



Whitepaper técnico

Diseñe y cree una canalización de datos para sus flujos de trabajo de IA

Ponga en marcha la IA, aprendizaje automático y aprendizaje profundo en toda su empresa: del perímetro al núcleo y al cloud

Santosh Rao, NetApp
Marzo de 2018 | WP-7264

Resumen ejecutivo

Las empresas están deseando sacar partido a las tecnologías de inteligencia artificial (IA), tales como el aprendizaje profundo (DL), para introducir nuevos servicios y conocer mejor los datos empresariales. A medida que los equipos de ciencia de datos superen la prueba de concepto para poner en práctica el aprendizaje profundo, deberán centrarse en crear toda una arquitectura de datos que elimine los cuellos de botella con el objetivo de facilitar un modelo repetible más rápidamente.

Diseñar una arquitectura de datos implica un pensamiento holístico sobre la canalización de datos, que abarque desde su ingesta y análisis perimetral hasta su preparación y entrenamiento en el núcleo del centro de datos y su archivado en el cloud.. Es crucial saber cuáles son los requisitos de rendimiento, los conjuntos de datos y los servicios de datos necesarios. No obstante, también debería tener en cuenta la capacidad de ampliación futura y de compatibilidad a medida que el hardware de aprendizaje profundo y los enfoques del cloud vayan evolucionando con el paso del tiempo.

En este whitepaper se tratan los retos de las infraestructuras de IA y cómo NetApp le puede ayudar a crear una canalización de datos para sus flujos de trabajo de aprendizaje profundo actuales, garantizando el futuro de las inversiones que haga en dicha infraestructura. Una planificación minuciosa de la infraestructura puede facilitar el flujo de datos a través de la canalización de aprendizaje profundo, puede comportar una reducción en el tiempo de puesta en marcha y puede diferenciarle aún más de la competencia.

ÍNDICE

1	Introducción: ¿Tiene preparada su infraestructura para dar cabida a flujos de trabajo de IA en entornos de producción?	3
2	Flujo de datos en una canalización de aprendizaje profundo	4
3	Acelerar la I/O en una canalización de aprendizaje profundo	5
3.1	Eliminar los cuellos de botella en el perímetro	5
3.2	Eliminar los cuellos de botella en las instalaciones	6
3.3	Eliminar los cuellos de botella en el cloud	8
4	Sistema de archivos y arquitectura de datos para una canalización de aprendizaje profundo	9
4.1	Flujo de datos hacia el clúster de entrenamiento	11
4.2	Otros factores relativos al rendimiento	13
5	Tecnologías de NetApp y la canalización de aprendizaje profundo	15
6	Garantizar el futuro de su canalización de aprendizaje profundo	16
6.1	Planificar la evolución del hardware en el núcleo	16
	Conclusión: tome el control de su canalización de datos y de su futuro respecto a la IA	17

LISTA DE TABLAS

Tabla 1)	Preguntas y consideraciones clave	10
----------	-----------------------------------	----

LISTA DE FIGURAS

Figura 1)	Una canalización de datos diseñada para el aprendizaje profundo también puede acomodar otros flujos de trabajo de IA y de Big Data	3
Figura 2)	Las canalizaciones de aprendizaje profundo pueden estar en las instalaciones o en el cloud	4
Figura 3)	Mediante el análisis perimetral con una organización de datos en niveles, los datos perimetrales se pueden separar en datos con prioridad alta destinados al núcleo y en datos con prioridad baja para su archivado	6
Figura 4)	Una canalización de aprendizaje profundo con el núcleo de la canalización en las instalaciones	7
Figura 5)	Si coloca los datos cerca del cloud, puede aprovechar el cloud computing a la vez que ofrece más aceleración de datos y tiene un mayor control	9
Figura 6)	Los datos no estructurados permiten fusionar los datos en el lago de datos y transmitirlos al clúster de entrenamiento	11
Figura 7)	Los datos estructurados se leen utilizando pequeñas I/O aleatorias y se fusionan en el clúster de entrenamiento	12
Figura 8)	Tecnologías de NetApp para Data Fabric	16
Figura 9)	El núcleo de su canalización de IA/ML/DL seguirá creciendo	17

1 Introducción: ¿Tiene preparada su infraestructura para dar cabida a flujos de trabajo de IA en entornos de producción?

Muchas organizaciones de todos los sectores están deseando sacar partido a las tecnologías de inteligencia artificial (IA) con el objetivo de introducir nuevos servicios y obtener información nueva de los datos empresariales. Sin embargo, a medida que los equipos de ciencia de datos superan los proyectos de prueba de concepto y empiezan a poner en práctica la tecnología de IA, a menudo se encuentran con problemas relacionados con la gestión de datos. Por ejemplo, mover o copiar datos por varios repositorios puede ser una tarea ardua. También ha supuesto un desafío satisfacer niveles de servicio de calidad y producción en cuanto al rendimiento y la protección en conjuntos de datos dinámicos de gran tamaño.


Parte del desafío radica en que el flujo de datos necesario para implementar una IA satisfactoria no esté aislado del centro de datos. A medida que las empresas de toda clase adopten el Internet de las cosas (IoT) y las tecnologías de IA, deberán hacer frente a retos desde el perímetro al núcleo y al cloud en lo que a datos se refiere.

Por ejemplo, muchas empresas automovilísticas han empezado a recopilar datos de un número cada vez mayor de vehículos (perímetro). Estos datos se utilizan para entrenar los algoritmos de IA necesarios para llevar a cabo operaciones autónomas (núcleo). Dado que los conjuntos de datos crecen exponencialmente y se deben almacenar para su reutilización, deben almacenarse en una plataforma escalable y de bajo costo (cloud). Hoy en día, las empresas automovilísticas están aprovechando la tecnología de la información al máximo. Los minoristas hacen frente a retos parecidos a la hora de crear modelos de inferencias basados en datos recopilados con dispositivos de punto de venta de cientos de ubicaciones de todo el mundo.

Habrà quien le haga creer que el desafío de los datos en la IA solo es cuestión de ofrecer rendimiento. El rendimiento es crucial en el núcleo de una canalización de IA. Sin embargo, necesita una canalización de datos que abarque todo el flujo de datos, desde la ingesta hasta el archivado, garantizando el éxito operativo y, al mismo tiempo, ofreciendo un rendimiento, una eficiencia y un costo óptimos en cada fase.

En este whitepaper se tratan los desafíos de las infraestructuras de IA y se describe cómo NetApp puede ayudarle a crear una canalización de datos que posibilite el aprendizaje profundo (DL). Dado que el aprendizaje profundo es el flujo de trabajo de IA más exigente en términos de computación y de I/O, una canalización de datos diseñada para el aprendizaje profundo también se adapta a otros flujos de trabajo de IA y de Big Data (ver figura 1).

Figura 1) Una canalización de datos diseñada para el aprendizaje profundo también puede acomodar otros flujos de trabajo de IA y de Big Data.

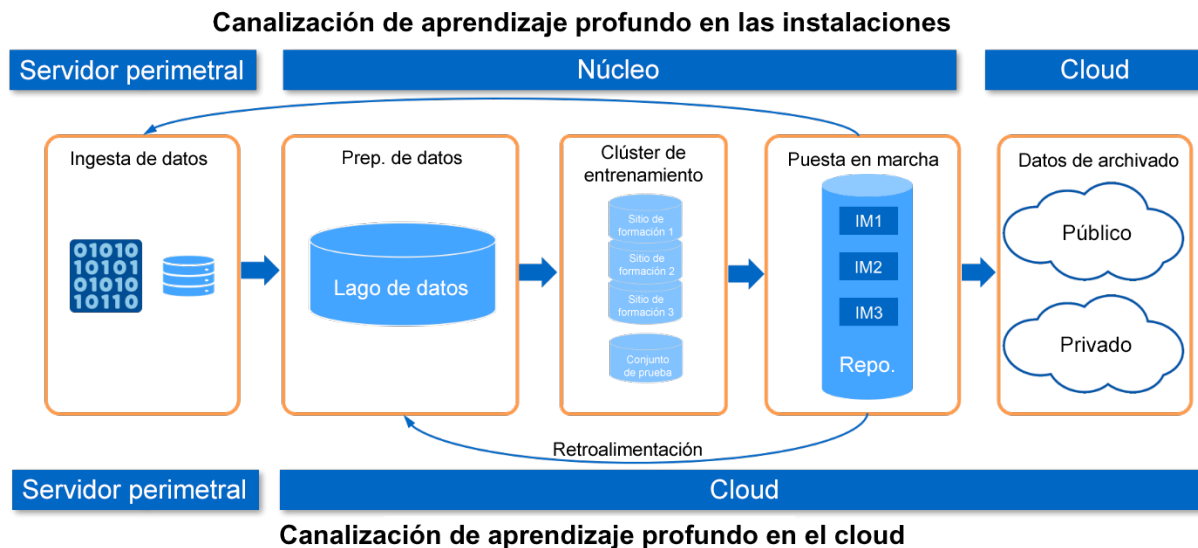


2 Flujo de datos en una canalización de aprendizaje profundo

A la hora de diseñar una canalización de datos para la IA o para el aprendizaje profundo, debería empezar teniendo en cuenta estos pasos, que se muestran en la figura 2:

1. **Ingesta de datos.** La ingesta suele tener lugar en el perímetro; por ejemplo, capturando una transmisión de datos procedente de automóviles o de dispositivos de punto de venta. En función del caso práctico, es posible que la infraestructura tecnológica deba ubicarse en el punto de ingesta o cerca de él. Por ejemplo, un comercio minorista podría necesitar una huella pequeña en cada tienda, consolidando datos de varios dispositivos.
2. **Preparación de los datos.** El procesamiento previo es necesario para normalizar los datos antes de el entrenamiento. El procesamiento previo se lleva a cabo en un lago de datos, posiblemente en el cloud como un nivel S3 o en las instalaciones como almacén de archivos o de objetos.
3. **Entrenamiento.** Durante la crucial fase de entrenamiento del aprendizaje profundo, los datos se suelen copiar a intervalos periódicos del lago de datos al clúster de entrenamiento. Los servidores empleados en esta fase a menudo utilizan unidades de procesamiento gráfico (GPU) o hardware personalizado para paralelizar operaciones, lo que genera una enorme avidez de datos. Un ancho de banda de I/O bruto es esencial.
4. **Puesta en marcha.** El modelo resultante se prueba y luego se traslada a producción. En función del caso de uso, el modelo podría volver a ponerse en marcha en operaciones perimetrales. Se supervisan los resultados reales del modelo y se produce una retroalimentación en forma de datos nuevos que vuelven al lago de datos, junto con datos nuevos que repetirán el proceso.
5. **Archivado.** Los datos fríos de iteraciones anteriores se pueden guardar de forma indefinida. Muchos equipos de IA archivan datos fríos en un almacenamiento de objetos, ya sea en un cloud público o privado.

Figura 2) Las canalizaciones de aprendizaje profundo pueden estar en las instalaciones o en el cloud.



Muchas empresas han tratado de crear este tipo de canalización de datos, ya sea en el cloud o en las instalaciones. Este enfoque suele implicar un hardware genérico y un enfoque de fuerza bruta en la gestión de datos. El cloud puede llegar a tener unos costes realmente elevados. Sacar del cloud grandes cantidades de datos implica incurrir fácilmente en altos costes; una vez consignados ahí los datos, el resto de la canalización probablemente acabará ejecutándose en el cloud. En cualquier caso, será inevitable que se produzcan cuellos de botella a medida que los proyectos pasen al entorno de producción y el volumen de datos vaya aumentando.

Los cuellos de botella más importantes se producen durante la fase de entrenamiento, en la que se necesita una gran cantidad de ancho de banda de I/O con un paralelismo de I/O extremo para alimentar el procesamiento de los datos en el clúster de entrenamiento de aprendizaje profundo. Después de la fase de entrenamiento, los modelos de inferencias resultantes suelen almacenarse en un repositorio tipo DevOps, en el que pueden aprovechar un acceso de latencia ultrabaja.

No obstante, si los datos no avanzan de manera óptima por toda la canalización, comenzando por la ingesta, su canalización de datos de IA nunca logrará una productividad completa. Tendrá que asignar cada vez más tiempo de personal para gestionar la canalización.

3 Acelerar la I/O en una canalización de aprendizaje profundo

Tanto si ejecuta su flujo de trabajo de IA en las instalaciones como si lo hace en el cloud, los cuellos de botella operativos pueden hacer aumentar el tiempo necesario para llevar a cabo cada ciclo de entrenamiento. Este tiempo adicional reduce la productividad de la canalización e implica asignar una valiosa dedicación del personal.

En esta sección se describen soluciones para tratar los cuellos de botella de I/O del perímetro al núcleo y al cloud. A continuación se muestran algunas de ellas:

- Cuellos de botella en el perímetro que reducen la ingesta de datos
- Cuellos de botella en las instalaciones
- Cuellos de botella en el cloud

Las tres fases situadas en el núcleo de la canalización en cuestión (preparación de los datos, entrenamiento y puesta en marcha) crean requisitos de I/O únicos que deben abordarse de forma específica.

3.1 Eliminar los cuellos de botella en el perímetro

El volumen de datos generados por los dispositivos periféricos inteligentes y una gran cantidad de puntos de ingesta puede saturar los recursos computacionales, de almacenamiento y las redes en el perímetro. Estos datos pueden generar cuellos de botella a medida que avanzan hacia su centro de datos o hacia el cloud.

Mediante la aplicación de análisis de nivel perimetral, puede procesar y pasar datos de forma selectiva durante la ingesta. Este enfoque requiere una infraestructura en el perímetro con un alto rendimiento y con un almacenamiento de latencia ultrabaja. Muchos clientes de NetApp están adoptando un enfoque jerárquico, con una infraestructura en el último tramo y con sensores en el perímetro que actúan como extremos.

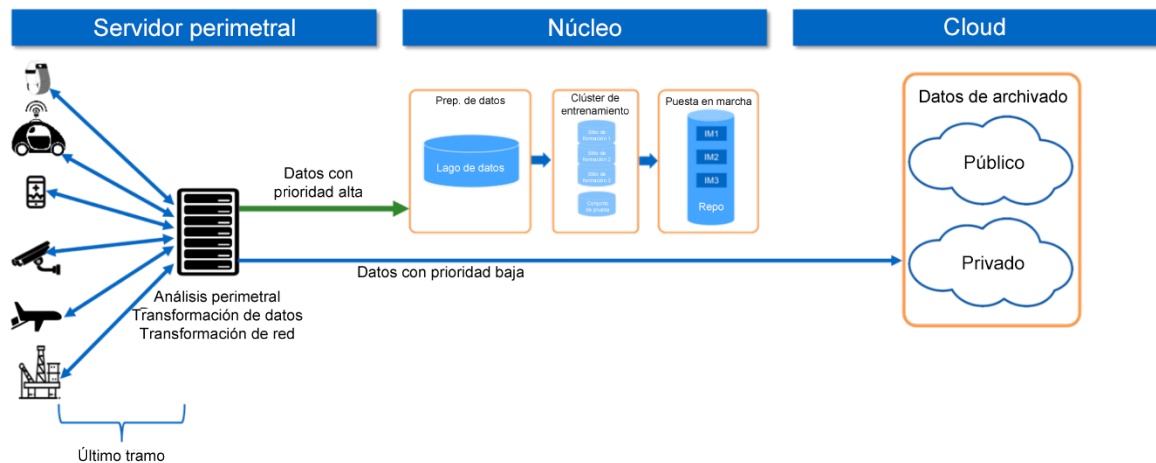
Los sensores de los equipamientos de fabricación suministran datos en la infraestructura implementada en cada centro a fin de incorporar y analizar datos, de modo que se puedan pasar de forma selectiva a lo largo de la cadena. Este enfoque también puede ser idóneo para los vehículos autónomos (en los que cada extremo puede generar hasta 7 TB de datos al día), los comercios minoristas y muchos sectores más.

Gestión de datos por niveles en el perímetro

Mediante el análisis de nivel perimetral, puede crear distintos niveles de servicio de datos. Con este enfoque se da prioridad a algunos datos (ya sea mediante un filtrado sencillo o mediante IA y análisis avanzado), que se pasan de forma eficiente a la canalización de IA, de aprendizaje automático (ML) o de aprendizaje profundo (DL). Por otro lado, se quita prioridad a otros datos, que pueden descartarse o bien gestionarse con otra clase de servicio.

En función de los requisitos, cada nivel de datos se puede procesar con distintas transformaciones a fin de lograr los niveles necesarios de seguridad y eficiencia del almacenamiento. Por ejemplo, los datos con una prioridad baja se podrían comprimir, deduplicar, cifrar y almacenar en un repositorio en el cloud a efectos de cumplimiento de normativas o por si fueran necesarios para su posterior procesamiento (ver figura 3).

Figura 3) Mediante el análisis perimetral con una organización de datos en niveles, los datos perimetrales se pueden separar en datos con prioridad alta destinados al núcleo y en datos con prioridad baja para su archivado.



La capacidad de procesar análisis en el perímetro se establece en función de la potencia de computación disponible. El escenario actual es de competición entre los proveedores de computación y de cloud por hacerse con la huella perimetral con distintas estrategias. Por ejemplo, NVIDIA está llevando la potencia de la GPU al perímetro para poder aplicar la IA en aplicaciones como los vehículos sin conductor. Un aspecto que tienen en común todas estas soluciones desde la óptica de los datos es la incorporación de un almacenamiento DAS genérico que carece de una gestión de datos inteligente. En este caso hay una clara necesidad de almacenamiento de datos inteligente.

Transportadores de datos inteligentes

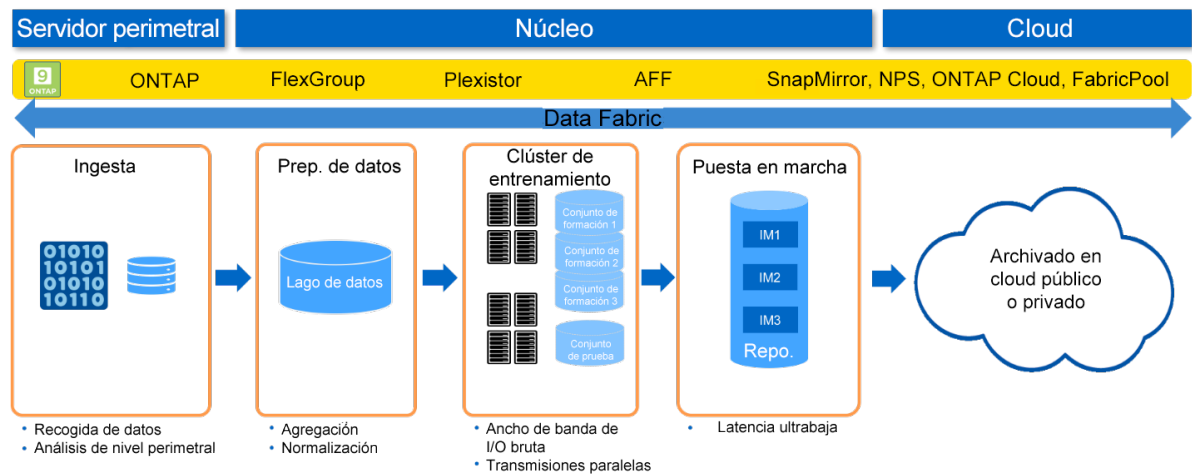
Para suministrar datos desde el perímetro con un ancho de banda alto, uno de los puntos clave es disponer de un transportador de datos inteligente. En la arquitectura actual más habitual, los datos se trasladan mediante transportes de datos completos en forma de objetos PUT S3. Esta práctica tiene la desventaja de que se transportan datos en bloque sin aplicar ninguna transformación.

Este método bruto se puede sustituir por transportadores de datos inteligentes que los fusionen, apliquen transformaciones de datos para reducir el espacio utilizado y transformaciones de red para trasladar únicamente los bloques cambiados. De esta forma se puede acelerar de forma drástica el movimiento de datos y reducir los requisitos de ancho de banda.

3.2 Eliminar los cuellos de botella en las instalaciones

Si el núcleo de su canalización de aprendizaje profundo se encuentra en las instalaciones, como se muestra en la figura 4, tiene un control directo sobre el lago de datos, el clúster de entrenamiento y la puesta en marcha del modelo de inferencias.

Figura 4) Una canalización de aprendizaje profundo con el núcleo de la canalización en las instalaciones.



Lago de datos

A medida que los datos avanzan desde el perímetro, se recopilan en un lago de datos. Un lago de datos mal implementado se convierte en un cuello de botella a medida que aumenta el volumen de datos. Un lago de datos puede adoptar la forma de una puesta en marcha de Hadoop con el sistema de archivos de Hadoop (HDFS) o bien se puede implementar con un almacén de objetos o con un almacén de archivos. HDFS no está optimizado a efectos de rendimiento y suele conservar tres copias de cada objeto de datos, lo que reduce el rendimiento de escritura y aumenta los costes.

Los almacenes de objetos estaban pensados para el archivado en el cloud y no para el rendimiento, pero en muchos casos se han convertido en el almacén de datos "de facto" de proyectos de Big Data. Como hemos visto antes, en relación con el aprendizaje profundo, los almacenes de objetos dejan mucho que desear en cuanto a rendimiento.

En lo que respecta a los almacenes de archivos, los sistemas de archivos de escalado horizontal, como Lustre y GPFS, están diseñados para el procesamiento por lotes de computación de alto rendimiento, por lo que no funcionan bien con cargas de trabajo de archivos pequeños. Los datos que se transmiten al lago de datos desde los dispositivos periféricos inteligentes suelen ser numerosos archivos pequeños, para los que estos sistemas no están optimizados, de ahí que el rendimiento se resienta.

El sistema AFF de NetApp, sobre todo cuando se utiliza con volúmenes de NFS y de ONTAP® FlexGroup, supera las limitaciones de otros enfoques relativos a los lagos de datos. Los grupos de FlexGroup pueden proporcionar un alto rendimiento tanto a las cargas de trabajo de lotes orientadas al ancho de banda como a las de archivos pequeños. Las otras soluciones de lagos de datos mencionadas (HDFS, almacenamiento de objetos, Lustre, GPFS y otros almacenamientos de archivos de escalado horizontal) pueden ofrecer ambas opciones, pero no ofrecen un buen rendimiento para la I/O secuencial y la I/O aleatoria.

Clúster de entrenamiento

Lo último en cuanto a clústeres de entrenamiento de aprendizaje profundo es un clúster de escalado horizontal con entre 32 y 64 servidores y entre 4 y 8 GPU por servidor. Desde un punto de vista de la I/O, debe mantener ocupadas al 100 % todas estas GPU, lo cual significa proporcionar un flujo de I/O paralelo a cada núcleo de CPU. A su vez, cada núcleo de CPU tiene una afinidad con una GPU. La CPU procesa su flujo, fusiona la I/O y alimenta los datos en la GPU.

Este proceso introduce cuellos de botella de I/O de las siguientes formas:

- Los datos se deben transmitir de manera rápida y eficiente desde el lago de datos hasta el clúster de entrenamiento.

- Se deben tener totalmente cargados y organizados hasta 256 flujos de I/O paralelos (entre 32 y 64 servidores, cada uno de ellos con entre 4 y 8 GPU) para alimentar las GPU de manera que nunca tengan que esperar a que lleguen los datos.

La arquitectura de software de ONTAP de NetApp satisface extraordinariamente ambos requisitos. El lago de datos se puede diseñar empleando nodos flash híbridos, que pueden transmitir datos al clúster de entrenamiento con un ancho de banda extremadamente alto. Todos los nodos de almacenamiento all-flash que dan cabida al clúster de entrenamiento pueden ofrecer un ancho de banda de hasta 18 GB/s por pareja de alta disponibilidad de dos controladoras y latencias inferiores a 500 microsegundos, proporcionando el ancho de banda necesario para dar cabida a una gran cantidad de flujos de I/O en paralelo. NetApp también ofrece un plan de acción tecnológico con el que puede seguir aumentando el rendimiento de I/O de su canalización de IA/ML/DL a medida que aumentan sus necesidades.

Puesta en marcha

Una vez concluido el entrenamiento, los modelos de inferencias resultantes se colocan en un repositorio tipo DevOps y se someten a pruebas de inferencia y a validaciones de hipótesis. En esta etapa es importante poner en marcha sistemas de almacenamiento que admitan una latencia extremadamente baja.

Con NetApp, una única arquitectura de almacenamiento aborda todas las necesidades de rendimiento para el núcleo de su canalización de aprendizaje profundo. Aunque este enfoque presenta ventajas directas, el último avance para la mayoría de los clientes consiste en manejar clústeres independientes para cada etapa de la canalización. Las canalizaciones de Big Data deben aplicarse con un lago de datos ya implementado. Tal vez le interese implementar únicamente los elementos nuevos necesarios para el aprendizaje profundo como un proyecto independiente y copiar los datos de fase en fase. No obstante, a medida que los datos vayan aumentando, deberá seguir unificando la canalización. Y AFF también hace posible esta unificación.

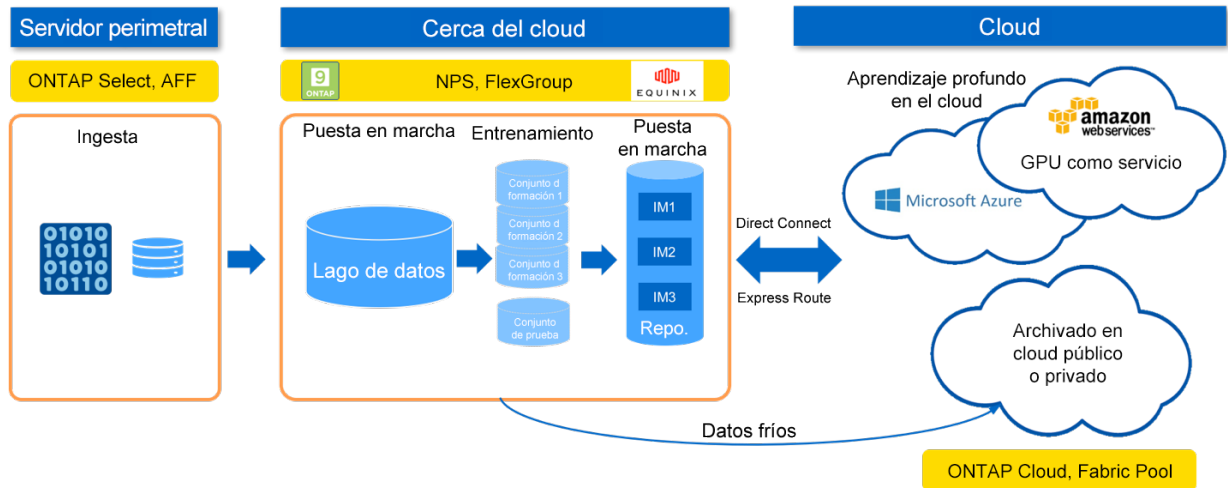
3.3 Eliminar los cuellos de botella en el cloud

Puede que opte por poner en marcha el aprendizaje profundo en el cloud por motivos de agilidad y facilidad de consumo, pero se pueden producir los mismos cuellos de botella al ejecutar la canalización de aprendizaje profundo en el cloud:

- ¿Su lago de datos puede proporcionar el rendimiento necesario para la ingesta de datos?
¿Puede transmitir datos al clúster de entrenamiento?
- ¿Su proveedor de cloud puede ofrecer el paralelismo de I/O necesario para el clúster de entrenamiento?
- ¿Cómo puede proporcionar la latencia ultrabaja necesaria para los modelos de inferencias finalizados?
- ¿Qué pasa si debe asegurarse de la soberanía de los datos confidenciales?

El Almacenamiento privado de NetApp (NPS) le permite almacenar sus datos cerca del cloud de manera que pueda utilizar funcionalidades de cloud computing público y otros servicios, a la vez que controla totalmente sus datos. (ver figura 5). El Almacenamiento privado de NetApp aporta al cloud público la misma arquitectura y el mismo rendimiento descritos en la sección anterior. Los problemas relacionados con la soberanía de datos quedan resueltos y sus datos nunca quedan bloqueados en el cloud.

Figura 5) Si coloca los datos cerca del cloud, puede aprovechar el cloud computing a la vez que ofrece más aceleración de datos y tiene un mayor control.



Si su lago de datos debe residir sí o sí en el cloud, Data Fabric de NetApp le permite almacenar y gestionar sin problemas los datos de NFS en el servicio cloud de Azure o AWS.

4 Sistema de archivos y arquitectura de datos para una canalización de aprendizaje profundo

En una canalización de IA hay distintas características de I/O para los datos transmitidos desde el perímetro en comparación con los datos transmitidos del lago de datos al clúster de entrenamiento. En esta sección se tratan las distintas opciones específicas que debe tener en cuenta para facilitar el flujo de datos a través de la canalización de datos y hacia el clúster de entrenamiento.

Imagínese que las GPU de su clúster de entrenamiento son un automóvil de gama alta. Una buena canalización de datos es como la diferencia entre conducir ese coche en un circuito y conducirlo por la autopista en hora punta. Para conseguir los mejores resultados de su puesta en marcha de la IA, así como del aprendizaje automático y del aprendizaje profundo, la canalización de datos quizás sea lo más importante que hay que tener en cuenta, pero muchas veces se pasa por alto. La arquitectura de datos óptima tiene en cuenta las necesidades de I/O en el perímetro, en el lago de datos y en el clúster de entrenamiento.

El almacenamiento de objetos no está diseñado para aportar el nivel de rendimiento que necesita su canalización de datos. Los almacenes de objetos estaban pensados para el archivado en el cloud y no para el rendimiento, pero en muchos casos se han convertido en el almacén de datos "de facto" de proyectos de Big Data. Para el aprendizaje profundo en concreto, los almacenes de objetos dejan mucho que desear en lo que a rendimiento se refiere.

El sistema de archivos y la arquitectura de datos que elija deben tener en cuenta todos los factores relevantes en su entorno de IA. El almacenamiento basado en archivos sigue siendo una mejor opción, pero hay muchos factores que se deben tener presentes, como se refleja en la tabla 1.

Tabla 1) Preguntas y consideraciones clave.

Preguntas clave	Consideraciones clave
¿Qué sistemas de archivos se deberían tener en cuenta?	<ul style="list-style-type: none"> • Un sistema de archivos de escalado horizontal como Lustre o GPFS • HDFS, un sistema de archivos de Big Data que se utiliza habitualmente • NFS, el sistema de archivos compartidos de mayor implementación para aplicaciones técnicas de los últimos 30 años
¿El sistema de archivos puede incluir y federar datos estructurados y datos no estructurados desde varios orígenes de datos sin tener que sacrificar el rendimiento?	<ul style="list-style-type: none"> • Datos de registro y de sensores • Bases de datos, como RDBMS y NoSQL • I/O aleatoria para distintos tipos de bases de datos: recorridos de tablas, lecturas de documentos y colecciones en NoSQL, lecturas en columnas en bases de datos de columnas y lecturas aleatorias de pares de clave-valor en bases de datos de pares de clave-valor • I/O secuencial para bases de datos en memoria y motores en memoria como Spark • Registros de correo electrónico • Directorios iniciales • Otros orígenes
¿Ofrece rendimiento para una pequeña I/O aleatoria en comparación con la I/O secuencial?	<ul style="list-style-type: none"> • Algunos orígenes de datos generan una I/O aleatoria, mientras que otros son secuenciales. • El sistema de archivos debe poder equilibrar el rendimiento entre ambos tipos de I/O
¿Cuáles son las funcionalidades y el rendimiento de los transportadores de datos?	<ul style="list-style-type: none"> • Rendimiento excepcional • Movimiento de datos de mayor eficiencia
¿Le puede ayudar a la hora de automatizar el ciclo de vida de los datos?	<ul style="list-style-type: none"> • Filtrado inteligente para determinar qué datos van al núcleo en comparación con los niveles de archivado • Rendimiento en tiempo real para las decisiones de filtrado
¿Da cabida a los medios de almacenamiento y de memoria más recientes, posibilitando así avances no disruptivos en cuanto al rendimiento y a la latencia?	<ul style="list-style-type: none"> • Niveles de almacenamiento que pueden cumplir con las expectativas de precio y rendimiento del almacén de datos, como la memoria de clase de almacenamiento (SCM), Non-Volatile Memory Express (NVMe), flash, flash híbrido, disco y cloud • Movimiento de datos no disruptivo por los distintos niveles • Diseños de escalado horizontal para añadir un rendimiento incremental

4.1 Flujo de datos hacia el clúster de entrenamiento

Además de los aspectos detallados en la tabla 1, hay algunos matices relacionados con el modo en que los datos se dirigen al clúster de entrenamiento que se deben entender. Estos factores afectan a los siguientes aspectos:

- La ubicación en la que se fusiona la I/O
- Los requisitos de un espacio de nombres único
- El escalado de los metadatos


Fusión de la I/O

La curación de datos es una función del origen de datos. La fusión de la I/O puede tener lugar en dos sitios distintos:

- En el lago de datos como proceso de la curación y transformación de los datos, con la consiguiente transmisión de I/O al clúster de entrenamiento.
- En el clúster de entrenamiento en cuestión, con la consiguiente I/O aleatoria del lago de datos.

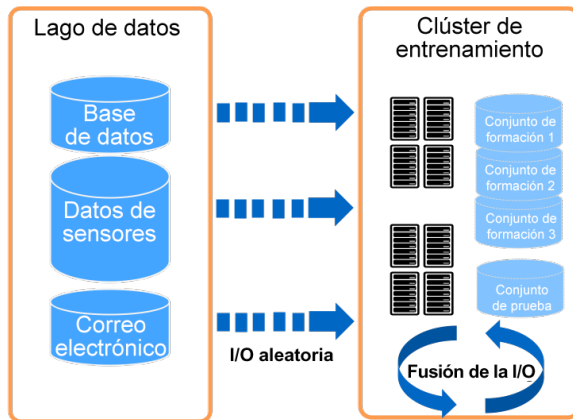
Cuando tiene un lago de datos no estructurados, se trata, casi por definición, de un sistema de archivos. Tiene la capacidad de curar los datos y de presentarlos como un conjunto de flujos de archivos fusionados. Estos flujos de archivos se pueden alinear muy bien con el clúster de entrenamiento, lo que permite que los datos se transmitan directamente a las CPU del clúster para precargar y alimentar las GPU. (ver figura 6).

Figura 6) Los datos no estructurados permiten fusionar los datos en el lago de datos y transmitirlos al clúster de entrenamiento.



Por el contrario, con orígenes de datos como bases de datos, registros de sensores, registros de archivos, correos electrónicos, etc., podría ser imposible disponer de buenas lecturas curadas que le permitan transmitir datos al clúster. En estos casos, se accede a los datos mediante lecturas aleatorias y la fusión de I/O tiene lugar en el clúster de entrenamiento en cuestión. (ver figura 7).

Figura 7) Los datos estructurados se leen utilizando pequeñas I/O aleatorias y se fusionan en el clúster de entrenamiento.



En función de los tipos de orígenes de datos de los que disponga, es posible que su arquitectura de datos tenga que poder proporcionar lecturas secuenciales grandes y lecturas aleatorias pequeñas en el clúster de entrenamiento.

Espacio de nombres único

Los conjuntos de datos de IA tienen el potencial de crecer de forma masiva, lo cual genera una extensión de datos inmensa. El hecho de dar cabida a este crecimiento requiere un sistema de archivos de escalado horizontal con un espacio de nombres único que pueda escalar el rendimiento de forma lineal a un solo nodo de cliente o a varios que accedan a los mismos datos en paralelo. Por ello, resulta crucial disponer de una arquitectura que se pueda seguir escalando a medida que se añade capacidad y computación.

Puede haber distintos tipos de acceso de cliente a este espacio de nombres único, cada uno de ellos con repercusiones en el rendimiento. Algunos modelos de entrenamiento se consideran "asíncronos": se crean particiones estáticas del conjunto de datos por los nodos del clúster de entrenamiento con un acceso de un solo nodo a las distintas regiones del espacio de nombres, con lo que se produce un escenario en el que hay un único cliente activo.

Por otro lado, existen otros modelos de entrenamiento que se ejecutan de forma síncrona. El modelo de entrenamiento y su conjunto de datos tienen un estrecho vínculo y el conjunto de datos se comparte por todos los nodos del clúster con acceso simultáneo. Este escenario en el que hay varios clientes activos es el caso más exigente desde un punto de vista del rendimiento.

Existen otros casos prácticos en los que una red neuronal multicapa forma las capas de la red en distintos nodos. Los nodos actúan como canalización de modelo en la que el modelo progresa de un nodo al siguiente. En este enfoque, todo el conjunto de datos se lee repetidamente, de nodo en nodo, en una clase de acceso de "barrido de mano" (sweeping hand).

A medida que vaya analizando los sistemas de archivos capaces de tratar estos patrones de uso, verá que NFS se ha aplicado a una amplia gama de cargas de trabajo. Estas cargas de trabajo comprenden desde sus raíces de la computación de alto rendimiento y los directorios iniciales a las bases de datos, como Oracle y SQL, que se ejecutan en un almacenamiento conectado a la red, hasta SAP y más recientemente, la virtualización y el Big Data. Este extenso historial de uso de NFS en numerosas cargas de trabajo le permite manejar tanto la I/O aleatoria como la secuencial. Esta I/O se puede generar mediante distintos patrones de acceso al espacio de nombres, sobre todo cuando se combina con las ventajas del almacenamiento all-flash en un clúster lineal de escalado horizontal.

HDFS, un sistema de archivos relativamente nuevo, ha tenido una exposición limitada a distintas cargas de trabajo de datos y a distintas características de rendimiento. Los proveedores de Big Data han realizado reescrituras significativas (y de propiedad) para abordar las necesidades en términos de rendimiento en la transición de MapReduce a Spark. La IA introduce otra vuelta de tuerca en la historia de HDFS.

Depender de un sistema de archivos específico de Big Data como HDFS puede comportar más copias de datos y silos, ya que deberá hacer otra copia de datos desde HDFS en un sistema de archivos de escalado horizontal de alto rendimiento para la IA.

Rendimiento de los metadatos

Los patrones de acceso mencionados anteriormente también tienen implicaciones en el rendimiento de los metadatos. Cada nodo del clúster de entrenamiento podría consultar los metadatos de manera independiente, por lo que el rendimiento del acceso a los metadatos se debe escalar de forma lineal con el crecimiento del sistema de archivos. El acceso a los metadatos con sistemas de archivos como Lustre y GPFS puede convertirse en un cuello de botella debido a la dependencia de almacenamiento y de servidores de metadatos independientes.

4.2 Otros factores relativos al rendimiento

Hay otros factores que deberá tener en cuenta a la hora de elegir un sistema de archivos para su canalización de datos de IA que afectan tanto al rendimiento como a la facilidad de uso. Algunos de ellos son los siguientes:

- Facilidad de gestión
- Calidad de servicio (QoS)
- Funcionalidades de clonado
- Ecosistema de soluciones de almacenamiento en caché en el cliente
- Capacidad de aplicar una IA/DL "in situ" con un sistema de archivos unificado por todo el lago de datos y por todos los niveles de IA/DL
- Mejor soporte de medios
- Garantía de futuro

Facilidad de gestión

A medida que evalúa los sistemas de archivos, es importante formular preguntas relativas a la gestión. ¿El sistema de archivos se puede escalar de forma autónoma y automática sin la intervención de la gestión? ¿Cuánto tiempo y qué grado de experiencia técnica necesita el sistema de archivos para llevar a cabo tareas de gestión? ¿En qué medida es fácil encontrar personas que cuenten con la experiencia necesaria?

Los sistemas de archivos de escalado horizontal como Lustre y GPFS pueden ser difíciles de configurar, mantener, supervisar y gestionar. En cambio, NFS es fácil de gestionar y los conocimientos en NFS están extendidos.

Calidad de servicio

La calidad de servicio también puede ser un elemento importante de su arquitectura de datos. Es posible que esté creando clústeres de entrenamiento multi-tenant con costes que alcanzan los millones de dólares. La calidad de servicio desempeña un papel clave en su capacidad de ofrecer multi-tenancy, lo que permite que distintas actividades compartan los mismos recursos.

- ¿El sistema de archivos ofrece calidad de servicio?
- ¿La calidad de servicio está incorporada de forma integral?
- ¿Puede aplicar límites al consumo del rendimiento en el almacenamiento, las redes y la computación para dividir los niveles de servicio para distintos modelos de entrenamiento?

Funcionalidades de clonado

Parte del requisito de multi-tenancy consiste en satisfacer distintas funciones en su organización. Podría tener una serie de modelos de entrenamiento en distintas etapas de desarrollo, que darían como resultado diferentes casos prácticos:

- Entrenamiento inicial
- Validación del modelo

- Implementación previa
- Implementación de producción

Gracias a la capacidad de clonar conjuntos de datos y de asignar distintas configuraciones de calidad de servicio a cada clon, puede proporcionar distintos acuerdos de nivel de servicio de rendimiento para distintos casos prácticos. Así pues, el clonado con gestión eficiente del espacio es un elemento indispensable para un clúster multi-tenant.

Almacenamiento en caché en el cliente

El uso de una caché en el cliente permite seguir acelerando el rendimiento al proporcionar un búfer de datos que posibilita un flujo de datos ininterrumpido mientras se accede al conjunto de datos de entrenamiento desde los nodos del clúster de entrenamiento. Un sistema de archivos que dé cabida a un ecosistema de productos de almacenamiento en caché de cliente (ya sean de código abierto o comerciales) puede implicar importantes ventajas.

Para el almacenamiento basado en NFS existen numerosas opciones comerciales y de código abierto; pocas si ya existe algún producto de almacenamiento en caché en el cliente para Lustre, GPFS o HDFS. Prácticamente ninguna de ellas son de código abierto y no tienen una amplia disponibilidad.

IA/AP "in situ" con un sistema de archivos unificado

Habrán casos en los que quiera utilizar los mismos datos para tratar cargas de trabajo de análisis de Big Data y cargas de trabajo de IA/ML/DL. Para la IA que se aplica al posprocesamiento (como en la vigilancia, la detección de fraudes, etc.), el sistema de archivos adecuado permite efectuar ambas cargas de trabajo sin tener que hacer copias de datos. El conjunto de datos reside en una única ubicación. Tanto el análisis "in situ" como el procesamiento computacional de IA/ML/DL "in situ" se aplican (posiblemente con el almacenamiento en caché en el cliente, como acabamos de comentar) sin copiar los datos en sistemas de archivos dedicados de su lago de datos y su clúster de entrenamiento.

No obstante, si el rendimiento en tiempo real es un requisito esencial o un diferenciador de la competencia clave, probablemente seguirá necesitando una copia de datos dedicada para el clúster de entrenamiento.

Soporte para los medios y la memoria de vanguardia

Por último, escoja un sistema de archivos que pueda dar cabida a los últimos avances en cuanto a medios y memoria, de modo que el rendimiento de su canalización de datos pueda seguir evolucionando junto con el plan de acción tecnológico. ¿El sistema de archivos está optimizado para el flash actual? ¿Se puede ampliar sin problemas el soporte de nuevas tecnologías? ¿Están innovando de forma activa los proveedores en campos como NVMe over Fabrics (NVMe-oF), NVDIMM o 3D XPoint?

El flash actual puede llegar a tener latencias de cerca de 500 microsegundos. NVMe-oF las reduce a 200 microsegundos. Las tecnologías NVDIMM, 3D XPoint y de memoria persistente están preparadas para alcanzar latencias inferiores a los 100 microsegundos, inferiores a los 10 microsegundos y, con el tiempo, en cuestión de nanosegundos. Su proveedor de canalizaciones de datos tiene que invertir continuamente para seguir el ritmo de esta evolución en las soluciones de almacenamiento compartido y en las soluciones basadas en servidores.

Garantizar el futuro de la arquitectura de datos y del sistema de archivos que elija

El sector de la IA en su conjunto está evolucionando muy rápidamente, pero puede resultar poco práctico o incluso imposible de reconstruir desde cero en cuestión de medio año a un año. Como reflexión final, debería tratar de tomar decisiones relativas a la tecnología que tengan la mayor garantía de futuro posible. Es importante desarrollar de forma fluida y no disruptiva distintas capas de tecnología (por ejemplo, un sistema de archivos, una interconexión, una ubicación de puesta en marcha, medios o un tipo de memoria) en una infraestructura que hayamos elegido. Esta

funcionalidad permite tener un retorno de la inversión a largo plazo y la capacidad de asimilar evoluciones tecnológicas a medida que se originan.

El sistema de archivos que elija hoy probablemente dependerá de los niveles de confort, de las habilidades y de la experiencia previa de su equipo. Probablemente querrá tener en cuenta cualquier experiencia de puesta en marcha anterior, las puestas en marcha existentes y la infraestructura existente.

A modo de ejemplo, si se siente cómodo y tiene pensado efectuar una puesta en marcha en FC o en InfiniBand, le convendría una arquitectura SAN y Lustre o GPFS. Con el tiempo, tal vez decida que una hoja de ruta de 100 o 400 GbE con NFS se ajusta mejor a sus necesidades. Una arquitectura de datos bien planificada es capaz de acomodar la solución y de garantizar su futuro, de manera que pueda cambiar de sistema de archivos sin problemas y sin tener que sustituir la infraestructura.

Asimismo, puede que hoy elija NFS pero, en el futuro, decida que necesita un sistema de archivos basado en SAN, NVMe o NVMe-oF o una distribución de datos basada en una memoria persistente. Una arquitectura con garantía de futuro le permite desarrollar las tecnologías de almacenes de datos sin tener que sustituir toda su infraestructura desplegada.

Los criterios descritos en este capítulo deberían haberle servido como un buen punto de partida para seleccionar un sistema de archivos y una arquitectura de datos que se ajusten al máximo a sus necesidades de inteligencia artificial, aprendizaje automático o aprendizaje profundo. Creemos que la combinación de NFS ejecutado en un almacenamiento All Flash FAS de NetApp es la mejor opción según nuestra experiencia en abordar estas necesidades y de evolucionar a fin de adoptar las tecnologías más recientes.

5 Tecnologías de NetApp y la canalización de aprendizaje profundo

Data Fabric de NetApp incluye tecnologías de gestión de datos para satisfacer las necesidades de toda la canalización de aprendizaje profundo (ver figura 8). Los proveedores de cloud por sí mismos no abarcan el perímetro y podrían verse apurados por el rendimiento de I/O. Otros proveedores de almacenamiento tratan de resolver los problemas del ancho de banda durante el entrenamiento, pero son incapaces de proporcionar una latencia ultrabaja y no disponen de la tecnología necesaria para abordar todo el flujo de trabajo. Aquí es donde Data Fabric de NetApp ofrece claras ventajas.

En el perímetro, NetApp ofrece ONTAP Select, que se ejecuta en un hardware genérico para hacer posible la agregación de datos y la gestión de datos avanzada. Nuestra próxima tecnología Plexistor facilitará la ingesta, sobre todo en los casos en los que la tasa de ingesta es extremadamente alta.

Con el objetivo de abordar las necesidades de almacenamiento del lago de datos y del clúster de entrenamiento, el almacenamiento AFF de NetApp proporciona un alto rendimiento y una gran capacidad, a la vez que reduce la necesidad de utilizar copias de datos lentas. NetApp está trabajando para proporcionar NVMe-oF y Plexistor a fin de seguir ampliando las funcionalidades de AFF. El Almacenamiento privado de NetApp ofrece muchas de estas ventajas para las canalizaciones de aprendizaje profundo en el cloud.

En cuanto al archivado de datos fríos, FabricPool migra los datos a un almacenamiento de objetos de forma automática a partir de unas políticas definidas.

Figura 8) Tecnologías de NetApp para Data Fabric.

	Servidor perimetral	Núcleo	Cloud
Hoy	ONTAP® Select Agregación de datos y gestión en el hardware genérico	All Flash FAS Almacenamiento all-flash de alto rendimiento	Almacenamiento privado de NetApp Almacenamiento de alto rendimiento cerca del cloud
Futuro	Plexistor Almacenamiento de latencia ultrabaja en el lado servidor	<ul style="list-style-type: none"> NVMe-oF Plexistor 	Pool de estructura Organización en niveles automatizada de datos fríos en el cloud

6 Garantizar el futuro de su canalización de aprendizaje profundo

El tamaño de los conjuntos de datos de aprendizaje profundo y los requisitos de I/O de su canalización de aprendizaje profundo seguirán aumentando, casi con toda probabilidad, a medida que incremente el número de servidores y las CPU, GPU y el silicio de IA específico seguirán aumentando en potencia. La hoja de ruta de NetApp incorpora una serie de elementos que le permitirán escalar la I/O para mantenerse al día. Algunos de ellos son los siguientes:

- **NVMe-oF.** La incorporación de NVMe-oF como elemento de la arquitectura AFF permite a NetApp controlar las latencias en un orden de magnitud inferior.
- **Plexistor.** En junio de 2017, NetApp adquirió Plexistor, lo que nos aportó una tecnología de almacenamiento en el lado servidor que reduce aún más las latencias y amplía Data Fabric de NetApp al servidor. Plexistor se puede poner en marcha en el perímetro, en el núcleo y en el cloud, acelerando la ingesta de datos, el análisis perimetral y el entrenamiento.

Además, si el núcleo de su canalización de IA actualmente se encuentra en las instalaciones, tal vez le interese estudiar algunas estrategias que facilitan la evolución del hardware del núcleo. También debería planificar la posibilidad de que en un futuro necesite pasar de una estrategia que vaya del perímetro al núcleo y al cloud a una estrategia que vaya del perímetro al cloud.

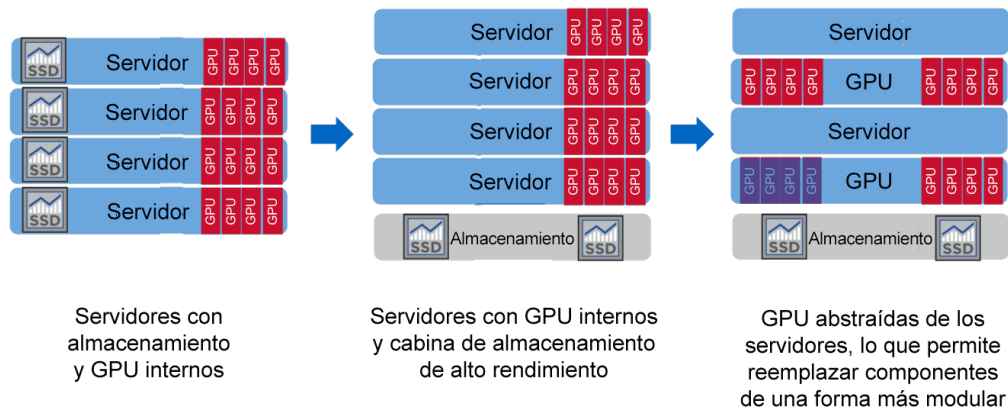
6.1 Planificar la evolución del hardware en el núcleo

Una ventaja que tiene el cloud es que puede consumir un servicio de aprendizaje profundo sin tener que entender los entresijos de la pila de hardware, aunque paga un precio por esa comodidad en términos de pérdida de control. Si pensamos en el núcleo de la canalización de aprendizaje profundo en las instalaciones, una de las tendencias clave es la evolución constante del hardware necesario.

Se está produciendo una fuerte pugna por cuál será el proveedor de hardware elegido para el aprendizaje profundo. Aunque NVIDIA está en cabeza por el momento, hay numerosas tecnologías emergentes. Cada proveedor de cloud crea su propio hardware personalizado (la unidad de procesamiento tensorial (TPU) de Google es un ejemplo) y muchas empresas emergentes también crean su propio hardware personalizado de IA.

Una tendencia que cabe vigilar de cerca es la capacidad de separar la infraestructura del servidor de la infraestructura de la GPU, que permite que ambas crezcan de forma independiente. Una solución que abstraiga el hardware de GPU del hardware de servidor y de almacenamiento (ver figura 9) podrá evolucionar con mayor facilidad (y con un menor costo) para sacar provecho de los nuevos desarrollos.

Figura 9) El núcleo de su canalización de IA/ML/DL seguirá creciendo.



NetApp ofrece una infraestructura convergente con una serie de partners de servidores, como Cisco ([FlexPod®](#)) o Fujitsu ([NFLEX™](#), una infraestructura convergente de NetApp y Fujitsu), entre otros proveedores. Esto quiere decir que puede aprovechar fácilmente el almacenamiento de NetApp junto con una serie de plataformas de servidores a la hora de crear su clúster de aprendizaje profundo.

Conclusión: tome el control de su canalización de datos y de su futuro respecto a la IA

Las pautas descritas en este whitepaper tienen la finalidad de ayudarle a planificar su canalización de datos. Algunas de ellas son las siguientes:

- Elija el mejor sistema de archivos y la mejor arquitectura de datos para satisfacer sus necesidades actuales, sin perder de vista el futuro.
- Acelere el flujo de datos a través de su canalización, tanto en las instalaciones como en el cloud.
- Implemente una gestión de datos inteligente en el perímetro para hacer frente al crecimiento de los datos de forma óptima.
- Mueva los datos de forma más inteligente y eficiente del perímetro al núcleo o al cloud.
- Esté preparado para adoptar un modelo que vaya del perímetro al cloud si resulta preciso.
- Cree una arquitectura de hardware de núcleo más ágil que pueda evolucionar rápidamente.

Si toma estas medidas, puede deshacerse de los cuellos de botella y conseguir un mayor rendimiento, así como garantizar el futuro de las inversiones que haga en su infraestructura de IA.

Consulte la [matriz de interoperabilidad \(IMT\)](#) en el sitio web de soporte de NetApp con el fin de confirmar que las versiones exactas del producto y las funciones descritas en este documento son compatibles con su entorno concreto. La herramienta IMT de NetApp define los componentes y las versiones del producto que pueden utilizarse para crear configuraciones que sean compatibles con NetApp. Los resultados específicos dependen de la instalación que realice cada cliente de acuerdo con las especificaciones publicadas.

Información de copyright

Copyright © 2018 NetApp, Inc. Todos los derechos reservados. Impreso en EE. UU. No se puede reproducir este documento protegido por copyright ni parte del mismo de ninguna forma ni por ningún medio (gráfico, electrónico o mecánico, incluidas fotocopias, grabaciones o almacenamiento en un sistema de recuperación electrónico) sin la autorización previa y por escrito del propietario del copyright.

El software derivado del material de NetApp con copyright está sujeto a la siguiente licencia y exención de responsabilidad:

ESTE SOFTWARE LO PROPORCIONA NETAPP "TAL CUAL" Y SIN NINGUNA GARANTÍA EXPRESA O IMPLÍCITA, INCLUYENDO, SIN EXENCIÓN, LAS GARANTÍAS IMPLÍCITAS DE COMERCIALIZACIÓN O IDONEIDAD PARA UN FIN CONCRETO, CUYA RESPONSABILIDAD QUEDA EXIMIDA POR EL PRESENTE DOCUMENTO. EN NINGÚN CASO NETAPP SERÁ RESPONSABLE DE NINGÚN DAÑO DIRECTO, INDIRECTO, ESPECIAL, EJEMPLAR O RESULTANTE (INCLUYENDO, ENTRE OTROS, LA OBTENCIÓN DE BIENES O SERVICIOS SUSTITUTIVOS, PÉRDIDA DE USO, DE DATOS O DE BENEFICIOS, O INTERRUPCIÓN DE LA ACTIVIDAD EMPRESARIAL) CUALQUIERA SEA EL MODO EN EL QUE SE PRODUJERON Y LA TEORÍA DE RESPONSABILIDAD QUE SE APLIQUE, YA SEA EN CONTRATO, RESPONSABILIDAD OBJETIVA O AGRAVIO (INCLUIDA LA NEGLIGENCIA U OTRO TIPO), QUE SURJAN DE ALGÚN MODO DEL USO DE ESTE SOFTWARE, INCLUSO SI HUBIEREN SIDO ADVERTIDOS DE LA POSIBILIDAD DE TALES DAÑOS.

NetApp se reserva el derecho de modificar cualquiera de los productos aquí descritos en cualquier momento y sin aviso previo. NetApp no asume ningún tipo de responsabilidad que surja del uso de los productos aquí descritos, excepto aquello expresamente acordado por escrito por parte de NetApp. El uso o adquisición de este producto no lleva implícita ninguna licencia con derechos de patente, de marcas comerciales o cualquier otro derecho de propiedad intelectual de NetApp.

Es posible que el producto que se describe en este manual esté protegido por una o más patentes de EE. UU., patentes extranjeras o solicitudes pendientes.

LEYENDA DE DERECHOS LIMITADOS: El uso, la copia o la divulgación por parte del gobierno están sujetos a las restricciones establecidas en el subpárrafo (c)(1)(ii) de la cláusula sobre derechos de datos técnicos y software informático de DFARS 252.277-7103 (octubre de 1988) y FAR 52-227-19 (junio de 1987).

Información sobre marcas

NETAPP, el logotipo de NETAPP y las marcas que constan en <http://www.netapp.com/TM> son marcas registradas de NetApp, Inc. El resto de los nombres de empresa y de producto pueden ser marcas registradas de sus respectivos propietarios.