AWS.
- **Retener (revisitar):** conserve las aplicaciones en el entorno de origen. Estas pueden incluir las aplicaciones que requieren una refactorización importante, que desee posponer para más adelante, y las aplicaciones heredadas que desee retener, ya que no hay ninguna justificación empresarial para migrarlas.

- Retirar: retire o elimine las aplicaciones que ya no sean necesarias en un entorno de origen.

A

ABAC

Consulte [control de acceso basado en atributos](#).

servicios abstractos

Consulte [servicios administrados](#).

ACID

Consulte [atomicidad, consistencia, aislamiento, durabilidad](#).

migración activa-activa

Método de migración de bases de datos en el que las bases de datos de origen y destino se mantienen sincronizadas (mediante una herramienta de replicación bidireccional o mediante operaciones de escritura doble) y ambas bases de datos gestionan las transacciones de las aplicaciones conectadas durante la migración. Este método permite la migración en lotes pequeños y controlados, en lugar de requerir una transición única. Es más flexible, pero requiere más trabajo que una [migración activa-pasiva](#).

migración activa-pasiva

Método de migración de bases de datos en el que las bases de datos de origen y destino se mantienen sincronizadas, pero solo la de origen gestiona las transacciones de las aplicaciones conectadas, mientras los datos se replican en la de destino. La base de datos de destino no acepta ninguna transacción durante la migración.

función de agregación

Función SQL que actúa en un grupo de filas y calcula un único valor de devolución para el grupo. Entre los ejemplos de funciones de agregación se incluyen SUM y MAX.

IA

Consulte [inteligencia artificial](#).

AIOps

Consulte [operaciones de inteligencia artificial](#)

anonimización

El proceso de eliminar permanentemente la información personal de un conjunto de datos. La anonimización puede ayudar a proteger la privacidad personal. Los datos anonimizados ya no se consideran datos personales.

antipatronos

Una solución que se utiliza con frecuencia para un problema recurrente en el que la solución es contraproducente, ineficaz o menos eficaz que una alternativa.

control de aplicaciones

Enfoque de seguridad que permite usar de manera exclusiva aplicaciones aprobadas para ayudar a proteger un sistema contra el malware.

cartera de aplicaciones

Recopilación de información detallada sobre cada aplicación que utiliza una organización, incluido el costo de creación y mantenimiento de la aplicación y su valor empresarial. Esta información es clave para [el proceso de detección y análisis de la cartera](#) y ayuda a identificar y priorizar las aplicaciones que se van a migrar, modernizar y optimizar.

inteligencia artificial (IA)

El campo de la informática que se dedica al uso de tecnologías informáticas para realizar funciones cognitivas que suelen estar asociadas a los seres humanos, como el aprendizaje, la resolución de problemas y el reconocimiento de patrones. Para más información, consulte [¿Qué es la inteligencia artificial?](#)

operaciones de inteligencia artificial (AIOps)

El proceso de utilizar técnicas de machine learning para resolver problemas operativos, reducir los incidentes operativos y la intervención humana, y mejorar la calidad del servicio. Para obtener más información sobre cómo AIOps se utiliza en la estrategia de AWS migración, consulte la [guía de integración de operaciones](#).

cifrado asimétrico

Algoritmo de cifrado que utiliza un par de claves, una clave pública para el cifrado y una clave privada para el descifrado. Puede compartir la clave pública porque no se utiliza para el descifrado, pero el acceso a la clave privada debe estar sumamente restringido.

atomicidad, consistencia, aislamiento, durabilidad (ACID)

Conjunto de propiedades de software que garantizan la validez de los datos y la fiabilidad operativa de una base de datos, incluso en caso de errores, cortes de energía u otros problemas.

control de acceso basado en atributos (ABAC)

La práctica de crear permisos detallados basados en los atributos del usuario, como el departamento, el puesto de trabajo y el nombre del equipo. Para obtener más información, consulte [ABAC AWS en la](#) documentación AWS Identity and Access Management (IAM).

origen de datos fidedigno

Ubicación en la que se almacena la versión principal de los datos, que se considera la fuente de información más fiable. Puede copiar los datos del origen de datos autorizado a otras ubicaciones con el fin de procesarlos o modificarlos, por ejemplo, anonimizarlos, redactarlos o seudonimizarlos.

Zona de disponibilidad

Una ubicación distinta dentro de una Región de AWS que está aislada de los fallos en otras zonas de disponibilidad y que proporciona una conectividad de red económica y de baja latencia a otras zonas de disponibilidad de la misma región.

AWS Marco de adopción de la nube (AWS CAF)

Un marco de directrices y mejores prácticas AWS para ayudar a las organizaciones a desarrollar un plan eficiente y eficaz para migrar con éxito a la nube. AWS CAF organiza la orientación en seis áreas de enfoque denominadas perspectivas: negocios, personas, gobierno, plataforma, seguridad y operaciones. Las perspectivas empresariales, humanas y de gobernanza se centran en las habilidades y los procesos empresariales; las perspectivas de plataforma, seguridad y operaciones se centran en las habilidades y los procesos técnicos. Por ejemplo, la perspectiva humana se dirige a las partes interesadas que se ocupan de los Recursos Humanos (RR. HH.), las funciones del personal y la administración de las personas. Desde esta perspectiva, AWS CAF proporciona orientación para el desarrollo, la formación y la comunicación de las personas a fin de preparar a la organización para una adopción exitosa de la nube. Para obtener más información, consulte la [Página web de AWS CAF](#) y el [Documento técnico de AWS CAF](#).

AWS Marco de calificación de la carga de trabajo (AWS WQF)

Herramienta que evalúa las cargas de trabajo de migración de bases de datos, recomienda estrategias de migración y proporciona estimaciones de trabajo. AWS WQF se incluye con AWS

Schema Conversion Tool (). AWS SCT Analiza los esquemas de bases de datos y los objetos de código, el código de las aplicaciones, las dependencias y las características de rendimiento y proporciona informes de evaluación.

B

bot malicioso

[Bot](#) destinado a causar interrupciones o daños a personas u organizaciones.

BCP

Consulte [planificación de la continuidad del negocio](#).

gráfico de comportamiento

Una vista unificada e interactiva del comportamiento de los recursos y de las interacciones a lo largo del tiempo. Puede utilizar un gráfico de comportamiento con Amazon Detective para examinar los intentos de inicio de sesión fallidos, las llamadas sospechosas a la API y acciones similares. Para obtener más información, consulte [Datos en un gráfico de comportamiento](#) en la documentación de Detective.

sistema big-endian

Un sistema que almacena primero el byte más significativo. Consulte también [endianidad](#).

clasificación binaria

Un proceso que predice un resultado binario (una de las dos clases posibles). Por ejemplo, es posible que su modelo de ML necesite predecir problemas como “¿Este correo electrónico es spam o no es spam?” o “¿Este producto es un libro o un automóvil?”.

filtro de floración

Estructura de datos probabilística y eficiente en términos de memoria que se utiliza para comprobar si un elemento es miembro de un conjunto.

implementación azul/verde

Estrategia de implementación en la que se crean dos entornos separados, pero idénticos. La versión actual de la aplicación se ejecuta en un entorno (azul) y la nueva versión de la aplicación se ejecuta en el otro entorno (verde). Esta estrategia lo ayuda a hacer reversiones rápidas con un impacto mínimo.

bot

Aplicación de software que ejecuta tareas automatizadas a través de Internet y simula la actividad o interacción humana. Algunos bots son útiles o beneficiosos, como los rastreadores web que indexan la información de Internet. Otros bots, conocidos como bots maliciosos, tienen como objetivo causar interrupciones o daños a personas u organizaciones.

botnet

Redes de [bots](#) infectadas por [malware](#) y que están bajo el control de una sola parte, conocida como pastor de bots u operador de bots. Las botnets son el mecanismo más conocido para escalar los bots y su impacto.

branch

Área contenida de un repositorio de código. La primera rama que se crea en un repositorio es la rama principal. Puede crear una rama nueva a partir de una rama existente y, a continuación, desarrollar características o corregir errores en la rama nueva. Una rama que se genera para crear una característica se denomina comúnmente rama de característica. Cuando la característica se encuentra lista para su lanzamiento, se vuelve a combinar la rama de característica con la rama principal. Para obtener más información, consulte [Acerca de las sucursales](#) (GitHub documentación).

acceso de emergencia

En circunstancias excepcionales y mediante un proceso aprobado, es una forma rápida de que un usuario pueda acceder a un Cuenta de AWS sitio al que normalmente no tiene permisos de acceso. Para más información, consulte el indicador [Implement break-glass procedures](#) en la guía de AWS Well-Architected.

estrategia de implementación sobre infraestructura existente

La infraestructura existente en su entorno. Al adoptar una estrategia de implementación sobre infraestructura existente para una arquitectura de sistemas, se diseña la arquitectura en función de las limitaciones de los sistemas y la infraestructura actuales. Si está ampliando la infraestructura existente, puede combinar las estrategias de implementación sobre infraestructuras existentes y de [implementación desde cero](#).

caché de búfer

El área de memoria donde se almacenan los datos a los que se accede con más frecuencia.

capacidad empresarial

Lo que hace una empresa para generar valor (por ejemplo, ventas, servicio al cliente o marketing). Las arquitecturas de microservicios y las decisiones de desarrollo pueden estar impulsadas por las capacidades empresariales. Para obtener más información, consulte la sección [Organizado en torno a las capacidades empresariales](#) del documento técnico [Ejecutar microservicios en contenedores en AWS](#).

planificación de la continuidad del negocio (BCP)

Plan que aborda el posible impacto de un evento disruptivo, como una migración a gran escala en las operaciones y permite a la empresa reanudar las operaciones rápidamente.

C

CAF

Consulte [AWS Cloud Adoption Framework](#).

implementación canario

Lanzamiento lento e incremental de una versión para los usuarios finales. Cuando tenga mayor confianza en la nueva versión, la implementa y reemplaza la versión actual en su totalidad.

CCoE

Consulte [Centro de excelencia en la nube](#).

CDC

Consulte [captura de datos de cambios](#).

captura de datos de cambio (CDC)

Proceso de seguimiento de los cambios en un origen de datos, como una tabla de base de datos, y registro de los metadatos relacionados con el cambio. Puede utilizar los CDC para diversos fines, como auditar o replicar los cambios en un sistema de destino para mantener la sincronización.

ingeniería del caos

Introducción intencionada de fallos o eventos disruptivos para poner a prueba la resiliencia de un sistema. Puedes usar [AWS Fault Injection Service \(AWS FIS\)](#) para realizar experimentos que estresen tus AWS cargas de trabajo y evalúen su respuesta.

CI/CD

Consulte [integración continua y entrega continua](#).

clasificación

Un proceso de categorización que permite generar predicciones. Los modelos de ML para problemas de clasificación predicen un valor discreto. Los valores discretos siempre son distintos entre sí. Por ejemplo, es posible que un modelo necesite evaluar si hay o no un automóvil en una imagen.

cifrado del cliente

Cifrado de datos localmente, antes de que el objetivo los Servicio de AWS reciba.

Centro de excelencia en la nube (CCoE)

Equipo multidisciplinario que impulsa los esfuerzos de adopción de la nube en toda la organización, incluido el desarrollo de las prácticas recomendadas en la nube, la movilización de recursos, el establecimiento de plazos de migración y la dirección de la organización durante las transformaciones a gran escala. Para obtener más información, consulte las [publicaciones de CCoE](#) en el blog de estrategia Nube de AWS empresarial.

computación en la nube

La tecnología en la nube que se utiliza normalmente para la administración de dispositivos de IoT y el almacenamiento de datos de forma remota. La computación en la nube suele estar relacionada con la tecnología de [computación de periferia](#).

modelo operativo en la nube

En una organización de TI, el modelo operativo que se utiliza para crear, madurar y optimizar uno o más entornos de nube. Para obtener más información, consulte [Creación de su modelo operativo de nube](#).

etapas de adopción de la nube

Las siguientes son las cuatro fases por las que suelen pasar las empresas cuando migran a la Nube de AWS:

- Proyecto: ejecución de algunos proyectos relacionados con la nube con fines de prueba de concepto y aprendizaje
- Fundamento: realizar inversiones fundamentales para escalar su adopción de la nube (p. ej., crear una landing zone, definir una CCoE, establecer un modelo de operaciones)

- Migración: migración de aplicaciones individuales
- Reinención: optimización de productos y servicios e innovación en la nube

Stephen Orban definió estas etapas en la entrada del blog [The Journey Toward Cloud-First & the Stages of Adoption en el](#) blog Nube de AWS Enterprise Strategy. Para obtener información sobre su relación con la estrategia de AWS migración, consulte la guía de [preparación para la migración](#).

CMDB

Consulte [base de datos de administración de configuración](#).

repositorio de código

Una ubicación donde el código fuente y otros activos, como documentación, muestras y scripts, se almacenan y actualizan mediante procesos de control de versiones. Algunos repositorios en la nube comunes son GitHub o Bitbucket Cloud. Cada versión del código se denomina rama. En una estructura de microservicios, cada repositorio se encuentra dedicado a una única funcionalidad. Una sola canalización de CI/CD puede utilizar varios repositorios.

caché en frío

Una caché de búfer que está vacía no está bien poblada o contiene datos obsoletos o irrelevantes. Esto afecta al rendimiento, ya que la instancia de la base de datos debe leer desde la memoria principal o el disco, lo que es más lento que leer desde la memoria caché del búfer.

datos fríos

Datos a los que se accede con poca frecuencia y que suelen ser históricos. Al consultar este tipo de datos, normalmente se aceptan consultas lentas. Trasladar estos datos a niveles o clases de almacenamiento de menor rendimiento y menos costosos puede reducir los costos.

visión artificial (CV)

Campo de la [IA](#) que utiliza el machine learning para analizar y extraer información de formatos visuales, como imágenes y videos digitales. Por ejemplo, Amazon SageMaker AI proporciona algoritmos de procesamiento de imágenes para CV.

deriva de configuración

En el caso de una carga de trabajo, un cambio en la configuración con respecto al estado esperado. Podría provocar que la carga de trabajo deje de cumplir las normas y, por lo general, es gradual e involuntaria.

base de datos de administración de configuración (CMDB)

Repositorio que almacena y administra información sobre una base de datos y su entorno de TI, incluidos los componentes de hardware y software y sus configuraciones. Por lo general, los datos de una CMDB se utilizan en la etapa de detección y análisis de la cartera de productos durante la migración.

paquete de conformidad

Un conjunto de AWS Config reglas y medidas correctivas que puede reunir para personalizar sus controles de conformidad y seguridad. Puede implementar un paquete de conformidad como una entidad única en una región Cuenta de AWS y, o en una organización, mediante una plantilla YAML. Para obtener más información, consulta los [paquetes de conformidad](#) en la documentación. AWS Config

integración y entrega continuas (CI/CD)

El proceso de automatización de las etapas de origen, compilación, prueba, puesta en escena y producción del proceso de publicación del software. CI/CD se describe comúnmente como una canalización. CI/CD puede ayudarlo a automatizar los procesos, mejorar la productividad, mejorar la calidad del código y entregar más rápido. Para obtener más información, consulte [Beneficios de la entrega continua](#). CD también puede significar implementación continua. Para obtener más información, consulte [Entrega continua frente a implementación continua](#).

CV

Consulte [visión artificial](#).

D

datos en reposo

Datos que están estacionarios en la red, como los datos que se encuentran almacenados.

clasificación de datos

Un proceso para identificar y clasificar los datos de su red en función de su importancia y sensibilidad. Es un componente fundamental de cualquier estrategia de administración de riesgos de ciberseguridad porque lo ayuda a determinar los controles de protección y retención adecuados para los datos. La clasificación de datos es un componente del pilar de seguridad

del AWS Well-Architected Framework. Para obtener más información, consulte [Clasificación de datos](#).

deriva de datos

Una variación significativa entre los datos de producción y los datos que se utilizaron para entrenar un modelo de machine learning, o un cambio significativo en los datos de entrada a lo largo del tiempo. La deriva de datos puede reducir la calidad, la precisión y la imparcialidad generales de las predicciones de los modelos de machine learning.

datos en tránsito

Datos que se mueven de forma activa por la red, por ejemplo, entre los recursos de la red.

malla de datos

Marco de arquitectura que proporciona una propiedad de datos distribuida y descentralizada con una administración y una gobernanza centralizadas.

minimización de datos

El principio de recopilar y procesar solo los datos estrictamente necesarios. Practicar la minimización de los datos Nube de AWS puede reducir los riesgos de privacidad, los costos y la huella de carbono de la analítica.

perímetro de datos

Un conjunto de barreras preventivas en su AWS entorno que ayudan a garantizar que solo las identidades confiables accedan a los recursos confiables desde las redes esperadas. Para obtener más información, consulte [Crear un perímetro de datos sobre](#) AWS

preprocesamiento de datos

Transformar los datos sin procesar en un formato que su modelo de ML pueda analizar fácilmente. El preprocesamiento de datos puede implicar eliminar determinadas columnas o filas y corregir los valores faltantes, incoherentes o duplicados.

procedencia de los datos

El proceso de rastrear el origen y el historial de los datos a lo largo de su ciclo de vida, por ejemplo, la forma en que se generaron, transmitieron y almacenaron los datos.

titular de los datos

Persona cuyos datos se recopilan y procesan.

almacenamiento de datos

Sistema de administración de datos que respalda la inteligencia empresarial, como los análisis. Los almacenes de datos suelen contener grandes cantidades de datos históricos y, por lo general, se utilizan para las consultas y los análisis.

lenguaje de definición de datos (DDL)

Instrucciones o comandos para crear o modificar la estructura de tablas y objetos de una base de datos.

lenguaje de manipulación de datos (DML)

Instrucciones o comandos para modificar (insertar, actualizar y eliminar) la información de una base de datos.

DDL

Consulte [lenguaje de definición de bases de datos](#).

conjunto profundo

Combinar varios modelos de aprendizaje profundo para la predicción. Puede utilizar conjuntos profundos para obtener una predicción más precisa o para estimar la incertidumbre de las predicciones.

aprendizaje profundo

Un subcampo del ML que utiliza múltiples capas de redes neuronales artificiales para identificar el mapeo entre los datos de entrada y las variables objetivo de interés.

defense-in-depth

Un enfoque de seguridad de la información en el que se distribuyen cuidadosamente una serie de mecanismos y controles de seguridad en una red informática para proteger la confidencialidad, la integridad y la disponibilidad de la red y de los datos que contiene. Al adoptar esta estrategia AWS, se añaden varios controles en diferentes capas de la AWS Organizations estructura para ayudar a proteger los recursos. Por ejemplo, un defense-in-depth enfoque podría combinar la autenticación multifactorial, la segmentación de la red y el cifrado.

administrador delegado

En AWS Organizations, un servicio compatible puede registrar una cuenta de AWS miembro para administrar las cuentas de la organización y gestionar los permisos de ese servicio. Esta

cuenta se denomina administrador delegado para ese servicio. Para obtener más información y una lista de servicios compatibles, consulte [Servicios que funcionan con AWS Organizations](#) en la documentación de AWS Organizations .

Implementación

El proceso de hacer que una aplicación, características nuevas o correcciones de código se encuentren disponibles en el entorno de destino. La implementación abarca implementar cambios en una base de código y, a continuación, crear y ejecutar esa base en los entornos de la aplicación.

entorno de desarrollo

Consulte [entorno](#).

control de detección

Un control de seguridad que se ha diseñado para detectar, registrar y alertar después de que se produzca un evento. Estos controles son una segunda línea de defensa, ya que lo advierten sobre los eventos de seguridad que han eludido los controles preventivos establecidos. Para obtener más información, consulte [Controles de detección](#) en Implementación de controles de seguridad en AWS.

asignación de flujos de valor para el desarrollo (DVSM)

Proceso que se utiliza para identificar y priorizar las restricciones que afectan negativamente a la velocidad y la calidad en el ciclo de vida del desarrollo de software. DVSM amplía el proceso de asignación del flujo de valor diseñado originalmente para las prácticas de fabricación ajustada. Se centra en los pasos y los equipos necesarios para crear y transferir valor a través del proceso de desarrollo de software.

gemelo digital

Representación virtual de un sistema del mundo real, como un edificio, una fábrica, un equipo industrial o una línea de producción. Los gemelos digitales son compatibles con el mantenimiento predictivo, la supervisión remota y la optimización de la producción.

tabla de dimensiones

En un [esquema en estrella](#), tabla más pequeña que contiene los atributos de datos sobre los datos cuantitativos en una tabla de hechos. Los atributos de la tabla de dimensiones suelen ser campos de texto o números discretos que se comportan como texto. Estos atributos se suelen utilizar para restringir consultas, filtrarlas y etiquetar los conjuntos de resultados.

desastre

Un evento que impide que una carga de trabajo o un sistema cumplan sus objetivos empresariales en su ubicación principal de implementación. Estos eventos pueden ser desastres naturales, fallos técnicos o el resultado de acciones humanas, como una configuración incorrecta involuntaria o un ataque de malware.

recuperación de desastres (DR)

Estrategia y proceso que utiliza para minimizar el tiempo de inactividad y la pérdida de datos a causa de un [desastre](#). Para obtener más información, consulte [Recuperación ante desastres de cargas de trabajo en AWS: Recovery in the Cloud in the AWS Well-Architected Framework](#).

DML

Consulte [lenguaje de manipulación de bases de datos](#).

diseño basado en el dominio

Un enfoque para desarrollar un sistema de software complejo mediante la conexión de sus componentes a dominios en evolución, o a los objetivos empresariales principales, a los que sirve cada componente. Este concepto lo introdujo Eric Evans en su libro, *Diseño impulsado por el dominio: abordando la complejidad en el corazón del software* (Boston: Addison-Wesley Professional, 2003). Para obtener información sobre cómo utilizar el diseño basado en dominios con el patrón de higos estranguladores, consulte [Modernización gradual de los servicios web antiguos de Microsoft ASP.NET \(ASMX\) mediante contenedores y Amazon API Gateway](#).

DR

Consulte [recuperación ante desastres](#).

Detección de desviaciones

Seguimiento de las desviaciones con respecto a una configuración con línea de base. Por ejemplo, puedes usarlo AWS CloudFormation para [detectar desviaciones en los recursos del sistema](#) o puedes usarlo AWS Control Tower para [detectar cambios en tu landing zone](#) que puedan afectar al cumplimiento de los requisitos de gobierno.

DVSM

Consulte [asignación de flujos de valor para el desarrollo](#).

E

EDA

Consulte [análisis de datos de tipo exploratorio](#).

EDI

Consulte [intercambio electrónico de datos](#).

computación en la periferia

La tecnología que aumenta la potencia de cálculo de los dispositivos inteligentes en la periferia de una red de IoT. En comparación con la [computación en la nube](#), la computación de periferia puede reducir la latencia de la comunicación y mejorar el tiempo de respuesta.

intercambio electrónico de datos (EDI)

Intercambio automatizado de documentos comerciales entre organizaciones. Para más información, consulte [¿Qué es el intercambio electrónico de datos?](#)

cifrado

Proceso de computación que transforma datos de texto plano, que son legibles por humanos, en texto cifrado.

clave de cifrado

Cadena criptográfica de bits aleatorios que se genera mediante un algoritmo de cifrado. Las claves pueden variar en longitud y cada una se ha diseñado para ser impredecible y única.

endianidad

El orden en el que se almacenan los bytes en la memoria del ordenador. Los sistemas big-endianos almacenan primero el byte más significativo. Los sistemas Little-Endian almacenan primero el byte menos significativo.

punto de conexión

Consulte [punto de conexión de servicio](#).

servicio de punto de conexión

Servicio que puede alojar en una nube privada virtual (VPC) para compartir con otros usuarios. Puede crear un servicio de punto final AWS PrivateLink y conceder permisos a otras Cuentas de AWS o a responsables AWS Identity and Access Management (de IAM). Estas cuentas o entidades principales pueden conectarse a su servicio de punto de conexión de forma privada

mediante la creación de puntos de conexión de VPC de interfaz. Para obtener más información, consulte [Creación de un servicio de punto de conexión](#) en la documentación de Amazon Virtual Private Cloud (Amazon VPC).

planificación de recursos empresariales (ERP)

Sistema que automatiza y administra los procesos empresariales clave (como la contabilidad, [MES](#) y la administración de proyectos) de una empresa.

cifrado de sobre

El proceso de cifrar una clave de cifrado con otra clave de cifrado. Para obtener más información, consulte el [cifrado de sobres](#) en la documentación de AWS Key Management Service (AWS KMS).

entorno

Una instancia de una aplicación en ejecución. Los siguientes son los tipos de entornos más comunes en la computación en la nube:

- entorno de desarrollo: instancia de una aplicación en ejecución que solo se encuentra disponible para el equipo principal responsable del mantenimiento de la aplicación. Los entornos de desarrollo se utilizan para probar los cambios antes de promocionarlos a los entornos superiores. Este tipo de entorno a veces se denomina entorno de prueba.
- entornos inferiores: todos los entornos de desarrollo de una aplicación, como los que se utilizan para las compilaciones y pruebas iniciales.
- entorno de producción: instancia de una aplicación en ejecución a la que pueden acceder los usuarios finales. En un CI/CD proceso, el entorno de producción es el último entorno de implementación.
- entornos superiores: todos los entornos a los que pueden acceder usuarios que no sean del equipo de desarrollo principal. Esto puede incluir un entorno de producción, entornos de preproducción y entornos para las pruebas de aceptación por parte de los usuarios.

epopeya

En las metodologías ágiles, son categorías funcionales que ayudan a organizar y priorizar el trabajo. Las epopeyas brindan una descripción detallada de los requisitos y las tareas de implementación. Por ejemplo, las epopeyas AWS de seguridad de CAF incluyen la gestión de identidades y accesos, los controles de detección, la seguridad de la infraestructura, la protección de datos y la respuesta a incidentes. Para obtener más información sobre las epopeyas en la estrategia de migración de AWS , consulte la [Guía de implementación del programa](#).

ERP

Consulte [planificación de recursos empresariales](#).

análisis de datos de tipo exploratorio (EDA)

El proceso de analizar un conjunto de datos para comprender sus características principales. Se recopilan o agregan datos y, a continuación, se realizan las investigaciones iniciales para encontrar patrones, detectar anomalías y comprobar las suposiciones. El EDA se realiza mediante el cálculo de estadísticas resumidas y la creación de visualizaciones de datos.

F

tabla de hechos

Tabla central de un [esquema en estrella](#). Almacena datos cuantitativos sobre operaciones empresariales. Por lo general, una tabla de hechos contiene dos tipos de columnas: las que contienen medidas y las que contienen una clave externa para una tabla de dimensiones.

Fail Fast

Filosofía que utiliza pruebas frecuentes e incrementales para reducir el ciclo de vida del desarrollo. Es una parte fundamental de los enfoques ágiles.

límite de aislamiento de errores

En el Nube de AWS, un límite, como una zona de disponibilidad Región de AWS, un plano de control o un plano de datos, que limita el efecto de una falla y ayuda a mejorar la resiliencia de las cargas de trabajo. Para más información, consulte [AWS Fault Isolation Boundaries](#).

rama de característica

Consulte [rama](#).

características

Los datos de entrada que se utilizan para hacer una predicción. Por ejemplo, en un contexto de fabricación, las características pueden ser imágenes que se capturan periódicamente desde la línea de fabricación.

importancia de las características

La importancia que tiene una característica para las predicciones de un modelo. Por lo general, esto se expresa como una puntuación numérica que se puede calcular mediante diversas

técnicas, como las explicaciones aditivas de Shapley (SHAP) y los gradientes integrados. Para obtener más información, consulte [Interpretabilidad del modelo de aprendizaje automático](#) con AWS

transformación de funciones

Optimizar los datos para el proceso de ML, lo que incluye enriquecer los datos con fuentes adicionales, escalar los valores o extraer varios conjuntos de información de un solo campo de datos. Esto permite que el modelo de ML se beneficie de los datos. Por ejemplo, si divide la fecha del “27 de mayo de 2021 00:15:37” en “jueves”, “mayo”, “2021” y “15”, puede ayudar al algoritmo de aprendizaje a aprender patrones matizados asociados a los diferentes componentes de los datos.

peticiones con pocos pasos

Proporcionar a un [LLM](#) una pequeña cantidad de ejemplos que demuestren la tarea y el resultado deseado antes de pedirle que lleve a cabo una tarea similar. Esta técnica es una aplicación del aprendizaje contextual, mediante el que los modelos aprenden a partir de ejemplos (pasos) incrustados en las peticiones. La técnica de peticiones con pocos pasos puede ser eficaz para las tareas que requieren un formato, un razonamiento o un conocimiento del dominio específicos. Consulte también [peticiones desde cero](#).

FGAC

Consulte [control de acceso detallado](#).

control de acceso preciso (FGAC)

El uso de varias condiciones que tienen por objetivo permitir o denegar una solicitud de acceso.

migración relámpago

Método de migración de bases de datos que utiliza la replicación continua de datos mediante la [captura de datos de cambio](#) para migrar los datos en el menor tiempo posible, en lugar de utilizar un enfoque gradual. El objetivo es reducir al mínimo el tiempo de inactividad.

FM

Consulte [modelo fundacional](#).

Modelo fundacional (FM)

Una gran red neuronal de aprendizaje profundo que se ha estado entrenando con conjuntos de datos masivos de datos generalizados y sin etiquetar. FMs son capaces de realizar una

amplia variedad de tareas generales, como comprender el lenguaje, generar texto e imágenes y conversar en lenguaje natural. Para más información, consulte [¿Qué son los modelos fundacionales?](#)

G

IA generativa

Subconjunto de modelos de [IA](#) que se entrenaron con grandes cantidades de datos y que pueden utilizar una simple petición de texto para crear contenido y artefactos nuevos, como imágenes, videos, texto y audio. Para más información, consulte [¿Qué es la IA generativa?](#)

bloqueo geográfico

Consulte [restricciones geográficas](#).

restricciones geográficas (bloqueo geográfico)

En Amazon CloudFront, una opción para impedir que los usuarios de países específicos accedan a las distribuciones de contenido. Puede utilizar una lista de permitidos o bloqueados para especificar los países aprobados y prohibidos. Para obtener más información, consulta [la sección Restringir la distribución geográfica del contenido](#) en la CloudFront documentación.

Flujo de trabajo de Gitflow

Un enfoque en el que los entornos inferiores y superiores utilizan diferentes ramas en un repositorio de código fuente. El flujo de trabajo de Gitflow se considera heredado, mientras que el [flujo de trabajo basado en enlaces troncales](#) es el enfoque moderno preferido.

imagen dorada

Instantánea de un sistema o software que se usa como plantilla para implementar nuevas instancias de ese sistema o software. Por ejemplo, en la fabricación, una imagen dorada se puede utilizar para aprovisionar software en varios dispositivos y ayuda a mejorar la velocidad, la escalabilidad y la productividad de las operaciones de fabricación de dispositivos.

estrategia de implementación desde cero

La ausencia de infraestructura existente en un entorno nuevo. Al adoptar una estrategia de implementación desde cero para una arquitectura de sistemas, puede seleccionar todas las tecnologías nuevas sin que estas deban ser compatibles con una infraestructura existente, lo que también se conoce como [implementación sobre infraestructura existente](#). Si está

ampliando la infraestructura existente, puede combinar las estrategias de implementación sobre infraestructuras existentes y de implementación desde cero.

barrera de protección

Una regla de alto nivel que ayuda a regular los recursos, las políticas y el cumplimiento en todas las unidades organizativas (OUs). Las barreras de protección preventivas aplican políticas para garantizar la alineación con los estándares de conformidad. Se implementan mediante políticas de control de servicios y límites de permisos de IAM. Las barreras de protección de detección detectan las vulneraciones de las políticas y los problemas de conformidad, y generan alertas para su corrección. Se implementan mediante Amazon AWS Config AWS Security Hub CSPM GuardDuty AWS Trusted Advisor, Amazon Inspector y AWS Lambda cheques personalizados.

H

HA

Consulte [alta disponibilidad](#).

migración heterogénea de bases de datos

Migración de la base de datos de origen a una base de datos de destino que utilice un motor de base de datos diferente (por ejemplo, de Oracle a Amazon Aurora). La migración heterogénea suele ser parte de un esfuerzo de rediseño de la arquitectura y convertir el esquema puede ser una tarea compleja. [AWS ofrece AWS SCT](#), lo cual ayuda con las conversiones de esquemas.

alta disponibilidad (HA)

La capacidad de una carga de trabajo para funcionar de forma continua, sin intervención, en caso de desafíos o desastres. Los sistemas de alta disponibilidad están diseñados para realizar una conmutación por error automática, ofrecer un rendimiento de alta calidad de forma constante y gestionar diferentes cargas y fallos con un impacto mínimo en el rendimiento.

modernización histórica

Un enfoque utilizado para modernizar y actualizar los sistemas de tecnología operativa (TO) a fin de satisfacer mejor las necesidades de la industria manufacturera. Un histórico es un tipo de base de datos que se utiliza para recopilar y almacenar datos de diversas fuentes en una fábrica.

datos de reserva

Parte de los datos históricos etiquetados que se ocultan de un conjunto de datos que se utiliza para entrenar un modelo de [machine learning](#). Puede utilizar los datos de reserva para evaluar el rendimiento del modelo mediante la comparación de las predicciones del modelo con los datos de reserva.

migración homogénea de bases de datos

Migración de la base de datos de origen a una base de datos de destino que comparte el mismo motor de base de datos (por ejemplo, Microsoft SQL Server a Amazon RDS para SQL Server). La migración homogénea suele formar parte de un esfuerzo para volver a alojar o redefinir la plataforma. Puede utilizar las utilidades de bases de datos nativas para migrar el esquema.

datos recientes

Datos a los que se accede con frecuencia, como datos en tiempo real o datos traslacionales recientes. Por lo general, estos datos requieren un nivel o una clase de almacenamiento de alto rendimiento para proporcionar respuestas rápidas a las consultas.

hotfix

Una solución urgente para un problema crítico en un entorno de producción. Debido a su urgencia, una revisión suele realizarse fuera del flujo de trabajo de DevOps publicación típico.

periodo de hiperatención

Periodo, inmediatamente después de la transición, durante el cual un equipo de migración administra y monitorea las aplicaciones migradas en la nube para solucionar cualquier problema. Por lo general, este periodo dura de 1 a 4 días. Al final del periodo de hiperatención, el equipo de migración suele transferir la responsabilidad de las aplicaciones al equipo de operaciones en la nube.

I

IaC

Consulte [infraestructura como código](#).

políticas basadas en identidades

Política asociada a uno o más directores de IAM que define sus permisos en el entorno. Nube de AWS

aplicación inactiva

Aplicación que utiliza un promedio de CPU y memoria de entre 5 y 20 por ciento durante un periodo de 90 días. En un proyecto de migración, es habitual retirar estas aplicaciones o mantenerlas en las instalaciones.

IIoT

Consulte [Internet de las cosas industrial](#).

infraestructura inmutable

Modelo que implementa una nueva infraestructura para las cargas de trabajo de producción en lugar de actualizar o modificar la infraestructura existente o aplicarle revisiones. Las infraestructuras inmutables son de manera intrínseca más coherentes, fiables y predecibles que las [infraestructuras mutables](#). Para más información, consulte la práctica recomendada [Implementación mediante una infraestructura inmutable](#) en el Marco de AWS Well-Architected.

VPC entrante (de entrada)

En una arquitectura de AWS cuentas múltiples, una VPC que acepta, inspecciona y enruta las conexiones de red desde fuera de una aplicación. La [arquitectura AWS de referencia de seguridad](#) recomienda configurar la cuenta de red con entradas, salidas e inspección VPCs para proteger la interfaz bidireccional entre la aplicación y el resto de Internet.

migración gradual

Estrategia de transición en la que se migra la aplicación en partes pequeñas en lugar de realizar una transición única y completa. Por ejemplo, puede trasladar inicialmente solo unos pocos microservicios o usuarios al nuevo sistema. Tras comprobar que todo funciona correctamente, puede trasladar microservicios o usuarios adicionales de forma gradual hasta que pueda retirar su sistema heredado. Esta estrategia reduce los riesgos asociados a las grandes migraciones.

Industria 4.0

Término que introdujo [Klaus Schwab](#) en 2016 para referirse a la modernización de los procesos de fabricación mediante los avances en la conectividad, los datos en tiempo real, la automatización, el análisis, la IA y el ML.

infraestructura

Todos los recursos y activos que se encuentran en el entorno de una aplicación.

infraestructura como código (IaC)

Proceso de aprovisionamiento y administración de la infraestructura de una aplicación mediante un conjunto de archivos de configuración. La IaC se ha diseñado para ayudarlo a centralizar la administración de la infraestructura, estandarizar los recursos y escalar con rapidez a fin de que los entornos nuevos sean repetibles, fiables y consistentes.

Internet de las cosas industrial (IIoT)

El uso de sensores y dispositivos conectados a Internet en los sectores industriales, como el productivo, el eléctrico, el automotriz, el sanitario, el de las ciencias de la vida y el de la agricultura. Para obtener más información, consulte [Creación de una estrategia de transformación digital de la Internet de las cosas \(IIoT\) industrial](#).

VPC de inspección

En una arquitectura de AWS cuentas múltiples, una VPC centralizada que gestiona las inspecciones del tráfico de red VPCs entre Internet y las redes locales (en una misma o Regiones de AWS diferente). La [arquitectura AWS de referencia de seguridad](#) recomienda configurar su cuenta de red con entrada, salida e inspección VPCs para proteger la interfaz bidireccional entre la aplicación e Internet en general.

Internet de las cosas (IoT)

Red de objetos físicos conectados con sensores o procesadores integrados que se comunican con otros dispositivos y sistemas a través de Internet o de una red de comunicación local. Para obtener más información, consulte [¿Qué es IoT?](#).

interpretabilidad

Característica de un modelo de machine learning que describe el grado en que un ser humano puede entender cómo las predicciones del modelo dependen de sus entradas. Para obtener más información, consulte Interpretabilidad del [modelo de aprendizaje automático](#) con AWS

IoT

Consulte [Internet de las cosas](#).

biblioteca de información de TI (ITIL)

Conjunto de prácticas recomendadas para ofrecer servicios de TI y alinearlos con los requisitos empresariales. La ITIL proporciona la base para la ITSM.

administración de servicios de TI (ITSM)

Actividades asociadas con el diseño, la implementación, la administración y el soporte de los servicios de TI para una organización. Para obtener información sobre la integración de las operaciones en la nube con las herramientas de ITSM, consulte la [Guía de integración de operaciones](#).

ITIL

Consulte [biblioteca de información de TI](#).

ITSM

Consulte [administración de servicios de TI](#).

L

control de acceso basado en etiquetas (LBAC)

Una implementación del control de acceso obligatorio (MAC) en la que a los usuarios y a los propios datos se les asigna explícitamente un valor de etiqueta de seguridad. La intersección entre la etiqueta de seguridad del usuario y la etiqueta de seguridad de los datos determina qué filas y columnas puede ver el usuario.

zona de aterrizaje

Una landing zone es un AWS entorno multicuenta bien diseñado, escalable y seguro. Este es un punto de partida desde el cual las empresas pueden lanzar e implementar rápidamente cargas de trabajo y aplicaciones con confianza en su entorno de seguridad e infraestructura. Para obtener más información sobre las zonas de aterrizaje, consulte [Configuración de un entorno de AWS seguro y escalable con varias cuentas](#).

modelo de lenguaje de gran tamaño (LLM)

Modelo de [IA](#) de aprendizaje profundo que se entrenó previamente con una gran cantidad de datos. Un LLM puede llevar a cabo varias tareas, como responder preguntas, resumir documentos, traducir textos a otros idiomas y completar oraciones. [Para obtener más información, consulte Qué son. LLMs](#)

migración grande

Migración de 300 servidores o más.

LBAC

Consulte [control de acceso basado en etiquetas](#).

privilegio mínimo

La práctica recomendada de seguridad que consiste en conceder los permisos mínimos necesarios para realizar una tarea. Para obtener más información, consulte [Aplicar permisos de privilegio mínimo](#) en la documentación de IAM.

migrar mediante lift-and-shift

Consulte [Las 7 R](#).

sistema little-endian

Un sistema que almacena primero el byte menos significativo. Consulte también [endianidad](#).

LLM

Consulte [modelo de lenguaje de gran tamaño](#).

entornos inferiores

Consulte [entorno](#).

M

machine learning (ML)

Un tipo de inteligencia artificial que utiliza algoritmos y técnicas para el reconocimiento y el aprendizaje de patrones. El ML analiza y aprende de los datos registrados, como los datos del Internet de las cosas (IoT), para generar un modelo estadístico basado en patrones. Para más información, consulte [Machine learning](#).

rama principal

Consulte [rama](#).

malware

Software diseñado para comprometer la seguridad o la privacidad de la computadora. El malware podría interrumpir los sistemas informáticos, filtrar información confidencial u obtener acceso

no autorizado. Algunos ejemplos de malware son los virus, los gusanos, el ransomware, los troyanos, el spyware y los registradores de pulsaciones de teclas.

Servicios administrados

Servicios de AWS para lo cual AWS opera la capa de infraestructura, el sistema operativo y las plataformas, y se accede a los puntos finales para almacenar y recuperar datos. Amazon Simple Storage Service (Amazon S3) y Amazon DynamoDB son ejemplos de servicios administrados. También se conocen como servicios abstractos.

sistema de ejecución de fabricación (MES)

Sistema de software para seguir, supervisar, documentar y controlar los procesos de producción que convierten las materias primas en productos acabados en la zona de producción.

MAP

Consulte [Programa de aceleración de la migración](#).

mecanismo

Proceso completo mediante el que se crea una herramienta, se impulsa su adopción y, a continuación, se inspeccionan los resultados para hacer ajustes. Un mecanismo es un ciclo que se refuerza y mejora por sí mismo a medida que funciona. Para obtener más información, consulte [Creación de mecanismos](#) en el AWS Well-Architected Framework.

cuenta de miembro

Todas las Cuentas de AWS demás cuentas, excepto la de administración, que forman parte de una organización. AWS Organizations Una cuenta no puede pertenecer a más de una organización a la vez.

MES

Consulte [sistema de ejecución de fabricación](#).

Message Queuing Telemetry Transport (MQTT)

[Un protocolo de comunicación ligero machine-to-machine \(M2M\), basado en el patrón de publicación/suscripción, para dispositivos de IoT con recursos limitados.](#)

microservicio

Un servicio pequeño e independiente que se comunica a través de una red bien definida APIs y que, por lo general, es propiedad de equipos pequeños e independientes. Por ejemplo,

un sistema de seguros puede incluir microservicios que se adapten a las capacidades empresariales, como las de ventas o marketing, o a subdominios, como las de compras, reclamaciones o análisis. Los beneficios de los microservicios incluyen la agilidad, la escalabilidad flexible, la facilidad de implementación, el código reutilizable y la resiliencia. Para obtener más información, consulte [Integrar microservicios mediante AWS servicios sin servidor](#).

arquitectura de microservicios

Un enfoque para crear una aplicación con componentes independientes que ejecutan cada proceso de la aplicación como un microservicio. Estos microservicios se comunican a través de una interfaz bien definida mediante un uso ligero. APIs Cada microservicio de esta arquitectura se puede actualizar, implementar y escalar para satisfacer la demanda de funciones específicas de una aplicación. Para obtener más información, consulte [Implementación de microservicios](#) en AWS

Programa de aceleración de la migración (MAP)

Un AWS programa que proporciona soporte de consultoría, formación y servicios para ayudar a las organizaciones a crear una base operativa sólida para migrar a la nube y para ayudar a compensar el costo inicial de las migraciones. El MAP incluye una metodología de migración para ejecutar las migraciones antiguas de forma metódica y un conjunto de herramientas para automatizar y acelerar los escenarios de migración más comunes.

migración a escala

Proceso de transferencia de la mayoría de la cartera de aplicaciones a la nube en oleadas, con más aplicaciones desplazadas a un ritmo más rápido en cada oleada. En esta fase, se utilizan las prácticas recomendadas y las lecciones aprendidas en las fases anteriores para implementar una fábrica de migración de equipos, herramientas y procesos con el fin de agilizar la migración de las cargas de trabajo mediante la automatización y la entrega ágil. Esta es la tercera fase de la [estrategia de migración de AWS](#).

fábrica de migración

Equipos multifuncionales que agilizan la migración de las cargas de trabajo mediante enfoques automatizados y ágiles. Los equipos de las fábricas de migración suelen incluir a analistas y propietarios de operaciones, empresas, ingenieros de migración, desarrolladores y DevOps profesionales que trabajan a pasos agigantados. Entre el 20 y el 50 por ciento de la cartera de aplicaciones empresariales se compone de patrones repetidos que pueden optimizarse mediante un enfoque de fábrica. Para obtener más información, consulte la [discusión sobre las fábricas de migración](#) y la [Guía de fábricas de migración a la nube](#) en este contenido.

metadatos de migración

Información sobre la aplicación y el servidor que se necesita para completar la migración. Cada patrón de migración requiere un conjunto diferente de metadatos de migración. Algunos ejemplos de metadatos de migración son la subred de destino, el grupo de seguridad y AWS la cuenta.

patrón de migración

Tarea de migración repetible que detalla la estrategia de migración, el destino de la migración y la aplicación o el servicio de migración utilizados. Ejemplo: rehospede la migración a Amazon EC2 AWS con Application Migration Service.

Migration Portfolio Assessment (MPA)

Herramienta en línea que proporciona información a fin de validar los argumentos comerciales necesarios para migrar a la Nube de AWS. La MPA ofrece una evaluación detallada de la cartera (adecuación del tamaño de los servidores, precios, comparaciones del costo total de propiedad, análisis de los costos de migración), así como una planificación de la migración (análisis y recopilación de datos de aplicaciones, agrupación de aplicaciones, priorización de la migración y planificación de oleadas). La [herramienta MPA](#) (requiere iniciar sesión) está disponible de forma gratuita para todos los AWS consultores y consultores de los socios de APN.

Evaluación de la preparación para la migración (MRA)

Proceso que consiste en obtener información sobre el estado de preparación de una organización para la nube, identificar sus puntos fuertes y débiles y elaborar un plan de acción para cerrar las brechas identificadas mediante el AWS CAF. Para obtener más información, consulte la [Guía de preparación para la migración](#). La MRA es la primera fase de la [estrategia de migración de AWS](#).

estrategia de migración

Enfoque utilizado para migrar una carga de trabajo a la Nube de AWS. Para más información, consulte la entrada [Las 7 R](#) de este glosario y también [Mobilize your organization to accelerate large-scale migrations](#).

ML

Consulte [machine learning](#).

modernización

Transformar una aplicación obsoleta (antigua o monolítica) y su infraestructura en un sistema ágil, elástico y de alta disponibilidad en la nube para reducir los gastos, aumentar la eficiencia

y aprovechar las innovaciones. Para más información, consulte [Strategy for modernizing applications in the Nube de AWS](#).

evaluación de la preparación para la modernización

Evaluación que ayuda a determinar la preparación para la modernización de las aplicaciones de una organización; identifica los beneficios, los riesgos y las dependencias; y determina qué tan bien la organización puede soportar el estado futuro de esas aplicaciones. El resultado de la evaluación es un esquema de la arquitectura objetivo, una hoja de ruta que detalla las fases de desarrollo y los hitos del proceso de modernización y un plan de acción para abordar las brechas identificadas. Para más información, consulte [Evaluating modernization readiness for applications in the Nube de AWS](#).

aplicaciones monolíticas (monolitos)

Aplicaciones que se ejecutan como un único servicio con procesos estrechamente acoplados. Las aplicaciones monolíticas presentan varios inconvenientes. Si una característica de la aplicación experimenta un aumento en la demanda, se debe escalar toda la arquitectura. Agregar o mejorar las características de una aplicación monolítica también se vuelve más complejo a medida que crece la base de código. Para solucionar problemas con la aplicación, puede utilizar una arquitectura de microservicios. Para obtener más información, consulte [Descomposición de monolitos en microservicios](#).

MPA

Consulte [Migration Portfolio Assessment](#).

MQTT

Consulte [Message Queuing Telemetry Transport](#).

clasificación multiclase

Un proceso que ayuda a generar predicciones para varias clases (predice uno de más de dos resultados). Por ejemplo, un modelo de ML podría preguntar “¿Este producto es un libro, un automóvil o un teléfono?” o “¿Qué categoría de productos es más interesante para este cliente?”.

infraestructura mutable

Modelo que actualiza y modifica la infraestructura actual para las cargas de trabajo de producción. Para mejorar la coherencia, la fiabilidad y la previsibilidad, el AWS Well-Architected Framework recomienda el uso [de una infraestructura inmutable](#) como práctica recomendada.

O

OAC

Consulte [control de acceso de origen](#).

OAI

Consulte [identidad de acceso de origen](#).

OCM

Consulte [administración del cambio organizacional](#).

migración fuera de línea

Método de migración en el que la carga de trabajo de origen se elimina durante el proceso de migración. Este método implica un tiempo de inactividad prolongado y, por lo general, se utiliza para cargas de trabajo pequeñas y no críticas.

OI

Consulte [integración de operaciones](#).

OLA

Consulte [acuerdo de nivel operativo](#).

migración en línea

Método de migración en el que la carga de trabajo de origen se copia al sistema de destino sin que se desconecte. Las aplicaciones que están conectadas a la carga de trabajo pueden seguir funcionando durante la migración. Este método implica un tiempo de inactividad nulo o mínimo y, por lo general, se utiliza para cargas de trabajo de producción críticas.

OPC-UA

Consulte [Open Process Communications: arquitectura unificada](#).

Open Process Communications: arquitectura unificada (OPC-UA)

Un protocolo de machine-to-machine comunicación (M2M) para la automatización industrial. OPC-UA establece un estándar de interoperabilidad con esquemas de autenticación, autorización y cifrado de datos.

acuerdo de nivel operativo (OLA)

Acuerdo que aclara lo que los grupos de TI operativos se comprometen a ofrecerse entre sí, para respaldar un acuerdo de nivel de servicio (SLA).

revisión de la preparación operativa (ORR)

Lista de comprobación de preguntas y prácticas recomendadas asociadas que son útiles para comprender, evaluar, prevenir o reducir el alcance de los incidentes y posibles errores. Para más información, consulte [Operational Readiness Reviews \(ORR\)](#) en el Marco de AWS Well-Architected.

tecnología operativa (TO)

Sistemas de hardware y software que funcionan con el entorno físico para controlar las operaciones, los equipos y la infraestructura industriales. En el sector de la fabricación, la integración de los sistemas de TO y tecnología de la información (TI) es un enfoque clave para las transformaciones de la [industria 4.0](#).

integración de operaciones (OI)

Proceso de modernización de las operaciones en la nube, que implica la planificación de la preparación, la automatización y la integración. Para obtener más información, consulte la [Guía de integración de las operaciones](#).

registro de seguimiento organizativo

Un registro creado por y AWS CloudTrail que registra todos los eventos para todos los miembros Cuentas de AWS de una organización. AWS Organizations Este registro de seguimiento se crea en cada Cuenta de AWS que forma parte de la organización y realiza un seguimiento de la actividad en cada cuenta. Para obtener más información, consulte [Crear un registro para una organización](#) en la CloudTrail documentación.

administración del cambio organizacional (OCM)

Marco para administrar las transformaciones empresariales importantes y disruptivas desde la perspectiva de las personas, la cultura y el liderazgo. La OCM ayuda a las empresas a prepararse para nuevos sistemas y estrategias y a realizar la transición a ellos, al acelerar la adopción de cambios, abordar los problemas de transición e impulsar cambios culturales y organizacionales. En la estrategia de AWS migración, este marco se denomina aceleración de personal, debido a la velocidad de cambio que requieren los proyectos de adopción de la nube. Para obtener más información, consulte la [Guía de OCM](#).

control de acceso de origen (OAC)

En CloudFront, una opción mejorada para restringir el acceso y proteger el contenido del Amazon Simple Storage Service (Amazon S3). El OAC admite todos los buckets de S3 Regiones de AWS, el cifrado del lado del servidor AWS KMS (SSE-KMS) y las solicitudes dinámicas PUT y DELETE dirigidas al bucket de S3.

identidad de acceso de origen (OAI)

En CloudFront, una opción para restringir el acceso y proteger el contenido de Amazon S3. Cuando utiliza OAI, CloudFront crea un principal con el que Amazon S3 puede autenticarse. Los directores autenticados solo pueden acceder al contenido de un bucket de S3 a través de una distribución específica. CloudFront Consulte también el [OAC](#), que proporciona un control de acceso más detallado y mejorado.

ORR

Consulte [revisión de la preparación operativa](#).

OT

Consulte [tecnología operativa](#).

VPC saliente (de salida)

En una arquitectura de AWS cuentas múltiples, una VPC que gestiona las conexiones de red que se inician desde una aplicación. La [arquitectura AWS de referencia de seguridad](#) recomienda configurar la cuenta de red con entradas, salidas e inspección VPCs para proteger la interfaz bidireccional entre la aplicación e Internet en general.

P

límite de permisos

Una política de administración de IAM que se adjunta a las entidades principales de IAM para establecer los permisos máximos que puede tener el usuario o el rol. Para obtener más información, consulte [Límites de permisos](#) en la documentación de IAM.

información de identificación personal (PII)

Información que, vista directamente o combinada con otros datos relacionados, puede utilizarse para deducir de manera razonable la identidad de una persona. Algunos ejemplos de información de identificación personal son los nombres, las direcciones y la información de contacto.

PII

Consulte [información de identificación personal](#).

manual de estrategias

Conjunto de pasos predefinidos que capturan el trabajo asociado a las migraciones, como la entrega de las funciones de operaciones principales en la nube. Un manual puede adoptar la forma de scripts, manuales de procedimientos automatizados o resúmenes de los procesos o pasos necesarios para operar un entorno modernizado.

PLC

Consulte [controlador lógico programable](#).

PLM

Consulte [administración del ciclo de vida del producto](#).

policy

Objeto que puede definir permisos (consulte [política basada en identidad](#)), especificar las condiciones de acceso (consulte [política basada en recursos](#)) o definir los permisos máximos para todas las cuentas de una organización de AWS Organizations (consulte [política de control de servicio](#)).

persistencia políglota

Elegir de forma independiente la tecnología de almacenamiento de datos de un microservicio en función de los patrones de acceso a los datos y otros requisitos. Si sus microservicios tienen la misma tecnología de almacenamiento de datos, pueden enfrentarse a desafíos de implementación o experimentar un rendimiento deficiente. Los microservicios se implementan más fácilmente y logran un mejor rendimiento y escalabilidad si utilizan el almacén de datos que mejor se adapte a sus necesidades.

evaluación de cartera

Proceso de detección, análisis y priorización de la cartera de aplicaciones para planificar la migración. Para obtener más información, consulte la [Evaluación de la preparación para la migración](#).

predicate

Condición de consulta que devuelve true o false. En general, se encuentra en una cláusula WHERE.

inserción de predicados

Técnica de optimización de consultas en bases de datos que filtra los datos de la consulta antes de transferirlos. Esta técnica reduce la cantidad de datos de la base de datos relacional que se tienen que recuperar y procesar. Además, mejora el rendimiento de las consultas.

control preventivo

Un control de seguridad diseñado para evitar que ocurra un evento. Estos controles son la primera línea de defensa para evitar el acceso no autorizado o los cambios no deseados en la red. Para obtener más información, consulte [Controles preventivos](#) en Implementación de controles de seguridad en AWS.

entidad principal

Una entidad AWS que puede realizar acciones y acceder a los recursos. Esta entidad suele ser un usuario raíz para un Cuenta de AWS rol de IAM o un usuario. Para obtener más información, consulte Entidad principal en [Términos y conceptos de roles](#) en la documentación de IAM.

Privacidad desde el diseño

Enfoque de ingeniería de sistemas que tiene en cuenta la privacidad durante todo el proceso de desarrollo.

zonas alojadas privadas

Un contenedor que contiene información sobre cómo desea que Amazon Route 53 responda a las consultas de DNS de un dominio y sus subdominios dentro de uno o más VPCs. Para obtener más información, consulte [Uso de zonas alojadas privadas](#) en la documentación de Route 53.

control proactivo

[Control de seguridad](#) que se diseñó para evitar la implementación de recursos que no cumplan con la normativa. Estos controles analizan los recursos antes de aprovisionarlos. Si el recurso no cumple con los requisitos del control, no se aprovisiona. Para obtener más información, consulte la [guía de referencia de controles](#) en la AWS Control Tower documentación y consulte [Controles proactivos](#) en la sección Implementación de controles de seguridad en AWS.

administración del ciclo de vida del producto (PLM)

Administración de los datos y los procesos de un producto a lo largo de todo su ciclo de vida, desde el diseño, el desarrollo y el lanzamiento, pasando por el crecimiento y la madurez, hasta la reducción de su uso y su retirada.

entorno de producción

Consulte [entorno](#).

controlador lógico programable (PLC)

En el sector de la fabricación, computadora adaptable y altamente fiable que supervisa las máquinas y automatiza los procesos de fabricación.

encadenamiento de peticiones

Uso de la salida de una petición de [LLM](#) como entrada para la siguiente petición a fin de generar mejores respuestas. Esta técnica se utiliza para dividir una tarea compleja en tareas secundarias o para refinar o ampliar de forma iterativa una respuesta preliminar. Ayuda a mejorar la precisión y la relevancia de las respuestas de un modelo y permite obtener resultados más detallados y personalizados.

seudonimización

El proceso de reemplazar los identificadores personales de un conjunto de datos por valores de marcadores de posición. La seudonimización puede ayudar a proteger la privacidad personal. Los datos seudonimizados siguen considerándose datos personales.

publish/subscribe (pub/sub)

Patrón que permite establecer comunicaciones asíncronas entre microservicios para mejorar la escalabilidad y la capacidad de respuesta. Por ejemplo, en un [MES](#) basado en microservicios, un microservicio puede publicar mensajes de eventos en un canal al que se pueden suscribir otros microservicios. El sistema puede agregar nuevos microservicios sin cambiar el servicio de publicación.

Q

plan de consulta

Serie de pasos, como instrucciones, que se utilizan para acceder a los datos de un sistema de base de datos relacional SQL.

regresión del plan de consulta

El optimizador de servicios de la base de datos elige un plan menos óptimo que antes de un cambio determinado en el entorno de la base de datos. Los cambios en estadísticas,

restricciones, configuración del entorno, enlaces de parámetros de consultas y actualizaciones del motor de base de datos PostgreSQL pueden provocar una regresión del plan.

R

Matriz RACI

Consulte [responsable, fiable, consultada e informada \(RACI\)](#).

RAG

Consulte [generación aumentada por recuperación](#).

ransomware

Software malicioso que se ha diseñado para bloquear el acceso a un sistema informático o a los datos hasta que se efectúe un pago.

Matriz RASCI

Consulte [responsable, fiable, consultada e informada \(RACI\)](#).

RCAC

Consulte [control de acceso por filas y columnas](#).

réplica de lectura

Una copia de una base de datos que se utiliza con fines de solo lectura. Puede enrutar las consultas a la réplica de lectura para reducir la carga en la base de datos principal.

rediseñar

Consulte [Las 7 R](#).

objetivo de punto de recuperación (RPO)

La cantidad de tiempo máximo aceptable desde el último punto de recuperación de datos. Esto determina qué se considera una pérdida de datos aceptable entre el último punto de recuperación y la interrupción del servicio.

objetivo de tiempo de recuperación (RTO)

La demora máxima aceptable entre la interrupción del servicio y el restablecimiento del servicio.

refactorizar

Consulte [Las 7 R.](#)

Region

Conjunto de AWS recursos en un área geográfica. Cada uno Región de AWS está aislado e independiente de los demás para proporcionar tolerancia a las fallas, estabilidad y resiliencia. Para más información, consulte [Specify which Regions de AWS your account can use.](#)

regresión

Una técnica de ML que predice un valor numérico. Por ejemplo, para resolver el problema de “¿A qué precio se venderá esta casa?”, un modelo de ML podría utilizar un modelo de regresión lineal para predecir el precio de venta de una vivienda en función de datos conocidos sobre ella (por ejemplo, los metros cuadrados).

volver a alojar

Consulte [Las 7 R.](#)

versión

En un proceso de implementación, el acto de promover cambios en un entorno de producción.

reubicar

Consulte [Las 7 R.](#)

redefinir la plataforma

Consulte [Las 7 R.](#)

recomprar

Consulte [Las 7 R.](#)

resiliencia

Capacidad de una aplicación para resistir interrupciones o recuperarse de ellas. Al planificar la resiliencia en la Nube de AWS, la [alta disponibilidad](#) y la [recuperación ante desastres](#) son consideraciones comunes. Para más información, consulte [Resiliencia en la Nube de AWS.](#)

política basada en recursos

Una política asociada a un recurso, como un bucket de Amazon S3, un punto de conexión o una clave de cifrado. Este tipo de política especifica a qué entidades principales se les permite el acceso, las acciones compatibles y cualquier otra condición que deba cumplirse.

matriz responsable, confiable, consultada e informada (RACI)

Una matriz que define las funciones y responsabilidades de todas las partes involucradas en las actividades de migración y las operaciones de la nube. El nombre de la matriz se deriva de los tipos de responsabilidad definidos en la matriz: responsable (R), contable (A), consultado (C) e informado (I). El tipo de soporte (S) es opcional. Si incluye el soporte, la matriz se denomina matriz RASCI y, si la excluye, se denomina matriz RACI.

control receptivo

Un control de seguridad que se ha diseñado para corregir los eventos adversos o las desviaciones con respecto a su base de seguridad. Para obtener más información, consulte [Controles receptivos](#) en Implementación de controles de seguridad en AWS.

retain

Consulte [Las 7 R](#).

retirar

Consulte [Las 7 R](#).

Generación aumentada de recuperación (RAG)

Tecnología de [IA generativa](#) mediante la que un [LLM](#) hace referencia a un origen de datos autorizado que se encuentra fuera de sus orígenes de datos de entrenamiento antes de generar una respuesta. Por ejemplo, un modelo de RAG podría hacer una búsqueda semántica en la base de conocimientos o en los datos personalizados de una organización. Para más información, consulte [¿Qué es RAG \(generación aumentada por recuperación\)?](#)

rotación

Proceso mediante el que periódicamente se actualiza un [secreto](#) para que resulte más difícil que un atacante pueda acceder a las credenciales.

control de acceso por filas y columnas (RCAC)

El uso de expresiones SQL básicas y flexibles que tienen reglas de acceso definidas. El RCAC consta de permisos de fila y máscaras de columnas.

RPO

Consulte [objetivo de punto de recuperación](#).

RTO

Consulte [objetivo de tiempo de recuperación](#).

manual de procedimientos

Conjunto de procedimientos manuales o automatizados necesarios para realizar una tarea específica. Por lo general, se diseñan para agilizar las operaciones o los procedimientos repetitivos con altas tasas de error.

S

SAML 2.0

Un estándar abierto que utilizan muchos proveedores de identidad (IdPs). Esta función permite el inicio de sesión único (SSO) federado, de modo que los usuarios pueden iniciar sesión en la Consola de administración de AWS o llamar a las operaciones de la AWS API sin tener que crear un usuario en IAM para todos los miembros de la organización. Para obtener más información sobre la federación basada en SAML 2.0, consulte [Acerca de la federación basada en SAML 2.0](#) en la documentación de IAM.

SCADA

Consulte [control de supervisión y adquisición de datos](#).

SCP

Consulte [política de control de servicio](#).

secreta

En AWS Secrets Manager, información confidencial o restringida, como una contraseña o credenciales de usuario, que se almacena de forma cifrada. Se compone del valor del secreto y de sus metadatos. El valor del secreto puede ser binario, una sola cadena o varias cadenas. Para más información, consulte [What's in a Secrets Manager secret?](#) en la documentación de Secrets Manager.

seguridad desde el diseño

Enfoque de ingeniería de sistemas que tiene en cuenta la seguridad durante todo el proceso de desarrollo.

control de seguridad

Barrera de protección técnica o administrativa que impide, detecta o reduce la capacidad de un agente de amenazas para aprovechar una vulnerabilidad de seguridad. Existen cuatro tipos de controles de seguridad principales: [preventivos](#), [de detección](#), [de respuesta](#) y [proactivos](#).

refuerzo de la seguridad

Proceso de reducir la superficie expuesta a ataques para hacerla más resistente a los ataques. Esto puede incluir acciones, como la eliminación de los recursos que ya no se necesitan, la implementación de prácticas recomendadas de seguridad consistente en conceder privilegios mínimos o la desactivación de características innecesarias en los archivos de configuración.

sistema de información sobre seguridad y administración de eventos (SIEM)

Herramientas y servicios que combinan sistemas de administración de información sobre seguridad (SIM) y de administración de eventos de seguridad (SEM). Un sistema de SIEM recopila, monitorea y analiza los datos de servidores, redes, dispositivos y otras fuentes para detectar amenazas y brechas de seguridad y generar alertas.

automatización de la respuesta de seguridad

Acción predefinida y programada que está diseñada para responder automáticamente a un evento de seguridad o corregirlo. Estas automatizaciones sirven como controles de seguridad [preventivos o adaptables](#) que le ayudan a implementar las mejores prácticas AWS de seguridad. La modificación de un grupo de seguridad de VPC, la aplicación de revisiones a una instancia de Amazon EC2 o la rotación de credenciales son algunos ejemplos de acciones de respuesta automatizadas.

cifrado del servidor

Cifrado de los datos en su destino, por parte de Servicio de AWS quien los recibe.

política de control de servicio (SCP)

Política que proporciona un control centralizado de los permisos de todas las cuentas de una organización en AWS Organizations. SCPs defina barreras o establezca límites a las acciones que un administrador puede delegar en usuarios o roles. Puede utilizarlas SCPs como listas de permitidos o rechazados para especificar qué servicios o acciones están permitidos o prohibidos. Para obtener más información, consulte [las políticas de control de servicios](#) en la AWS Organizations documentación.

punto de enlace de servicio

La URL del punto de entrada de un Servicio de AWS. Para conectarse mediante programación a un servicio de destino, puede utilizar un punto de conexión. Para obtener más información, consulte [Puntos de conexión de Servicio de AWS](#) en Referencia general de AWS.

acuerdo de nivel de servicio (SLA)

Acuerdo que aclara lo que un equipo de TI se compromete a ofrecer a los clientes, como el tiempo de actividad y el rendimiento del servicio.

indicador de nivel de servicio (SLI)

Medición de un aspecto del rendimiento de un servicio, como la tasa de errores, la disponibilidad o el rendimiento.

objetivo de nivel de servicio (SLO)

Métrica objetivo que representa el estado de un servicio medido mediante un [indicador de nivel de servicio](#).

modelo de responsabilidad compartida

Un modelo que describe la responsabilidad con AWS la que compartes la seguridad y el cumplimiento de la nube. AWS es responsable de la seguridad de la nube, mientras que usted es responsable de la seguridad en la nube. Para obtener más información, consulte el [Modelo de responsabilidad compartida](#).

SIEM

Consulte [sistema de administración de eventos e información de seguridad](#).

único punto de error (SPOF)

Error en un único componente crítico de una aplicación que puede interrumpir el sistema.

SLA

Consulte [acuerdo de nivel de servicio](#).

SLI

Consulte [indicador de nivel de servicio](#).

SLO

Consulte [objetivo de nivel de servicio](#).

split-and-seed modelo

Un patrón para escalar y acelerar los proyectos de modernización. A medida que se definen las nuevas funciones y los lanzamientos de los productos, el equipo principal se divide para

crear nuevos equipos de productos. Esto ayuda a ampliar las capacidades y los servicios de su organización, mejora la productividad de los desarrolladores y apoya la innovación rápida. Para más información, consulte [Phased approach to modernizing applications in the Nube de AWS](#).

SPOF

Consulte [único punto de error](#).

esquema en estrella

Estructura organizativa de una base de datos que utiliza una tabla de hechos de gran tamaño para almacenar datos transaccionales o medidos y una o varias tablas dimensionales más pequeñas para almacenar los atributos de los datos. Esta estructura está diseñada para utilizarse en un [almacén de datos](#) o con fines de inteligencia empresarial.

patrón de higo estrangulador

Un enfoque para modernizar los sistemas monolíticos mediante la reescritura y el reemplazo gradual de las funciones del sistema hasta que se pueda dismantelar el sistema heredado. Este patrón utiliza la analogía de una higuera que crece hasta convertirse en un árbol estable y, finalmente, se apodera y reemplaza a su host. El patrón fue [presentado por Martin Fowler](#) como una forma de gestionar el riesgo al reescribir sistemas monolíticos. Para ver un ejemplo con la aplicación de este patrón, consulte [Modernización gradual de los servicios web antiguos de Microsoft ASP.NET \(ASMX\) mediante contenedores y Amazon API Gateway](#).

subred

Un intervalo de direcciones IP en la VPC. Una subred debe residir en una sola zona de disponibilidad.

control de supervisión y adquisición de datos (SCADA)

En el sector de la fabricación, sistema que utiliza hardware y software para supervisar los activos físicos y las operaciones de producción.

cifrado simétrico

Un algoritmo de cifrado que utiliza la misma clave para cifrar y descifrar los datos.

pruebas sintéticas

Prueba de un sistema de manera que simule las interacciones de los usuarios para detectar posibles problemas o supervisar el rendimiento. Puede usar [Amazon CloudWatch Synthetics](#) para crear estas pruebas.

petición del sistema

Técnica para proporcionar contexto, instrucciones o pautas a un [LLM](#) para dirigir su comportamiento. Las peticiones del sistema ayudan a establecer el contexto y las reglas para las interacciones con los usuarios.

T

etiquetas

Pares clave-valor que actúan como metadatos para organizar los recursos. AWS Las etiquetas pueden ayudar a administrar, identificar, organizar, buscar y filtrar recursos de . Para obtener más información, consulte [Etiquetado de los recursos de AWS](#).

variable de destino

El valor que intenta predecir en el ML supervisado. Esto también se conoce como variable de resultado. Por ejemplo, en un entorno de fabricación, la variable objetivo podría ser un defecto del producto.

lista de tareas

Herramienta que se utiliza para hacer un seguimiento del progreso mediante un manual de procedimientos. La lista de tareas contiene una descripción general del manual de procedimientos y una lista de las tareas generales que deben completarse. Para cada tarea general, se incluye la cantidad estimada de tiempo necesario, el propietario y el progreso.

entorno de prueba

Consulte [entorno](#).

entrenamiento

Proporcionar datos de los que pueda aprender su modelo de ML. Los datos de entrenamiento deben contener la respuesta correcta. El algoritmo de aprendizaje encuentra patrones en los datos de entrenamiento que asignan los atributos de los datos de entrada al destino (la respuesta que desea predecir). Genera un modelo de ML que captura estos patrones. Luego, el modelo de ML se puede utilizar para obtener predicciones sobre datos nuevos para los que no se conoce el destino.

puerta de enlace de tránsito

Un centro de tránsito de red que puede usar para interconectar sus redes con VPCs las locales. Para obtener más información, consulte [Qué es una pasarela de tránsito](#) en la AWS Transit Gateway documentación.

flujo de trabajo basado en enlaces troncales

Un enfoque en el que los desarrolladores crean y prueban características de forma local en una rama de característica y, a continuación, combinan esos cambios en la rama principal. Luego, la rama principal se adapta a los entornos de desarrollo, preproducción y producción, de forma secuencial.

acceso de confianza

Otorgar permisos a un servicio que especifique para realizar tareas en su organización AWS Organizations y en sus cuentas en su nombre. El servicio de confianza crea un rol vinculado al servicio en cada cuenta, cuando ese rol es necesario, para realizar las tareas de administración por usted. Para obtener más información, consulte [AWS Organizations Utilización con otros AWS servicios](#) en la AWS Organizations documentación.

ajuste

Cambiar aspectos de su proceso de formación a fin de mejorar la precisión del modelo de ML. Por ejemplo, puede entrenar el modelo de ML al generar un conjunto de etiquetas, incorporar etiquetas y, luego, repetir estos pasos varias veces con diferentes ajustes para optimizar el modelo.

equipo de dos pizzas

Un DevOps equipo pequeño al que puedes alimentar con dos pizzas. Un equipo formado por dos integrantes garantiza la mejor oportunidad posible de colaboración en el desarrollo de software.

U

incertidumbre

Un concepto que hace referencia a información imprecisa, incompleta o desconocida que puede socavar la fiabilidad de los modelos predictivos de ML. Hay dos tipos de incertidumbre: la incertidumbre epistémica se debe a datos limitados e incompletos, mientras que la incertidumbre aleatoria se debe al ruido y la aleatoriedad inherentes a los datos. Para más información, consulte la guía [Cuantificación de la incertidumbre en los sistemas de aprendizaje profundo](#).

tareas indiferenciadas

También conocido como tareas arduas, es el trabajo que es necesario para crear y operar una aplicación, pero que no proporciona un valor directo al usuario final ni proporciona una ventaja competitiva. Algunos ejemplos de tareas indiferenciadas son la adquisición, el mantenimiento y la planificación de la capacidad.

entornos superiores

Consulte [entorno](#).

V

succión

Una operación de mantenimiento de bases de datos que implica limpiar después de las actualizaciones incrementales para recuperar espacio de almacenamiento y mejorar el rendimiento.

control de versión

Procesos y herramientas que realizan un seguimiento de los cambios, como los cambios en el código fuente de un repositorio.

Emparejamiento de VPC

Una conexión entre dos VPCs que le permite enrutar el tráfico mediante direcciones IP privadas. Para obtener más información, consulte [¿Qué es una interconexión de VPC?](#) en la documentación de Amazon VPC.

vulnerabilidad

Defecto de software o hardware que pone en peligro la seguridad del sistema.

W

caché caliente

Un búfer caché que contiene datos actuales y relevantes a los que se accede con frecuencia. La instancia de base de datos puede leer desde la caché del búfer, lo que es más rápido que leer desde la memoria principal o el disco.

datos templados

Datos a los que el acceso es infrecuente. Al consultar este tipo de datos, normalmente se aceptan consultas moderadamente lentas.

función de ventana

Función SQL que hace un cálculo en un grupo de filas que se relacionan de alguna manera con el registro actual. Las funciones de ventana son útiles para las tareas de procesamiento, como calcular una media móvil o acceder al valor de las filas en función de la posición relativa de la fila actual.

carga de trabajo

Conjunto de recursos y código que ofrece valor comercial, como una aplicación orientada al cliente o un proceso de backend.

flujo de trabajo

Grupos funcionales de un proyecto de migración que son responsables de un conjunto específico de tareas. Cada flujo de trabajo es independiente, pero respalda a los demás flujos de trabajo del proyecto. Por ejemplo, el flujo de trabajo de la cartera es responsable de priorizar las aplicaciones, planificar las oleadas y recopilar los metadatos de migración. El flujo de trabajo de la cartera entrega estos recursos al flujo de trabajo de migración, que luego migra los servidores y las aplicaciones.

WORM

Consulte [escritura única y lectura múltiple](#).

WQF

Consulte [AWS Workload Qualification Framework](#).

escritura única y lectura múltiple (WORM)

Modelo de almacenamiento que escribe los datos una sola vez y evita que se eliminen o modifiquen. Los usuarios autorizados pueden leer los datos tantas veces como sea necesario, pero no los pueden cambiar. Esta infraestructura de almacenamiento de datos se considera [inmutable](#).

Z

ataque de día cero

Ataque, normalmente de malware, que se aprovecha de una [vulnerabilidad de día cero](#).

vulnerabilidad de día cero

Un defecto o una vulnerabilidad sin mitigación en un sistema de producción. Los agentes de amenazas pueden usar este tipo de vulnerabilidad para atacar el sistema. Los desarrolladores suelen darse cuenta de la vulnerabilidad a raíz del ataque.

peticiones desde cero

Proporcionar a un [LLM](#) instrucciones para llevar a cabo una tarea, pero sin ejemplos (pasos) que puedan ayudar a guiarlo. El LLM debe usar los conocimientos del entrenamiento previo para llevar a cabo la tarea. La eficacia de la petición desde cero depende de la complejidad de la tarea y de la calidad de la petición. Consulte también [peticiones con pocos pasos](#).

aplicación zombi

Aplicación que utiliza un promedio de CPU y memoria menor al 5 por ciento. En un proyecto de migración, es habitual retirar estas aplicaciones.

Las traducciones son generadas a través de traducción automática. En caso de conflicto entre la traducción y la versión original de inglés, prevalecerá la versión en inglés.