



# Hybrides Cloud-KI-Betriebssystem mit Daten-Caching

NetApp Solutions

NetApp  
January 30, 2025

# Inhalt

- Hybrides Cloud-KI-Betriebssystem mit Daten-Caching ..... 1
  - TR-4841: Hybrides Cloud-KI-Betriebssystem mit Daten-Caching ..... 1
  - Fallübersicht zu Anwendungsfall und Problembeschreibung ..... 1
  - Lösungsüberblick ..... 3
  - Konzepte und Komponenten ..... 7
  - Hardware- und Software-Anforderungen ..... 9
  - Details zur Lösungsimplementierung und -Validierung ..... 11
  - Schlussfolgerung ..... 22
  - Weitere Informationen ..... 22

# Hybrides Cloud-KI-Betriebssystem mit Daten-Caching

## TR-4841: Hybrides Cloud-KI-Betriebssystem mit Daten-Caching

Rick Huang, David Arnette, NetApp Yochay Ettun, cnvrg.io

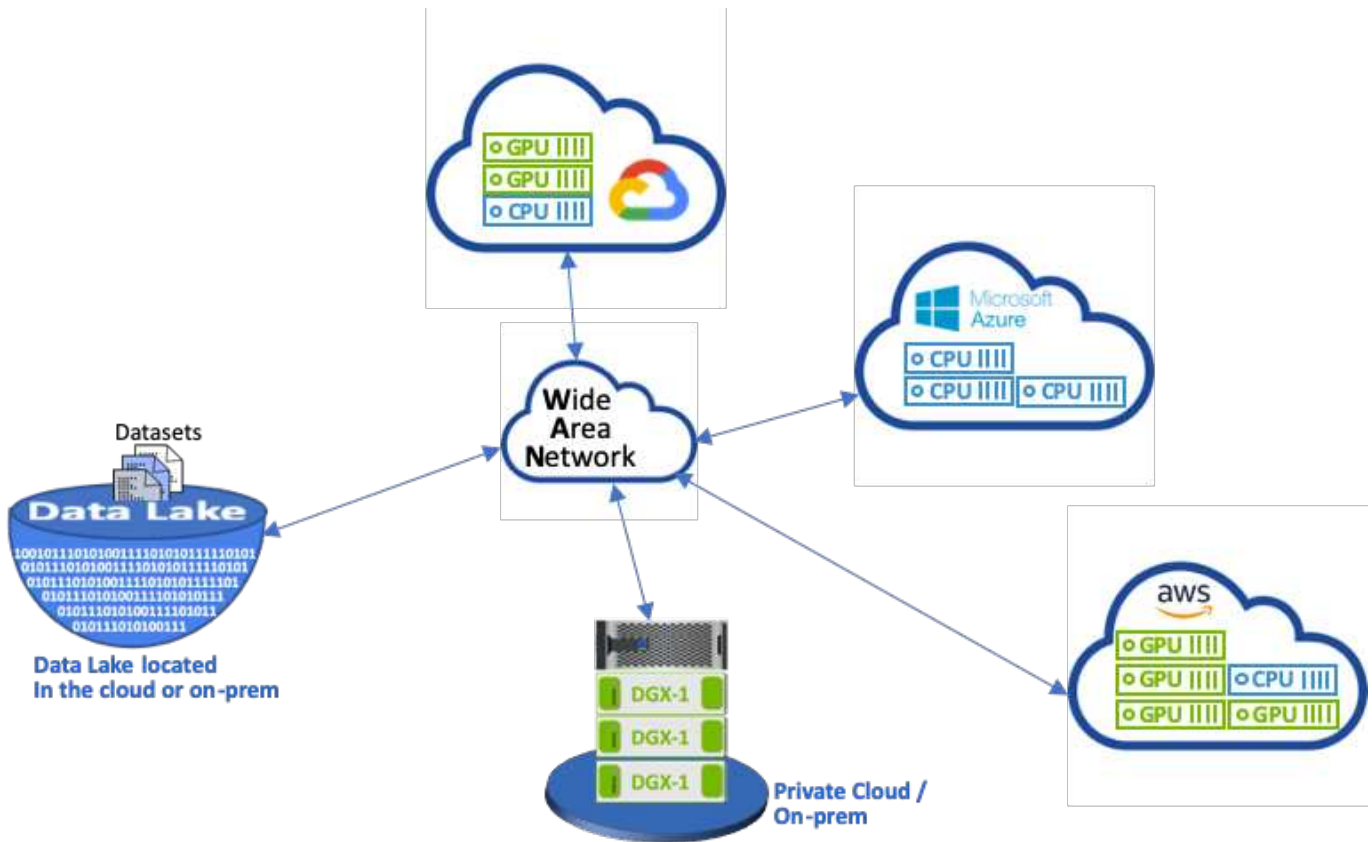
Das explosionsartige Datenwachstum und das exponentielle Wachstum VON ML und KI haben sich konvergiert, um eine Zettabyte-Wirtschaft mit einzigartigen Herausforderungen bei Entwicklung und Implementierung zu schaffen.

Es ist zwar allgemein bekannt, dass ML-Modelle datenintensiv sind und in Bezug auf Computing-Ressourcen hochperformanten Storage benötigen. In der Praxis ist es jedoch nicht ganz einfach, dieses Modell zu implementieren, insbesondere bei Hybrid Cloud- und elastischen Computing-Instanzen. In der Regel werden enorme Datenmengen in kostengünstigen Data Lakes gespeichert, auf denen hochperformante KI-Computing-Ressourcen wie GPUs nicht effizient zugreifen können. In einer Hybrid-Cloud-Infrastruktur, in der einige Workloads in der Cloud ausgeführt werden und einige sich vor Ort oder in einer anderen HPC-Umgebung vollständig befinden, wird dieses Problem verschärft.

In diesem Dokument stellen wir eine neue Lösung vor, mit der IT-Experten und Data Engineers eine echte Hybrid-Cloud-KI-Plattform erstellen können. Diese Plattform bietet einen Topologiefähigen Daten-Hub, mit dem Datenanalysten sofort und automatisch einen Cache ihrer Datensätze in der Nähe ihrer Computing-Ressourcen erstellen können. Wo immer sie sich befinden. Somit kann nicht nur das Training eines hochperformanten Modells durchgeführt werden, sondern es werden auch zusätzliche Vorteile erzielt, etwa die Zusammenarbeit mehrerer KI-Fachleute, die innerhalb eines Dataset-Version-Hubs sofortigen Zugriff auf Datensatz-Caches, -Versionen und -Lineages haben.

## Fallübersicht zu Anwendungsfall und Problembeschreibung

Datensätze und Datensatzversionen befinden sich normalerweise in einem Data Lake, wie z. B. objektbasierter NetApp StorageGRID Storage, der geringere Kosten und andere betriebliche Vorteile bietet. Die Data Scientists erhalten diese Datensätze in mehreren Schritten, um sie für das Training mit einem bestimmten Modell vorzubereiten. Oft erstellen sie dabei mehrere Versionen. Im nächsten Schritt muss der Data Scientist optimierte Computing-Ressourcen (GPUs, High-End-CPU-Instanzen, On-Premises-Cluster usw.) auswählen, um das Modell auszuführen. Die folgende Abbildung zeigt den Mangel an Dataset-Nähe in einer ML-Computing-Umgebung.



Mehrere Trainingsversuche müssen jedoch parallel in verschiedenen Computing-Umgebungen ausgeführt werden, von denen jeder einen Download des Datensatzes aus dem Data Lake erfordert, was ein kostspieliger und zeitaufwendiger Prozess ist. Die Nähe des Datensatzes zur Computing-Umgebung (insbesondere bei einer Hybrid Cloud) ist nicht garantiert. Außerdem müssen andere Teammitglieder, die ihre eigenen Experimente mit demselben Datensatz durchführen, denselben mühsamen Prozess durchlaufen. Neben dem offensichtlichen langsamen Datenzugriff sind Probleme bei der Nachverfolgung von Datensatzversionen, der Datensatzfreigabe, der Zusammenarbeit und der Reproduzierbarkeit zu überwinden.

## Kundenanforderungen

Die Kundenanforderungen können variieren, um bei effizienter Nutzung von Ressourcen hochperformante ML-Durchläufe zu erreichen. Kunden benötigen beispielsweise Folgendes:

- Schneller Zugriff auf Datensätze von jeder Computing-Instanz, die das Trainingsmodell ausführt, ohne dass teure Downloads und der Datenzugriff komplexer werden
- Die Verwendung von Compute-Instanzen (GPU oder CPU) in der Cloud oder lokal, ohne sich um den Speicherort der Datensätze zu kümmern
- Höhere Effizienz und Produktivität, da mehrere Trainingsversuche parallel mit unterschiedlichen Computing-Ressourcen auf demselben Datensatz durchgeführt werden können ohne unnötige Verzögerungen und Datenlatenz
- Minimale Kosten für Computing-Instanzen
- Verbesserte Reproduzierbarkeit mit Tools, mit denen Datensätze, deren Herkunft, Versionen und andere Metadatendetails aufgezeichnet werden können
- Verbessertes Sharing und Zusammenarbeit, sodass autorisierte Teammitglieder auf die Datensätze zugreifen und Experimente ausführen können

Zur Implementierung von Datensatz-Caching mit NetApp ONTAP Datenmanagement-Software müssen

Kunden die folgenden Aufgaben durchführen:

- Konfigurieren Sie den NFS-Storage, der den Computing-Ressourcen am nächsten ist, und legen Sie ihn fest.
- Bestimmen Sie, welche Datensätze und Version im Cache gespeichert werden sollen.
- Überwachen Sie den gesamten Arbeitsspeicher, der in Cache-Datensätzen gespeichert ist, und wie viel NFS-Speicher für zusätzliche Cache-Commits zur Verfügung steht (beispielsweise Cache-Management).
- Alter aus Datensätzen im Cache, wenn sie in einer bestimmten Zeit nicht verwendet wurden. Die Standardeinstellung ist ein Tag; weitere Konfigurationsoptionen sind verfügbar.

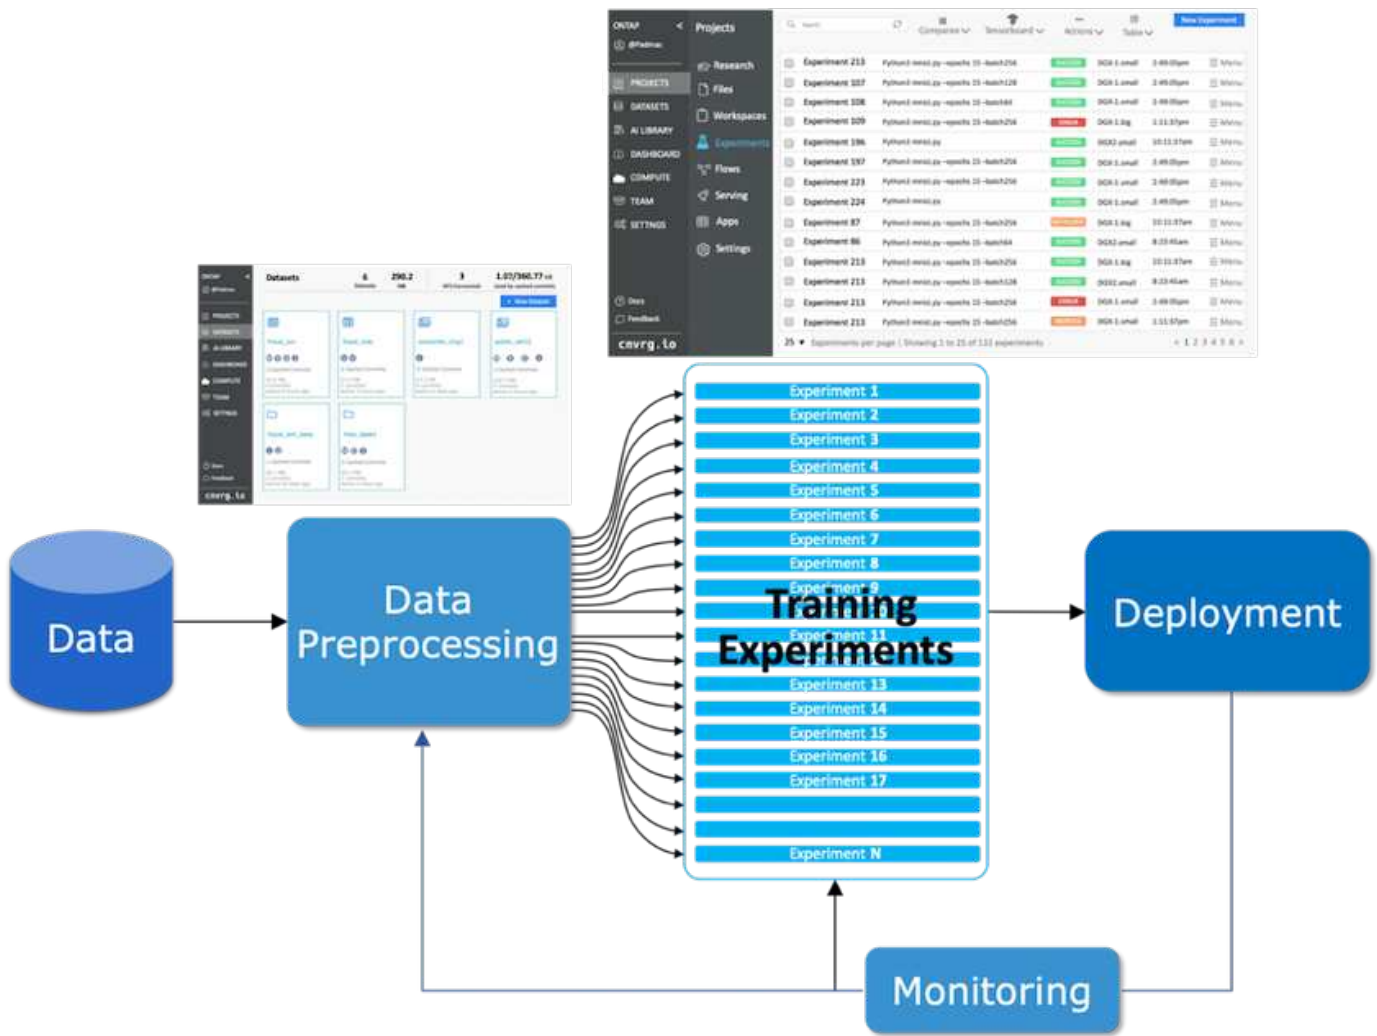
## Lösungsüberblick

In diesem Abschnitt werden eine konventionelle Datenwissenschaftspipeline und ihre Nachteile überprüft. Sie stellt außerdem die Architektur der vorgeschlagenen Lösung für das Datensatz-Caching dar.

### Herkömmliche Data Science-Pipeline und Nachteile

Eine typische Sequenz der ENTWICKLUNG und Bereitstellung VON ML-Modellen umfasst iterative Schritte, die Folgendes beinhalten:

- Datenaufnahme
- Datenvorverarbeitung (Erstellung mehrerer Versionen der Datensätze)
- Durchführung mehrerer Experimente mit Hyperparameter-Optimierung, verschiedenen Modellen usw.
- Einsatz
- Monitoringcnvrg.io hat eine umfassende Plattform entwickelt, um alle Aufgaben von der Forschung bis zur Bereitstellung zu automatisieren. In der folgenden Abbildung ist ein kleiner Ausschnitt von Dashboard-Screenshots zu der Pipeline dargestellt.



In der Handhabung sind mehrere Datensätze häufig aus öffentlichen Repositories und privaten Daten wiedergegeben. Darüber hinaus verfügt jeder Datensatz wahrscheinlich über mehrere Versionen, die sich aus der Datenbereinigung oder dem Feature Engineering ergeben. Eine Konsole, die einen Datensatz-Hub und einen VersionHub bereitstellt, ist erforderlich, um sicherzustellen, dass dem Team Collaboration- und Konsistenztools zur Verfügung stehen, wie in der folgenden Abbildung zu sehen sind.

The screenshot displays the ONTAP Datasets interface. At the top, it shows a summary: 6 Datasets (290.2 MB) and 3 NFS Connected (1.07/360.77 GB Used by cached commits). A '+ New Dataset' button is visible. The datasets listed are:

Dataset Name	Size	Commits	Active Time
fraud_jun	32.4 MB	4 commits	Active 8 hours ago
fraud_may	57.6 MB	2 commits	Active 3 hours ago
consumer_img1	27.3 MB	4 commits	Active 4 days ago
public_set12	102.7 MB	7 commits	Active 4 hours ago
fraud_sim_base	45.1 MB	2 commits	Active 24 days ago
misc_base1	25.1 MB	1 commit	Active 2 days ago

Der nächste Schritt in der Pipeline ist das Training. Es erfordert mehrere parallele Instanzen von Trainingsmodellen, die jeweils mit einem Datensatz und einer bestimmten Computing-Instanz verknüpft sind. Die Bindung eines Datensatzes an ein bestimmtes Experiment mit einer bestimmten Computing-Instanz ist eine Herausforderung, da es möglich ist, dass einige Experimente mit GPU-Instanzen von Amazon Web Services (AWS) durchgeführt werden, während andere Experimente vor Ort durch DGX-1 oder DGX-2-Instanzen durchgeführt werden. Andere Experimente können auf den CPU-Servern in GCP ausgeführt werden, während der Speicherort des Datensatzes nicht in angemessenem Umfang zu den Computing-Ressourcen liegt, die das Training durchführen. In angemessener Nähe wären volle 10 GbE oder mehr Konnektivität mit niedriger Latenz vom Datensatz-Storage zur Computing-Instanz.

Data Scientists können den Datensatz in die Computing-Instanz herunterladen, die das Training durchführt und das Experiment ausführt. Allerdings gibt es bei diesem Ansatz mehrere potenzielle Probleme:

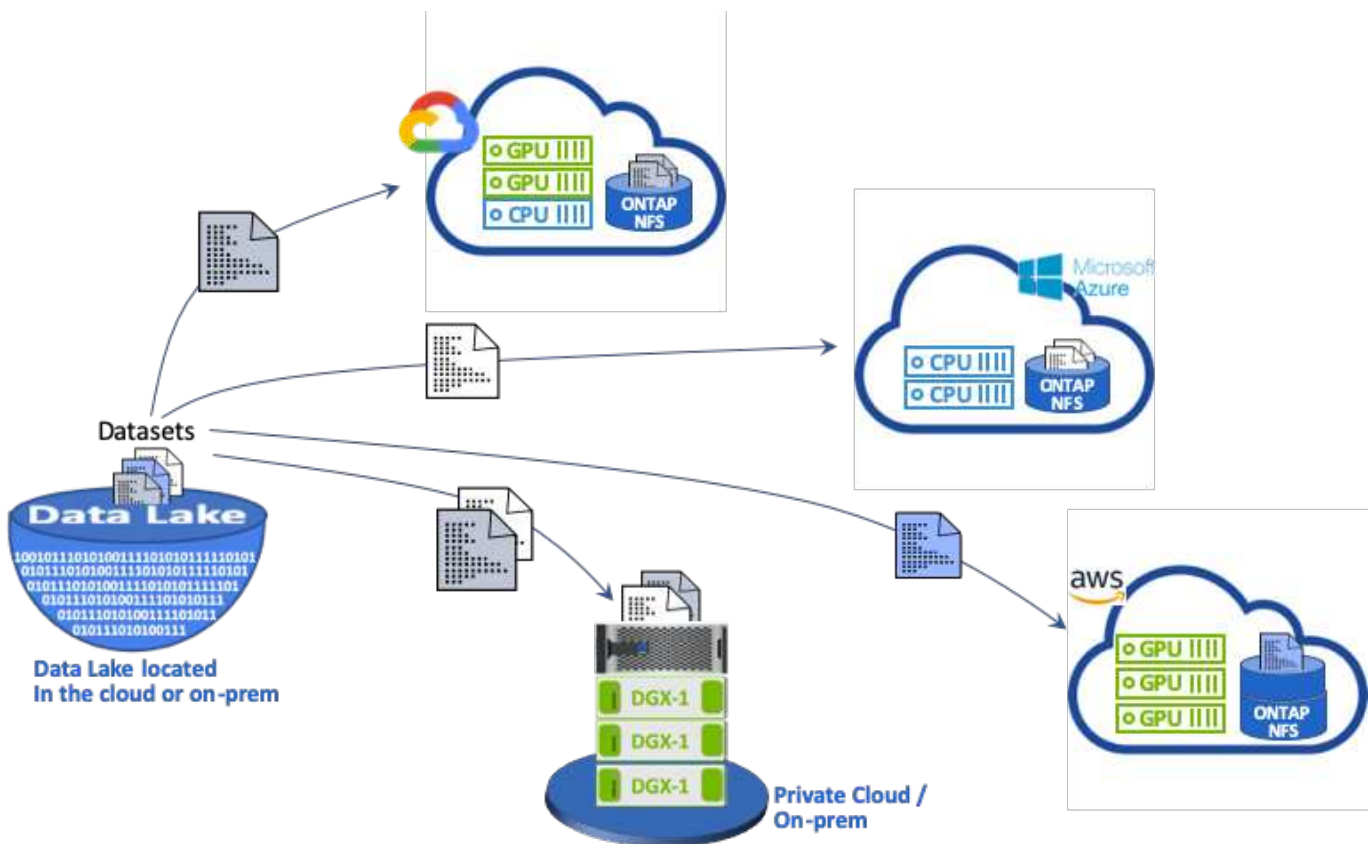
- Wenn der Data Scientist den Datensatz auf eine Computing-Instanz herunterlädt, gibt es keine Garantie für eine hohe Performance des integrierten Computing-Storage (ein Beispiel für ein hochperformantes System wäre die ONTAP AFF A800 NVMe Lösung).
- Wenn sich der heruntergeladene Datensatz in einem Computing-Node befindet, kann Storage zum Engpass werden, wenn verteilte Modelle über mehrere Nodes ausgeführt werden (im Gegensatz zu dem hochperformanten verteilten ONTAP Storage von NetApp).
- Die nächste Iteration des Trainingsexperiments kann in einer anderen Computing-Instanz aufgrund von Warteschlangenkongestionen oder Prioritäten durchgeführt werden, was erneut zu einer beträchtlichen Netzwerkdistanz vom Datensatz zum Computing-Standort führt.
- Andere Teammitglieder, die Trainingsexperimente auf demselben Computing Cluster ausführen, können diesen Datensatz nicht gemeinsam nutzen. Jeder einzelne von einem beliebigen Ort aus kann den (kostspieligen) Download des Datensatzes durchführen.
- Wenn andere Datensätze oder Versionen desselben Datensatzes für die nachfolgenden

Trainingsaufgaben benötigt werden, müssen die Datenanalysten erneut den (teuren) Download des Datensatzes auf die Computing-Instanz durchführen, die die training.NetApp und cnvrg.io ausführt, eine neue Caching-Lösung für Datensätze erstellt haben, die diese Hürden beseitigt. Die Lösung sorgt für eine schnellere Ausführung der ML-Pipeline und speichert häufig abgerufene Datensätze auf dem hochperformanten ONTAP Storage-System. Bei ONTAP NFS werden die Datensätze nur einmal (und nur einmal) in einer Data Fabric von NetApp (wie AFF A800) zwischengespeichert, die mit den Computing-Ressourcen verbunden ist. Da der Hochgeschwindigkeits-Storage NetApp ONTAP NFS mehrere ML-Computing-Nodes verarbeiten kann, wird die Performance der Trainingsmodelle optimiert. Dadurch können dem Unternehmen Kosteneinsparungen, Produktivität und betriebliche Effizienz erzielt werden.

## Lösungsarchitektur

Diese Lösung von NetApp und cnvrg.io bietet Datensatz-Caching, wie in der folgenden Abbildung dargestellt. Beim Datensatz-Caching können Data Scientists einen gewünschten Datensatz oder eine Datensatzversion auswählen und diesen in den ONTAP NFS-Cache verschieben, der sich in der Nähe des ML-Computing-Clusters befindet. Der Data Scientist kann nun mehrere Experimente ausführen, ohne dass es zu Verzögerungen oder Downloads kommt. Zudem können alle gemeinsam genutzten Engineers denselben Datensatz mit dem angeschlossenen Computing-Cluster verwenden (bei freier Auswahl eines beliebigen Nodes), ohne dass weitere Downloads aus dem Data Lake erforderlich sind. Die Data Scientists erhalten ein Dashboard, das alle Datensätze und Versionen überwacht und eine Ansicht darüber liefert, welche Datensätze im Cache gespeichert wurden.

Die cnvrg.io-Plattform erkennt automatisch ältere Datensätze, die für eine bestimmte Zeit nicht verwendet wurden, und entfernt sie aus dem Cache. Diese behält freien NFS-Cache-Speicherplatz für häufiger verwendete Datensätze bei. Hierbei ist zu beachten, dass das Datensatz-Caching mit ONTAP in der Cloud und on-Premises funktioniert und somit maximale Flexibilität bietet.





# Konzepte und Komponenten

In diesem Abschnitt werden Konzepte und Komponenten für das Daten-Caching in einem ML-Workflow behandelt.

## Maschinelles Lernen

ML werden in vielen Unternehmen und Unternehmen auf der ganzen Welt schnell zum entscheidenden Faktor. IT- und DevOps-Teams stehen daher vor der Herausforderung, ML-Workloads zu standardisieren und Cloud-, On-Premises- und Hybrid-Computing-Ressourcen bereitzustellen, die die dynamischen und intensiven Workflows unterstützen, die ML-Jobs und Pipelines benötigen.

## Container-basiertes Machine Learning und Kubernetes

Container sind isolierte Instanzen von Benutzerspeicherplatz, die auf einem Kernel des Shared-Host-Betriebssystems laufen. Die Einführung von Containern nimmt rasant zu. Container bieten viele der gleichen Vorteile von Applikationen im Sandbox-Bereich, die Virtual Machines (VMs) bieten. Da jedoch der Hypervisor und das Gastbetriebssystem die Anzahl der VMs beseitigen, sind die Container viel schlanker.

Container erlauben außerdem die effiziente Bündelung von Applikationsabhängigkeiten, Laufzeiten usw. und zwar direkt mit einer Applikation. Das am häufigsten verwendete Format für Containerverpackungen ist der Docker Container. Eine Applikation, die im Docker-Container-Format gesichert wurde, kann auf jeder Maschine ausgeführt werden, die Docker Container ausführen kann. Dies gilt auch dann, wenn die Abhängigkeiten der Anwendung nicht auf der Maschine vorhanden sind, weil alle Abhängigkeiten im Container selbst verpackt sind. Weitere Informationen finden Sie auf der "[Docker-Website](#)".

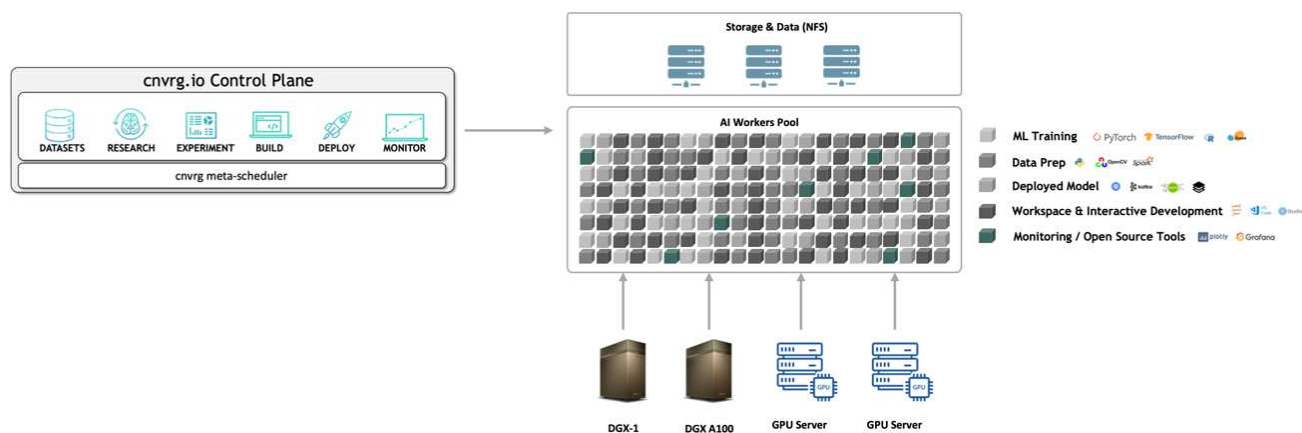
Kubernetes, der beliebte Container-Orchestrator, ermöglicht Datenanalysten die Einführung flexibler, containerbasierter Jobs und Pipelines. Darüber hinaus sind Infrastrukturteams in der Lage, ML-Workloads in einer einzigen gemanagten und Cloud-nativen Umgebung zu managen und zu überwachen. Weitere Informationen finden Sie auf der "[Kubernetes-Website](#)".

## Cnvrq.io

Cnvrq.io ist ein KI-Betriebssystem, das Unternehmen einen Wandel beim Management, der Skalierung und der Beschleunigung der KI- und Datenwissenschaft in der Forschung und Produktion ermöglicht. Die Code-First-Plattform wurde von Data Scientists für Data Scientists entwickelt und bietet Flexibilität für die Ausführung vor Ort oder in der Cloud. Mit Modellmanagement, MLOps und kontinuierlichen ML-Lösungen vereint cnvrq.io den Datenwissenschaftler Top-Technologien, mit denen sie sich weniger Zeit für DevOps und sich auf reale Algorithmen konzentrieren können. Seit dem Einsatz von cnvrq.io haben Teams aus allen Branchen immer mehr Modelle in die Produktion aufgenommen und damit einen höheren geschäftlichen Nutzen erzielt.

### Cnvrq.io Meta-Scheduler

Cnvrq.io verfügt über eine einzigartige Architektur, die IT und Ingenieuren die Möglichkeit ermöglicht, unterschiedliche Computing-Ressourcen auf derselben Kontrollebene zu verbinden. Cnvrq.io ermöglicht das Management VON ML-Jobs auf allen Ressourcen. Das bedeutet, DASS DIE IT diverse lokale Kubernetes-Cluster, VM-Server und Cloud-Konten anbinden und ML-Workloads auf allen Ressourcen ausführen kann, wie in der folgenden Abbildung dargestellt.



## Cnvr.io Daten-Caching

Cnvr.io ermöglicht Data Scientists die Definition von Versionen mit oft benötigten Datensätzen und liefert Daten-Caching-Technologie. Datensätze werden standardmäßig in einer zentralen Objekt-Storage-Datenbank gespeichert. Data Scientists können dann eine bestimmte Datenversion auf der ausgewählten Computing-Ressource zwischenspeichern, um Zeit beim Download zu sparen und damit die ML-Entwicklung und -Produktivität zu steigern. Datensätze, die gecachte und für einige Tage nicht in Verwendung sind, werden automatisch aus dem ausgewählten NFS gelöscht. Das Caching und Löschen des Cache erfolgt mit einem einzigen Klick. Es ist kein Coding, ER ODER DevOps Work erforderlich.

## Cnvr.io fließt und ML-Pipelines

Cnvr.io Flows ist ein Werkzeug für den Bau von ml-Pipelines für die Produktion. Jede Komponente in einem Flow ist ein Skript/Code, das auf einem ausgewählten Rechner mit einem Basis-Docker-Image ausgeführt wird. Data Scientists und Engineers können auf diesem Design eine einzige Pipeline aufbauen, die sowohl On-Premises als auch in der Cloud ausgeführt werden kann. Cnvr.io sorgt dafür, dass Daten, Parameter und Artefakte zwischen den verschiedenen Komponenten verschoben werden. Darüber hinaus wird jeder Flow überwacht und für 100% reproduzierbare Datenwissenschaft nachverfolgt.

## KERN cnvr.io

Cnvr.io CORE ist eine kostenlose Plattform für die Data-Science-Community, mit der sich Data Scientists auf Data Science konzentrieren können, statt sich auf DevOps zu konzentrieren. DIE flexible Infrastruktur DES KERNs ermöglicht Data Scientists die Kontrolle über die Verwendung beliebiger Sprache, KI-Frameworks oder Computing-Umgebungen – vor Ort oder in der Cloud –, um das Beste aus ihnen zu machen – Algorithmen zu entwickeln. Cnvr.io CORE kann mit einem einzigen Befehl auf einem beliebigen Kubernetes Cluster ganz einfach installiert werden.

## NetApp ONTAP AI

ONTAP AI ist eine Datacenter-Referenzarchitektur für ML- und Deep-Learning-Workloads (DL), die NetApp AFF Storage-Systeme und NVIDIA DGX-Systeme mit Tesla V100 GPUs verwenden. ONTAP AI basiert auf dem branchenüblichen NFS-Dateiprotokoll über 100 GB Ethernet. Dadurch verfügen Kunden über eine hochperformante ML/DL-Infrastruktur, die mithilfe standardisierter Datacenter-Technologien den Implementierungs- und Administrations-Overhead reduziert. Mithilfe standardisierter Netzwerke und Protokolle kann ONTAP AI in Hybrid-Cloud-Umgebungen integriert werden, während gleichzeitig die betriebliche Konsistenz und Benutzerfreundlichkeit erhalten bleiben. Als vorab validierte Infrastrukturlösung senkt ONTAP AI die Implementierungszeit und -Risiken und reduziert den Administrations-Overhead erheblich, sodass Kunden eine schnellere Amortisierung erreichen können.

## **NVIDIA DeepOps**

DeepOps ist ein Open-Source-Projekt von NVIDIA, das mithilfe von Ansible die Implementierung von GPU-Server-Clustern gemäß Best Practices automatisiert. DeepOps ist modular aufgebaut und kann für verschiedene Implementierungsaufgaben verwendet werden. DeepOps wird in diesem Dokument und der hier beschriebene Validierungsübung verwendet, um ein Kubernetes-Cluster zu implementieren, der aus GPU-Server-Worker-Nodes besteht. Weitere Informationen finden Sie auf der "[DeepOps-Website](#)".

## **NetApp Trident**

Trident ist ein Open-Source-Storage-Orchestrator, der von NetApp entwickelt und gewartet wird. Damit wird die Erstellung, das Management und die Nutzung von persistentem Storage für Kubernetes-Workloads erheblich vereinfacht. Trident selbst ist eine native Kubernetes-Applikation, die direkt in einem Kubernetes Cluster ausgeführt werden kann. Mit Trident können Kubernetes-Benutzer (Entwickler, Data Scientists, Kubernetes Administratoren usw.) persistente Storage-Volumes im gewohnten Kubernetes-Standardformat erstellen, managen und interagieren. Gleichzeitig können sie von den erweiterten Datenmanagement-Funktionen von NetApp und der Data Fabric Strategie von NetApp profitieren. Trident abstrahiert die Komplexität von persistentem Storage und vereinfacht die Nutzung. Weitere Informationen finden Sie auf der "[Trident Website](#)".

## **NetApp StorageGRID**

NetApp StorageGRID ist eine softwaredefinierte Objekt-Storage-Plattform, die diese Anforderungen erfüllt. Sie bietet einfachen Cloud-ähnlichen Storage, auf den Benutzer über das S3-Protokoll zugreifen können. StorageGRID ist ein Scale-out-System, das diverse Nodes unabhängig von der Entfernung über Internet-verbundene Standorte unterstützt. Mithilfe der intelligenten Richtlinien-Engine von StorageGRID können Benutzer Objekte zur Einhaltung von Datenkonsistenz (Erasure Coding) über Standorte hinweg auswählen und so für Ausfallsicherheit bei geografisch verteilten Standorten oder Objektreplizierung zwischen Remote Standorten sorgen, um die WAN-Zugriffslatenz zu minimieren. StorageGRID bietet in dieser Lösung einen hervorragenden primären Objekt-Storage-See in der Private Cloud.

## **NetApp Cloud Volumes ONTAP**

Die NetApp Cloud Volumes ONTAP Datenmanagement-Software bietet Kontrolle, Schutz und Effizienz für Benutzerdaten. Gleichzeitig bietet sie die Flexibilität von Public Cloud-Providern, einschließlich AWS, Google Cloud Platform und Microsoft Azure. Cloud Volumes ONTAP ist eine Cloud-native Datenmanagement-Software auf Basis der Storage-Software NetApp ONTAP. Sie bietet Benutzern eine erstklassige universelle Storage-Plattform, die ihre Datenanforderungen in der Cloud erfüllt. Mit derselben Storage-Software in der Cloud und on-Premises profitieren Benutzer von allen Vorteilen der Data-Fabric-Strategie, ohne DASS DAS IT-Personal komplett neue Methoden zum Datenmanagement erlernen muss.

Kunden, die sich für Hybrid-Cloud-Implementierungsmodelle interessieren, können Cloud Volumes ONTAP in den meisten Public Clouds dieselben Funktionen und erstklassige Performance bieten. Damit profitieren sie in jeder Umgebung von einer konsistenten und nahtlosen Benutzererfahrung.

# **Hardware- und Software-Anforderungen**


In diesem Abschnitt werden die Technologieanforderungen für die ONTAP AI Lösung erläutert.

## **Hardwareanforderungen**

Obwohl die Hardwareanforderungen von bestimmten Kunden-Workloads abhängen, kann ONTAP AI in jedem

Umfang für das Data Engineering, das Modelltraining und die Produktionserwartung von einer einzelnen GPU bis zu Rack-Scale-Konfigurationen für umfangreiche ML/DL-Operationen implementiert werden. Weitere Informationen zu ONTAP AI finden Sie im ["ONTAP AI Website"](#).

Diese Lösung wurde mit einem DGX-1-System für Computing, einem NetApp AFF A800 Storage-System und Cisco Nexus 3232C für die Netzwerk-Konnektivität validiert. Die in dieser Validierung verwendete AFF A800 kann bis zu 10 DGX-1-Systeme für die meisten ML/DL-Workloads unterstützen. Die folgende Abbildung zeigt die in dieser Validierung verwendete ONTAP KI-Topologie für das Modelltraining.



Um diese Lösung auf eine Public Cloud zu erweitern, lässt sich Cloud Volumes ONTAP zusammen mit Cloud-GPU-Computing-Ressourcen implementieren und in eine Hybrid Cloud Data Fabric integrieren. Damit können Kunden die für jeden Workload geeigneten Ressourcen verwenden.

## Softwareanforderungen

In der folgenden Tabelle sind die spezifischen Softwareversionen aufgeführt, die in dieser Lösungsvalidierung verwendet werden.

Komponente	Version
Ubuntu	18.04.4 LTS
NVIDIA DGX-BETRIEBSSYSTEM	4.4.0
NVIDIA DeepOps	20.02.1
Kubernetes	1.15
Helm	3.1.0
Cnvrg.io	3.0.0
NetApp ONTAP	9.6P4

Kubernetes wurde für diese Lösungsvalidierung als Single-Node-Cluster auf dem DGX-1-System implementiert. Bei groß angelegten Implementierungen sollten unabhängige Kubernetes-Master-Nodes implementiert werden, um für Hochverfügbarkeit der Managementservices zu sorgen und wertvolle DGX-Ressourcen für ML- und DL-Workloads zu reservieren.

# Details zur Lösungsimplementierung und -Validierung

## Details zur Lösungsimplementierung und -Validierung

In den folgenden Abschnitten werden die Einzelheiten zur Implementierung und Validierung der Lösung beschrieben.

### ONTAP AI Implementierung

Für die Implementierung von ONTAP AI sind die Installation und Konfiguration von Netzwerk-, Computing- und Storage-Hardware erforderlich. Spezifische Anweisungen für die Implementierung der ONTAP AI-Infrastruktur liegen nicht im Umfang dieses Dokuments vor. Detaillierte Informationen zur Bereitstellung finden Sie unter "[NVA-1121-DEPLOY: NetApp ONTAP AI, Powered by NVIDIA](#)".

Für diese Lösungsvalidierung wurde ein einzelnes Volume erstellt und auf dem DGX-1-System gemountet. Dieser Mount-Punkt wurde dann in die Container eingebunden, um die Daten für das Training zugänglich zu machen. Bei umfangreichen Implementierungen automatisiert NetApp Trident die Erstellung und das Mounten von Volumes, um den administrativen Overhead zu beseitigen und Ressourcen für Endbenutzer zu managen.

### Kubernetes Deployment

Um Ihren Kubernetes-Cluster mit NVIDIA DeepOps zu implementieren und zu konfigurieren, führen Sie die folgenden Aufgaben über einen Bereitstellungs-Jump-Host aus:

1. Laden Sie NVIDIA DeepOps herunter, indem Sie den Anweisungen auf der folgen "[Erste Schritte](#)" Auf der NVIDIA DeepOps GitHub Website.
2. Implementieren Sie Kubernetes in Ihrem Cluster, indem Sie die Anweisungen auf dem befolgen "[Kubernetes Deployment Guide](#)" Auf der NVIDIA DeepOps GitHub Website.



Damit die Implementierung von DeepOps Kubernetes funktioniert, muss auf allen Kubernetes Master- und Worker-Nodes derselbe Benutzer vorhanden sein.

Wenn die Bereitstellung fehlschlägt, ändern Sie den Wert von `kubectl_localhost` Mit FALSE innen `deepops/config/group_vars/k8s-cluster.yml` Und wiederholen Sie Schritt 2. Der Copy `kubectl binary to ansible host` Aufgabe, die nur dann ausgeführt wird, wenn der Wert von `kubectl_localhost` Stimmt. Es basiert auf dem `fetch` Ansible-Modul, das bekannte Probleme bei der Speichernutzung hat. Diese Probleme mit der Speichernutzung können manchmal dazu führen, dass die Aufgabe nicht ausgeführt wird. Wenn die Aufgabe aufgrund eines Speicherproblems ausfällt, wird der restliche Bereitstellungsvorgang nicht erfolgreich abgeschlossen.

Wenn die Bereitstellung erfolgreich abgeschlossen wurde, nachdem Sie den Wert von geändert haben `kubectl_localhost` Bis `false`, Dann müssen Sie die manuell kopieren `kubectl binary` Von einem Kubernetes-Master-Node zu dem Bereitstellungs-Jump-Host Sie finden den Standort des `kubectl binary` Auf einem bestimmten Master-Knoten, indem Sie den ausführen `which kubectl` Befehl direkt auf diesem Node.

## Implementierung von cnvrg.io

Dieser Abschnitt enthält Details zur Bereitstellung von cnvrg-KERN mithilfe von Helm-Diagrammen.

### Cnvrg-KERN mit Helm implementieren

Helm ist der einfachste Weg, cnvrg schnell über beliebige Cluster, On-Premises, Minikube oder in einem beliebigen Cloud-Cluster (wie AKS, EKS und GKE) zu implementieren. In diesem Abschnitt wird beschrieben, wie cnvrg auf einer On-Premises-Instanz (DGX-1) mit installiertem Kubernetes installiert wurde.

#### Voraussetzungen

Bevor Sie die Installation abschließen können, müssen Sie die folgenden Abhängigkeiten auf Ihrem lokalen Computer installieren und vorbereiten:

- Kubectl
- Helm 3.x
- Kubernetes-Cluster ab 1.15

#### Implementierung Mit Helm

1. Um die aktuellsten cnvrg Steuerdiagramme herunterzuladen, führen Sie den folgenden Befehl aus:

```
helm repo add cnvrg https://helm.cnvrg.io
helm repo update
```

2. Bevor Sie cnvrg implementieren, benötigen Sie die externe IP-Adresse des Clusters und den Namen des Node, auf dem Sie cnvrg bereitstellen. Führen Sie den folgenden Befehl aus, um cnvrg auf einem lokalen Kubernetes-Cluster zu implementieren:

```
helm install cnvrg cnvrg/cnvrg --timeout 1500s --wait \ --set
global.external_ip=<ip_of_cluster> \ --set global.node=<name_of_node>
```

3. Führen Sie die aus `helm install` Befehl. Alle Services und Systeme werden automatisch in Ihrem Cluster installiert. Dieser Vorgang kann bis zu 15 Minuten dauern.
4. Der `helm install` Der Befehl kann bis zu 10 Minuten dauern. Nach Abschluss der Bereitstellung rufen Sie die URL Ihrer neu implementierten cnvrg auf oder fügen Sie den neuen Cluster als Ressource innerhalb Ihres Unternehmens hinzu. Der `helm` Der Befehl informiert Sie über die richtige URL.

```
Thank you for installing cnvrg.io!
Your installation of cnvrg.io is now available, and can be reached via:
Talk to our team via email at
```

5. Wenn der Status aller Container ausgeführt oder abgeschlossen ist, wurde cnvrg erfolgreich bereitgestellt. Es sollte ähnlich wie bei der folgenden Beispielausgabe aussehen:

NAME	READY	STATUS	RESTARTS	AGE
cnvrg-app-69fbb9df98-6xrgf	1/1	Running	0	2m
cnvrg-sidekiq-b9d54d889-5x4fc	1/1	Running	0	2m
controller-65895b47d4-s96v6	1/1	Running	0	2m
init-app-vs-config-wv9c4	0/1	Completed	0	9m
init-gateway-vs-config-2zbpp	0/1	Completed	0	9m
init-minio-vs-config-cd2rg	0/1	Completed	0	9m
minio-0	1/1	Running	0	2m
postgres-0	1/1	Running	0	2m
redis-695c49c986-kcbt9	1/1	Running	0	2m
seeder-wh655	0/1	Completed	0	2m
speaker-5sghr	1/1	Running	0	2m

### Computer Vision Model Training mit ResNet50 und dem Thorax-Röntgendatensatz


Cnvrg.io AI OS wurde in einem Kubernetes Setup auf einer NetApp ONTAP KI-Architektur auf Basis des NVIDIA DGX-Systems implementiert. Zur Validierung haben wir den NIH Chest Röntgendatensatz verwendet, der aus entidentifizierten Bildern von Thoraxröntgenbildern besteht. Die Bilder waren im PNG-Format. Die Daten wurden vom NIH Clinical Center bereitgestellt und sind über den verfügbar ["NIH Download-Site"](#). Wir verwendeten eine 250-GB-Datenprobe mit 627, 615 Bildern aus 15 Klassen.

Der Datensatz wurde auf die cnvrg Plattform hochgeladen und auf einem NFS-Export aus dem NetApp AFF A800 Speichersystem zwischengespeichert.

### Richten Sie die Computing-Ressourcen ein

Die cnvrg Architektur und die Meta-Scheduling-Funktion ermöglichen es Ingenieuren und IT-Experten, verschiedene Computing-Ressourcen zu einer einzelnen Plattform anzubinden. In unserem Setup haben wir denselben Cluster cnvrg verwendet, der für die Ausführung der Deep-Learning-Workloads implementiert wurde. Wenn Sie weitere Cluster hinzufügen müssen, verwenden Sie die GUI, wie im folgenden Screenshot gezeigt.





## Daten Laden

Zum Hochladen von Daten auf die cnvrg Plattform können Sie die GUI oder den cnvrg CLI verwenden. Für große Datensätze empfiehlt NetApp die Verwendung der CLI, da es sich um ein starkes, skalierbares und zuverlässiges Tool handelt, das eine große Anzahl von Dateien verarbeiten kann.

Gehen Sie wie folgt vor, um Daten hochzuladen:


1. Laden Sie die herunter "[Cnvrg CLI](#)".
2. Navigieren Sie zum Röntgenverzeichnis.
3. Initialisieren Sie den Datensatz in der Plattform mit dem `cnvrg data init` Befehl.
4. Alle Inhalte des Verzeichnisses mit dem in den zentralen Data Lake hochladen `cnvrg data sync` Befehl. Nachdem die Daten in den zentralen Objektspeicher hochgeladen wurden (StorageGRID, S3 oder andere), können Sie mit der GUI navigieren. Die folgende Abbildung zeigt eine geladene PNG-Datei mit Röntgenfibrose im Brustbild. Darüber hinaus versioniere cnvrg die Daten, so dass jedes Modell, das Sie erstellen, auf die Datenversion reproduziert werden kann.





## Cach-Daten

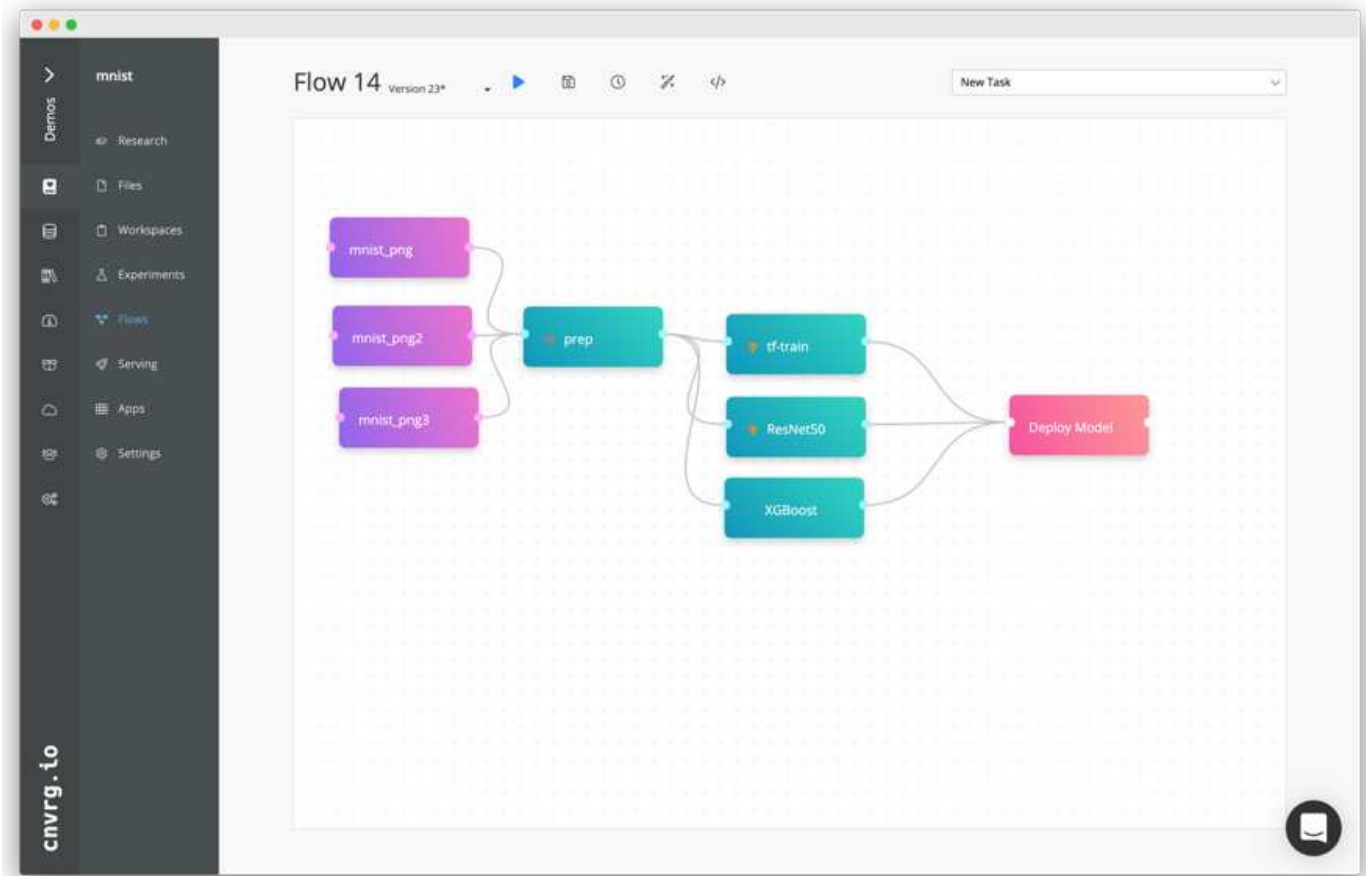
Damit das Training schneller durchgeführt wird und mehr als 600.000 Dateien für jedes Modelltraining und jedes Experiment nicht heruntergeladen werden können, haben wir die Daten-Caching-Funktion verwendet, nachdem die Daten ursprünglich in den zentralen Data-Lake-Objektpeicher hochgeladen wurden.



Nachdem Benutzer auf Cache geklickt haben, lädt cnvrg die Daten in seinem spezifischen Commit aus dem Remote-Objektspeicher herunter und speichert sie auf dem ONTAP NFS Volume ab. Nach Abschluss der Schulung stehen die Daten für ein sofortiges Training zur Verfügung. Wenn die Daten zudem für einige Tage nicht verwendet werden (z. B. für Modelltraining oder Exploration), löscht cnvrg automatisch den Cache.

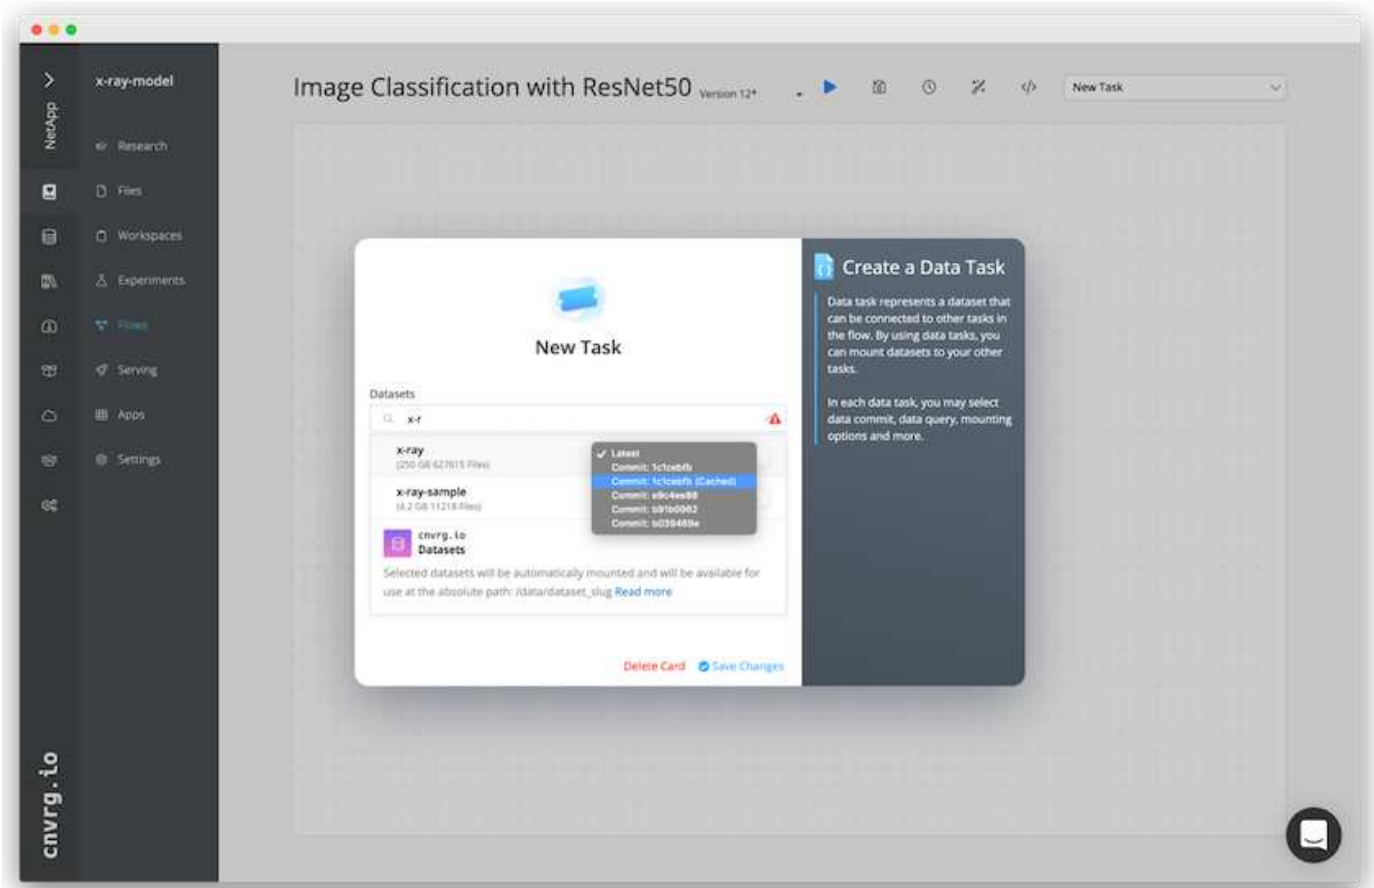
### AUFBAU einer ML-Pipeline mit zwischengespeicherten Daten

Cnvrg-Ströme ermöglichen es Ihnen, problemlos Produktions-ML-Pipelines aufzubauen. Flows sind flexibel, können für jede Art VON ML-Anwendungsfall und über die GUI oder den Code erstellt werden. Jede Komponente in einem Flow kann auf unterschiedlichen Computing-Ressourcen mit einem anderen Docker-Image ausgeführt werden. So lässt sich Hybrid-Cloud- und ml-Pipelines erstellen.



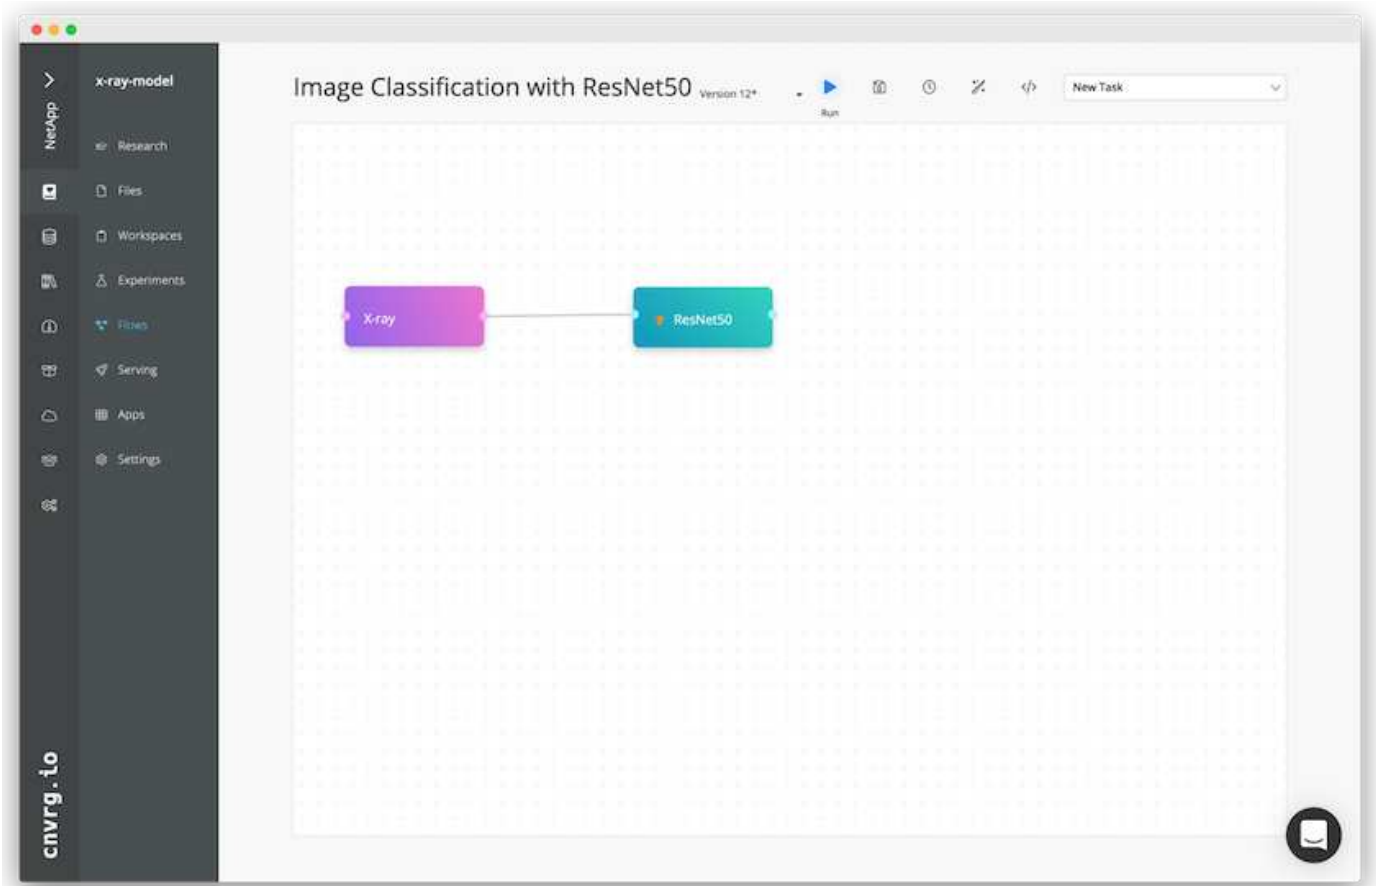
### Erstellen des Thoraxröntgendurchflusses: Einstellen der Daten

Wir haben unseren Datensatz zu einem neu erstellten Flow hinzugefügt. Beim Hinzufügen des Datensatzes können Sie die bestimmte Version (Commit) auswählen und angeben, ob die zwischengespeicherte Version verwendet werden soll. In diesem Beispiel haben wir den Cache-Commit ausgewählt.




### Erstellen des Thorax-Röntgenflusses: Einstellen Trainingsmodell: ResNet50

In der Pipeline können Sie jede Art von benutzerdefiniertem Code hinzufügen. In cnvrg gibt es auch die AI-Bibliothek, eine wiederverwendbare ML-Komponenten-Sammlung. In der KI-Bibliothek gibt es Algorithmen, Skripte, Datenquellen und andere Lösungen, die in jedem ML- oder Deep-Learning-Flow verwendet werden können. In diesem Beispiel haben wir das vordefinierte ResNet50-Modul ausgewählt. Wir haben Standardparameter wie `Batch_size:128`, `Epochs:10` und mehr verwendet. Diese Parameter können in der Dokumentation der KI-Bibliothek angezeigt werden. Der folgende Screenshot zeigt den neuen Flow, in dem der Röntgendatensatz an ResNet50 angeschlossen ist.





### Definieren Sie die Compute-Ressource für ResNet50

Jeder Algorithmus oder jede Komponente in cnvrg-Flows kann auf einer anderen Computing-Instanz mit einem anderen Docker-Image ausgeführt werden. In unserem Setup wollten wir den Trainingsalgorithmus auf den NVIDIA DGX Systemen mit der NetApp ONTAP AI Architektur ausführen. In der folgenden Abbildung haben wir ausgewählt `gpu-real`, Eine Computing-Vorlage und -Spezifikation für unseren On-Premises-Cluster. Wir haben auch eine Warteschlange mit Vorlagen erstellt und mehrere Vorlagen ausgewählt. Auf diese Weise, wenn der `gpu-real` Die Ressource kann nicht zugewiesen werden (wenn beispielsweise andere Data Scientists sie nutzen), dann können Sie automatisches Cloud-Bursting durch Hinzufügen einer Cloud-Provider-Vorlage aktivieren. Der folgende Screenshot zeigt die Verwendung von `gpu-Real` als Compute-Node für ResNet50.



## Nachverfolgung und Überwachung der Ergebnisse

Nachdem ein Flow ausgeführt wurde, löst cnvrg die Tracking- und Monitoring-Engine aus. Jeder Flow-Durchlauf wird automatisch dokumentiert und in Echtzeit aktualisiert. Hyperparameter, Metriken, Ressourcenauslastung (GPU-Auslastung und mehr), Codeversion, Artefakte, Protokolle Und so weiter sind im Abschnitt Experimente automatisch verfügbar, wie in den folgenden beiden Screenshots gezeigt.



# Schlussfolgerung

NetApp und cnvrg.io bieten ihren Kunden eine umfassende Datenmanagement-Lösung für DIE ML- und DL-Softwareentwicklung. ONTAP AI bietet High-Performance-Computing und -Storage für alle Betriebsabläufe. Die Software cnvrg.io optimiert Datenwissenschaftler und verbessert die Ressourcenauslastung.

## Danksagungen

- Mike Oglesby, Technical Marketing Engineer, NetApp
- Santosh Rao, Senior Technical Director, NetApp

## Weitere Informationen

Folgende Ressourcen enthalten ausführlichere Informationen zu den Angaben in diesem Dokument:

- Cnvrg.io ( "<https://cnvrg.io>" ):
  - Cnvrg-KERN (kostenlose ML-Plattform)  
<https://cnvrg.io/platform/core>
  - Cnvrg Dokumentation  
["https://app.cnvrg.io/docs"](https://app.cnvrg.io/docs)
- NVIDIA DGX-1-Server:
  - NVIDIA DGX-1-Server  
<https://www.nvidia.com/en-us/data-center/dgx-1/>
  - NVIDIA Tesla V100 Tensor Core GPU  
<https://www.nvidia.com/en-us/data-center/tesla-v100/>
  - NVIDIA GPU CLOUD (NGC)  
<https://www.nvidia.com/en-us/gpu-cloud/>
  - NetApp FlashAdvantage für AFF  
<https://www.netapp.com/pdf.html?item=/media/19894-ds-3733.pdf>
  - ONTAP 9.x Dokumentation  
<http://mysupport.netapp.com/documentation/productlibrary/index.html?productID=62286>
  - Technischer Bericht von NetApp FlexGroup  
<https://www.netapp.com/pdf.html?item=/media/7337-tr4557pdf.pdf>



- Persistenter NetApp Storage für Container:
  - NetApp Trident
    - <https://netapp.io/persistent-storage-provisioner-for-kubernetes/>
- NetApp Interoperabilitäts-Matrix:
  - NetApp Interoperabilitäts-Matrix-Tool
    - <https://mysupport.netapp.com/matrix/#welcome>
- ONTAP KI-Netzwerk:
  - Switches der Cisco Nexus 3232C-Serie
    - <https://www.cisco.com/c/en/us/products/switches/nexus-3232c-switch/index.html>
  - Switches der Mellanox Spectrum 2000-Serie
    - [http://www.mellanox.com/page/products\\_dyn?product\\_family=251&mtag=sn2000](http://www.mellanox.com/page/products_dyn?product_family=251&mtag=sn2000)
- ML-Rahmen und Werkzeuge:
  - DALI
    - <https://github.com/NVIDIA/DALI>
  - TensorFlow: Ein Open-Source Machine Learning Framework für alle
    - <https://www.tensorflow.org/>
  - Horovod: Ubers Open-Source Distributed Deep Learning Framework for TensorFlow
    - <https://eng.uber.com/horovod/>
  - NVIDIA-Blog: Enabling GPUs in the Container Runtime Ecosystem
    - <https://devblogs.nvidia.com/gpu-containers-runtime/>
  - Docker
    - <https://docs.docker.com>
  - Kubernetes
    - <https://kubernetes.io/docs/home/>
  - NVIDIA DeepOps
    - <https://github.com/NVIDIA/deepops>
  - Kubeflow
    - <http://www.kubeflow.org/>
  - Jupyter Notebook Server

<http://www.jupyter.org/>

- Datensatz und Benchmarks:

- Röntgendatensatz der NIH Thoraxröntgenaufnahme

<https://nihcc.app.box.com/v/ChestXray-NIHCC>

- Xiaosong Wang, Yifan Peng, Le Lu, Zhiyong Lu, Mohammadhadi Bagheri, Ronald Summers, ChestX-ray8: Thorax-Röntgendatenbank im Krankenhausmaßstab und Benchmarks auf schwach überwachte Klassifizierung und Lokalisierung allgemeiner Thorax-Erkrankungen, IEEE CVPR, S. 3462-3471, 2017TR-4841-0620

## Copyright-Informationen

Copyright © 2025 NetApp. Alle Rechte vorbehalten. Gedruckt in den USA. Dieses urheberrechtlich geschützte Dokument darf ohne die vorherige schriftliche Genehmigung des Urheberrechtinhabers in keiner Form und durch keine Mittel – weder grafische noch elektronische oder mechanische, einschließlich Fotokopieren, Aufnehmen oder Speichern in einem elektronischen Abrufsystem – auch nicht in Teilen, vervielfältigt werden.

Software, die von urheberrechtlich geschütztem NetApp Material abgeleitet wird, unterliegt der folgenden Lizenz und dem folgenden Haftungsausschluss:

DIE VORLIEGENDE SOFTWARE WIRD IN DER VORLIEGENDEN FORM VON NETAPP ZUR VERFÜGUNG GESTELLT, D. H. OHNE JEGLICHE EXPLIZITE ODER IMPLIZITE GEWÄHRLEISTUNG, EINSCHLIESSLICH, JEDOCH NICHT BESCHRÄNKT AUF DIE STILLSCHWEIGENDE GEWÄHRLEISTUNG DER MARKTGÄNGIGKEIT UND EIGNUNG FÜR EINEN BESTIMMTEN ZWECK, DIE HIERMIT AUSGESCHLOSSEN WERDEN. NETAPP ÜBERNIMMT KEINERLEI HAFTUNG FÜR DIREKTE, INDIREKTE, ZUFÄLLIGE, BESONDERE, BEISPIELHAFT SCHÄDEN ODER FOLGESCHÄDEN (EINSCHLIESSLICH, JEDOCH NICHT BESCHRÄNKT AUF DIE BESCHAFFUNG VON ERSATZWAREN ODER -DIENSTLEISTUNGEN, NUTZUNGS-, DATEN- ODER GEWINNVERLUSTE ODER UNTERBRECHUNG DES GESCHÄFTSBETRIEBS), UNABHÄNGIG DAVON, WIE SIE VERURSACHT WURDEN UND AUF WELCHER HAFTUNGSTHEORIE SIE BERUHEN, OB AUS VERTRAGLICH FESTGELEGTER HAFTUNG, VERSCHULDENSUNABHÄNGIGER HAFTUNG ODER DELIKTSHAFTUNG (EINSCHLIESSLICH FAHRLÄSSIGKEIT ODER AUF ANDEREM WEGE), DIE IN IRGEND EINER WEISE AUS DER NUTZUNG DIESER SOFTWARE RESULTIEREN, SELBST WENN AUF DIE MÖGLICHKEIT DERARTIGER SCHÄDEN HINGEWIESEN WURDE.

NetApp behält sich das Recht vor, die hierin beschriebenen Produkte jederzeit und ohne Vorankündigung zu ändern. NetApp übernimmt keine Verantwortung oder Haftung, die sich aus der Verwendung der hier beschriebenen Produkte ergibt, es sei denn, NetApp hat dem ausdrücklich in schriftlicher Form zugestimmt. Die Verwendung oder der Erwerb dieses Produkts stellt keine Lizenzierung im Rahmen eines Patentrechts, Markenrechts oder eines anderen Rechts an geistigem Eigentum von NetApp dar.

Das in diesem Dokument beschriebene Produkt kann durch ein oder mehrere US-amerikanische Patente, ausländische Patente oder anhängige Patentanmeldungen geschützt sein.

ERLÄUTERUNG ZU „RESTRICTED RIGHTS“: Nutzung, Vervielfältigung oder Offenlegung durch die US-Regierung unterliegt den Einschränkungen gemäß Unterabschnitt (b)(3) der Klausel „Rights in Technical Data – Noncommercial Items“ in DFARS 252.227-7013 (Februar 2014) und FAR 52.227-19 (Dezember 2007).

Die hierin enthaltenen Daten beziehen sich auf ein kommerzielles Produkt und/oder einen kommerziellen Service (wie in FAR 2.101 definiert) und sind Eigentum von NetApp, Inc. Alle technischen Daten und die Computersoftware von NetApp, die unter diesem Vertrag bereitgestellt werden, sind gewerblicher Natur und wurden ausschließlich unter Verwendung privater Mittel entwickelt. Die US-Regierung besitzt eine nicht ausschließliche, nicht übertragbare, nicht unterlizenzierbare, weltweite, limitierte unwiderrufliche Lizenz zur Nutzung der Daten nur in Verbindung mit und zur Unterstützung des Vertrags der US-Regierung, unter dem die Daten bereitgestellt wurden. Sofern in den vorliegenden Bedingungen nicht anders angegeben, dürfen die Daten ohne vorherige schriftliche Genehmigung von NetApp, Inc. nicht verwendet, offengelegt, vervielfältigt, geändert, aufgeführt oder angezeigt werden. Die Lizenzrechte der US-Regierung für das US-Verteidigungsministerium sind auf die in DFARS-Klausel 252.227-7015(b) (Februar 2014) genannten Rechte beschränkt.

## Markeninformationen

NETAPP, das NETAPP Logo und die unter <http://www.netapp.com/TM> aufgeführten Marken sind Marken von NetApp, Inc. Andere Firmen und Produktnamen können Marken der jeweiligen Eigentümer sein.