

솔루션 개요

## ONTAP AI

NetApp 및 NVIDIA를 통해 ML 및  
DL을 위한 데이터 파이프라인을  
간소화, 가속화, 통합



## AI 인프라 과제

점점 더 경쟁이 치열해지는 시장에서 인공 지능 (AI), 머신 러닝 (ML) 및 딥 러닝 (DL)을 통해 기업은 사기를 탐지하고 고객 관계를 개선하며 공급망을 최적화하고 혁신적인 제품과 서비스를 제공할 수 있습니다 . 귀사도 디지털 혁신을 유도하고 경쟁 우위를 확보하기 위해 새로운 AI 접근법을 활용하는 수많은 조직 중 하나일 수 있습니다 . AI에서 최대한의 이점을 얻으려면 먼저 몇 가지 주요 과제를 해결해야 합니다 .

DIY 통합은 복잡합니다 . 기성품인 ML 및 DL 컴퓨팅 , 스토리지 , 네트워킹 및 소프트웨어 구성 요소를 조립 및 통합하면 복잡성이 증가하고 구축 시간이 길어질 수 있습니다 . 결과적으로 시스템 통합 작업에 귀중한 데이터 과학 리소스가 낭비됩니다 .

예측 가능하고 확장 가능한 성능을 달성하는 것은 어렵습니다 . DL 모범 사례에서는 작은 규모로 시작한 후 성장에 따라 확장할 것을 제안합니다 . 기존에는 컴퓨팅과 직접 연결 스토리지가 데이터를 AI 워크플로에 공급하는 데 사용되고 있습니다 . 그러나 기존 스토리지를 확장하면서 진행 중인 운영에 장애가 발생할 수 있으며 다운타임이 발생할 수 있습니다 .

작업 중단은 데이터 과학자의 생산성에 영향을 미칩니다 . ML 및 DL 인프라는 수많은 하드웨어 및 소프트웨어 상호 종속성을 수반합니다 . 인프라를 계속 유지하려면 전체 스택 AI에 대한 깊이 있는 전문 지식이 필요합니다 . 다운타임이나 AI의 느린 성능은 개발자의 생산성을 저하하고 운영 비용이 통제 불능 상태가 되는 연쇄 반응을 일으킬 수 있습니다 .

## 솔루션

이제 AI, ML 및 DL의 약속을 완벽하게 실현할 수 있습니다 . NVIDIA DGX™ 시스템과 NetApp 클라우드 연결형 All-Flash 스토리지 기반의 검증된 NetApp® ONTAP® AI 아키텍처를 사용하여 데이터 파이프라인을 간소화 , 가속 , 통합합니다 . 데이터 흐름을 안정적으로 간소화하고 에지에서 코어 및 클라우드에 이르는 Data Fabric을 사용하여 분석 , 훈련 , 추론의 속도를 높일 수 있습니다 .

## 주요 이점

### 유연하고 검증된 솔루션으로 위험 완화

- 설계의 복잡성과 추측에 의한 작업을 제거하여 신속하게 작업 처리

- 사전 구성된 솔루션으로 구성 및 구축 간소화

### 정확한 성능 및 확장성 제공

- 작게 시작한 후 중단 없이 확장

- 고성능 솔루션으로 신속하게 결과 확인

### 통합 데이터 파이프라인 구축

- 에지에서 코어 , 클라우드에 이르기까지 통합 파이프라인으로 데이터를 지능적으로 관리
- 솔루션 구축 시 AI 전문가의 지원 및 간단한 지원 옵션 활용

### AI 워크로드 통합

- 인프라 사일로 제거
- 비즈니스 수요에 유연하게 대처

NetApp ONTAP AI는 세계 최초의 5 페타플롭 AI 시스템인 NVIDIA DGX A100 시스템과 NVIDIA Mellanox 고성능 이더넷 스위치를 통합한 최초의 컨버지드 인프라 스택 중 하나로 , AI 워크로드를 통합하고 구축을 단순화하고 투자 수익률 회수를 앞당겨 줍니다 .

" 딥 러닝은 거의 모든 시장에서 혁명을 일으키고 있습니다 . NetApp은 다양한 시장에서 딥 러닝을 적용하여 미래의 기술을 주도하고 있습니다 .

NVIDIA DGX 시스템 및 NetApp All-Flash 스토리지 기반 NetApp ONTAP AI는 딥 러닝을 위한 데이터 파이프라인을 단순화 및 가속합니다 ."

Tim Ensor, 인공 지능 책임자  
케임브리지 컨설턴트



그림 1) DGX A100, 2, 4, 8 노드 구성의 ONTAP AI 아키텍처

### **유연하고 검증된 솔루션으로 위험 완화**

AI 혁신의 빠른 속도로 인해 AI 인프라를 효과적으로 설계하기 어렵습니다. ONTAP AI를 통해 현장에서 검증된 참조 아키텍처를 사용하면 불확실한 추측을 없애고 더 빠르게 시작할 수 있습니다. 또는 복잡한 설계 및 관리 작업을 수행할 필요 없이 쉽게 조달하고 구축할 수 있는 사전 구성된 통합 솔루션을 선택할 수 있습니다.

ONTAP AI 통합 솔루션은 사전 구성된 4 가지 옵션으로 제공되며 선택에 따라 용량을 확장하거나 고급 소프트웨어를 사용할 수 있습니다. 이 통합 솔루션은 한 번의 통화로 현장 설치 및 사고 보고에서 해결에 이르기까지 포괄적인 지원을 제공하므로 복잡성이 더욱더 감소합니다.

### **정확한 성능 및 확장성 제공**

DL 훈련 루틴에는 엄청난 양의 컴퓨팅 파워가 필요합니다. 더 빠른 이미지 훈련을 통해 전체적인 컴퓨팅 비용을 줄이는 동시에 AI 혁신과 생산성을 높일 수 있습니다.

새로운 NVIDIA Ampere 아키텍처를 사용하여 구축된 DGX A100 시스템은 이전 세대보다 최대 6 배의 훈련 성능을 제공합니다. 이제 데이터 센터에 상응하는 분석, 훈련 및 추론용 컴퓨팅 인프라를 단일 시스템에 통합할 수 있습니다. DGX A100 시스템은 CPU 시스템과 비교하여 1/25의 공간과 1/20의 전력을 사용하며 비용은 단 1/10에 불과합니다.

첨단 컴퓨팅에 투자하려면 초당 수천 개의 훈련 이미지를 처리할 수 있는 최첨단 스토리지가 필요합니다. 가장 까다로운 DL 훈련 워크로드를 지원할 수 있는 고성능 데이터 서비스 솔루션이 필요합니다.

NetApp All-Flash 스토리지를 활용하면 2GBps 이상의 일관된 처리량 (최대 5GBps)을 확보할 수 있습니다. 또한, 1 밀리초 미만의 지연 시간과 95% 이상의 GPU 활용률을 실현할 수 있습니다. NAS 워크로드의 경우 단일 NetApp AFF A800 시스템은 순차적 읽기에서 25GBps의 처리량을 지원하고, 크기가 작은 랜덤 읽기에서 500μs 미만의 지연 시간으로 100 만 IOPS를 지원합니다.

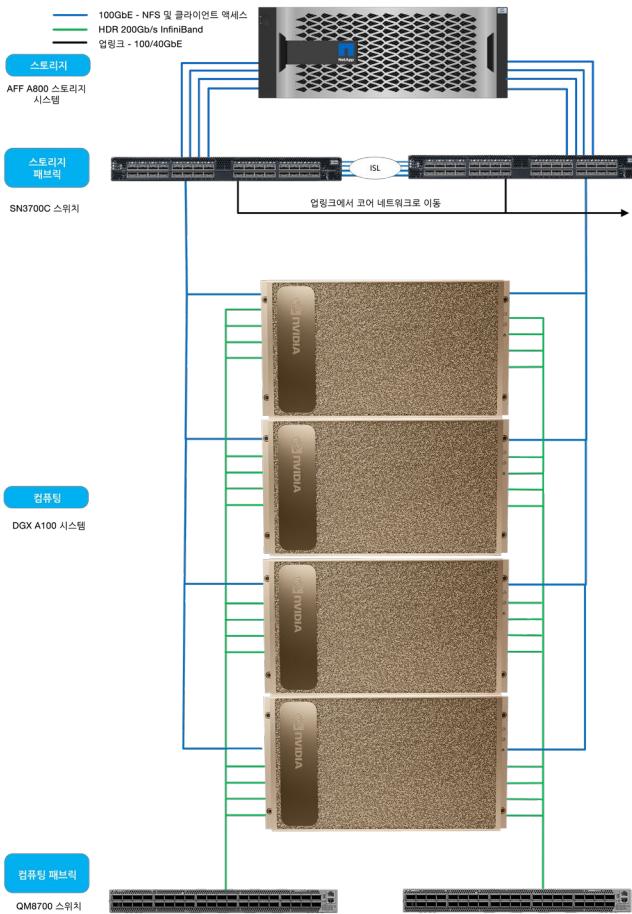


그림 2) Mellanox Spectrum 100GbE 스위치를 포함한 ONTAP AI 4 노드 구성

NetApp 랙 확장 아키텍처에서 All-Flash 스토리지를 통해 수십 테라바이트에서 수십 페타바이트로 확장할 수 있습니다. NetApp ONTAP FlexGroup을 사용하면 최대 20PB의 단일 네임스페이스로 4천억 개 이상의 파일을 처리할 수 있습니다.

### 에지에서 코어, 클라우드에 이르는 통합 데이터 파이프라인 구축

ONTAP AI는 Data Fabric을 사용하여 단일 플랫폼으로 데이터 파이프라인에서 데이터 관리를 통합합니다. 동일한 도구를 사용하여 이동 중이거나 사용 중인 데이터 또는 유형 데이터를 안전하게 제어 및 보호하고 자신 있게 규정 준수 요구사항을 충족할 수 있습니다. DL 환경에서 문제가 발생하면 검증된 지원 모델을 통해 문제를 해결하고 지침을 제공할 수 있습니다.

### AI 워크로드 통합

이제 조직은 사용량이 적거나 AI 워크로드를 처리하지 못하는 인프라 사일로를 제거할 수 있습니다. ONTAP AI를 사용하면 DGX A100 시스템을 기반으로 하는 범용 AI 인프라 솔루션을 구축할 수 있습니다. 이 솔루션은 분석, 훈련, 추론을 단일 플랫폼으로 통합하여 비즈니스 수요에 유연하게 대처할 수 있습니다. 또한, 기존 아키텍처보다 TCO가 더 우수합니다.

### NetApp 과 NVIDIA: 함께 혁신 추진

ONTAP AI의 핵심에는 훈련, 추론, 데이터 과학, 기타 고성능 워크로드를 지원하는 데이터 센터 AI용 범용 구성 요소인 DGX A100 시스템이 있습니다. 각 DGX A100 시스템은 8개 NVIDIA A100 Tensor Core GPU와 듀얼 2세대 AMD EPYC™ 프로세서로 구동되며 최신 고속 NVIDIA Mellanox 100/200Gb 이더넷과 InfiniBand 지원 ConnectX-6 어댑터 인터커넥트가 통합되어 있습니다.

새로운 NVIDIA 멀티 인스턴스 GPU(MIG) 기술로 DGX A100을 시스템당 최대 56개의 인스턴스로 파티셔닝하여 여러 작은 워크로드의 성능을 높일 수 있습니다. 빠른 속도를 통해 조직은 ONTAP AI에 GPU 성능을 효율적으로 할당할 수 있습니다. 기업의 데이터 과학팀은 더 빠르게 추론하고 재현 기능을 자동화하여, 우수한 품질의 AI 프로젝트를 최대 3개월 더 빠르게 완수할 수 있습니다.

NetApp AFF 시스템은 업계에서 세계 최초의 엔드 투 엔드 NVMe 기술을 제공하는 가장 빠르고 유연한 All-Flash 스토리지를 통해 ML 및 DL 프로세스의 데이터 흐름을 유지합니다. AFF A800 시스템은 DGX 시스템에 경쟁 솔루션보다 최대 4배 더 빠르게 데이터를 공급할 수 있습니다.<sup>1</sup>

ONTAP AI 솔루션은 Mellanox Spectrum 이더넷 스위치와 통합되어 제공됩니다. 이 스위치는 AI 환경에서 요구하는 짧은 지연 시간, 높은 밀도, 고성능, 전력 효율성을 제공합니다.

1. All-Flash 클러스터당 최대 300GBps의 읽기 처리량(주요 경쟁업체의 75GBps 대비)

NetApp에서 지원하는 Data Fabric은 동급 최강의 데이터 관리 및 클라우드 통합을 제공하여 중요한 데이터를 관리 및 보호하면서 DL의 속도를 높여줍니다.ONTAP은 직접 연결 스토리지와 비교하여 탁월한 22:1의 전체 데이터 감소율과 최대 54%의 TCO를 제공합니다.

DGX A100은 AI 및 데이터 과학 워크로드에 최적화된 NVIDIA DGX 소프트웨어 스택을 기반으로 하므로, 성능을 극대화하여 기업에서 AI 인프라에 대한 투자 수익률을 더 빠르게 회수할 수 있습니다.

NetApp AI Control Plane을 사용하면 Kubernetes 및 Kubeflow를 NetApp Data Fabric과 통합하여 AI 데이터 관리를 간소화할 수 있습니다. 이 통합 솔루션은 에지, 코어, 클라우드에서 최적의 데이터 가용성과 이동성을 제공합니다. AI Control Plane은 NetApp DataOps Toolkit을 통해 개선합니다. 이는 데이터 과학자와 데이터 엔지니어가 다양한 데이터 관리 작업을 쉽게 수행할 수 있도록 하는 Python 라이브러리입니다. 예를 들어, 새로운 데이터 볼륨을 프로비저닝하고, 데이터 볼륨을 즉시 복제하고, 추적 기능과 기준선 설정을 위한 NetApp Snapshot™ 데이터 볼륨 복사본을 생성할 수 있습니다.

성공을 위해서는 적합한 툴을 사용해야 합니다. 이것이 바로 ONTAP AI가 Domino Data Lab, Iguazio 등을 포함하여 선도적인 MLOps(머신 러닝 운영) 소프트웨어로 검증된 이유입니다. 익숙한 툴을 사용하여 AI 환경의 가치를 극대화하고 더 빠르게 통찰력을 얻을 수 있습니다.

#### 솔루션 구성 요소

- NVIDIA DGX A100 시스템
- NetApp AFF A-Series 스토리지 시스템 (ONTAP 9 포함)
- NVIDIA Mellanox Spectrum SN3700C, NVIDIA Mellanox Quantum QM8700 및 / 또는 NVIDIA Mellanox Spectrum SN3700-V
- NVIDIA DGX 소프트웨어 스택
- NetApp AI Control Plane
- NetApp DataOps 툴킷

#### 참조 아키텍처

NetApp은 특정 산업의 사용 사례를 대상으로 다음과 같은 ONTAP AI 기반 참조 아키텍처를 출시했습니다.

- ONTAP AI Reference Architecture for Healthcare: 진단 이미징
- ONTAP AI Reference Architecture for Autonomous Driving Workloads: 솔루션 설계
- ONTAP AI Reference Architecture for Financial Services Workloads: 솔루션 설계

#### NetApp 정보

평범함으로 가득한 세상에서 NetApp은 특별함을 선사합니다. NetApp은 귀사가 데이터를 최대한 활용할 수 있도록 돋는다는 한 가지 목표에 주력하고 있습니다. NetApp은 귀사에서 사용 중인 엔터프라이즈급 데이터 서비스를 클라우드로 전환하고, 클라우드의 유연성을 데이터 센터에 제공합니다. 업계 최고 수준의 NetApp 솔루션은 다양한 고객 환경과 세계 최대의 퍼블릭 클라우드에서 작동합니다.

클라우드 주도형 데이터 중심 소프트웨어 회사인 NetApp만이 고유한 Data Fabric을 구축하고, 클라우드를 단순화하고 연결하며, 언제 어디서나 원하는 사람에게 원하는 데이터와 서비스, 애플리케이션을 안전하게 제공하도록 지원할 수 있습니다.

[www.netapp.com/kr](http://www.netapp.com/kr)

#### NVIDIA 정보

NVIDIA는 1999년 GPU를 발명하여 PC 게임 시장 성장에 핵심적인 역할을 했으며, 현대적 컴퓨터 그래픽을 재정의하고 병렬 컴퓨팅의 변혁을 일으켰습니다. 최근 GPU 딥 러닝은 컴퓨팅의 다음 시대라 할 수 있는 현대적 인공지능(AI)의 포문을 열었습니다. GPU는 컴퓨터와 로봇, 자율주행차 등에 탑재되어 세계를 인지하고 이해할 수 있도록 돋는 뇌 역할을 하고 있습니다. 오늘날, NVIDIA는 'AI 컴퓨팅 기업'으로서의 인지도를 높여가고 있습니다. 자세한 내용은 [www.nvidia.com](http://www.nvidia.com)을 참조하십시오.

