aws

Panduan Developer

AWS Deep Learning AMIs

Copyright © 2025 Amazon Web Services, Inc. and/or its affiliates. All rights reserved.

AWS Deep Learning AMIs: Panduan Developer

Copyright © 2025 Amazon Web Services, Inc. and/or its affiliates. All rights reserved.

Merek dagang dan tampilan dagang Amazon tidak boleh digunakan sehubungan dengan produk atau layanan apa pun yang bukan milik Amazon, dengan cara apa pun yang dapat menyebabkan kebingungan di antara pelanggan, atau dengan cara apa pun yang merendahkan atau mendiskreditkan Amazon. Semua merek dagang lain yang tidak dimiliki oleh Amazon merupakan hak milik masing-masing pemiliknya, yang mungkin atau tidak terafiliasi, terkait dengan, atau disponsori oleh Amazon.

Table of Contents

Apa itu AWS Deep Learning AMIs?

AWS Deep Learning AMIs (DLAMI) menyediakan gambar mesin khusus yang dapat Anda gunakan untuk pembelajaran mendalam di cloud. Sebagian besar DLAMIs tersedia Wilayah AWS untuk berbagai jenis instans Amazon Elastic Compute Cloud (Amazon EC2), dari instans kecil khusus CPU hingga instans multi-GPU berdaya tinggi terbaru. DLAMIs Datang dikonfigurasikan sebelumnya dengan NVIDIA CUDA dan NVIDIA cuDNN dan rilis terbaru dari kerangka pembelajaran mendalam yang paling populer.

Tentang panduan ini

Konten di dapat membantu Anda meluncurkan dan menggunakan DLAMIs. Panduan ini mencakup beberapa kasus penggunaan pembelajaran mendalam yang umum, baik untuk pelatihan maupun inferensi. Ini juga mencakup cara memilih AMI yang tepat untuk tujuan Anda dan jenis contoh yang mungkin Anda sukai.

Selain itu, DLAMIs termasuk beberapa tutorial yang disediakan oleh kerangka kerja yang didukung mereka. Panduan ini dapat menunjukkan cara mengaktifkan setiap kerangka kerja dan menemukan tutorial yang sesuai untuk memulai. Ini juga memiliki tutorial tentang pelatihan terdistribusi, debugging, menggunakan AWS Inferentia dan AWS Trainium, dan konsep kunci lainnya. Untuk petunjuk tentang cara mengatur server notebook Jupyter untuk menjalankan tutorial di browser Anda, lihat. Menyiapkan server Jupyter Notebook pada instance DLAMI

Prasyarat

Agar berhasil menjalankan DLAMIs, kami sarankan Anda terbiasa dengan alat baris perintah dan Python dasar.

Contoh kasus penggunaan DLAMI

Berikut ini adalah contoh dari beberapa kasus penggunaan umum untuk AWS Deep Learning AMIs (DLAMI).

Belajar tentang pembelajaran mendalam — DLAMI adalah pilihan tepat untuk belajar atau mengajar pembelajaran mesin dan kerangka pembelajaran mendalam. DLAMIs Menghilangkan sakit kepala dari pemecahan masalah instalasi setiap kerangka kerja dan membuat mereka bermain bersama di komputer yang sama. DLAMIs Termasuk notebook Jupyter dan membuatnya mudah untuk

menjalankan tutorial yang disediakan kerangka kerja bagi orang-orang yang baru mengenal pembelajaran mesin dan pembelajaran mendalam.

Pengembangan aplikasi — Jika Anda seorang pengembang aplikasi yang tertarik menggunakan pembelajaran mendalam untuk membuat aplikasi Anda memanfaatkan kemajuan terbaru dalam AI, maka DLAMI adalah tempat uji yang sempurna untuk Anda. Setiap kerangka kerja dilengkapi dengan tutorial tentang cara memulai pembelajaran mendalam, dan banyak dari mereka memiliki kebun binatang model yang membuatnya mudah untuk mencoba pembelajaran mendalam tanpa harus membuat jaringan saraf sendiri atau melakukan pelatihan model apa pun. Beberapa contoh menunjukkan cara membuat aplikasi deteksi gambar hanya dalam beberapa menit, atau cara membuat aplikasi pengenalan suara untuk chatbot Anda sendiri.

Pembelajaran mesin dan analitik data — Jika Anda seorang ilmuwan data atau Anda tertarik untuk memproses data Anda dengan pembelajaran mendalam, maka Anda akan menemukan bahwa banyak kerangka kerja memiliki dukungan untuk R dan Spark. Anda akan menemukan tutorial tentang cara melakukan regresi sederhana, hingga membangun sistem pemrosesan data yang dapat diskalakan untuk sistem personalisasi dan prediksi.

Penelitian — Jika Anda seorang peneliti yang ingin mencoba kerangka kerja baru, menguji model baru, atau melatih model baru, maka DLAMI AWS dan kemampuan untuk skala dapat mengurangi rasa sakit instalasi yang membosankan dan pengelolaan beberapa node pelatihan.

> **Note**
>
> Meskipun pilihan awal Anda mungkin memutakhirkan jenis instans Anda ke instans yang lebih besar dengan lebih banyak GPUs (hingga 8), Anda juga dapat menskalakan secara horizontal dengan membuat klaster instans DLAMI. Lihat informasi Informasi terkait DLAMI lebih lanjut tentang build cluster.

Fitur DLAMI

Fitur AWS Deep Learning AMIs (DLAMI) termasuk kerangka kerja pembelajaran mendalam yang telah diinstal sebelumnya, perangkat lunak GPU, server model, dan alat visualisasi model.

Kerangka kerja terinstal

Saat ini ada dua rasa utama DLAMI dengan variasi lain yang terkait dengan sistem operasi (OS) dan versi perangkat lunak:

- Pembelajaran Mendalam AMI dengan Conda— Kerangka kerja diinstal secara terpisah menggunakan `conda` paket dan lingkungan Python terpisah.
- Dasar Pembelajaran Mendalam AMI— Tidak ada kerangka kerja yang diinstal; hanya NVIDIA CUDA dan dependensi lainnya.

AMI Pembelajaran Mendalam dengan Conda menggunakan `conda` lingkungan untuk mengisolasi setiap kerangka kerja, sehingga Anda dapat beralih di antara mereka sesuka hati dan tidak khawatir tentang dependensinya yang bertentangan. AMI Pembelajaran Mendalam dengan Conda mendukung kerangka kerja berikut:

- PyTorch
- TensorFlow 2

> **Note**
>
> DLAMI tidak lagi mendukung kerangka pembelajaran mendalam berikut: Apache, Microsoft Cognitive Toolkit (CNTK) MXNet, Caffe, Caffe2, Theano, Chainer, dan Keras.

Perangkat lunak GPU yang sudah diinstal sebelumnya

Bahkan jika Anda menggunakan instance khusus CPU, DLAMIs akan memiliki NVIDIA CUDA dan NVIDIA cuDNN. Perangkat lunak yang diinstal adalah sama terlepas dari jenis instancenya. Perlu diingat bahwa alat khusus GPU hanya berfungsi pada instance yang memiliki setidaknya satu GPU. Untuk informasi selengkapnya tentang jenis instance, lihatMemilih tipe instans DLAMI.

Untuk informasi lebih lanjut tentang CUDA, lihatInstalasi CUDA dan Binding Kerangka Kerja.

Penyajian model dan visualisasi

Deep Learning AMI with Conda sudah diinstal sebelumnya dengan server model untuk TensorFlow, serta TensorBoard untuk visualisasi model. Untuk informasi selengkapnya, lihat TensorFlow Melayani.

Catatan AMIs Rilis Deep Learning

Di sini Anda dapat menemukan catatan rilis terperinci untuk semua opsi yang saat ini didukung AWS Deep Learning AMIs (DLAMI).

Untuk catatan rilis untuk kerangka kerja DLAMI yang tidak lagi kami dukung, lihat bagian Unsupported Framework Release Notes Archive pada halaman DLAMI Framework Support Policy.

> **Note**
>
> AWS Deep Learning AMIs Memiliki irama rilis malam untuk patch keamanan. Kami tidak menyertakan patch keamanan tambahan ini dalam catatan rilis.

Catatan Rilis

- P6-B200 DLAMI yang Didukung
- Catatan Rilis untuk Base DLAMIs
- Catatan Rilis untuk Kerangka Tunggal DLAMIs
- Catatan Rilis untuk Multi-Framework DLAMIs

P6-B200 DLAMI yang Didukung

Di bawah ini adalah persyaratan terperinci untuk menjalankan DLAMI

P6-B200 Didukung DLAMIs

DLAMI Berikut mendukung instans P6-B200:

- AWS Basis Pembelajaran Mendalam AMI (Amazon Linux 2023)
- AWS AMI Dasar Pembelajaran Mendalam (Ubuntu 24.04)
- AWS Basis Pembelajaran Mendalam AMI (Ubuntu 22.04)

DLAMI ini berisi perangkat lunak berikut yang diperlukan untuk mengoperasikan instance P6-B200:

Perangkat lunak	Persyaratan Versi Minimum
Kit Alat Nvidia CUDA	12.8
Pengemudi Nvidia	R570
NVLINK 5	R570
Kernel Linux	6.1
Adaptor Kain Elastis (EFA)	1.41.0
AWS Plugin OFI NCCL	1.15.0

Konfirmasikan Fungsionalitas GPU

Untuk mengkonfirmasi fungsional GPUs:

1. Jalankan Uji Kueri Perangkat GPU Nvidia berikut

```
$ /usr/local/cuda/extras/demo_suite/deviceQuery
```

2. Konfirmasikan output Berikut dari Device Query Run:

```
$ /usr/local/cuda/extras/demo_suite/deviceQuery
/usr/local/cuda/extras/demo_suite/deviceQuery Starting...

 CUDA Device Query (Runtime API)

Detected 8 CUDA Capable device(s)
...
deviceQuery, CUDA Driver = CUDART, CUDA Driver Version = 12.8, CUDA Runtime Version
 = 12.8, NumDevs = 8, Device0 = NVIDIA B200, Device1 = NVIDIA B200, Device2 =
 NVIDIA B200, Device3 = NVIDIA B200, Device4 = NVIDIA B200, Device5 = NVIDIA B200,
 Device6 = NVIDIA B200, Device7 = NVIDIA B200
Result = PASS
```

Untuk mengkonfirmasi driver NVIDIA fungsional:

1. Jalankan Antarmuka Manajemen Sistem Nvidia

```
$ nvidia-smi
```

2. Konfirmasikan output Berikut dari Antarmuka Manajemen Sistem

```
+-----------------------------------------------------------------------------------------
+
| NVIDIA-SMI 570.133.20             Driver Version: 570.133.20     CUDA Version:
 12.8     |
|-----------------------------------------+------------------------
+----------------------+
| GPU  Name                 Persistence-M | Bus-Id          Disp.A | Volatile
 Uncorr. ECC |
| Fan  Temp   Perf          Pwr:Usage/Cap |           Memory-Usage | GPU-Util
 Compute M. |
|                                         |                        |
 MIG M. |
|=========================================+========================
+======================|
|   0  NVIDIA B200                    Off |   00000000:51:00.0 Off |
     0 |
| N/A   32C    P0            145W / 1000W |       0MiB / 183359MiB |      0%
 Default |
|                                         |                        |
 Disabled |
+-----------------------------------------+------------------------
+----------------------+
|   1  NVIDIA B200                    Off |   00000000:52:00.0 Off |
     0 |
| N/A   30C    P0            140W / 1000W |       0MiB / 183359MiB |      0%
 Default |
|                                         |                        |
 Disabled |
+-----------------------------------------+------------------------
+----------------------+
|   2  NVIDIA B200                    Off |   00000000:62:00.0 Off |
     0 |
| N/A   31C    P0            139W / 1000W |       0MiB / 183359MiB |      0%
 Default |
|                                         |                        |
 Disabled |
```

```
+-----------------------------------------+------------------------
+----------------------+
|   3  NVIDIA B200                    Off |   00000000:63:00.0 Off |
     0 |
| N/A   29C    P0            139W / 1000W |       0MiB / 183359MiB |      0%
 Default |
|                                         |                        |
 Disabled |
+-----------------------------------------+------------------------
+----------------------+
|   4  NVIDIA B200                    Off |   00000000:75:00.0 Off |
     0 |
| N/A   31C    P0            141W / 1000W |       0MiB / 183359MiB |      0%
 Default |
|                                         |                        |
 Disabled |
+-----------------------------------------+------------------------
+----------------------+
|   5  NVIDIA B200                    Off |   00000000:76:00.0 Off |
     0 |
| N/A   31C    P0            141W / 1000W |       0MiB / 183359MiB |      0%
 Default |
|                                         |                        |
 Disabled |
+-----------------------------------------+------------------------
+----------------------+
|   6  NVIDIA B200                    Off |   00000000:86:00.0 Off |
     0 |
| N/A   32C    P0            141W / 1000W |       0MiB / 183359MiB |      0%
 Default |
|                                         |                        |
 Disabled |
+-----------------------------------------+------------------------
+----------------------+
|   7  NVIDIA B200                    Off |   00000000:87:00.0 Off |
     0 |
| N/A   30C    P0            138W / 1000W |       0MiB / 183359MiB |      0%
 Default |
|                                         |                        |
 Disabled |
+-----------------------------------------+------------------------
+----------------------+
```

```
+-----------------------------------------------------------------------------------------
+
| Processes:
       |
|  GPU   GI   CI              PID   Type   Process name                          GPU
 Memory |
|        ID   ID
 Usage      |
|
=============================================================================================|
|  No running processes found
       |
+-----------------------------------------------------------------------------------------
+
```

Jika Anda mengalami masalah dengan instans P6-B200, silakan hubungi Support. AWS

Catatan Rilis untuk Base DLAMIs

Catatan Rilis DLAMI Basis X86

- Catatan Rilis DLAMI Basis X86
- ARM64 Catatan Rilis DLAMI Dasar

Catatan Rilis DLAMI Basis X86

Berikut adalah catatan rilis untuk X86 Base DLAMI:

GPU

- AWS Basis Pembelajaran Mendalam AMI (Amazon Linux 2023) (Mendukung P6-B200)
- AWS AMI Dasar Pembelajaran Mendalam (Ubuntu 24.04) (Mendukung P6-B200)
- AWS AMI Dasar Pembelajaran Mendalam (Ubuntu 22.04) (Mendukung P6-B200)
- AWS Basis Pembelajaran Mendalam AMI (Amazon Linux 2)

Qualcomm

- AWS Basis Pembelajaran Mendalam Qualcomm AMI (Amazon Linux 2)

AWS Neuron

- Lihat Panduan Pengguna DLAMI Neuron.

AWS GPU Basis Pembelajaran Mendalam AMI (Amazon Linux 2023)

Untuk bantuan memulai, lihatMemulai dengan DLAMI.

Format nama AMI

- Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Amazon Linux 2023) $ {YYYY-MM-DD}

EC2 Instans yang Didukung

- Silakan lihat Perubahan penting pada DLAMI
- Pembelajaran Mendalam dengan OSS Nvidia Driver mendukung G4dn, G5, G6, Gr6, G6e, P4d, P4de, P5, P5e, P5en, P6-B200

AMI meliputi yang berikut:

- AWS Layanan yang Didukung: Amazon EC2
- Sistem Operasi: Amazon Linux 2023
- Arsitektur Komputasi: x86
- Versi terbaru yang tersedia diinstal untuk paket-paket berikut:
  - Kernel Linux: 6.1
  - FSx Kilau
  - NVIDIA GDS
  - Docker
  - AWS CLI v2 di/usr/local/bin/aws2 dan AWS CLI v1 di/usr/bin/aws
  - NVIDIA DCGM
  - Toolkit wadah Nvidia:
    - Perintah versi: nvidia-container-cli -V
  - NVIDIA-Docker2:
    - Perintah versi: versi nvidia-docker

- Pengemudi NVIDIA: 570.133.20
- NVIDIA CUDA 12.4-12.6 dan 12.8 tumpukan:
  - Direktori instalasi CUDA, NCCL dan cudDN:/-xx.x/ usr/local/cuda
    - Contoh:/usr/local/cuda-12.8/ , /usr/local/cuda-12.8/
  - Versi NCCL yang dikompilasi: 2.26.5
  - CUDA standar: 12.8
    - PATH/usr/local/cudamenunjuk ke CUDA 12.8
    - Diperbarui di bawah env vars:
      - LD_LIBRARY_PATH memiliki/usr/local/cuda-12.8/lib:/usr/local/cuda-12.8/lib64:/usr/local/cuda-12.8:/usr/local/cuda-12.4/targets/x86_64-linux/lib
      - PATH untuk memiliki/usr/local/cuda-12.8/bin/:/usr/local/cuda-12.8/include/
      - Untuk versi CUDA yang berbeda, harap perbarui LD_LIBRARY_PATH yang sesuai.
- Pemasang EFA: 1.40.0
- Nvidia GDRCopy: 2.5.1
- AWS Plugin OFI NCCL dilengkapi dengan installer EFA
  - opt/amazon/ofi-nccl/lib and /opt/amazon/ofi-nccl/efaPaths/ditambahkan ke LD_LIBRARY_PATH.
- AWS CLI v2 di/usr/local/bin/aws2 dan AWS CLI v1 di/usr/bin/aws
- Jenis volume EBS: gp3
- Python:/3.9 usr/bin/python
- NVMe Lokasi Penyimpanan Instance (pada EC2 instance yang Didukung):/opt/dlami/nvme
- Kueri AMI-ID dengan Parameter SSM (contoh Wilayah adalah us-east-1):
  - Pengemudi OSS Nvidia:

```
SSM_PARAMETER=base-oss-nvidia-driver-gpu-amazon-linux-2023/latest/ami-id \
    aws ssm get-parameter --region us-east-1 \
    --name /aws/service/deeplearning/ami/x86_64/$SSM_PARAMETER  \
    --query "Parameter.Value" \
    --output text
```

- Kueri AMI-ID dengan AWSCLI (contoh Wilayah adalah us-east-1):
  - Pengemudi OSS Nvidia:

```
aws ec2 describe-images --region us-east-1 \
    --owners amazon \
```

```
    --filters 'Name=name,Values=Deep Learning Base OSS Nvidia Driver GPU AMI
 (Amazon Linux 2023) ????????' 'Name=state,Values=available' \
    --query 'reverse(sort_by(Images, &CreationDate))[:1].ImageId' \
    --output text
```

Pemberitahuan

Toolkit Kontainer NVIDIA 1.17.4

Dalam Container Toolkit versi 1.17.4 pemasangan pustaka compat CUDA sekarang dinonaktifkan. Untuk memastikan kompatibilitas dengan beberapa versi CUDA pada alur kerja kontainer, pastikan Anda memperbarui LD_LIBRARY_PATH Anda untuk menyertakan pustaka kompatibilitas CUDA Anda seperti yang ditunjukkan dalam tutorial Jika Anda menggunakan lapisan kompatibilitas CUDA.

Kebijakan Support

AMIs Komponen versi AMI seperti CUDA ini dapat dihapus dan diubah berdasarkan kebijakan dukungan kerangka kerja atau untuk mengoptimalkan kinerja untuk wadah pembelajaran mendalam atau untuk mengurangi ukuran AMI di rilis mendatang, tanpa pemberitahuan sebelumnya. Kami menghapus versi CUDA dari AMIs jika tidak digunakan oleh versi kerangka kerja yang didukung.

Instans P6-B200

Instans P6-B200 berisi 8 kartu antarmuka jaringan, dan dapat diluncurkan menggunakan perintah berikut: AWS CLI

```
aws ec2 run-instances --region $REGION \
    --instance-type $INSTANCETYPE \
    --image-id $AMI --key-name $KEYNAME \
    --iam-instance-profile "Name=dlami-builder" \
    --tag-specifications "ResourceType=instance,Tags=[{Key=Name,Value=$TAG}]" \
    --network-interfaces "NetworkCardIndex=0,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa" \
      "NetworkCardIndex=1,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      "NetworkCardIndex=2,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      "NetworkCardIndex=3,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      "NetworkCardIndex=4,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
```

```
      "NetworkCardIndex=5,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      "NetworkCardIndex=6,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      "NetworkCardIndex=7,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
```

Contoh P5en

Instans P5en berisi 16 kartu antarmuka jaringan, dan dapat diluncurkan menggunakan perintah berikut: AWS CLI

```
aws ec2 run-instances --region $REGION \
    --instance-type $INSTANCETYPE \
    --image-id $AMI --key-name $KEYNAME \
    --iam-instance-profile "Name=dlami-builder" \
    --tag-specifications "ResourceType=instance,Tags=[{Key=Name,Value=$TAG}]" \
    --network-interfaces "NetworkCardIndex=0,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa" \
      "NetworkCardIndex=1,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      "NetworkCardIndex=2,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      "NetworkCardIndex=3,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      "NetworkCardIndex=4,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      ...
      "NetworkCardIndex=15,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
```

Contoh P5/P5e

Instans P5 dan P5e berisi 32 kartu antarmuka jaringan, dan dapat diluncurkan menggunakan perintah berikut: AWS CLI

```
aws ec2 run-instances --region $REGION \
    --instance-type $INSTANCETYPE \
    --image-id $AMI --key-name $KEYNAME \
    --iam-instance-profile "Name=dlami-builder" \
    --tag-specifications "ResourceType=instance,Tags=[{Key=Name,Value=$TAG}]" \
    --network-interfaces "NetworkCardIndex=0,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa" \
      "NetworkCardIndex=1,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
```

```
    "NetworkCardIndex=2,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
\
    "NetworkCardIndex=3,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
\
    "NetworkCardIndex=4,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
\
    ...
    "NetworkCardIndex=31,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
```

Kernel

- Versi kernel disematkan menggunakan perintah:

```
sudo dnf versionlock kernel*
```

- Kami menyarankan agar pengguna menghindari memperbarui versi kernel mereka (kecuali karena patch keamanan) untuk memastikan kompatibilitas dengan driver dan versi paket yang diinstal. Jika pengguna masih ingin memperbarui, mereka dapat menjalankan perintah berikut untuk melepaskan pin versi kernel mereka:

```
sudo dnf versionlock delete kernel*
sudo dnf update -y
```

- Untuk setiap versi baru DLAMI, kernel kompatibel terbaru yang tersedia digunakan.

Tanggal Rilis: 2025-05-15

Nama AMI: Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Amazon Linux 2023) 20250515

Ditambahkan

- Menambahkan dukungan untuk instance P6-B200 EC2

Diperbarui

- Installer EFA yang ditingkatkan dari versi 1.38.1 ke 1.40.0
- Upgrade GDRCopy dari versi 2.4 ke 2.5
- Plugin AWS OFI NCCL yang ditingkatkan dari versi 1.13.0-aws ke 1.14.2-aws

- Diperbarui dikompilasi Versi NCCL dari versi 2.25.1 ke 2.26.5
- Diperbarui versi CUDA default dari versi 12.6 ke 12.8
- Diperbarui versi Nvidia DCGM dari 3.3.9 ke 4.4.3

Tanggal Rilis: 2025-04-22

Nama AMI: Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Amazon Linux 2023) 20250421

Diperbarui

- Driver Nvidia yang ditingkatkan dari versi 570.124.06 ke 570.133.20 ke alamat yang CVEs ada di Buletin Keamanan Driver Tampilan GPU NVIDIA untuk April 2025

Tanggal Rilis: 2025-03-31

Nama AMI: Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Amazon Linux 2023) 20250328

Ditambahkan

- Menambahkan dukungan untuk NVIDIA GPU Direct Storage (GDS)

Tanggal Rilis: 2025-02-17

Nama AMI: Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Amazon Linux 2023) 20250215

Diperbarui

- Diperbarui NVIDIA Container Toolkit dari versi 1.17.3 ke versi 1.17.4
  - Silakan lihat halaman catatan rilis di sini untuk informasi lebih lanjut: https://github.com/NVIDIA/nvidia-container-toolkit/releases/tag/v1.17.4
  - Di Container Toolkit versi 1.17.4, pemasangan pustaka compat CUDA sekarang dinonaktifkan. Untuk memastikan kompatibilitas dengan beberapa versi CUDA pada alur kerja kontainer, pastikan Anda memperbarui LD_LIBRARY_PATH Anda untuk menyertakan pustaka kompatibilitas CUDA Anda seperti yang ditunjukkan dalam tutorial Jika Anda menggunakan lapisan kompatibilitas CUDA.

Dihapus

- Pustaka ruang pengguna yang dihapus cuobj dan nvdisasm disediakan oleh toolkit NVIDIA CUDA untuk mengatasi yang CVEs ada di Buletin Keamanan NVIDIA CUDA Toolkit untuk 18 Februari 2025

Tanggal Rilis: 2025-02-05

Nama AMI: Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Amazon Linux 2023) 20250205

Ditambahkan

- Ditambahkan CUDA toolkit versi 12.6 di direktori/-12.6 usr/local/cuda
- Menambahkan dukungan untuk Instans G5 EC2

Dihapus

- CUDA versi 12.1 dan 12.2 telah dihapus dari DLAMI ini. Pelanggan yang membutuhkan versi toolkit CUDA ini dapat menginstalnya langsung dari NVIDIA menggunakan tautan di bawah ini
  - https://developer.nvidia.com/cuda-toolkit-archive

Tanggal Rilis: 2025-02-03

Nama AMI: Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Amazon Linux 2023) 20250131

Diperbarui

- Versi EFA yang ditingkatkan dari 1.37.0 ke 1.38.0
  - EFA sekarang menggabungkan plugin AWS OFI NCCL, yang sekarang dapat ditemukan di/-ofi-nccl/. opt/amazon/ofi-nccl rather than the original /opt/aws Jika memperbarui variabel LD_LIBRARY_PATH Anda, pastikan Anda memodifikasi lokasi OFI NCCL Anda dengan benar.
- Toolkit Kontainer Nvidia yang ditingkatkan dari 1.17.3 ke 1.17.4

Tanggal Rilis: 2025-01-08

Nama AMI: Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Amazon Linux 2023) 20250107

Diperbarui

- Menambahkan dukungan untuk instance G4dn

Tanggal Rilis: 2024-12-09

Nama AMI: Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Amazon Linux 2023) 20241206

Diperbarui

- Toolkit Kontainer Nvidia yang ditingkatkan dari versi 1.17.0 ke 1.17.3

Tanggal Rilis: 2024-11-21

Nama AMI: Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Amazon Linux 2023) 20241121

Ditambahkan

- Menambahkan dukungan untuk Instans P5en EC2 .

Diperbarui

- Installer EFA yang ditingkatkan dari versi 1.35.0 ke 1.37.0
- Tingkatkan Plugin AWS OFI NCCL dari versi 1.121-aws ke 1.13.0-aws

Tanggal Rilis: 2024-10-30

Nama AMI: Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Amazon Linux 2023) 20241030

Ditambahkan

- Rilis awal Deep Learning Base OSS DLAMI untuk Amazon Linux 2023

Masalah yang Diketahui

- DLAMI ini tidak mendukung instans G4dn dan G5 saat ini. EC2 AWS menyadari ketidakcocokan yang dapat mengakibatkan kegagalan inisialisasi CUDA, yang memengaruhi keluarga instans G4dn dan G5 saat menggunakan driver NVIDIA open source bersama dengan kernel Linux versi 6.1 atau yang lebih baru. Masalah ini memengaruhi distribusi Linux seperti Amazon Linux 2023, Ubuntu 22.04 atau yang lebih baru, atau SUSE Linux Enterprise Server 15 SP6 atau yang lebih baru, antara lain.

AWS GPU AMI Dasar Pembelajaran Mendalam (Ubuntu 24.04)

Untuk bantuan memulai, lihatMemulai dengan DLAMI.

Format nama AMI

- Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Ubuntu 24.04) $ {YYYY-MM-DD}

EC2 Contoh yang didukung

- Silakan lihat Perubahan penting pada DLAMI.
- Pembelajaran Mendalam dengan OSS Nvidia Driver mendukung G4dn, G5, G6, Gr6, G6e, P4d, P4de, P5, P5e, P5en, P6-B200.

AMI meliputi yang berikut:

- AWS Layanan yang Didukung: Amazon EC2
- Sistem Operasi: Ubuntu 24.04
- Arsitektur Komputasi: x86
- Versi terbaru yang tersedia diinstal untuk paket-paket berikut:
  - Kernel Linux: 6. 8
  - FSx Kilau
  - Docker
  - AWS CLI v2 di/usr/bin/aws
  - NVIDIA DCGM
  - Toolkit wadah Nvidia:

    - Perintah versi: nvidia-container-cli -V
  - NVIDIA-Docker2:
    - Perintah versi: versi nvidia-docker
- Pengemudi NVIDIA: 570.133.20
- NVIDIA CUDA 12.6 dan 12.8 tumpukan:
  - Direktori instalasi CUDA, NCCL dan cudDN:/-xx.x/ usr/local/cuda
    - Contoh:/usr/local/cuda-12.8/ , /usr/local/cuda-12.8/
  - Versi NCCL yang dikompilasi: 2.25.1
  - CUDA standar: 12.8
    - PATH/usr/local/cudamenunjuk ke CUDA 12.8
    - Diperbarui di bawah env vars:
      - LD_LIBRARY_PATH memiliki/64 usr/local/cuda-12.8/lib:/usr/local/cuda-12.8/lib64:/usr/local/cuda-12.8:/usr/local/cuda-12.8/targets/sbsa-linux/lib:/usr/local/cuda-12.8/nvvm/lib64:/usr/local/cuda-12.8/extras/CUPTI/lib
      - PATH untuk memiliki/usr/local/cuda-12.8/bin/:/usr/local/cuda-12.8/include/
      - Untuk versi CUDA yang berbeda, harap perbarui LD_LIBRARY_PATH yang sesuai.
- Pemasang EFA: 1.40.0
- Nvidia GDRCopy: 2.5.1
- AWS Plugin OFI NCCL dilengkapi dengan installer EFA
  - opt/amazon/ofi-nccl/lib and /opt/amazon/ofi-nccl/efaPaths/ditambahkan ke LD_LIBRARY_PATH.
- AWS CLI v2 di/usr/bin/aws
- Jenis volume EBS: gp3
- Python:/3.12 usr/bin/python
- NVMe Lokasi Penyimpanan Instance (pada EC2 instance yang Didukung):/opt/dlami/nvme
- Kueri AMI-ID dengan Parameter SSM (contoh Wilayah adalah us-east-1):
  - Pengemudi OSS Nvidia:

```
SSM_PARAMETER=base-oss-nvidia-driver-gpu-ubuntu-24.04/latest/ami-id \
    aws ssm get-parameter --region us-east-1 \
    --name /aws/service/deeplearning/ami/x86_64/$SSM_PARAMETER  \
    --query "Parameter.Value" \
    --output text
```

- Kueri AMI-ID dengan AWSCLI (contoh Wilayah adalah us-east-1):
  - Pengemudi OSS Nvidia:

```
aws ec2 describe-images --region us-east-1 \
    --owners amazon \
    --filters 'Name=name,Values=Deep Learning Base OSS Nvidia Driver GPU AMI
 (Ubuntu 24.04) ????????' 'Name=state,Values=available' \
    --query 'reverse(sort_by(Images, &CreationDate))[:1].ImageId' \
    --output text
```

Pemberitahuan

Kebijakan Support

AMIs Komponen versi AMI seperti CUDA ini dapat dihapus dan diubah berdasarkan kebijakan dukungan kerangka kerja atau untuk mengoptimalkan kinerja untuk wadah pembelajaran mendalam atau untuk mengurangi ukuran AMI di rilis mendatang, tanpa pemberitahuan sebelumnya. Kami menghapus versi CUDA dari AMIs jika tidak digunakan oleh versi kerangka kerja yang didukung.

EC2 misalnya dengan beberapa kartu jaringan

- Banyak jenis contoh yang mendukung EFA juga memiliki beberapa kartu jaringan.
- DeviceIndex unik untuk setiap kartu jaringan, dan harus berupa bilangan bulat non-negatif kurang dari batas per. ENIs NetworkCard Pada P5, jumlah ENIs per NetworkCard adalah 2, yang berarti bahwa satu-satunya nilai yang valid untuk DeviceIndex adalah 0 atau 1.
  - Untuk antarmuka jaringan utama (indeks kartu jaringan 0, indeks perangkat 0), buat antarmuka EFA (EFA dengan ENA). Anda tidak dapat menggunakan antarmuka jaringan khusus EFA sebagai antarmuka jaringan utama.
  - Untuk setiap antarmuka jaringan tambahan, gunakan indeks kartu jaringan yang tidak digunakan berikutnya, indeks perangkat 1, dan EFA (EFA dengan ENA) atau antarmuka jaringan khusus EFA, tergantung pada kasus penggunaan Anda, seperti persyaratan bandwidth ENA atau ruang alamat IP. Misalnya kasus penggunaan, lihat konfigurasi EFA untuk instance P5.
  - Untuk informasi lebih lanjut, lihat Panduan EFA di sini.

Instans P6-B200

Instans P6-B200 berisi 8 kartu antarmuka jaringan, dan dapat diluncurkan menggunakan perintah berikut: AWS CLI

```
aws ec2 run-instances --region $REGION \
    --instance-type $INSTANCETYPE \
    --image-id $AMI --key-name $KEYNAME \
    --iam-instance-profile "Name=dlami-builder" \
    --tag-specifications "ResourceType=instance,Tags=[{Key=Name,Value=$TAG}]" \
    --network-interfaces "NetworkCardIndex=0,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa" \
      "NetworkCardIndex=1,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      "NetworkCardIndex=2,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      "NetworkCardIndex=3,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      "NetworkCardIndex=4,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      "NetworkCardIndex=5,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      "NetworkCardIndex=6,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      "NetworkCardIndex=7,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
```

Contoh P5en

P5en berisi 16 kartu antarmuka jaringan, dan dapat diluncurkan menggunakan perintah berikut: AWS CLI

```
aws ec2 run-instances --region $REGION \
    --instance-type $INSTANCETYPE \
    --image-id $AMI --key-name $KEYNAME \
    --iam-instance-profile "Name=dlami-builder" \
    --tag-specifications "ResourceType=instance,Tags=[{Key=Name,Value=$TAG}]" \
    --network-interfaces "NetworkCardIndex=0,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa" \
      "NetworkCardIndex=1,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      "NetworkCardIndex=2,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      "NetworkCardIndex=3,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      "NetworkCardIndex=4,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      ...
```

```
      "NetworkCardIndex=15,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
```

Contoh P5/P5e

Instans P5 dan P5e berisi 32 kartu antarmuka jaringan, dan dapat diluncurkan menggunakan perintah berikut: AWS CLI

```
aws ec2 run-instances --region $REGION \
    --instance-type $INSTANCETYPE \
    --image-id $AMI --key-name $KEYNAME \
    --iam-instance-profile "Name=dlami-builder" \
    --tag-specifications "ResourceType=instance,Tags=[{Key=Name,Value=$TAG}]" \
    --network-interfaces "NetworkCardIndex=0,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa" \
     "NetworkCardIndex=1,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
     "NetworkCardIndex=2,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
     "NetworkCardIndex=3,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
     "NetworkCardIndex=4,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
     ...
     "NetworkCardIndex=31,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
```

Kernel

- Versi kernel disematkan menggunakan perintah:

  ```
  echo linux-aws hold | sudo dpkg –set-selections
  echo linux-headers-aws hold | sudo dpkg –set-selections
  echo linux-image-aws hold | sudo dpkg –set-selections
  ```

- Kami menyarankan agar pengguna menghindari memperbarui versi kernel mereka (kecuali karena patch keamanan) untuk memastikan kompatibilitas dengan driver dan versi paket yang diinstal. Jika pengguna masih ingin memperbarui, mereka dapat menjalankan perintah berikut untuk melepas pin versi kernel mereka:

  ```
  echo linux-aws install | sudo dpkg -set-selections
  echo linux-headers-aws install | sudo dpkg -set-selections
  echo linux-image-aws install | sudo dpkg -set-selections
  ```

- Untuk setiap versi baru DLAMI, kernel kompatibel terbaru yang tersedia digunakan.

Tanggal Rilis: 2025-05-22

Nama AMI: Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Ubuntu 24.04) 20250522

Ditambahkan

- Menambahkan dukungan untuk instance P6-B200 EC2

Diperbarui

- Installer EFA yang ditingkatkan dari versi 1.40.0 ke 1.41.0
- Diperbarui dikompilasi Versi NCCL dari versi 2.25.1 ke 2.26.5
- Diperbarui versi Nvidia DCGM dari 3.3.9 ke 4.4.3

Tanggal Rilis: 2025-05-13

Nama AMI: Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Ubuntu 24.04) 20250513

Ditambahkan

- Rilis awal dari Deep Learning Base OSS DLAMI untuk Ubuntu 24.04

AWS GPU AMI Dasar Pembelajaran Mendalam (Ubuntu 22.04)

Untuk bantuan memulai, lihatMemulai dengan DLAMI.

Format nama AMI

- Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Ubuntu 22.04) $ {YYYY-MM-DD}

EC2 Contoh yang didukung

- Silakan lihat Perubahan penting pada DLAMI.
- Pembelajaran Mendalam dengan OSS Nvidia Driver mendukung G4dn, G5, G6, Gr6, G6e, P4d, P4de, P5, P5e, P6-B200.

AMI meliputi yang berikut:

- AWS Layanan yang Didukung: Amazon EC2

- Sistem Operasi: Ubuntu 22.04
- Arsitektur Komputasi: x86
- Versi terbaru yang tersedia diinstal untuk paket-paket berikut:
  - Kernel Linux: 6. 8
  - FSx Kilau
  - Docker
  - AWS CLI v2 di/usr/local/bin/aws2 dan AWS CLI v1 di/usr/bin/aws
  - NVIDIA DCGM
  - Toolkit wadah Nvidia:
    - Perintah versi: nvidia-container-cli -V
  - NVIDIA-Docker2:
    - Perintah versi: versi nvidia-docker
- Pengemudi NVIDIA: 570.133.20
- NVIDIA CUDA 12.4-12.6 dan 12.8 tumpukan:
  - Direktori instalasi CUDA, NCCL dan cudDN:/-xx.x/ usr/local/cuda
    - Contoh:/usr/local/cuda-12.8/ , /usr/local/cuda-12.8/
  - Versi NCCL yang dikompilasi: 2.26.5
  - CUDA standar: 12.8
    - PATH/usr/local/cudamenunjuk ke CUDA 12.8
    - Diperbarui di bawah env vars:
      - LD_LIBRARY_PATH memiliki/64 usr/local/cuda-12.8/lib:/usr/local/cuda-12.8/lib64:/usr/local/cuda-12.8:/usr/local/cuda-12.8/targets/x86_64-linux/lib:/usr/local/cuda-12.8/extras/CUPTI/lib
      - PATH untuk memiliki/usr/local/cuda-12.8/bin/:/usr/local/cuda-12.8/include/
      - Untuk versi CUDA yang berbeda, harap perbarui LD_LIBRARY_PATH yang sesuai.
- Pemasang EFA: 1.40.0
- Nvidia GDRCopy: 2.5.1
- AWS Plugin OFI NCCL dilengkapi dengan installer EFA
  - opt/amazon/ofi-nccl/lib and /opt/amazon/ofi-nccl/efaPaths/ditambahkan ke LD_LIBRARY_PATH.
- AWS CLI v2 di/usr/local/bin/aws2 dan AWS CLI v1 di/usr/bin/aws
- Jenis volume EBS: gp3
- Python:/3.10 usr/bin/python

- NVMe Lokasi Penyimpanan Instance (pada EC2 instance yang Didukung):/opt/dlami/nvme
- Kueri AMI-ID dengan Parameter SSM (contoh Wilayah adalah us-east-1):
  - Pengemudi OSS Nvidia:

```
SSM_PARAMETER=base-oss-nvidia-driver-gpu-ubuntu-22.04/latest/ami-id \
    aws ssm get-parameter --region us-east-1 \
    --name /aws/service/deeplearning/ami/x86_64/$SSM_PARAMETER  \
    --query "Parameter.Value" \
    --output text
```

- Kueri AMI-ID dengan AWSCLI (contoh Wilayah adalah us-east-1):
  - Pengemudi OSS Nvidia:

```
aws ec2 describe-images --region us-east-1 \
      --owners amazon \
      --filters 'Name=name,Values=Deep Learning Base OSS Nvidia Driver GPU AMI
 (Ubuntu 22.04) ????????' 'Name=state,Values=available' \
      --query 'reverse(sort_by(Images, &CreationDate))[:1].ImageId' \
      --output text
```

Pemberitahuan

Toolkit Kontainer NVIDIA 1.17.4

Dalam Container Toolkit versi 1.17.4 pemasangan pustaka compat CUDA sekarang dinonaktifkan. Untuk memastikan kompatibilitas dengan beberapa versi CUDA pada alur kerja kontainer, pastikan Anda memperbarui LD_LIBRARY_PATH Anda untuk menyertakan pustaka kompatibilitas CUDA Anda seperti yang ditunjukkan dalam tutorial Jika Anda menggunakan lapisan kompatibilitas CUDA.

Pembaruan EFA dari 1.37 ke 1.38 (Rilis pada 2025-01-31)

EFA sekarang menggabungkan plugin AWS OFI NCCL, yang sekarang dapat ditemukan di/-ofi-nccl/. opt/amazon/ofi-nccl rather than the original /opt/aws Jika memperbarui variabel LD_LIBRARY_PATH Anda, pastikan Anda memodifikasi lokasi OFI NCCL Anda dengan benar.

Dukungan Multi ENI

- Ubuntu 22.04 secara otomatis mengatur dan mengonfigurasi perutean sumber pada beberapa NICss menggunakan cloud-init pada boot awalnya. Jika alur kerja attaching/detaching Anda

menyertakan ENIs saat instans dihentikan, konfigurasi tambahan harus ditambahkan ke data pengguna cloud-init untuk memastikan konfigurasi NIC yang tepat selama peristiwa ini. Contoh konfigurasi cloud disediakan di bawah ini.

- Silakan referensi dokumentasi Canonical ini di sini untuk informasi lebih lanjut tentang cara mengonfigurasi konfigurasi cloud untuk instance Anda - -/https://documentation.ubuntu.com/aws/en/latest/aws-how-to/instances/automaticallysetup-multiple-nics

```
#cloud-config
# apply network config on every boot and hotplug event
updates:
  network:
    when: ['boot', 'hotplug']
```

Kebijakan Support

AMIs Komponen versi AMI seperti CUDA ini dapat dihapus dan diubah berdasarkan kebijakan dukungan kerangka kerja atau untuk mengoptimalkan kinerja untuk wadah pembelajaran mendalam atau untuk mengurangi ukuran AMI di rilis mendatang, tanpa pemberitahuan sebelumnya. Kami menghapus versi CUDA dari AMIs jika tidak digunakan oleh versi kerangka kerja yang didukung.

EC2 contoh dengan beberapa kartu jaringan

- Banyak jenis contoh yang mendukung EFA juga memiliki beberapa kartu jaringan.
- DeviceIndex unik untuk setiap kartu jaringan, dan harus berupa bilangan bulat non-negatif kurang dari batas per. ENIs NetworkCard Pada P5, jumlah ENIs per NetworkCard adalah 2, yang berarti bahwa satu-satunya nilai yang valid untuk DeviceIndex adalah 0 atau 1.
  - Untuk antarmuka jaringan utama (indeks kartu jaringan 0, indeks perangkat 0), buat antarmuka EFA (EFA dengan ENA). Anda tidak dapat menggunakan antarmuka jaringan khusus EFA sebagai antarmuka jaringan utama.
  - Untuk setiap antarmuka jaringan tambahan, gunakan indeks kartu jaringan yang tidak digunakan berikutnya, indeks perangkat 1, dan EFA (EFA dengan ENA) atau antarmuka jaringan khusus EFA, tergantung pada kasus penggunaan Anda, seperti persyaratan bandwidth ENA atau ruang alamat IP. Misalnya kasus penggunaan, lihat konfigurasi EFA untuk instance P5.
  - Untuk informasi lebih lanjut, lihat Panduan EFA di sini.

Instans P6-B200

P6-B200 berisi 8 kartu antarmuka jaringan, dan dapat diluncurkan menggunakan perintah berikut: AWS CLI

```
aws ec2 run-instances --region $REGION \
    --instance-type $INSTANCETYPE \
    --image-id $AMI --key-name $KEYNAME \
    --iam-instance-profile "Name=dlami-builder" \
    --tag-specifications "ResourceType=instance,Tags=[{Key=Name,Value=$TAG}]" \
    --network-interfaces "NetworkCardIndex=0,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa" \
     "NetworkCardIndex=1,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
     "NetworkCardIndex=2,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
     "NetworkCardIndex=3,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
     "NetworkCardIndex=4,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
     "NetworkCardIndex=5,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
     "NetworkCardIndex=6,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
     "NetworkCardIndex=7,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
```

Contoh P5en

P5en berisi 16 kartu antarmuka jaringan, dan dapat diluncurkan menggunakan perintah berikut: AWS CLI

```
aws ec2 run-instances --region $REGION \
    --instance-type $INSTANCETYPE \
    --image-id $AMI --key-name $KEYNAME \
    --iam-instance-profile "Name=dlami-builder" \
    --tag-specifications "ResourceType=instance,Tags=[{Key=Name,Value=$TAG}]" \
    --network-interfaces "NetworkCardIndex=0,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa" \
     "NetworkCardIndex=1,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
     "NetworkCardIndex=2,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
     "NetworkCardIndex=3,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
     "NetworkCardIndex=4,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
     ....
     "NetworkCardIndex=15,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
```

Contoh P5/P5e

Instans P5 dan P5e berisi 32 kartu antarmuka jaringan, dan dapat diluncurkan menggunakan perintah berikut: AWS CLI

```
aws ec2 run-instances --region $REGION \
    --instance-type $INSTANCETYPE \
    --image-id $AMI --key-name $KEYNAME \
    --iam-instance-profile "Name=dlami-builder" \
    --tag-specifications "ResourceType=instance,Tags=[{Key=Name,Value=$TAG}]" \
    --network-interfaces "NetworkCardIndex=0,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa" \
     "NetworkCardIndex=1,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
     "NetworkCardIndex=2,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
     "NetworkCardIndex=3,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
     "NetworkCardIndex=4,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
     ...
     "NetworkCardIndex=31,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
```

Kernel

- Versi kernel disematkan menggunakan perintah:

```
echo linux-aws hold | sudo dpkg –set-selections
echo linux-headers-aws hold | sudo dpkg –set-selections
echo linux-image-aws hold | sudo dpkg –set-selections
```

- Kami menyarankan agar pengguna menghindari memperbarui versi kernel mereka (kecuali karena patch keamanan) untuk memastikan kompatibilitas dengan driver dan versi paket yang diinstal. Jika pengguna masih ingin memperbarui, mereka dapat menjalankan perintah berikut untuk melepas pin versi kernel mereka:

```
echo linux-aws install | sudo dpkg -set-selections
echo linux-headers-aws install | sudo dpkg -set-selections
echo linux-image-aws install | sudo dpkg -set-selections
```

- Untuk setiap versi baru DLAMI, kernel kompatibel terbaru yang tersedia digunakan.

Tanggal Rilis: 2025-05-16

Nama AMI: Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Ubuntu 22.04) 20250516

Ditambahkan

- Menambahkan dukungan untuk instance P6-B200 EC2

Diperbarui

- Installer EFA yang ditingkatkan dari versi 1.39.0 ke 1.40.0
- Tingkatkan Plugin AWS OFI NCCL dari versi 1.13.0-aws ke 1.14.2-aws
- Diperbarui dikompilasi Versi NCCL dari versi 2.22.3 ke 2.26.5
- Diperbarui versi CUDA default dari versi 12.6 ke 12.8
- Diperbarui versi Nvidia DCGM dari 3.3.9 ke 4.4.3

Tanggal Rilis: 2025-05-05

Nama AMI: Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Ubuntu 22.04) 20250503

Diperbarui

- Upgrade GDRCopy dari 2.4.1 ke 2.5.1

Tanggal Rilis: 2025-04-24

Nama AMI: Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Ubuntu 22.04) 20250424

Diperbarui

- Driver Nvidia yang ditingkatkan dari versi 570.124.06 ke 570.133.20 ke alamat yang CVEs ada di Buletin Keamanan Driver Tampilan GPU NVIDIA untuk April 2025

Tanggal Rilis: 2025-02-17

Nama AMI: Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Ubuntu 22.04) 20250214

Diperbarui

- Diperbarui NVIDIA Container Toolkit dari versi 1.17.3 ke versi 1.17.4
  - Silakan lihat halaman catatan rilis di sini untuk informasi lebih lanjut: https://github.com/NVIDIA/nvidia-container-toolkit/releases/tag/v1.17.4
  - Di Container Toolkit versi 1.17.4, pemasangan pustaka compat CUDA sekarang dinonaktifkan. Untuk memastikan kompatibilitas dengan beberapa versi CUDA pada alur kerja kontainer, pastikan Anda memperbarui LD_LIBRARY_PATH Anda untuk menyertakan pustaka

kompatibilitas CUDA Anda seperti yang ditunjukkan dalam tutorial Jika Anda menggunakan lapisan kompatibilitas CUDA.

Dihapus

- Pustaka ruang pengguna yang dihapus cuobj dan nvdisasm disediakan oleh toolkit NVIDIA CUDA untuk mengatasi yang CVEs ada di Buletin Keamanan NVIDIA CUDA Toolkit untuk 18 Februari 2025

Tanggal Rilis: 2025-02-07

Nama AMI: Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Ubuntu 22.04) 20250205

Ditambahkan

- Ditambahkan CUDA toolkit versi 12.6 di direktori/-12.6 usr/local/cuda

Dihapus

- CUDA versi 12.1 dan 12.2 telah dihapus dari DLAMI ini. Pelanggan dapat menginstal versi ini dari NVIDIA menggunakan tautan di bawah ini
  - https://developer.nvidia.com/cuda-toolkit-archive

Tanggal Rilis: 2025-01-31

Nama AMI: Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Ubuntu 22.04) 20250131

Diperbarui

- Versi EFA yang ditingkatkan dari 1.37.0 ke 1.38.0
  - EFA sekarang menggabungkan plugin AWS OFI NCCL, yang sekarang dapat ditemukan di/-ofi-nccl/. opt/amazon/ofi-nccl rather than the original /opt/aws Jika memperbarui variabel LD_LIBRARY_PATH Anda, pastikan Anda memodifikasi lokasi OFI NCCL Anda dengan benar.
- Toolkit Kontainer Nvidia yang ditingkatkan dari 1.17.3 ke 1.17.4

Tanggal Rilis: 2025-01-17

Nama AMI: Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Ubuntu 22.04) 20250117

Diperbarui

- Driver Nvidia yang ditingkatkan dari versi 550.127.05 ke 550.144.03 ke alamat yang CVEs ada di Buletin Keamanan Driver Tampilan GPU NVIDIA untuk Januari 2025

Tanggal Rilis: 2024-11-18

Nama AMI: Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Ubuntu 22.04) 20241115

Ditambahkan

- FSx Paket Amazon untuk dukungan Lustre ditambahkan.

Tetap

- Karena perubahan kernel Ubuntu untuk mengatasi cacat pada fungsionalitas Kernel Address Space Layout Randomization (KASLR), instance G4Dn/G5 tidak dapat menginisialisasi CUDA dengan benar pada driver OSS Nvidia. Untuk mengurangi masalah ini, DLAMI ini menyertakan fungsionalitas yang secara dinamis memuat driver berpemilik untuk instans G4Dn dan G5. Harap izinkan periode inisialisasi singkat untuk pemuatan ini untuk memastikan bahwa instans Anda dapat berfungsi dengan baik.

  Untuk memeriksa status dan kesehatan layanan ini, Anda dapat menggunakan perintah berikut:

```
sudo systemctl is-active dynamic_driver_load.service
active
```

Tanggal Rilis: 2024-10-23

Nama AMI: Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Ubuntu 22.04) 20241023

Diperbarui

- Driver Nvidia yang ditingkatkan dari versi 550.90.07 ke 550.127.05 untuk alamat yang CVEs ada di Buletin Keamanan Tampilan GPU NVIDIA untuk Oktober 2024

Tanggal Rilis: 2024-10-01

Nama AMI: Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Ubuntu 20.04) 20240930

Diperbarui

- Driver Nvidia dan Fabric Manager yang ditingkatkan dari versi 535.183.01 ke 550.90.07
- Nvidia Container Toolkit yang ditingkatkan dari versi 1.16.1 ke 1.16.2, mengatasi kerentanan keamanan CVE-2024-0133.
- Versi EFA yang ditingkatkan dari 1.32.0 ke 1.34.0
- Upgrade NCCL ke versi terbaru 2.22.3 untuk semua versi CUDA
  - CUDA 12.1, 12.2 ditingkatkan dari 2.18.5+ .2 CUDA12
  - CUDA 12.3 ditingkatkan dari versi 2.21.5+ .4 CUDA12

Ditambahkan

- Ditambahkan CUDA toolkit versi 12.4 di direktori/-12.4 usr/local/cuda
- Menambahkan dukungan untuk instance P5e EC2 .

Tanggal Rilis: 2024-08-19

Nama AMI: Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Ubuntu 22.04) 20240816

Ditambahkan

- Ditambahkan dukungan untuk contoh G6e EC2 .

Tanggal Rilis: 2024-06-06

Nama AMI: Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Ubuntu 22.04) 20240606

Diperbarui

- Diperbarui versi driver Nvidia ke 535.183.01 dari 535.161.08

Tanggal Rilis: 2024-05-15

Nama AMI: Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Ubuntu 22.04) 20240513

Dihapus

- Amazon FSx untuk dukungan Lustre telah dihapus dalam rilis ini karena ketidakcocokan dengan versi kernel Ubuntu 22.04 terbaru. Support FSx for for Lustre akan dipulihkan setelah versi kernel terbaru didukung. Pelanggan yang membutuhkan FSx Lustre harus terus menggunakan Deep Learning Base GPU AMI (Ubuntu 20.04).

Tanggal Rilis: 2024-04-29

Nama AMI: Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Ubuntu 22.04) 20240429

Ditambahkan

- Rilis awal dari Deep Learning Base OSS DLAMI untuk Ubuntu 22.04

AWS Basis Pembelajaran Mendalam AMI (Amazon Linux 2)

Untuk bantuan memulai, lihatMemulai dengan DLAMI.

Format nama AMI

- Basis Pembelajaran Mendalam OSS Nvidia Driver AMI (Amazon Linux 2) Versi $ {XX.X}
- Driver Nvidia Milik Basis Pembelajaran Mendalam AMI (Amazon Linux 2) Versi $ {XX.X}

EC2 Contoh yang didukung

- Silakan lihat Perubahan penting pada DLAMI.
- Pembelajaran Mendalam dengan OSS Nvidia Driver mendukung G4dn, G5, G6, Gr6, G6e, P4d, P4de, P5, P5e, P5en
- Pembelajaran Mendalam dengan Driver Nvidia Proprietary mendukung G3 (G3.16x tidak didukung), P3, P3dn

AMI meliputi yang berikut:

- AWS Layanan yang Didukung: Amazon EC2
- Sistem Operasi: Amazon Linux 2
- Arsitektur Komputasi: x86

- Versi terbaru yang tersedia diinstal untuk paket-paket berikut:
  - Kernel Linux: 5.10
  - Docker
  - AWS CLI v2 di/usr/local/bin/aws2 dan AWS CLI v1 di/usr/bin/aws
  - Toolkit wadah Nvidia:
    - Perintah versi: nvidia-container-cli -V
  - NVIDIA-Docker2:
    - Perintah versi: versi nvidia-docker
- Python:/3.7 usr/bin/python
- Pengemudi NVIDIA:
  - Pengemudi OSS Nvidia: 550.163.01
  - Driver Nvidia eksklusif: 550.163.01
- Tumpukan NVIDIA CUDA 12.1-12.4:
  - Direktori instalasi CUDA, NCCL dan cudDN:/-xx.x/ usr/local/cuda
  - CUDA standar: 12.1
    - PATH/usr/local/cudamenunjuk ke CUDA 12.1
    - Diperbarui di bawah env vars:
      - LD_LIBRARY_PATH memiliki/usr/local/cuda-12.1/lib:/usr/local/cuda-12.1/lib64:/usr/local/cuda-12.1:/usr/local/cuda-12.1/targets/x86_64-linux/lib
      - PATH untuk memiliki/usr/local/cuda-12.1/bin/:/usr/local/cuda-12.1/include/
      - Untuk versi CUDA yang berbeda, harap perbarui LD_LIBRARY_PATH yang sesuai.
  - Versi NCCL yang dikompilasi: 2.22.3
  - Lokasi Tes NCCL:
    - all_reduce, all_gather dan reduce_scatter:/-cuda-xx.x/ usr/local/cuda-xx.x/efa/test
    - Untuk menjalankan pengujian NCCL, LD_LIBRARY_PATH harus melewati pembaruan di bawah ini.
      - Umum sudah PATHs ditambahkan ke LD_LIBRARY_PATH:
        - /opt/amazon/efa/lib:/opt/amazon/openmpi/lib:/opt/aws-ofi-nccl/lib:/usr/local/lib:/usr/lib
      - Untuk versi CUDA yang berbeda, harap perbarui LD_LIBRARY_PATH yang sesuai.
- Pemasang EFA: 1.38.0
- Nvidia GDRCopy: 2.4

- AWS NCCL: 1.13.2
  - AWS OFI NCCL sekarang mendukung beberapa versi NCCL dengan build tunggal
  - Jalur instalasi:/opt/amazon/ofi-nccl/ . Path /opt/amazon/ofi-nccl/lib64 ditambahkan ke LD_LIBRARY_PATH.
- Jenis volume EBS: gp3
- Kueri AMI-ID dengan Parameter SSM (contoh Wilayah adalah us-east-1):
  - Pengemudi OSS Nvidia:

```
aws ssm get-parameter --region us-east-1 \
    --name /aws/service/deeplearning/ami/x86_64/base-oss-nvidia-driver-amazon-
linux-2/latest/ami-id  \
    --query "Parameter.Value" \
    --output text
```

  - Pengemudi Nvidia Berpemilik:

```
aws ssm get-parameter --region us-east-1 \
    --name /aws/service/deeplearning/ami/x86_64/base-proprietary-nvidia-driver-
amazon-linux-2/latest/ami-id \
    --query "Parameter.Value" \
    --output text
```

- Kueri AMI-ID dengan AWSCLI (contoh Wilayah adalah us-east-1):
  - Pengemudi OSS Nvidia:

```
aws ec2 describe-images --region us-east-1 \
    --owners amazon \
    --filters 'Name=name,Values=Deep Learning Base OSS Nvidia Driver AMI (Amazon
 Linux 2) Version ??.?' 'Name=state,Values=available' \
    --query 'reverse(sort_by(Images, &CreationDate))[:1].ImageId' \
    --output text
```

  - Pengemudi Nvidia Berpemilik:

```
aws ec2 describe-images --region us-east-1 \
    --owners amazon \
    --filters 'Name=name,Values=Deep Learning Base Proprietary Nvidia Driver AMI
 (Amazon Linux 2) Version ??.?' 'Name=state,Values=available' \
    --query 'reverse(sort_by(Images, &CreationDate))[:1].ImageId' \
```

```
    --output text
```

Pemberitahuan

Toolkit Kontainer NVIDIA 1.17.4

Dalam Container Toolkit versi 1.17.4 pemasangan pustaka compat CUDA sekarang dinonaktifkan. Untuk memastikan kompatibilitas dengan beberapa versi CUDA pada alur kerja kontainer, pastikan Anda memperbarui LD_LIBRARY_PATH Anda untuk menyertakan pustaka kompatibilitas CUDA Anda seperti yang ditunjukkan dalam tutorial Jika Anda menggunakan lapisan kompatibilitas CUDA.

Pembaruan EFA dari 1.37 ke 1.38 (Rilis pada 2025-02-04)

EFA sekarang menggabungkan plugin AWS OFI NCCL, yang sekarang dapat ditemukan di/-ofi-nccl/. opt/amazon/ofi-nccl rather than the original /opt/aws Jika memperbarui variabel LD_LIBRARY_PATH Anda, pastikan Anda memodifikasi lokasi OFI NCCL Anda dengan benar.

Kebijakan Support

AMIs Komponen versi AMI seperti CUDA ini dapat dihapus dan diubah berdasarkan kebijakan dukungan kerangka kerja atau untuk mengoptimalkan kinerja untuk wadah pembelajaran mendalam atau untuk mengurangi ukuran AMI di rilis mendatang, tanpa pemberitahuan sebelumnya. Kami menghapus versi CUDA dari AMIs jika tidak digunakan oleh versi kerangka kerja yang didukung.

EC2 contoh dengan beberapa kartu jaringan

- Banyak jenis contoh yang mendukung EFA juga memiliki beberapa kartu jaringan.
- DeviceIndex unik untuk setiap kartu jaringan, dan harus berupa bilangan bulat non-negatif kurang dari batas per. ENIs NetworkCard Pada P5, jumlah ENIs per NetworkCard adalah 2, yang berarti bahwa satu-satunya nilai yang valid untuk DeviceIndex adalah 0 atau 1.
  - Untuk antarmuka jaringan utama (indeks kartu jaringan 0, indeks perangkat 0), buat antarmuka EFA (EFA dengan ENA). Anda tidak dapat menggunakan antarmuka jaringan khusus EFA sebagai antarmuka jaringan utama.
  - Untuk setiap antarmuka jaringan tambahan, gunakan indeks kartu jaringan yang tidak digunakan berikutnya, indeks perangkat 1, dan EFA (EFA dengan ENA) atau antarmuka jaringan khusus EFA, tergantung pada kasus penggunaan Anda, seperti persyaratan bandwidth ENA atau ruang alamat IP. Misalnya kasus penggunaan, lihat konfigurasi EFA untuk instance P5.
  - Untuk informasi lebih lanjut, lihat Panduan EFA di sini.

Contoh P5/P5e

- Instans P5 dan P5e berisi 32 kartu antarmuka jaringan, dan dapat diluncurkan menggunakan perintah berikut: AWS CLI

```
aws ec2 run-instances --region $REGION \
    --instance-type $INSTANCETYPE \
    --image-id $AMI --key-name $KEYNAME \
    --iam-instance-profile "Name=dlami-builder" \
    --tag-specifications "ResourceType=instance,Tags=[{Key=Name,Value=$TAG}]" \
    --network-interfaces "NetworkCardIndex=0,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa" \
      "NetworkCardIndex=1,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      "NetworkCardIndex=2,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      "NetworkCardIndex=3,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      "NetworkCardIndex=4,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
       ...
      "NetworkCardIndex=31,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
```

Contoh P5en

- P5en berisi 16 kartu antarmuka jaringan, dan dapat diluncurkan menggunakan perintah berikut: AWS CLI

```
aws ec2 run-instances --region $REGION \
    --instance-type $INSTANCETYPE \
    --image-id $AMI --key-name $KEYNAME \
    --iam-instance-profile "Name=dlami-builder" \
    --tag-specifications "ResourceType=instance,Tags=[{Key=Name,Value=$TAG}]" \
    --network-interfaces "NetworkCardIndex=0,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa" \
      "NetworkCardIndex=1,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      "NetworkCardIndex=2,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      "NetworkCardIndex=3,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
```

```
      "NetworkCardIndex=4,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
\
       ...
      "NetworkCardIndex=15,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
```

Kernel

- Versi kernel disematkan menggunakan perintah:

```
sudo yum versionlock kernel*
```

- Kami menyarankan agar pengguna menghindari memperbarui versi kernel mereka (kecuali karena patch keamanan) untuk memastikan kompatibilitas dengan driver dan versi paket yang diinstal. Jika pengguna masih ingin memperbarui, mereka dapat menjalankan perintah berikut untuk melepas pin versi kernel mereka:

```
sudo yum versionlock delete kernel*
sudo yum update -y
```

- Untuk setiap versi baru DLAMI, kernel kompatibel terbaru yang tersedia digunakan.

Tanggal Rilis: 2025-04-22

Nama AMI

- Basis Pembelajaran Mendalam OSS Driver Nvidia AMI (Amazon Linux 2) Versi 69.3
- Driver Nvidia Proprietary Basis Pembelajaran Mendalam AMI (Amazon Linux 2) Versi 67.0

Diperbarui

- Driver Nvidia yang ditingkatkan dari versi 550.144.03 ke 550.163.01 untuk alamat yang CVEs ada di Buletin Keamanan Driver Tampilan GPU NVIDIA untuk April 2025

Tanggal Rilis: 2025-02-17

Nama AMI

- Basis Pembelajaran Mendalam OSS Driver Nvidia AMI (Amazon Linux 2) Versi 68.5
- Driver Nvidia Proprietary Basis Pembelajaran Mendalam AMI (Amazon Linux 2) Versi 66.3

Diperbarui

- Diperbarui NVIDIA Container Toolkit dari versi 1.17.3 ke versi 1.17.4. Silakan lihat halaman catatan rilis di sini untuk informasi lebih lanjut: https://github.com/NVIDIA/nvidia-container-toolkit/releases/tag/v1.17.4

Dihapus

- Pustaka ruang pengguna yang dihapus cuobj dan nvdisasm disediakan oleh toolkit NVIDIA CUDA untuk mengatasi yang CVEs ada di Buletin Keamanan NVIDIA CUDA Toolkit untuk 18 Februari 2025

Tanggal Rilis: 2025-02-04

Nama AMI

- Basis Pembelajaran Mendalam OSS Driver Nvidia AMI (Amazon Linux 2) Versi 68.4
- Driver Nvidia Proprietary Basis Pembelajaran Mendalam AMI (Amazon Linux 2) Versi 66.1

Diperbarui

- Versi EFA yang ditingkatkan dari 1.37.0 ke 1.38.0

Tanggal Rilis: 2025-01-17

Nama AMI

- Basis Pembelajaran Mendalam OSS Driver Nvidia AMI (Amazon Linux 2) Versi 68.3
- Driver Nvidia Proprietary Basis Pembelajaran Mendalam AMI (Amazon Linux 2) Versi 66.0

Diperbarui

- Driver Nvidia yang ditingkatkan dari versi 550.127.05 ke 550.144.03 ke alamat yang CVEs ada di Buletin Keamanan Driver Tampilan GPU NVIDIA untuk Januari 2025

Tanggal Rilis: 2025-01-06

Nama AMI

- Basis Pembelajaran Mendalam OSS Driver Nvidia AMI (Amazon Linux 2) Versi 68.2
- Driver Nvidia Proprietary Basis Pembelajaran Mendalam AMI (Amazon Linux 2) Versi 65.9

Diperbarui

- EFA yang ditingkatkan dari versi 1.34.0 ke 1.37.0
- Upgrade AWS OFI NCCL dari versi 1.11.0 ke 1.13.0

Tanggal Rilis: 2024-12-09

Nama AMI

- Basis Pembelajaran Mendalam OSS Driver Nvidia AMI (Amazon Linux 2) Versi 68.1
- Driver Nvidia Proprietary Basis Pembelajaran Mendalam AMI (Amazon Linux 2) Versi 65.8

Diperbarui

- Toolkit Kontainer Nvidia yang ditingkatkan dari versi 1.17.0 ke 1.17.3

Tanggal Rilis: 2024-11-09

Nama AMI

- Basis Pembelajaran Mendalam OSS Driver Nvidia AMI (Amazon Linux 2) Versi 67.9
- Driver Nvidia Proprietary Basis Pembelajaran Mendalam AMI (Amazon Linux 2) Versi 65.6

Diperbarui

- Nvidia Container Toolkit yang ditingkatkan dari versi 1.16.2 ke 1.17.0, mengatasi kerentanan keamanan CVE-2024-0134.

Tanggal Rilis: 2024-10-22

Nama AMI

- Basis Pembelajaran Mendalam OSS Driver Nvidia AMI (Amazon Linux 2) Versi 67.7
- Driver Nvidia Proprietary Basis Pembelajaran Mendalam AMI (Amazon Linux 2) Versi 65.4

Diperbarui

- Driver Nvidia yang ditingkatkan dari versi 550.90.07 ke 550.127.05 untuk alamat yang CVEs ada di Buletin Keamanan Tampilan GPU NVIDIA untuk Oktober 2024

Tanggal Rilis: 2024-10-03

Nama AMI

- Basis Pembelajaran Mendalam OSS Nvidia Driver Versi AMI (Amazon Linux 2)
- Driver Nvidia Proprietary Basis Pembelajaran Mendalam AMI (Amazon Linux 2) Versi 65.2

Diperbarui

- Nvidia Container Toolkit yang ditingkatkan dari versi 1.16.1 ke 1.16.2, mengatasi kerentanan keamanan CVE-2024-0133.

Tanggal Rilis: 2024-08-27

Nama AMI: Basis Pembelajaran Mendalam OSS Driver Nvidia AMI (Amazon Linux 2) Versi 67.0

Diperbarui

- Driver Nvidia dan Fabric Manager yang ditingkatkan dari versi 535.183.01 ke 550.90.07
  - Menghapus persyaratan shell multi-pengguna dari Fabric Manager berdasarkan rekomendasi Nvidia
  - Silakan referensi masalah yang diketahui untuk driver Tesla 550.90.07 di sini untuk informasi lebih lanjut
- Versi EFA yang ditingkatkan dari 1.32.0 ke 1.34.0
- Upgrade NCCL ke versi terbaru 2.22.3 untuk semua versi CUDA

- CUDA 12.1, 12.2 ditingkatkan dari 2.18.5+ .2 CUDA12
- CUDA 12.3 ditingkatkan dari 2.21.5+ .4 CUDA12

Ditambahkan

- Ditambahkan CUDA toolkit versi 12.4 di direktori/-12.4 usr/local/cuda
- Menambahkan dukungan untuk instance P5e EC2 .

Dihapus

- Dihapus CUDA Toolkit versi 11.8 tumpukan hadir di direktori/-11.8 usr/local/cuda

Tanggal Rilis: 2024-08-19

Nama AMI: Basis Pembelajaran Mendalam OSS Driver Nvidia AMI (Amazon Linux 2) Versi 66.3

Ditambahkan

- Menambahkan dukungan untuk instance G6e EC2 .

Tanggal Rilis: 2024-06-06

Nama AMI

- Basis Pembelajaran Mendalam OSS Driver Nvidia AMI (Amazon Linux 2) Versi 65.4
- Driver Nvidia Proprietary Basis Pembelajaran Mendalam AMI (Amazon Linux 2) Versi 63.9

Diperbarui

- Diperbarui versi driver Nvidia ke 535.183.01 dari 535.161.08

Tanggal Rilis: 2024-05-02

Nama AMI

- Basis Pembelajaran Mendalam OSS Driver Nvidia AMI (Amazon Linux 2) Versi 64.7
- Driver Nvidia Proprietary Basis Pembelajaran Mendalam AMI (Amazon Linux 2) Versi 63.2

Diperbarui

- Diperbarui versi EFA dari versi 1.30 ke versi 1.32
- Diperbarui plugin AWS OFI NCCL dari versi 1.7.4 ke versi 1.9.1
- Toolkit kontainer Nvidia yang diperbarui dari versi 1.13.5 ke versi 1.15.0

Ditambahkan

- Ditambahkan CUDA12 .3 tumpukan CUDA12 dengan.3, NCCL 2.21.5, cuDNN 8.9.7

  Versi 1.15.0 TIDAK menyertakan paket nvidia-container-runtime dan nvidia-docker2. Disarankan untuk menggunakan nvidia-container-toolkit paket secara langsung dengan mengikuti dokumen toolkit kontainer Nvidia.

Dihapus

- Menghapus tumpukan CUDA11 .7, CUDA12 .0 yang ada di/-12.0 usr/local/cuda-11.7 and /usr/local/cuda
- Menghapus paket nvidia-docker2 dan perintahnya nvidia-docker sebagai bagian dari pembaruan toolkit kontainer Nvidia dari 1.13.5 ke 1.15.0 yang TIDAK menyertakan paket dan nvidia-docker2. nvidia-container-runtime

Tanggal Rilis: 2024-04-04

Nama AMI: Basis Pembelajaran Mendalam OSS Driver Nvidia AMI (Amazon Linux 2) Versi 64.0

Ditambahkan

- Untuk driver OSS Nvidia DLAMIs, menambahkan dukungan instans G6 dan EC2 Gr6

Tanggal Rilis: 2024-03-29

Nama AMI

- Basis Pembelajaran Mendalam OSS Driver Nvidia AMI (Amazon Linux 2) Versi 62.3
- Driver Nvidia Proprietary Basis Pembelajaran Mendalam AMI (Amazon Linux 2) Versi 63.2

Diperbarui

- Driver Nvidia yang diperbarui dari 535.104.12 ke 535.161.08 di driver Proprietary dan OSS Nvidia. DLAMIs
- Instans baru yang didukung untuk setiap DLAMI adalah sebagai berikut:
  - Pembelajaran Mendalam dengan Driver Nvidia Proprietary mendukung G3 (G3.16x tidak didukung), P3, P3dn
  - Pembelajaran Mendalam dengan OSS Nvidia Driver mendukung G4dn, G5, P4d, P4de, P5.

Dihapus

- Dukungan EC2 instans G4dn, G5, G3.16x yang dihapus dari DLAMI driver Nvidia Proprietary.

Tanggal Rilis: 2024-03-20

Nama AMI: Basis Pembelajaran Mendalam OSS Driver Nvidia AMI (Amazon Linux 2) Versi 63.1

Ditambahkan

- Menambahkan awscliv2 di AMI sebagai usr/local/bin/aws2, alongside awscliv1 as /usr/local/bin/aws /pada OSS Nvidia Driver AMI

Tanggal Rilis: 2024-03-13

Nama AMI: Basis Pembelajaran Mendalam OSS Driver Nvidia AMI (Amazon Linux 2) Versi 63.0

Diperbarui

- DLAMI driver OSS Nvidia yang diperbarui dengan dukungan G4dn dan G5, berdasarkan dukungan saat ini terlihat seperti di bawah ini:
  - Driver Nvidia Proprietary Deep Learning Base AMI (Amazon Linux 2) mendukung P3, P3dn, G3, G4dn, G5.
  - Basis Pembelajaran Mendalam OSS Nvidia Driver AMI (Amazon Linux 2) mendukung G4dn, G5, P4, P5.
- Driver OSS Nvidia DLAMIs direkomendasikan untuk digunakan untuk G4dn, G5, P4, P5.

Tanggal Rilis: 2024-02-13

Nama AMI

- Basis Pembelajaran Mendalam OSS Driver Nvidia AMI (Amazon Linux 2) Versi 62.1
- Driver Nvidia Proprietary Basis Pembelajaran Mendalam AMI (Amazon Linux 2) Versi 62.1

Diperbarui

- Diperbarui driver OSS Nvidia dari 535.129.03 ke 535.154.05
- Diperbarui EFA dari 1.29.0 ke 1.30.0
- AWS OFI NCCL yang diperbarui dari 1.7.3-aws ke 1.7.4-aws

Tanggal Rilis: 2024-02-01

Nama AMI: Deep Learning Base Proprietary Nvidia Driver AMI (Amazon Linux 2) Versi 62.0

Keamanan

- Versi paket runc yang diperbarui untuk menggunakan patch untuk CVE-2024-21626.

Versi 61.4

Nama AMI: Basis Pembelajaran Mendalam OSS Driver Nvidia AMI (Amazon Linux 2) Versi 61.4

Diperbarui

- OSS Nvidia Driver diperbarui dari 535.104.12 ke 535.129.03

Versi 61.0

Nama AMI: Basis Pembelajaran Mendalam OSS Driver Nvidia AMI (Amazon Linux 2) Versi 61.4

Diperbarui

- EFA diperbarui dari 1.26.1 ke 1.29.0
- GDRCopy diperbarui dari 2.3 ke 2.4

Ditambahkan

- AWS Deep Learning AMI (DLAMI) dibagi menjadi dua kelompok terpisah:
  - DLAMI yang menggunakan Nvidia Proprietary Driver (untuk mendukung P3, P3dn, G3, G5, G4dn).
  - DLAMI yang menggunakan Nvidia OSS Driver untuk mengaktifkan EFA (untuk mendukung P4, P5).
- Silakan merujuk ke pengumuman publik untuk informasi lebih lanjut tentang DLAMI split.
- Untuk AWS CLI kueri, lihat bullet point Query AMI-ID AWSCLI dengan (contoh Region is us-east-1)

Versi 60.6

Nama AMI: Basis Pembelajaran Mendalam AMI (Amazon Linux 2) Versi 60.6

Diperbarui

- AWS OFI NCCL Plugin diperbarui dari versi 1.7.2 ke versi 1.7.3
- Direktori CUDA 12.0-12.1 yang diperbarui dengan NCCL versi 2.18.5
- CUDA12.1 diperbarui sebagai Versi CUDA default
  - Diperbarui LD_LIBRARY_PATH untuk memiliki//usr/local/cuda-12.1/targets/x86_64-linux/lib/:/usr/local/cuda-12.1/lib:/usr/local/cuda-12.1/lib64:/usr/local/cuda-12.1 and PATH to have /usr/local/cuda-12.1/bin
  - Untuk pelanggan yang ingin mengubah ke versi CUDA yang berbeda, harap tentukan variabel LD_LIBRARY_PATH dan PATH yang sesuai.

Ditambahkan

- Kernel Live Patching sekarang diaktifkan. Live patching memungkinkan pelanggan untuk menerapkan kerentanan keamanan dan patch bug kritis ke kernel Linux yang sedang berjalan, tanpa reboot atau gangguan pada aplikasi yang sedang berjalan. Harap dicatat bahwa dukungan patching langsung untuk kernel 5.10.192 akan berakhir pada 11/30/23.

Versi 60.5

Nama AMI: Basis Pembelajaran Mendalam AMI (Amazon Linux 2) Versi 60.5

Diperbarui

- Driver NVIDIA diperbarui dari 535.54.03 ke 535.104.12

  Driver terbaru ini memperbaiki perubahan kerusakan NVMLABI yang ditemukan di driver 535.54.03, serta regresi driver yang ditemukan di driver 535.86.10 yang memengaruhi toolkit CUDA pada instance P5. Silakan referensi catatan rilis NVIDIA berikut untuk rincian tentang perbaikan:

  - 4235941 - Perbaikan perubahan NVMLABI Breaking
  - 4228552 - Perbaikan Kesalahan CUDA Toolkit
- Direktori CUDA 12.2 yang diperbarui dengan NCCL 2.18.5
- EFA diperbarui dari 1.24.1 ke 1.26.1 terbaru

Ditambahkan

- Ditambahkan CUDA12 .2 di/usr/local/cuda-12.2

Dihapus

- Dukungan yang dihapus untuk CUDA 11.5 dan CUDA 11.6

Versi 60.2

Nama AMI: Basis Pembelajaran Mendalam AMI (Amazon Linux 2) Versi 60.2

Diperbarui

- Diperbarui aws-ofi-nccl plugin dari v1.7.1 untuk v1.7.2

Versi 60.0

Tanggal rilis: 2023-08-11

Ditambahkan

- AMI ini sekarang menyediakan dukungan untuk fungsionalitas pelatihan Multi-node pada P5 dan semua instans yang didukung sebelumnya EC2

- Untuk EC2 instance P5, NCCL 2.18 direkomendasikan untuk digunakan dan telah ditambahkan ke CUDA12 .0, dan .1. CUDA12

Dihapus

- Dihapus dukungan untuk CUDA11 .5.

Versi 59.2

Tanggal rilis: 2023-08-08

Dihapus

- Dihapus CUDA-11.3 dan CUDA-11.4

Versi 59.1

Tanggal rilis: 2023-08-03

Diperbarui

- Diperbarui AWS plugin OFI NCCL ke v1.7.1
- Membuat CUDA11 .8 sebagai default karena PyTorch 2.0 mendukung 11.8 dan untuk EC2 instance P5, disarankan untuk menggunakan >= .8 CUDA11
  - Diperbarui LD_LIBRARY_PATH untuk memiliki//usr/local/cuda-11.8/targets/x86_64-linux/lib/:/usr/local/cuda-11.8/lib:/usr/local/cuda-11.8/lib64:/usr/local/cuda-11.8 and PATH to have /usr/local/cuda-11.8/bin
  - Untuk versi cuda yang berbeda, harap tentukan LD_LIBRARY_PATH yang sesuai.

Tetap

- Memperbaiki masalah pemuatan paket Nvidia Fabric Manager (FM) yang disebutkan di Tanggal Rilis sebelumnya 2023-07-19.

Versi 58.9

Tanggal rilis: 2023-07-19

Diperbarui

- Driver Nvidia yang diperbarui dari 525.85.12 ke 535.54.03
- Diperbarui installer EFA dari 1.22.1 ke 1.24.1

Ditambahkan

- Menambahkan perubahan c-state untuk menonaktifkan status idle prosesor dengan menyetel c-state maks ke C1. Perubahan ini dilakukan dengan menyetel `intel_idle.max_cstate=1 processor.max_cstate=1` dalam argumen boot linux di file/etc/default/grub
- AWS EC2 Dukungan instance P5:
  - Ditambahkan P5 dukungan EC2 instance untuk alur kerja menggunakan node/instance tunggal. Dukungan multi-node (misalnya untuk pelatihan multi-node) menggunakan EFA (Elastic Fabric Adapter) dan plugin AWS OFI NCCL akan ditambahkan dalam rilis mendatang.
  - Silakan gunakan CUDA> = 11.8 untuk kinerja optimal.
  - Masalah yang Diketahui: Paket Nvidia Fabric Manager (FM) membutuhkan waktu untuk memuat pada P5, pelanggan harus menunggu selama 2-3 menit hingga FM dimuat setelah meluncurkan instans P5. Untuk memeriksa apakah FM dimulai, jalankan perintah sudo systemctl is-active nvidia-fabricmanager, itu harus kembali aktif sebelum memulai alur kerja apa pun. Ini akan diperbaiki dalam rilis mendatang.

Versi 58.0

Tanggal rilis: 2023-05-19

Dihapus

- Menghapus CUDA11 tumpukan.0-11.2 sesuai kebijakan dukungan yang disebutkan di bagian atas dokumen ini.

Versi 57.3

Tanggal rilis: 2023-04-06

Ditambahkan

- Menambahkan Nvidia GDRCopy 2.3

Versi 56.8

Tanggal rilis: 2023-03-09

Diperbarui

- Diperbarui driver NVIDIA dari 515.65.01 ke 525.85.12

Ditambahkan

- Ditambahkan cuda-11.8 di/-11.8/usr/local/cuda

Versi 56.0

Tanggal rilis: 2022-12-06

Diperbarui

- Versi EFA yang diperbarui dari 1.17.2 ke 1.19.0

Versi 55.0

Tanggal rilis: 2022-11-04

Diperbarui

- Diperbarui driver NVIDIA dari 510.47.03 ke 515.65.01

Ditambahkan

- Ditambahkan cuda-11.7 di/-11.7/usr/local/cuda

Versi 54.0

Tanggal rilis: 2022-09-15

Diperbarui

- Diperbarui versi EFA dari 1.16.0 ke 1.17.2

Versi 53.3

Tanggal rilis: 2022-05-25

Diperbarui

- Diperbarui aws-efa-installer ke versi 1.15.2
- Diperbarui aws-ofi-nccl ke versi 1.3.0-aws yang menyertakan topologi untuk p4de.24xlarge.

Ditambahkan

- Rilis ini menambahkan dukungan untuk instance EC2 p4de.24xlarge.

Versi 53.0

Tanggal rilis: 2022-04-28

Ditambahkan

- Ditambahkan Amazon CloudWatch Agent
- Menambahkan tiga layanan systemd yang menggunakan file json standar yang tersedia di pathopt/aws/amazon-cloudwatch-agent/etc//untuk mengkonfigurasi metrik GPU menggunakan cwagent pengguna linux
  - dlami-cloudwatch-agent@minimal
    - Perintah untuk mengaktifkan metrik GPU:

      ```
      sudo systemctl enable dlami-cloudwatch-agent@minimal
      sudo systemctl start dlami-cloudwatch-agent@minimal
      ```

    - Ini menciptakan metrik ini:`utilization_gpu`, `utilization_memory`
  - dlami-cloudwatch-agent@partial
    - Perintah untuk mengaktifkan metrik GPU:

      ```
      sudo systemctl enable dlami-cloudwatch-agent@partial
      sudo systemctl start dlami-cloudwatch-agent@partial
      ```

    - Ini menciptakan metrik ini:`utilization_gpu`,,`utilization_memory`,`memory_total`, `memory_used` `memory_free`

- dlami-cloudwatch-agent@all
  - Perintah untuk mengaktifkan metrik GPU:

```
sudo systemctl enable dlami-cloudwatch-agent@all
sudo systemctl start dlami-cloudwatch-agent@all
```

  - Ini menciptakan semua metrik GPU yang tersedia

Versi 52.0

Tanggal rilis: 2022-03-08

Diperbarui

- Diperbarui versi Kernel ke 5.10

Versi 51.0

Tanggal rilis: 2022-03-04

Diperbarui

- Driver Nvidia yang Diperbarui ke 510.47.03

Versi 50.0

Tanggal rilis: 2022-02-17

Diperbarui

- Terkunci aws-neuron-dkms dan tensorflow-model-server-neuron saat diperbarui ke versi yang lebih baru yang tidak didukung oleh paket Neuron yang ada di AMI
  - Perintah jika pelanggan ingin membuka kunci paket untuk memperbaruinya ke yang terbaru: sudo yum versionlock delete sudo yum versionlock delete aws-neuron-dkms tensorflow-model-server-neuron

Versi 49.0

Tanggal rilis: 2022-01-13

Ditambahkan

- Ditambahkan CUDA11 .2 dengan komponen-komponen berikut:
  - cuDNN v8.1.1.33
  - NCCL 2.8.4
  - CUDA 11.2.2

Diperbarui

- Symlink pip yang diperbarui ke pip3

penghentian

- Dukungan usang untuk jenis instans P2
- Python2.7 usang dan menghapus paket python2.7 terkait seperti “python-dev”, “python-pip”, dan “python-tk”

Versi 48.0

Tanggal rilis: 2021-12-27

Diperbarui

- Dihapus org.apache.ant_1.9.2.v201404171502\ lib\ ant-apache-log 4j.jar dari versi cuda karena tidak digunakan dan tidak ada risiko bagi pengguna yang memiliki file Log4j. Untuk informasi lebih lanjut, lihat https://nvidia.custhelp.com/app/answers/detail/a_id/5294.

Versi 47.0

Tanggal rilis: 2021-11-24

Diperbarui

- Diperbarui EFA ke 1.14.1

Versi 46.0

Tanggal rilis: 2021-11-12

Diperbarui

- Paket Neuron yang diperbarui dari aws-neuron-dkms =1.5. *, aws-neuron-runtime-base = 1,5. *, aws-neuron-tools =1.6.* hingga =2.2. aws-neuron-dkms *, aws-neuron-runtime-base = 1,6. *, aws-neuron-tools = 2.0.*.
- Paket Neuron yang dihapus aws-neuron-runtime =1.5.* karena Neuron tidak lagi memiliki runtime yang berjalan sebagai daemon dan runtime sekarang terintegrasi dengan kerangka kerja sebagai perpustakaan.

Versi 45.0

Tanggal rilis: 2021-10-21

Ditambahkan

- Laporan pemindaian keamanan dalam format JSON tersedia di/opt/aws/dlami/info/.

Versi 44.0

Tanggal rilis: 2021-10-08

Berubah

- Untuk setiap peluncuran instance menggunakan DLAMI, tag aws-dlami-autogenerated-tag "do-not-delete-" akan ditambahkan yang akan AWS memungkinkan untuk mengumpulkan jenis instance, ID instance, jenis DLAMI, dan informasi OS. Tidak ada informasi tentang perintah yang digunakan dalam DLAMI yang dikumpulkan atau disimpan. Tidak ada informasi lain tentang DLAMI yang dikumpulkan atau disimpan. Untuk memilih keluar dari pelacakan penggunaan untuk DLAMI Anda, tambahkan tag ke instans EC2 Amazon Anda selama peluncuran. Tag harus menggunakan kunci OPT_OUT_TRACKING dengan nilai terkait disetel ke true. Untuk informasi selengkapnya, lihat Menandai EC2 sumber daya Amazon Anda.

Keamanan

- Diperbarui versi docker ke docker-20.10.7-3

Versi 43.0

Tanggal rilis: 2021-08-24

Berubah

- Diperbarui “notebook” ke versi “6.4.1".

Versi 42.0

Tanggal rilis: 2021-07-23

Berubah

- Diperbarui driver Nvidia dan versi manajer Fabric ke 450.142.00.

Versi 41.0

Tanggal rilis: 2021-06-24

Berubah

- Paket Neuron yang diperbarui sesuai Rilis Neuron v1.14.0

Versi 40.0

Tanggal rilis: 2021-06-10

Berubah

- Diperbarui versi awscli ke 1.19.89

Versi 39.0

Tanggal rilis: 2021-05-27

Keamanan

- Menghapus komponen CUDA-10.0 yang rentan (Visual Profiler, Nsight EE, dan JRE) dari instalasi CUDA-10.0 (/-10.0). usr/local/cuda

Versi 38.0

Tanggal rilis: 2021-05-25

Berubah

- Runc yang ditingkatkan ke yang terbaru

Versi 37.0

Tanggal rilis: 2021-04-23

Berubah

- Diperbarui driver Nvidia Tesla dan versi Fabric Manager ke 450.119.03.

Versi 36.1

Tanggal rilis: 2021-04-21

Tetap

- Memperbaiki masalah yang memperlambat kecepatan peluncuran instance.

Versi 36.0

Tanggal rilis: 2021-03-24

Ditambahkan

- Ditambahkan tensorflow-model-server-neuron untuk mendukung penyajian model neuron.

Berubah

- Upgrade jupyterlab ke versi 3.0.8 untuk python3.

Tetap

- Instalasi lama OpenMPI diusr/local/mpi caused /opt/amazon/openmpi/bin/mpirun to be linked incorrectly. To fix the link issue, we removed /usr/local/mpi installation, OpenMPI installation in /opt/amazon/openmpi/tersedia.

- Hapus definisi lingkungan shell yang diduplikasi dan tidak ada yang telah mencemari variabel lingkungan shell seperti PATH, dan LD_LIBRARY_PATH. Akibatnya, ~/.dlami, dan/etc/profile.d/var.sh has been removed, and /etc/profile.d/dlami.sh telah ditambahkan.

Keamanan

- Kriptografi paket yang diperbarui untuk mengatasi CVE-2020-36242

Versi 35.0

Tanggal rilis: 2021-03-08

Ditambahkan

- Menambahkan instalasi TensorRT CUDA 11.0

Versi 34.3

Tanggal rilis: 2021-02-25

Tetap

- Memperbaiki kesalahan ketik di MOTD (pesan hari ini) yang salah menampilkan versi 34.1.

Versi 34.2

Tanggal rilis: 2021-02-24

Keamanan

- Python2 dan python3 yang ditambal untuk CVE-2021-3177

Masalah yang Diketahui

- Ada kesalahan ketik di MOTD (pesan hari ini) yang salah menampilkan versi 34.1, kami akan merilis versi 34.3 untuk mengatasi masalah ini.

Versi 34.0

Tanggal rilis: 2021-02-09

Berubah

- Pip disematkan ke versi 20.3.4 untuk python2, ini adalah versi pip terakhir yang mendukung python2, dan python3.5.

Versi 33.0

Tanggal rilis: 2021-01-19

Berubah

- Diperbarui versi cuDNN ke v8.0.5.39 di.0 dan .1. CUDA11 CUDA11

Versi 32.0

Tanggal rilis: 2020-12-01

Ditambahkan

- Ditambahkan CUDA11 .1 dengan NCCL 2.7.8, cuDNN 8.0.4.30 untuk AMI Pembelajaran Mendalam (Amazon Linux 2), AMI Pembelajaran Mendalam (Ubuntu 16.04), AMI Pembelajaran Mendalam (Ubuntu 18.04), Basis Pembelajaran Mendalam AMI (Ubuntu 16.04), Basis Pembelajaran Mendalam AMI (Ubuntu 18.04), Basis Pembelajaran Mendalam AMI (Amazon Linux 2).

Versi 31.0

Tanggal rilis: 2020-11-02

Berubah

- Installer EFA yang ditingkatkan ke versi 1.10.0.
- Versi cuDNN yang ditingkatkan ke v8.0.4.30 untuk CUDA 11.0.
- AWS Neuron yang ditingkatkan ke versi 1.1

Versi 30.0

Tanggal rilis: 2020-10-08

Berubah

- Versi NVIDIA Driver dan Fabric Manager yang diperbarui ke 450.80.02
- Diperbarui NCCL ke 2.7.8 untuk .0 CUDA11

Tetap

- Memperbaiki masalah saat paket python yang dikelola yum diganti oleh instalasi pipmanaged. Pip, pip3, dan pip3.7 yang dapat dieksekusi telah dipindahkan dari/bagian dari perbaikan ini. usr/binto / usr/local/binas

Versi 29.0

Tanggal rilis: 2020-09-11

Berubah

- Diperbarui driver NVIDIA dari versi 450.51.05 ke 450.51.06
- Ditambahkan NVIDIA Fabric Manager versi 450.51.06
- Upgrade EFA ke 1.9.4

Versi 28.0

Tanggal rilis: 2020-08-19

Berubah

- Menambahkan tumpukan CUDA 11.0 dengan NCCL 2.7.6, dan cuDNN 8.0.2.39

Versi 27.0

Tanggal rilis: 2020-08-07

Berubah

- EFA yang ditingkatkan dari versi 1.7.1 ke 1.9.3 di/opt/amazon/efa

- Upgrade Open MPI dari versi 4.0.3 ke 4.0.4 di '/ 'usr/local/mpi'. Open MPI at '/opt/amazon/openmpi/bin/mpirunmasih di versi 4.0.3
- Diperbarui Driver NVIDIA dari 440.33.01 ke 450.51.05
- Versi NCCL yang ditingkatkan dari 2.6.4 ke 2.7.6 di 0.2 CUDA1

Versi 26.0

Tanggal rilis: 2020-08-03

Berubah

- Upgrade AWS OFI NCCL ke yang terbaru, lihat di sini untuk detail lebih lanjut.
- Cuda 8.0/9.0/9.2 telah dihapus dari AMI

Tetap

- Memperbaiki kesalahan di mana file objek bersama: libopencv_dnn.so.4.2 tidak dapat dibuka.

Versi 25.0

Tanggal rilis: 2020-07-19

Berubah

- Versi EFA diperbarui ke 1.7.1 untuk mendukung NCCL 2.6.4
- Versi NCCL diperbarui ke 2.6.4 untuk CUDA 10.2
- versi awscli diperbarui dari 1.16.76 ke 1.18.80
- boto3 versi diperbarui dari 1.9.72 ke 1.14.3

Versi 24.1

Tanggal rilis: 2020-06-14

Berubah

- Versi Docker diperbarui ke 19.03.6

Versi 24.0

Tanggal rilis: 2020-05-20

Berubah

- Versi Docker diperbarui ke 19.03.6

Versi 23.0

Tanggal rilis: 2020-04-29

Berubah

- Versi paket python yang ditingkatkan

Versi 22.0

Tanggal rilis: 2020-03-04

Berubah

- Ditambahkan CUDA 10.2 tumpukan
- CUDA 10.0 dan 10.1 yang diperbarui untuk versi cuDNN dan NCCL

AWS Basis Pembelajaran Mendalam Qualcomm AMI (Amazon Linux 2)

Untuk bantuan memulai, lihatMemulai dengan DLAMI.

Format nama AMI

- Basis Pembelajaran Mendalam Qualcomm AMI (Amazon Linux 2) $ {YYYY-MM-DD}

AMI meliputi yang berikut:

- AWS Layanan yang Didukung: Amazon EC2
- Sistem Operasi: Amazon Linux 2
- Arsitektur Komputasi: x86

- Kernel Linux: 5.10.210-201.852.amzn2.x86_64
- Lokasi SDK: /opt/qai-sdk
- QTI Utils Lokasi: /opt/qti-aic
- Versi SDK Platform: 1.12.0.88
- Versi SDK Aplikasi: 1.12.0.87
- Jenis volume EBS: gp3
- Python: python3.8
- EC2 Contoh yang Didukung: dl2q
- Kueri AMI-ID dengan AWS CLI (contoh Wilayah adalah us-east-1):

```
aws ec2 describe-images --region us-east-1 \
    --owners amazon \
    --filters 'Name=name,Values=Deep Learning Base Qualcomm AMI (Amazon Linux
 2) ????????' 'Name=state,Values=available' \
    --query 'reverse(sort_by(Images, &CreationDate))[:1].ImageId' \
    --output text
```

Pemberitahuan

[4/12/24] Penghapusan Paket Audit

- DLAMIs dirilis antara 26 Maret 2024 (2024-03-26) dan 12 April 2024 (2024-04-12) dikirim tanpa paket audit. Jika Anda memerlukan paket khusus ini untuk kebutuhan pencatatan dan pemantauan Anda, silakan migrasi alur kerja Anda ke DLAMI terbaru untuk menggunakan paket audit yang diinstal.

Lingkungan QAIC:

- Secara default, qaic-pytools tidak diaktifkan melalui Qualcomm 00 Apps SDK. AI1 Untuk mengaktifkan dan membuat lingkungan pip qaic qaic-env, jalankan perintah berikut:

```
echo 'yes' | bash /opt/qai-sdk/qaic-apps-*/uninstall.sh
cd /opt/qai-sdk/qaic-apps-*/
sudo sed -i "s/python3 -V/python3.8 -V/g" install.sh
./install.sh --enable-qaic-pytools
```

Versi 20240314

Tanggal rilis: 2024-03-14

Nama AMI: Basis Pembelajaran Mendalam Qualcomm AMI (Amazon Linux 2) 20240314

Ditambahkan

- AI 100 Platform SDK diperbarui dari versi 1.10.0.200 ke versi 1.12.0.88
- AI 100 Apps SDK diperbarui dari versi 1.10.0.193 ke versi 1.12.0.87
- SDK Versi 1.12 menambahkan dukungan untuk model decoder transformator seperti Llama-2 dan Starcoder

Versi 20240110

Tanggal Rilis: 2024-01-10

Nama AMI: Basis Pembelajaran Mendalam Qualcomm AMI (Amazon Linux 2) 20240103

Ditambahkan

- Gambar Qualcomm AI 100 Platform ditingkatkan ke 1.10.0.200

Versi 20231115

Tanggal Rilis: 2023-11-15

Nama AMI: Basis Pembelajaran Mendalam Qualcomm AMI (Amazon Linux 2) 20231115

Ditambahkan

- Rilis awal seri Deep Learning Base Qualcomm AMI (Amazon Linux 2).
  - Silakan merujuk ke dokumentasi resmi Qualcomm untuk informasi lebih lanjut tentang Platform dan Aplikasi SDK: https://quic.github.io//cloud-ai-sdk-pages
  - Silakan merujuk ke AWS dokumentasi resmi untuk mempelajari lebih lanjut tentang instans dl2q: instance. DL2q

ARM64 Catatan Rilis DLAMI Dasar

- ARM64 Catatan Rilis DLAMI Dasar

ARM64 Catatan Rilis DLAMI Dasar

Di bawah ini adalah catatan rilis untuk ARM64 Base DLAMI:

GPU

- AWS Basis Pembelajaran Mendalam ARM64 AMI (Amazon Linux 2023) (Mendukung P6e- 00) GB2
- AWS ARM64 AMI Dasar Pembelajaran Mendalam (Ubuntu 22.04) (Mendukung P6e- 00) GB2
- AWS Basis Pembelajaran Mendalam ARM64 AMI (Amazon Linux 2)

AWS Neuron

- Lihat Panduan Pengguna DLAMI Neuron.

AWS GPU ARM64 Basis Pembelajaran Mendalam AMI (Amazon Linux 2023)

Untuk bantuan memulai, lihatMemulai dengan DLAMI.

Format nama AMI

- ARM64 Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Amazon Linux 2023) ${YYYY-MM-DD}

EC2 Contoh yang didukung

- G5g, P6e- GB2 00 (CUDA> = 12.8 didukung pada P6e- 00) GB2

AMI meliputi yang berikut:

- AWS Layanan yang Didukung: Amazon EC2
- Sistem Operasi: Amazon Linux 2023
- Arsitektur Komputasi: ARM64
- Versi terbaru yang tersedia diinstal untuk paket-paket berikut:
  - Kernel Linux: 6. 12
  - FSx Kilau

    - Docker
    - AWS CLI v2 di/usr/bin/aws
    - NVIDIA DCGM
    - Toolkit wadah Nvidia:
        - Perintah versi: nvidia-container-cli -V
    - NVIDIA-Docker2:
        - Perintah versi: versi nvidia-docker
- Pengemudi NVIDIA: 570.158.01
- NVIDIA CUDA 12.4, 12,5, 12.6, 12.8 tumpukan:
    - Direktori instalasi CUDA, NCCL dan cudDN:/-xx.x/ usr/local/cuda
        - Contoh:/usr/local/cuda-12.8/ , /usr/local/cuda-12.8/
    - Versi NCCL yang dikompilasi:
        - Untuk direktori CUDA 12.4, dikompilasi NCCL Versi 2.22.3+ .4 CUDA12
        - Untuk direktori CUDA 12.5, dikompilasi NCCL Versi 2.22.3+ .5 CUDA12
        - Untuk direktori CUDA 12.6, dikompilasi NCCL Versi 2.24.3+ .6 CUDA12
        - Untuk direktori CUDA 12.8, dikompilasi NCCL Versi 2.27.5+ .8 CUDA12
    - CUDA standar: 12.8
        - PATH/usr/local/cudamenunjuk ke CUDA 12.8
        - Diperbarui di bawah env vars:
            - LD_LIBRARY_PATH memiliki/64 usr/local/cuda-12.8/lib:/usr/local/cuda-12.8/lib64:/usr/local/cuda-12.8:/usr/local/cuda-12.8/targets/sbsa-linux/lib:/usr/local/cuda-12.8/nvvm/lib64:/usr/local/cuda-12.8/extras/CUPTI/lib
            - PATH untuk memiliki/usr/local/cuda-12.8/bin/:/usr/local/cuda-12.8/include/
            - Untuk versi CUDA yang berbeda, harap perbarui LD_LIBRARY_PATH yang sesuai.
- Pemasang EFA: 1.42.0
- Nvidia GDRCopy: 2.5.1
- AWS Plugin OFI NCCL dilengkapi dengan installer EFA
    - opt/amazon/ofi-nccl/lib and /opt/amazon/ofi-nccl/efaPaths/ditambahkan ke LD_LIBRARY_PATH.
- AWS CLI v2 di/usr/local/bin/aws
- Jenis volume EBS: gp3
- Python:/3.9 usr/bin/python

- Kueri AMI-ID dengan Parameter SSM (contoh wilayah adalah us-east-1):

```
SSM_PARAMETER=base-oss-nvidia-driver-gpu-amazon-linux-2023/latest/ami-id \
    aws ssm get-parameter --region us-east-1 \
    --name /aws/service/deeplearning/ami/arm64/$SSM_PARAMETER  \
    --query "Parameter.Value" \
    --output text
```

- Kueri AMI-ID dengan AWSCLI (contoh wilayah adalah us-east-1):

```
aws ec2 describe-images --region us-east-1 --owners amazon --filters
 'Name=name,Values=Deep Learning ARM64 Base OSS Nvidia Driver GPU AMI (Amazon Linux
 2023) ????????' 'Name=state,Values=available' --query 'reverse(sort_by(Images,
 &CreationDate))[:1].ImageId' --output text
```

P6e- 00 contoh GB2

Instans P6e- GB2 00 berisi 17 kartu antarmuka jaringan, dan dapat diluncurkan menggunakan perintah berikut: AWS CLI

```
aws ec2 run-instances --region $REGION \
    --instance-type $INSTANCETYPE \
    --image-id $AMI --key-name $KEYNAME \
    --iam-instance-profile "Name=dlami-builder" \
    --tag-specifications "ResourceType=instance,Tags=[{Key=Name,Value=$TAG}]" \
    --network-interfaces \
        "NetworkCardIndex=0,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=interface" \
        "NetworkCardIndex=1,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa-only" \
        "NetworkCardIndex=2,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa-only" \
        "NetworkCardIndex=3,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa-only" \
        "NetworkCardIndex=4,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa-only" \
        "NetworkCardIndex=5,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa-only" \
        "NetworkCardIndex=6,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa-only" \
        "NetworkCardIndex=7,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa-only" \
```

```
        "NetworkCardIndex=8,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa-only" \
        "NetworkCardIndex=9,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa-only" \
        "NetworkCardIndex=10,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa-only" \
        "NetworkCardIndex=11,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa-only" \
        "NetworkCardIndex=12,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa-only" \
        "NetworkCardIndex=13,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa-only" \
        "NetworkCardIndex=14,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa-only" \
        "NetworkCardIndex=15,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa-only" \
        "NetworkCardIndex=16,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa-only"
```

Pemberitahuan

Toolkit Kontainer NVIDIA 1.17.4

Dalam Container Toolkit versi 1.17.4 pemasangan pustaka compat CUDA sekarang dinonaktifkan. Untuk memastikan kompatibilitas dengan beberapa versi CUDA pada alur kerja kontainer, pastikan Anda memperbarui LD_LIBRARY_PATH Anda untuk menyertakan pustaka kompatibilitas CUDA Anda seperti yang ditunjukkan dalam tutorial Jika Anda menggunakan lapisan kompatibilitas CUDA.

Kebijakan Support

AMIs Komponen versi AMI seperti CUDA ini dapat dihapus dan diubah berdasarkan kebijakan dukungan kerangka kerja atau untuk mengoptimalkan kinerja untuk wadah pembelajaran mendalam atau untuk mengurangi ukuran AMI di rilis mendatang, tanpa pemberitahuan sebelumnya. Kami menghapus versi CUDA dari AMIs jika tidak digunakan oleh versi kerangka kerja yang didukung.

Kernel

- Versi kernel disematkan menggunakan perintah:

```
sudo dnf versionlock kernel*
```

- Kami menyarankan agar pengguna menghindari memperbarui versi kernel mereka (kecuali karena patch keamanan) untuk memastikan kompatibilitas dengan driver dan versi paket yang diinstal.

Jika pengguna masih ingin memperbarui, mereka dapat menjalankan perintah berikut untuk melepas pin versi kernel mereka:

```
sudo dnf versionlock delete kernel*
sudo dnf update -y
```

- Untuk setiap versi baru DLAMI, kernel kompatibel terbaru yang tersedia digunakan.

Tanggal Rilis: 2025-07-04

Nama AMI: ARM64 Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Amazon Linux 2023) 20250704

Diperbarui

- Ditambahkan dukungan untuk EC2 contoh P6e- GB2 00. Harap dicatat bahwa CUDA>=12.8 didukung pada P6e- 00 GB2
- Tambahkan EFA 1.42.0
- Driver Nvidia yang ditingkatkan dari versi 570.133.20 ke 570.158.01
- Tumpukan CUDA 12.8 yang ditingkatkan dengan NCCL 2.27.5

Tanggal Rilis: 2025-04-24

Nama AMI: ARM64 Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Amazon Linux 2023) 20250424

Diperbarui

- Driver Nvidia yang ditingkatkan dari versi 570.86.15 ke 570.133.20 ke alamat yang CVEs ada di Buletin Keamanan Driver Tampilan GPU NVIDIA untuk April 2025
- Diperbarui CUDA12 tumpukan.8 dengan NCCL 2.26.2
- CUDA default yang diperbarui dari 12.6 ke 12.8

Tanggal Rilis: 2025-04-22

Nama AMI: ARM64 Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Amazon Linux 2023) 20250421

Diperbarui

- Driver Nvidia yang ditingkatkan dari versi 570.124.06 ke 570.133.20 ke alamat yang CVEs ada di Buletin Keamanan Driver Tampilan GPU NVIDIA untuk April 2025

Tanggal Rilis: 2025-04-04

Nama AMI: ARM64 Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Amazon Linux 2023) 20250404

Diperbarui

- Versi kernel diperbarui dari 6.1 ke 6.12

Tanggal Rilis: 2025-03-03

Nama AMI: ARM64 Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Amazon Linux 2023) 20250303

Diperbarui

- Driver Nvidia dari 550.144.03 ke 570.86.15
- CUDA default diubah dari CUDA12 .4 menjadi .6 CUDA12

Ditambahkan

- Direktori CUDA 12.5 dengan dikompilasi NCCL Versi CUDA12 2.22.3+ .5 dan cuDNN 9.7.1.26
- Direktori CUDA 12.6 dengan dikompilasi NCCL Versi CUDA12 2.24.3+ .6 dan cuDNN 9.7.1.26
- Direktori CUDA 12.8 dengan dikompilasi NCCL Versi CUDA12 2.25.1+ .8 dan cuDNN 9.7.1.26

Tanggal Rilis: 2025-02-14

Nama AMI: ARM64 Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Amazon Linux 2023) 20250214

Ditambahkan

- Rilis awal Deep Learning ARM64 Base OSS DLAMI untuk Amazon Linux 2023

AWS GPU AMI ARM64 Dasar Pembelajaran Mendalam (Ubuntu 22.04)

Untuk bantuan memulai, lihatMemulai dengan DLAMI.

Format nama AMI

- ARM64 Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Ubuntu 22.04) $ {YYYY-MM-DD}

EC2 Contoh yang didukung

- G5g, P6e- GB2 00 (CUDA> = 12.8 didukung pada P6e- 00) GB2

AMI meliputi yang berikut:

- AWS Layanan yang Didukung: Amazon EC2
- Sistem Operasi: Ubuntu 22.04
- Arsitektur Komputasi: ARM64
- Versi terbaru yang tersedia diinstal untuk paket-paket berikut:
  - Kernel Linux: 6. 8
  - FSx Kilau
  - Docker
  - AWS CLI v2 di/usr/bin/aws
  - NVIDIA DCGM
  - Toolkit wadah Nvidia:
    - Perintah versi: nvidia-container-cli -V
  - NVIDIA-Docker2:
    - Perintah versi: versi nvidia-docker
- Pengemudi NVIDIA: 570.158.01
- NVIDIA CUDA 12.4, 12,5, 12.6, 12.8 tumpukan:
  - Direktori instalasi CUDA, NCCL dan cudDN:/-xx.x/ usr/local/cuda
    - Contoh:/usr/local/cuda-12.8/ , /usr/local/cuda-12.8/
  - Versi NCCL yang dikompilasi:
    - Untuk direktori CUDA 12.4, dikompilasi NCCL Versi 2.22.3+ .4 CUDA12

    - Untuk direktori CUDA 12.5, dikompilasi NCCL Versi 2.22.3+ .5 CUDA12
    - Untuk direktori CUDA 12.6, dikompilasi NCCL Versi 2.24.3+ .6 CUDA12
    - Untuk direktori CUDA 12.8, dikompilasi NCCL Versi 2.27.5+ .8 CUDA12
  - CUDA standar: 12.8
    - PATH/usr/local/cudamenunjuk ke CUDA 12.8
    - Diperbarui di bawah env vars:
      - LD_LIBRARY_PATH memiliki/64 usr/local/cuda-12.8/lib:/usr/local/cuda-12.8/lib64:/usr/local/cuda-12.8:/usr/local/cuda-12.8/targets/sbsa-linux/lib:/usr/local/cuda-12.8/nvvm/lib64:/usr/local/cuda-12.8/extras/CUPTI/lib
      - PATH untuk memiliki/usr/local/cuda-12.8/bin/:/usr/local/cuda-12.8/include/
      - Untuk versi CUDA yang berbeda, harap perbarui LD_LIBRARY_PATH yang sesuai.
- Pemasang EFA: 1.42.0
- Nvidia GDRCopy: 2.5.1
- AWS Plugin OFI NCCL dilengkapi dengan installer EFA
  - opt/amazon/ofi-nccl/lib and /opt/amazon/ofi-nccl/efaPaths/ditambahkan ke LD_LIBRARY_PATH.
- AWS CLI v2 di/usr/local/bin/aws2 dan AWS CLI v1 di/usr/bin/aws
- Jenis volume EBS: gp3
- Python:/3.10 usr/bin/python
- Kueri AMI-ID dengan Parameter SSM (contoh Wilayah adalah us-east-1):

```
SSM_PARAMETER=base-oss-nvidia-driver-gpu-ubuntu-22.04/latest/ami-id \
    aws ssm get-parameter --region us-east-1 \
    --name /aws/service/deeplearning/ami/arm64/$SSM_PARAMETER  \
    --query "Parameter.Value" \
    --output text
```

- Kueri AMI-ID dengan AWSCLI (contoh Wilayah adalah us-east-1):

```
aws ec2 describe-images --region us-east-1 \
    --owners amazon --filters 'Name=name,Values=Deep Learning ARM64 Base OSS Nvidia
 Driver GPU AMI (Ubuntu 22.04) ????????' 'Name=state,Values=available' \
    --query 'reverse(sort_by(Images, &CreationDate))[:1].ImageId' \
    --output text
```

P6e- 00 contoh GB2

Instans P6e- GB2 00 berisi 17 kartu antarmuka jaringan, dan dapat diluncurkan menggunakan perintah berikut: AWS CLI

```
aws ec2 run-instances --region $REGION \
    --instance-type $INSTANCETYPE \
    --image-id $AMI --key-name $KEYNAME \
    --iam-instance-profile "Name=dlami-builder" \
    --tag-specifications "ResourceType=instance,Tags=[{Key=Name,Value=$TAG}]" \
    --network-interfaces \
        "NetworkCardIndex=0,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=interface" \
        "NetworkCardIndex=1,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa-only" \
        "NetworkCardIndex=2,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa-only" \
        "NetworkCardIndex=3,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa-only" \
        "NetworkCardIndex=4,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa-only" \
        "NetworkCardIndex=5,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa-only" \
        "NetworkCardIndex=6,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa-only" \
        "NetworkCardIndex=7,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa-only" \
        "NetworkCardIndex=8,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa-only" \
        "NetworkCardIndex=9,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa-only" \
        "NetworkCardIndex=10,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa-only" \
        "NetworkCardIndex=11,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa-only" \
        "NetworkCardIndex=12,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa-only" \
        "NetworkCardIndex=13,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa-only" \
        "NetworkCardIndex=14,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa-only" \
        "NetworkCardIndex=15,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa-only" \
```

```
        "NetworkCardIndex=16,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa-only"
```

Pemberitahuan

Toolkit Kontainer NVIDIA 1.17.4

Dalam Container Toolkit versi 1.17.4 pemasangan pustaka compat CUDA sekarang dinonaktifkan. Untuk memastikan kompatibilitas dengan beberapa versi CUDA pada alur kerja kontainer, pastikan Anda memperbarui LD_LIBRARY_PATH Anda untuk menyertakan pustaka kompatibilitas CUDA Anda seperti yang ditunjukkan dalam tutorial Jika Anda menggunakan lapisan kompatibilitas CUDA.

Dukungan multi ENI

- Ubuntu 22.04 secara otomatis mengatur dan mengonfigurasi perutean sumber pada beberapa NICs melalui cloud-init pada boot awalnya. Jika alur kerja attaching/detaching Anda menyertakan ENI Anda saat instans dihentikan, konfigurasi tambahan harus ditambahkan ke data pengguna cloud-init untuk memastikan konfigurasi NIC yang tepat selama peristiwa ini. Contoh konfigurasi cloud disediakan di bawah ini.
- Silakan referensi dokumentasi Canonical ini di sini untuk informasi lebih lanjut tentang cara mengonfigurasi konfigurasi cloud untuk instance Anda - -/https://documentation.ubuntu.com/aws/en/latest/aws-how-to/instances/automaticallysetup-multiple-nics

```
#cloud-config
# apply network config on every boot and hotplug event
updates:
  network:
    when: ['boot', 'hotplug']
```

Kebijakan Support

AMIs Komponen versi AMI seperti CUDA ini dapat dihapus dan diubah berdasarkan kebijakan dukungan kerangka kerja atau untuk mengoptimalkan kinerja untuk wadah pembelajaran mendalam atau untuk mengurangi ukuran AMI di rilis mendatang, tanpa pemberitahuan sebelumnya. Kami menghapus versi CUDA dari AMIs jika tidak digunakan oleh versi kerangka kerja yang didukung.

Kernel

- Versi kernel disematkan menggunakan perintah:

```
echo linux-aws hold | sudo dpkg –set-selections
echo linux-headers-aws hold | sudo dpkg –set-selections
echo linux-image-aws hold | sudo dpkg –set-selections
```

- Kami menyarankan agar pengguna menghindari memperbarui versi kernel mereka (kecuali karena patch keamanan) untuk memastikan kompatibilitas dengan driver dan versi paket yang diinstal. Jika pengguna masih ingin memperbarui, mereka dapat menjalankan perintah berikut untuk melepas pin versi kernel mereka:

```
echo linux-aws install | sudo dpkg -set-selections
echo linux-headers-aws install | sudo dpkg -set-selections
echo linux-image-aws install | sudo dpkg -set-selections
```

- Untuk setiap versi baru DLAMI, kernel kompatibel terbaru yang tersedia digunakan.

Tanggal Rilis: 2025-07-04

Nama AMI: ARM64 Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Ubuntu 22.04) 20250704

Diperbarui

- Ditambahkan dukungan untuk EC2 contoh P6e- GB2 00. Harap dicatat bahwa CUDA>=12.8 didukung pada P6e- 00 GB2
- Tambahkan EFA 1.42.0
- Driver Nvidia yang ditingkatkan dari versi 570.133.20 ke 570.158.01
- Tumpukan CUDA 12.8 yang ditingkatkan dengan NCCL 2.27.5

Tanggal Rilis: 2025-04-24

Nama AMI: ARM64 Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Ubuntu 22.04) 20250424

Diperbarui

- Driver Nvidia yang ditingkatkan dari versi 570.86.15 ke 570.133.20 untuk mengatasi kehadiran CVE di Buletin Keamanan Driver Tampilan GPU NVIDIA untuk April 2025
- Tumpukan CUDA 12.8 yang diperbarui dengan NCCL 2.26.2

- CUDA default yang diperbarui dari 12.6 ke 12.8
- Dihapus CUDA 12.3

Tanggal Rilis: 2025-03-03

Nama AMI: ARM64 Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Ubuntu 22.04) 20250303

Diperbarui

- Driver Nvidia dari 550.144.03 ke 570.86.15
- CUDA default diubah dari CUDA12 .1 menjadi .6 CUDA12

Ditambahkan

- Direktori CUDA 12.4 dengan dikompilasi NCCL Versi CUDA12 2.22.3+ .4 dan cuDNN 9.7.1.26
- Direktori CUDA 12.5 dengan dikompilasi NCCL Versi CUDA12 2.22.3+ .5 dan cuDNN 9.7.1.26
- Direktori CUDA 12.6 dengan dikompilasi NCCL Versi CUDA12 2.24.3+ .6 dan cuDNN 9.7.1.26
- Direktori CUDA 12.8 dengan dikompilasi NCCL Versi CUDA12 2.25.1+ .8 dan cuDNN 9.7.1.26

Dihapus

- Direktori CUDA 12.1 dan 12.2

Tanggal Rilis: 2025-02-17

Nama AMI: ARM64 Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Ubuntu 22.04) 20250214

Diperbarui

- Diperbarui NVIDIA Container Toolkit dari versi 1.17.3 ke versi 1.17.4
  - Silakan lihat halaman catatan rilis di sini untuk informasi lebih lanjut: https://github.com/NVIDIA/nvidia-container-toolkit/releases/tag/v1.17.4
  - Di Container Toolkit versi 1.17.4, pemasangan pustaka compat CUDA sekarang dinonaktifkan. Untuk memastikan kompatibilitas dengan beberapa versi CUDA pada alur kerja kontainer,

pastikan Anda memperbarui LD_LIBRARY_PATH Anda untuk menyertakan pustaka kompatibilitas CUDA Anda seperti yang ditunjukkan dalam tutorial Jika Anda menggunakan lapisan kompatibilitas CUDA.

Dihapus

- Pustaka ruang pengguna yang dihapus cuobj dan nvdisasm disediakan oleh toolkit NVIDIA CUDA untuk mengatasi yang CVEs ada di Buletin Keamanan NVIDIA CUDA Toolkit untuk 18 Februari 2025

Tanggal Rilis: 2025-01-17

Nama AMI: ARM64 Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Ubuntu 22.04) 20250117

Diperbarui

- Driver Nvidia yang ditingkatkan dari versi 550.127.05 ke 550.144.03 ke alamat yang CVEs ada di Buletin Keamanan Driver Tampilan GPU NVIDIA untuk Januari 2025

Tanggal Rilis: 2024-10-23

Nama AMI: ARM64 Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Ubuntu 22.04) 20241023

Diperbarui

- Driver Nvidia yang ditingkatkan dari versi 550.90.07 ke 550.127.05 untuk alamat yang CVEs ada di Buletin Keamanan Tampilan GPU NVIDIA untuk Oktober 2024

Tanggal Rilis: 2024-06-06

Nama AMI: ARM64 Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Ubuntu 22.04) 20240606

Diperbarui

- Diperbarui versi driver Nvidia ke 535.183.01 dari 535.161.08

Tanggal Rilis: 2024-05-15

Nama AMI: ARM64 Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Ubuntu 22.04) 20240514

Ditambahkan

- Rilis awal dari Deep Learning ARM64 Base OSS DLAMI untuk Ubuntu 22.04

AWS GPU ARM64 Basis Pembelajaran Mendalam AMI (Amazon Linux 2)

Untuk bantuan memulai, lihatMemulai dengan DLAMI.

Format nama AMI

- ARM64 Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Amazon Linux 2) $ {YYYY-MM-DD}

EC2 Contoh yang didukung

- G5g

AMI meliputi yang berikut:

- AWS Layanan yang Didukung: Amazon EC2
- Sistem Operasi: Amazon Linux 2
- Arsitektur Komputasi: ARM64
- Kernel Linux: 5.10
- Pengemudi NVIDIA: 550.144.03
- NVIDIA CUDA 12.1, 12.2, 12.3 tumpukan:
  - Direktori instalasi CUDA, NCCL dan cudDN:
    - Contoh:/usr/local/cuda-12.1/ , /usr/local/cuda-12.1/
  - Versi NCCL yang dikompilasi:
    - Untuk direktori CUDA 12.3, dikompilasi NCCL Versi 2.21.5+ .4 CUDA12
    - Untuk direktori CUDA 12.1, 12.2, dikompilasi Versi NCCL .18.5+ .2 CUDA12
  - CUDA standar: 12.1

    - PATH/usr/local/cudamenunjuk ke CUDA 12.1
    - Diperbarui di bawah env vars:
        - LD_LIBRARY_PATH memiliki/64 usr/local/cuda-12.1/lib:/usr/local/cuda-12.1/lib64:/usr/local/cuda-12.1:/usr/local/cuda-12.1/targets/sbsa-linux/lib:/usr/local/cuda-12.1/nvvm/lib64:/usr/local/cuda-12.1/extras/CUPTI/lib
        - PATH untuk memiliki/usr/local/cuda-12.1/bin/:/usr/local/cuda-12.1/include/
        - Untuk versi CUDA yang berbeda, harap perbarui LD_LIBRARY_PATH yang sesuai.
- AWS CLI v2 di/usr/local/bin/aws2 dan AWS CLI v1 di/usr/bin/aws
- Jenis volume EBS: gp3
- Toolkit wadah Nvidia: 1.16.2
    - Perintah versi: nvidia-container-cli -V
- Docker: 26.1.2
- Python:/3.10 usr/bin/python
- Kueri AMI-ID dengan Parameter SSM (contoh Wilayah adalah us-east-1):

```
SSM_PARAMETER=base-oss-nvidia-driver-gpu-amazon-linux-2/latest/ami-id \
    aws ssm get-parameter --region us-east-1 \
    --name /aws/service/deeplearning/ami/arm64/$SSM_PARAMETER  \
    --query "Parameter.Value" \
    --output text
```

- Kueri AMI-ID dengan AWSCLI (contoh Wilayah adalah us-east-1):

```
aws ec2 describe-images --region us-east-1 \
    -owners amazon \
    --filters 'Name=name,Values=Deep Learning ARM64 Base OSS Nvidia Driver GPU AMI
 (Amazon Linux 2) ????????' 'Name=state,Values=available' \
    --query 'reverse(sort_by(Images, &CreationDate))[:1].ImageId' \
    --output text
```

Pemberitahuan

Toolkit Kontainer NVIDIA 1.17.4

Dalam Container Toolkit versi 1.17.4 pemasangan pustaka compat CUDA sekarang dinonaktifkan. Untuk memastikan kompatibilitas dengan beberapa versi CUDA pada alur kerja kontainer, pastikan

Anda memperbarui LD_LIBRARY_PATH Anda untuk menyertakan pustaka kompatibilitas CUDA Anda seperti yang ditunjukkan dalam tutorial Jika Anda menggunakan lapisan kompatibilitas CUDA.

Kebijakan Support

AMIs Komponen versi AMI seperti CUDA ini dapat dihapus dan diubah berdasarkan kebijakan dukungan kerangka kerja atau untuk mengoptimalkan kinerja untuk wadah pembelajaran mendalam atau untuk mengurangi ukuran AMI di rilis mendatang, tanpa pemberitahuan sebelumnya. Kami menghapus versi CUDA dari AMIs jika tidak digunakan oleh versi kerangka kerja yang didukung.

Kernel

- Versi kernel disematkan menggunakan perintah:

```
sudo yum versionlock kernel*
```

- Kami menyarankan agar pengguna menghindari memperbarui versi kernel mereka (kecuali karena patch keamanan) untuk memastikan kompatibilitas dengan driver dan versi paket yang diinstal. Jika pengguna masih ingin memperbarui, mereka dapat menjalankan perintah berikut untuk melepas pin versi kernel mereka:

```
sudo yum versionlock delete kernel*
sudo yum update -y
```

- Untuk setiap versi baru DLAMI, kernel kompatibel terbaru yang tersedia digunakan.

Tanggal Rilis: 2025-02-17

Nama AMI: ARM64 Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Amazon Linux 2) 20250214

Diperbarui

- Diperbarui NVIDIA Container Toolkit dari versi 1.17.3 ke versi 1.17.4
  - Silakan lihat halaman catatan rilis di sini untuk informasi lebih lanjut: https://github.com/NVIDIA/nvidia-container-toolkit/releases/tag/v1.17.4
  - Di Container Toolkit versi 1.17.4, pemasangan pustaka compat CUDA sekarang dinonaktifkan. Untuk memastikan kompatibilitas dengan beberapa versi CUDA pada alur kerja kontainer, pastikan Anda memperbarui LD_LIBRARY_PATH Anda untuk menyertakan pustaka

kompatibilitas CUDA Anda seperti yang ditunjukkan dalam tutorial Jika Anda menggunakan lapisan kompatibilitas CUDA.

Dihapus

- Pustaka ruang pengguna yang dihapus cuobj dan nvdisasm disediakan oleh toolkit NVIDIA CUDA untuk mengatasi yang CVEs ada di Buletin Keamanan NVIDIA CUDA Toolkit untuk 18 Februari 2025

Tanggal Rilis: 2025-01-17

Nama AMI: ARM64 Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Amazon Linux 2) 20250117

Diperbarui

- Driver Nvidia yang ditingkatkan dari versi 550.127.05 ke 550.144.03 ke alamat yang CVEs ada di Buletin Keamanan Driver Tampilan GPU NVIDIA untuk Januari 2025

Tanggal Rilis: 2024-10-22

Nama AMI: ARM64 Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Amazon Linux 2) 20241022

Diperbarui

- Driver Nvidia yang ditingkatkan dari versi 550.90.07 ke 550.127.05 untuk alamat yang CVEs ada di Buletin Keamanan Tampilan GPU NVIDIA untuk Oktober 2024

Tanggal Rilis: 2024-10-08

Nama AMI: ARM64 Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Amazon Linux 2) 20241008

Diperbarui

- Nvidia Container Toolkit yang ditingkatkan dari versi 1.16.1 ke 1.16.2, mengatasi kerentanan keamanan CVE-2024-0133.

Tanggal Rilis: 2024-06-06

Nama AMI: ARM64 Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Amazon Linux 2) 20240606

Diperbarui

- Diperbarui versi driver Nvidia ke 535.183.01 dari 535.161.08

Tanggal Rilis: 2024-05-14

Nama AMI: ARM64 Basis Pembelajaran Mendalam OSS Nvidia Driver GPU AMI (Amazon Linux 2) 20240514

Ditambahkan

- Rilis awal dari Deep Learning ARM64 Base OSS DLAMI untuk Amazon Linux 2

Catatan Rilis untuk Kerangka Tunggal DLAMIs

Catatan Rilis DLAMI Kerangka Tunggal

- PyTorch DLAMIs
- TensorFlow DLAMIs

PyTorch DLAMIs

Catatan Rilis Multi Framework DLAMI

- Catatan Rilis X86 PyTorch DLAMI
- ARM64 PyTorch Catatan Rilis DLAMI

Catatan Rilis X86 PyTorch DLAMI

Di bawah ini adalah catatan Rilis untuk X86 PyTorch DLAMIs:

GPU

- AWS Pembelajaran Mendalam AMI GPU PyTorch 2.7 (Amazon Linux 2023)
- AWS Pembelajaran Mendalam AMI GPU PyTorch 2.7 (Ubuntu 22.04)

- AWS Pembelajaran Mendalam AMI GPU PyTorch 2.6 (Amazon Linux 2023)
- AWS Pembelajaran Mendalam AMI GPU PyTorch 2.6 (Ubuntu 22.04)
- AWS Pembelajaran Mendalam AMI GPU PyTorch 2.5 (Amazon Linux 2023)
- AWS Pembelajaran Mendalam AMI GPU PyTorch 2.5 (Ubuntu 22.04)
- AWS Pembelajaran Mendalam AMI GPU PyTorch 2.4 (Ubuntu 22.04)

AWS Neuron

- Lihat Panduan Pengguna DLAMI Neuron

AWS Pembelajaran Mendalam OSS AMI GPU PyTorch 2.7 (Amazon Linux 2023)

Untuk bantuan memulai, lihatMemulai dengan DLAMI.

Format nama AMI

- Pembelajaran Mendalam OSS Nvidia Driver AMI GPU PyTorch 2.7 (Amazon Linux 2023) $ {YYYY-MM-DD}

EC2 Contoh yang didukung

- Silakan lihat Perubahan penting pada DLAMI
- G4dn, G5, G5, Gr6, P4, P4DE, P5, P5e, P5en, P6-B200

AMI meliputi yang berikut:

- AWS Layanan yang Didukung: Amazon EC2
- Sistem Operasi: Amazon Linux 2023
- Arsitektur Komputasi: x86
- Kernel Linux: 6.1
- Pengemudi NVIDIA: 570.133.20
- Tumpukan NVIDIA CUDA 12.8:
  - Direktori instalasi CUDA, NCCL dan cudDN:/-12.8/usr/local/cuda
  - Lokasi Tes NCCL:
    - all_reduce, all_gather, dan reduce_scatter:

```
/usr/local/cuda-12.8/efa/test-cuda-12.8/
```

- Untuk menjalankan pengujian NCCL, LD_LIBRARY_PATH sudah diperbarui dengan jalur yang diperlukan.
  - Umum sudah PATHs ditambahkan ke LD_LIBRARY_PATH:

```
/opt/amazon/efa/lib:/opt/amazon/openmpi/lib:/opt/amazon/ofi-nccl/lib:/usr/
local/lib:/usr/lib
```

  - LD_LIBRARY_PAT diperbarui dengan jalur versi CUDA:

```
/usr/local/cuda/lib:/usr/local/cuda/lib64:/usr/local/cuda:/usr/local/cuda/
targets/x86_64-linux/lib
```

- Versi NCCL yang dikompilasi:
  - Untuk direktori CUDA 12.8, dikompilasi NCCL Versi 2.26.2+ .8 CUDA12
- CUDA standar: 12.8
  - PATH/usr/local/cudamenunjuk ke CUDA 12.8
  - Diperbarui di bawah env vars:
    - LD_LIBRARY_PATH memiliki/usr/local/cuda/lib:/usr/local/cuda/lib64:/usr/local/cuda/targets/x86_64-linux/lib
    - PATH untuk memiliki/usr/local/cuda/bin/:/usr/local/cuda/include/
- Pemasang EFA: 1.40.0
- Nvidia GDRCopy: 2.5
- AWS OFI NCCL: 1.14.2-aws
  - Jalur instalasi:/ditambahkan ke opt/amazon/ofi-nccl/. Path /opt/amazon/ofi-nccl/lib LD_LIBRARY_PATH
- AWS CLI v2 di/usr/local/bin/aws
- Jenis volume EBS: gp3
- Toolkit wadah Nvidia: 1.17.7
  - Perintah versi: nvidia-container-cli -V
- Docker: 25.0.8
- Python:/3.12 usr/bin/python
- Kueri AMI-ID dengan Parameter SSM (contoh wilayah adalah us-east-1):

```
aws ssm get-parameter --region us-east-1 \
    --name /aws/service/deeplearning/ami/x86_64/oss-nvidia-driver-gpu-pytorch-2.7-
amazon-linux-2023/latest/ami-id \
    --query "Parameter.Value" \
    --output text
```

- Kueri AMI-ID dengan AWSCLI (contoh wilayah adalah us-east-1):

```
aws ec2 describe-images --region us-east-1 --owners amazon --filters
 'Name=name,Values=Deep Learning OSS Nvidia Driver AMI GPU PyTorch 2.7 (Amazon Linux
 2023) ????????' 'Name=state,Values=available' --query 'reverse(sort_by(Images,
 &CreationDate))[:1].ImageId' --output text
```

Pemberitahuan

Instans P6-B200

- Instans P6-B200 memerlukan CUDA versi 12.8 atau lebih tinggi dan driver NVIDIA 570 atau driver yang lebih baru.
- P6-B200 berisi 8 kartu antarmuka jaringan dan dapat diluncurkan menggunakan perintah CLI AWS berikut:

```
aws ec2 run-instances --region $REGION \
    --instance-type $INSTANCETYPE \
    --image-id $AMI --key-name $KEYNAME \
    --iam-instance-profile "Name=dlami-builder" \
    --tag-specifications "ResourceType=instanace,Tags=[{Key=Name,Value=$TAG}]" \
    --network-interfaces ""NetworkCardIndex=0,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa" \
    "NetworkCardIndex=1,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
    "NetworkCardIndex=2,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
    "NetworkCardIndex=3,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
    "NetworkCardIndex=4,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
    ....
    ....
    ....
    "NetworkCardIndex=7,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
```

Instans P5/P5e

- DeviceIndex unik untuk masing-masing NetworkCard dan harus berupa bilangan bulat non-negatif kurang dari batas per. ENIs NetworkCard Pada P5, jumlah ENIs per NetworkCard adalah 2, yang berarti bahwa satu-satunya nilai yang valid untuk DeviceIndex adalah 0 atau 1. Di bawah ini adalah contoh perintah peluncuran instance EC2 P5 menggunakan awscli yang menunjukkan NetworkCardIndex angka 0-31 dan DeviceIndex sebagai 0 untuk antarmuka pertama dan 1 untuk 31 antarmuka yang tersisa.

```
aws ec2 run-instances --region $REGION \
    --instance-type $INSTANCETYPE \
    --image-id $AMI --key-name $KEYNAME \
    --iam-instance-profile "Name=dlami-builder" \
    --tag-specifications "ResourceType=instanace,Tags=[{Key=Name,Value=$TAG}]" \
    --network-interfaces ""NetworkCardIndex=0,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa" \
    "NetworkCardIndex=1,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
    "NetworkCardIndex=2,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
    "NetworkCardIndex=3,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
    "NetworkCardIndex=4,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
    ....
    ....
    ....
    "NetworkCardIndex=31,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
```

Kernel

- Versi kernel disematkan menggunakan perintah:

```
sudo dnf versionlock kernel*
```

- Kami menyarankan pengguna untuk menghindari memperbarui versi kernel mereka (kecuali karena patch keamanan) untuk memastikan kompatibilitas dengan driver yang diinstal dan versi paket. Jika pengguna masih ingin memperbarui, mereka dapat menjalankan perintah berikut untuk melepas pin versi kernel mereka:

```
sudo dnf versionlock delete kernel*
sudo dnf update -y
```

- Untuk setiap versi baru DLAMI, kernel kompatibel terbaru yang tersedia digunakan.

PyTorch Penghentian Saluran Anaconda

Dimulai dengan PyTorch 2.6, PyTorch telah menghentikan dukungan untuk Conda (lihat pengumuman resmi). Akibatnya, PyTorch 2.6 ke atas akan beralih menggunakan Lingkungan Virtual Python. Untuk mengaktifkan PyTorch venv, gunakan sumber/opt/pytorch/bin/activate

Tanggal Rilis: 2025-05-22

Nama AMI: Driver OSS Nvidia Pembelajaran Mendalam AMI GPU PyTorch 2.7 (Amazon Linux 2023) 20250520

Ditambahkan

- Rilis awal seri Deep Learning AMI GPU PyTorch 2.7 (Amazon Linux 2023). Termasuk pytorch lingkungan virtual Python (sumber/opt/pytorch/bin/activate) yang dilengkapi dengan NVIDIA Driver R570, CUDA = 12.8, cuDNN = 9.10, NCCL = 2.26.2, dan EFA = 1.40.0. PyTorch

AWS Pembelajaran Mendalam OSS AMI GPU PyTorch 2.7 (Ubuntu 22.04)

Untuk bantuan memulai, lihatMemulai dengan DLAMI.

Format nama AMI

- Pembelajaran Mendalam OSS Nvidia Driver AMI GPU PyTorch 2.7 (Ubuntu 22.04) $ {YYYY-MM-DD}

EC2 Contoh yang didukung

- Silakan lihat Perubahan penting pada DLAMI
- G4dn, G5, G5, Gr6, P4, P4DE, P5, P5e, P5en, P6-B200

AMI meliputi yang berikut:

- AWS Layanan yang Didukung: Amazon EC2
- Sistem Operasi: Ubuntu 22.04
- Arsitektur Komputasi: x86
- Kernel Linux: 6.8
- Pengemudi NVIDIA: 570.133.20

- Tumpukan NVIDIA CUDA 12.8:
  - Direktori instalasi CUDA, NCCL dan cudDN:/-12.8/usr/local/cuda
  - Lokasi Tes NCCL:
    - all_reduce, all_gather, dan reduce_scatter:

      ```
      /usr/local/cuda-12.8/efa/test-cuda-12.8/
      ```

    - Untuk menjalankan pengujian NCCL, LD_LIBRARY_PATH sudah diperbarui dengan jalur yang diperlukan.
      - Umum sudah PATHs ditambahkan ke LD_LIBRARY_PATH:

        ```
        /opt/amazon/efa/lib:/opt/amazon/openmpi/lib:/opt/amazon/ofi-nccl/lib:/usr/
        local/lib:/usr/lib
        ```

      - LD_LIBRARY_PAT diperbarui dengan jalur versi CUDA:

        ```
        /usr/local/cuda/lib:/usr/local/cuda/lib64:/usr/local/cuda:/usr/local/cuda/
        targets/x86_64-linux/lib
        ```

  - Versi NCCL yang dikompilasi:
    - Untuk direktori CUDA 12.8, dikompilasi NCCL Versi 2.26.2+ .8 CUDA12
  - CUDA standar: 12.8
    - PATH/usr/local/cudamenunjuk ke CUDA 12.8
    - Diperbarui di bawah env vars:
      - LD_LIBRARY_PATH memiliki/usr/local/cuda/lib:/usr/local/cuda/lib64:/usr/local/cuda/targets/x86_64-linux/lib
      - PATH untuk memiliki/usr/local/cuda/bin/:/usr/local/cuda/include/
- Pemasang EFA: 1.40.0
- Nvidia GDRCopy: 2.5
- Mesin Transformator Nvidia: 1.11.0
- AWS OFI NCCL: 1.14.2-aws
  - Jalur instalasi:/ditambahkan ke opt/amazon/ofi-nccl/. Path /opt/amazon/ofi-nccl/lib LD_LIBRARY_PATH
- AWS CLI v2 di/usr/local/bin/aws
- Jenis volume EBS: gp3

- Toolkit wadah Nvidia: 1.17.7
  - Perintah versi: nvidia-container-cli -V
- Docker: 28.2.2
- Python:/3.12 usr/bin/python
- Kueri AMI-ID dengan Parameter SSM (contoh wilayah adalah us-east-1):

```
aws ssm get-parameter --region us-east-1 \
    --name /aws/service/deeplearning/ami/x86_64/oss-nvidia-driver-gpu-pytorch-2.7-
ubuntu-22.04/latest/ami-id \
    --query "Parameter.Value" \
    --output text
```

- Kueri AMI-ID dengan AWSCLI (contoh wilayah adalah us-east-1):

```
aws ec2 describe-images --region us-east-1 --owners amazon --filters
 'Name=name,Values=Deep Learning OSS Nvidia Driver AMI GPU PyTorch 2.7 (Ubuntu
 22.04) ????????' 'Name=state,Values=available' --query 'reverse(sort_by(Images,
 &CreationDate))[:1].ImageId' --output text
```

Pemberitahuan

Perhatian Flash

- Perhatian flash belum memiliki rilis resmi untuk PyTorch 2.7. Untuk alasan ini, sementara dihapus dari AMI ini. Setelah rilis resmi dibuat untuk PyTorch 2.7, kami akan memasukkannya ke dalam AMI ini.
- Tanpa perhatian kilat, mesin transformator default menggunakan perhatian cuDNN yang menyatu. Saat ini ada masalah yang diketahui dengan perhatian yang menyatu dan Blackwell GPUs, seperti contoh P6-B200.
  - “Dengan kemampuan komputasi sm10.0 (BlackWell-Architecture) GPUs, FP8 tipe data dengan perhatian produk titik berskala berisi kebuntuan yang menyebabkan kernel menggantung dalam beberapa keadaan, seperti ketika ukuran masalah besar atau GPU menjalankan beberapa kernel secara bersamaan. Perbaikan direncanakan untuk rilis di masa depan.” [cuDNN 9.10.0 catatan rilis]
  - Untuk pengguna yang ingin menjalankan instance P6-B200 dengan FP8 data dan perhatian produk titik berskala, harap pertimbangkan untuk menginstal perhatian flash secara manual.

Instans P6-B200

- Instans P6-B200 memerlukan CUDA versi 12.8 atau lebih tinggi dan driver NVIDIA 570 atau driver yang lebih baru.
- P6-B200 berisi 8 kartu antarmuka jaringan dan dapat diluncurkan menggunakan perintah CLI AWS berikut:

```
aws ec2 run-instances --region $REGION \
    --instance-type $INSTANCETYPE \
    --image-id $AMI --key-name $KEYNAME \
    --iam-instance-profile "Name=dlami-builder" \
    --tag-specifications "ResourceType=instanace,Tags=[{Key=Name,Value=$TAG}]" \
    --network-interfaces ""NetworkCardIndex=0,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa" \
    "NetworkCardIndex=1,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
    "NetworkCardIndex=2,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
    "NetworkCardIndex=3,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
    "NetworkCardIndex=4,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
    ....
    ....
    ....
    "NetworkCardIndex=7,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
```

Instans P5/P5e

- DeviceIndex unik untuk masing-masing NetworkCard dan harus berupa bilangan bulat non-negatif kurang dari batas per. ENIs NetworkCard Pada P5, jumlah ENIs per NetworkCard adalah 2, yang berarti bahwa satu-satunya nilai yang valid untuk DeviceIndex adalah 0 atau 1. Di bawah ini adalah contoh perintah peluncuran instance EC2 P5 menggunakan awscli yang menunjukkan NetworkCardIndex angka 0-31 dan DeviceIndex sebagai 0 untuk antarmuka pertama dan 1 untuk 31 antarmuka yang tersisa.

```
aws ec2 run-instances --region $REGION \
    --instance-type $INSTANCETYPE \
    --image-id $AMI --key-name $KEYNAME \
    --iam-instance-profile "Name=dlami-builder" \
    --tag-specifications "ResourceType=instanace,Tags=[{Key=Name,Value=$TAG}]" \
    --network-interfaces ""NetworkCardIndex=0,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa" \
```

```
    "NetworkCardIndex=1,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
    "NetworkCardIndex=2,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
    "NetworkCardIndex=3,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
    "NetworkCardIndex=4,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
    ....
    ....
    ....
    "NetworkCardIndex=31,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
```

Kernel

- Versi kernel disematkan menggunakan perintah:

```
echo linux-aws hold | sudo dkpg -set-selections
echo linux-headers-aws hold | sudo dpkg -set-selections
echo linux-image-aws hold | sudo dpkg -set-selections
```

- Kami menyarankan pengguna untuk menghindari memperbarui versi kernel mereka (kecuali karena patch keamanan) untuk memastikan kompatibilitas dengan driver yang diinstal dan versi paket. Jika pengguna masih ingin memperbarui, mereka dapat menjalankan perintah berikut untuk melepas pin versi kernel mereka:

```
echo linux-aws install | sudo dpkg -set-selections
echo linux-headers-aws install | sudo dpkg -set-selections
echo linux-image-aws install | sudo dpkg -set-selections
apt-get upgrade -y
```

- Untuk setiap versi baru DLAMI, kernel kompatibel terbaru yang tersedia digunakan.

PyTorch Penghentian Saluran Anaconda

Dimulai dengan PyTorch 2.6, PyTorch telah menghentikan dukungan untuk Conda (lihat pengumuman resmi). Akibatnya, PyTorch 2.6 ke atas akan beralih menggunakan Lingkungan Virtual Python. Untuk mengaktifkan PyTorch venv, gunakan sumber/opt/pytorch/bin/activate

Tanggal Rilis: 2025-06-03

Nama AMI: Driver OSS Nvidia Pembelajaran Mendalam AMI GPU PyTorch 2.7 (Ubuntu 22.04) 20250602

Ditambahkan

- Rilis awal seri Deep Learning AMI GPU PyTorch 2.7 (Ubuntu 22.04). Termasuk pytorch lingkungan virtual Python (sumber/opt/pytorch/bin/activate) yang dilengkapi dengan NVIDIA Driver R570, CUDA = 12.8, cuDNN = 9.10, NCCL = 2.26.5, dan EFA = 1.40.0. PyTorch

Masalah yang Diketahui

- “Dengan kemampuan komputasi sm10.0 (BlackWell-Architecture) GPUs, FP8 tipe data dengan perhatian produk titik berskala berisi kebuntuan yang menyebabkan kernel menggantung dalam beberapa keadaan, seperti ketika ukuran masalah besar atau GPU menjalankan beberapa kernel secara bersamaan. Perbaikan direncanakan untuk rilis di masa depan.” [cuDNN 9.10.0 catatan rilis]
  - Untuk pengguna yang ingin menjalankan instance P6-B200 dengan FP8 data dan perhatian produk titik berskala, harap pertimbangkan untuk menginstal perhatian flash secara manual.

AWS Pembelajaran Mendalam AMI GPU PyTorch 2.6 (Amazon Linux 2023)

Untuk bantuan memulai, lihatMemulai dengan DLAMI.

Format nama AMI

- Pembelajaran Mendalam OSS NVIDIA Driver AMI GPU PyTorch 2.6.0 (Amazon Linux 2023) $ {YYYY-MM-DD}

EC2 Contoh yang didukung:

- Silakan lihat Perubahan penting pada DLAMI
- Pembelajaran Mendalam dengan OSS NVIDIA Driver mendukung G4dn, G5, G6, Gr6, G6e, P4d, P4de, P5, P5e, P5en

AMI meliputi yang berikut:

- AWS Layanan yang Didukung: EC2
- Sistem Operasi: Amazon Linux 2023
- Arsitektur Komputasi: x86
- NVIDIA CUDA12 .6 tumpukan:
  - Jalur instalasi CUDA, NCCL dan cudDN:/-12.6/usr/local/cuda

  - CUDA standar: 12.6
    - JALAN/usr/local/cuda points to /usr/local/cuda-12.6/
    - Diperbarui di bawah env vars:
      - LD_LIBRARY_PATH memiliki/usr/local/cuda/lib:/usr/local/cuda/lib64:/usr/local/cuda:/usr/local/cud/targets/x86_64-linux/lib
      - PATH untuk memiliki/usr/local/cuda/bin/:/usr/local/cuda/include/
  - Versi NCCL yang dikompilasi untuk 12.6:2.24.3
- Lokasi Tes NCCL:
  - all_reduce, all_gather dan reduce_scatter:/-cuda-xx.x/ usr/local/cuda-xx.x/efa/test
  - Untuk menjalankan pengujian NCCL, LD_LIBRARY_PATH sudah diperbarui dengan jalur yang diperlukan.
    - Umum sudah PATHs ditambahkan ke LD_LIBRARY_PATH:
      - /opt/amazon/efa/lib:/opt/amazon/openmpi/lib:/opt/aws-ofi-nccl/lib:/usr/local/lib:/usr/lib
    - LD_LIBRARY_PATH diperbarui dengan jalur versi CUDA
      - /usr/local/cuda/lib:/usr/local/cuda/lib64:/usr/local/cuda:/usr/local/cud/targets/x86_64-linux/lib
- Pemasang EFA: 1.38.0
- Nvidia GDRCopy: 2.4.1
- AWS OFI NCCL: 1.13.2-aws
  - AWS OFI NCCL sekarang mendukung beberapa versi NCCL dengan build tunggal
  - Jalur instalasi:/ditambahkan ke opt/amazon/ofi-nccl/ . Path /opt/amazon/ofi-nccl/lib LD_LIBRARY_PATH.
- Versi Python: 3.12
- Python:/opt/pytorch/bin/python
- Pengemudi NVIDIA: 570.86.15
- AWS CLI v2 di/usr/bin/aws
- Jenis volume EBS: gp3
- NVMe Lokasi Penyimpanan Instance (pada EC2 instance yang Didukung):/opt/dlami/nvme
- Kueri AMI-ID dengan Parameter SSM (contoh Wilayah adalah us-east-1):
  - Pengemudi OSS Nvidia:

```
aws ssm get-parameter --region us-east-1 \
```

```
    --name /aws/service/deeplearning/ami/x86_64/oss-nvidia-driver-gpu-pytorch-2.6-
amazon-linux-2023/latest/ami-id  \
    --query "Parameter.Value" \
    --output text
```

- Kueri AMI-ID dengan AWSCLI (contoh Wilayah adalah us-east-1):
  - Pengemudi OSS Nvidia:

```
aws ec2 describe-images --region us-east-1 \
    --owners amazon --filters 'Name=name,Values=Deep Learning OSS Nvidia Driver AMI
 GPU PyTorch 2.6.? (Amazon Linux 2023) ????????' 'Name=state,Values=available' \
    --query 'reverse(sort_by(Images, &CreationDate))[:1].ImageId' \
    --output text
```

Pemberitahuan

PyTorch Penghentian Saluran Anaconda

Dimulai dengan PyTorch 2.6, PyTorch telah menghentikan dukungan untuk Conda (lihat pengumuman resmi). Akibatnya, PyTorch 2.6 ke atas akan beralih menggunakan Lingkungan Virtual Python. Untuk mengaktifkan PyTorch venv, gunakan sumber/opt/pytorch/bin/activateP5/P5e Instances:

- DeviceIndex unik untuk masing-masing NetworkCard, dan harus berupa bilangan bulat non-negatif kurang dari batas per. ENIs NetworkCard Pada P5, jumlah ENIs per NetworkCard adalah 2, yang berarti bahwa satu-satunya nilai yang valid untuk DeviceIndex adalah 0 atau 1. Di bawah ini adalah contoh perintah peluncuran instance EC2 P5 menggunakan awscli yang menunjukkan NetworkCardIndex dari nomor 0-31 dan DeviceIndex sebagai 0 untuk antarmuka pertama dan DeviceIndex sebagai 1 untuk istirahat 31 antarmuka.

```
aws ec2 run-instances --region $REGION \
    --instance-type $INSTANCETYPE \
    --image-id $AMI --key-name $KEYNAME \
    --iam-instance-profile "Name=dlami-builder" \
    --tag-specifications "ResourceType=instance,Tags=[{Key=Name,Value=$TAG}]" \
    --network-interfaces "NetworkCardIndex=0,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa" \
      "NetworkCardIndex=1,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
```

```
    "NetworkCardIndex=2,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
\
    "NetworkCardIndex=3,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
\
    "NetworkCardIndex=4,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
\
    ...
    "NetworkCardIndex=31,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
```

Kernel

- Versi kernel disematkan menggunakan perintah:

```
sudo dnf versionlock kernel*
```

- Kami menyarankan pengguna untuk menghindari memperbarui versi kernel mereka (kecuali karena patch keamanan) untuk memastikan kompatibilitas dengan driver yang diinstal dan versi paket. Jika pengguna masih ingin memperbarui, mereka dapat menjalankan perintah berikut untuk melepas pin versi kernel mereka:

```
sudo dnf versionlock delete kernel*
sudo dnf update -y
```

- Untuk setiap versi baru DLAMI, kernel kompatibel terbaru yang tersedia digunakan.

Tanggal Rilis: 2025-02-21

Nama AMI: Driver OSS Nvidia Pembelajaran Mendalam AMI GPU PyTorch 2.6.0 (Amazon Linux 2023) 20250220

Ditambahkan

- Rilis awal Deep Learning OSS Nvidia Driver AMI GPU PyTorch 2.6 untuk Amazon Linux 2023
  - Pada PyTorch 2.6, Pytorch telah menghentikan dukungan untuk Conda. Akibatnya, Pytorch 2.6 dan di atasnya akan beralih menggunakan Lingkungan Virtual Python. Untuk mengaktifkan pytorch venv, gunakan sumber/opt/pytorch/bin/activate

AWS Pembelajaran Mendalam AMI GPU PyTorch 2.6 (Ubuntu 22.04)

Untuk bantuan memulai, lihatMemulai dengan DLAMI.

Format nama AMI

- Pembelajaran Mendalam OSS Nvidia Driver AMI GPU 2.6 PyTorch . $ {VERSI TAMBALAN} (Ubuntu 22.04) $ {YYYY-MM-DD}

EC2 Contoh yang didukung

- Silakan lihat Perubahan penting pada DLAMI.
- Pembelajaran Mendalam dengan OSS Nvidia Driver mendukung G4dn, G5, G6, Gr6, P4, P4de, P5, P5e, P5en.

AMI meliputi yang berikut:

- AWS Layanan yang Didukung: Amazon EC2
- Sistem Operasi: Ubuntu 22.04
- Arsitektur Komputasi: x86
- Python:/opt/pytorch/bin/python
- Pengemudi NVIDIA:
  - Pengemudi OSS Nvidia: 570.86.15
- Tumpukan NVIDIA CUDA12 .1:
  - Jalur instalasi CUDA, NCCL dan cudDN:/-12.6/usr/local/cuda
  - CUDA standar: 12.6
    - JALAN/usr/local/cuda points to /usr/local/cuda-12.6/
    - Diperbarui di bawah env vars:
      - LD_LIBRARY_PATH memiliki/usr/local/cuda/lib:/usr/local/cuda/lib64:/usr/local/cuda:/usr/local/cuda/targets/x86_64-linux/lib
      - PATH untuk memiliki/usr/local/cuda/bin/:/usr/local/cuda/include/
  - Sistem terkompilasi Versi NCCL hadir di/usr/local/cuda/: 2.24.3
  - PyTorch Versi NCCL yang dikompilasi dari lingkungan PyTorch conda: 2.21.5
- Lokasi Tes NCCL:
  - all_reduce, all_gather dan reduce_scatter:/-cuda-xx.x/ usr/local/cuda-xx.x/efa/test
  - Untuk menjalankan pengujian NCCL, LD_LIBRARY_PATH sudah diperbarui dengan jalur yang diperlukan.

  - Umum sudah PATHs ditambahkan ke LD_LIBRARY_PATH:
  - /opt/amazon/efa/lib:/opt/amazon/openmpi/lib:/opt/aws-ofi-nccl/lib:/usr/local/lib:/usr/lib
  - LD_LIBRARY_PATH diperbarui dengan jalur versi CUDA
  - /usr/local/cuda/lib:/usr/local/cuda/lib64:/usr/local/cuda:/usr/local/cud/targets/x86_64-linux/lib
- Pemasang EFA: 1.38.0
- Nvidia GDRCopy: 2.4.1
- Mesin Transformer Nvidia: v1.11.0
- AWS OFI NCCL: 1.13.2-aws
  - Jalur instalasi:/ditambahkan ke opt/aws-ofi-nccl/ . Path /opt/aws-ofi-nccl/lib LD_LIBRARY_PATH.
  - Catatan: PyTorch paket dilengkapi dengan plugin AWS OFI NCCL yang ditautkan secara dinamis sebagai paket paket conda juga dan PyTorch akan menggunakan aws-ofi-nccl-dlc paket itu alih-alih sistem OFI NCCL. AWS
- AWS CLI v2 sebagai aws2 dan AWS CLI v1 sebagai aws
- Jenis volume EBS: gp3
- Versi Python: 3.11
- Kueri AMI-ID dengan Parameter SSM (contoh Wilayah adalah us-east-1):
  - Pengemudi OSS Nvidia:

```
aws ssm get-parameter --region us-east-1 \
    --name /aws/service/deeplearning/ami/x86_64/oss-nvidia-driver-gpu-pytorch-2.6-
ubuntu-22.04/latest/ami-id  \
    --query "Parameter.Value" \
    --output text
```

- Kueri AMI-ID dengan AWSCLI (contoh Wilayah adalah us-east-1):
  - Pengemudi OSS Nvidia:

```
aws ec2 describe-images --region us-east-1 \
    --owners amazon --filters 'Name=name,Values=Deep Learning OSS Nvidia Driver AMI
 GPU PyTorch 2.6.? (Ubuntu 22.04) ????????' 'Name=state,Values=available' \
    --query 'reverse(sort_by(Images, &CreationDate))[:1].ImageId' \
    --output text
```

Pemberitahuan

PyTorch Penghentian Saluran Anaconda

Dimulai dengan PyTorch 2.6, Pytorch telah menghentikan dukungan untuk Conda (lihat pengumuman resmi). Akibatnya, Pytorch 2.6 dan di atasnya akan beralih menggunakan Lingkungan Virtual Python. Tuntuk mengaktifkan pytorch venv, silakan gunakan sumber/opt/pytorch/bin/activate

Instans P5/P5e:

- DeviceIndex unik untuk masing-masing NetworkCard, dan harus berupa bilangan bulat non-negatif kurang dari batas per. ENIs NetworkCard Pada P5, jumlah ENIs per NetworkCard adalah 2, yang berarti bahwa satu-satunya nilai yang valid untuk DeviceIndex adalah 0 atau 1. Di bawah ini adalah contoh perintah peluncuran instance EC2 P5 menggunakan awscli yang menunjukkan NetworkCardIndex dari nomor 0-31 dan DeviceIndex sebagai 0 untuk antarmuka pertama dan DeviceIndex sebagai 1 untuk istirahat 31 antarmuka.

```
aws ec2 run-instances --region $REGION \
    --instance-type $INSTANCETYPE \
    --image-id $AMI --key-name $KEYNAME \
    --iam-instance-profile "Name=dlami-builder" \
    --tag-specifications "ResourceType=instance,Tags=[{Key=Name,Value=$TAG}]" \
    --network-interfaces "NetworkCardIndex=0,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa" \
      "NetworkCardIndex=1,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      "NetworkCardIndex=2,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      "NetworkCardIndex=3,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      "NetworkCardIndex=4,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      ...
      "NetworkCardIndex=31,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
```

Kernel

- Versi kernel disematkan menggunakan perintah:

```
echo linux-aws hold | sudo dpkg –set-selections
echo linux-headers-aws hold | sudo dpkg –set-selections
```

```
echo linux-image-aws hold | sudo dpkg –set-selections
```

- Kami menyarankan pengguna untuk menghindari memperbarui versi kernel mereka (kecuali karena patch keamanan) untuk memastikan kompatibilitas dengan driver yang diinstal dan versi paket. Jika pengguna masih ingin memperbarui, mereka dapat menjalankan perintah berikut untuk melepas pin versi kernel mereka:

```
echo linux-aws install | sudo dpkg –set-selections
echo linux-headers-aws install | sudo dpkg –set-selections
echo linux-image-aws install | sudo dpkg –set-selections
apt-get upgrade -y
```

- Untuk setiap versi baru DLAMI, kernel kompatibel terbaru yang tersedia digunakan.

Tanggal Rilis: 2025-02-21

Nama AMI: Driver OSS Nvidia Pembelajaran Mendalam AMI GPU PyTorch 2.6.0 (Ubuntu 22.04) 20250220

Ditambahkan

- Rilis awal seri Deep Learning AMI GPU PyTorch 2.6 (Ubuntu 22.04). Termasuk pytorch lingkungan virtual Python (sumber/opt/pytorch/bin/activate), dilengkapi dengan NVIDIA Driver R570, CUDA = 12.6, cuDNN = 9.7, NCCL = 2.21.5, dan EFA = 1.38.0. PyTorch
  - Dimulai dengan PyTorch 2.6, Pytorch telah menghentikan dukungan untuk Conda (lihat pengumuman resmi). Akibatnya, Pytorch 2.6 dan di atasnya akan beralih menggunakan Lingkungan Virtual Python. Tuntuk mengaktifkan pytorch venv, silakan aktifkan menggunakan sumber/opt/pytorch/bin/activate

AWS Pembelajaran Mendalam AMI GPU PyTorch 2.5 (Amazon Linux 2023)

Untuk bantuan memulai, lihatMemulai dengan DLAMI.

Format nama AMI

- Pembelajaran Mendalam OSS Nvidia Driver AMI GPU PyTorch 2.5.1 (Amazon Linux 2023) ${YYYY-MM-DD}

EC2 Contoh yang didukung

- Silakan lihat Perubahan penting pada DLAMI.
- Pembelajaran Mendalam dengan OSS Nvidia Driver mendukung G4dn, G5, G6, Gr6, G6e, P4d, P4de, P5, P5e, P5en

AMI meliputi yang berikut:

- AWS Layanan yang Didukung: EC2
- Sistem Operasi: Amazon Linux 2023
- Arsitektur Komputasi: x86
- NVIDIA CUDA12 .4 tumpukan:
  - Jalur instalasi CUDA, NCCL dan cudDN:/-12.4/usr/local/cuda
  - CUDA standar: 12.4
    - JALAN/usr/local/cuda points to /usr/local/cuda-12.4/
    - Diperbarui di bawah env vars:
      - LD_LIBRARY_PATH memiliki/usr/local/cuda/lib:/usr/local/cuda/lib64:/usr/local/cuda:/usr/local/cud/targets/x86_64-linux/lib
      - PATH untuk memiliki/usr/local/cuda/bin/:/usr/local/cuda/include/
  - Versi NCCL yang dikompilasi untuk 12.4:2.21.5
- Lokasi Tes NCCL:
  - all_reduce, all_gather dan reduce_scatter:/-cuda-xx.x/ usr/local/cuda-xx.x/efa/test
  - Untuk menjalankan pengujian NCCL, LD_LIBRARY_PATH sudah diperbarui dengan jalur yang diperlukan.
    - Umum sudah PATHs ditambahkan ke LD_LIBRARY_PATH:
      - /opt/amazon/efa/lib:/opt/amazon/openmpi/lib:/opt/aws-ofi-nccl/lib:/usr/local/lib:/usr/lib
  - LD_LIBRARY_PATH diperbarui dengan jalur versi CUDA
    - /usr/local/cuda/lib:/usr/local/cuda/lib64:/usr/local/cuda:/usr/local/cud/targets/x86_64-linux/lib
- Pemasang EFA: 1.38.0
- Nvidia GDRCopy: 2.4.1
- AWS OFI NCCL: 1.13.2-aws
  - AWS OFI NCCL sekarang mendukung beberapa versi NCCL dengan build tunggal

  - Jalur instalasi:/ditambahkan ke opt/aws-ofi-nccl/ . Path /opt/aws-ofi-nccl/lib LD_LIBRARY_PATH.
  - Jalur pengujian untuk dering, message_transfer:/opt/aws-ofi-nccl/tests
- Versi Python: 3.11
- Python:/opt/conda/envs/pytorch/bin/python
- Pengemudi NVIDIA: 560.35.03
- AWS CLI v2 di/usr/bin/aws
- Jenis volume EBS: gp3
- NVMe Lokasi Penyimpanan Instance (pada EC2 Instans yang Didukung):/opt/dlami/nvme
- Kueri AMI-ID dengan Parameter SSM (contoh Wilayah adalah us-east-1):
  - Pengemudi OSS Nvidia:

```
aws ssm get-parameter --region us-east-1 \
        --name /aws/service/deeplearning/ami/x86_64/oss-nvidia-driver-gpu-
pytorch-2.5-amazon-linux-2023/latest/ami-id \
        --query "Parameter.Value" \
        --output text
```

- Kueri AMI-ID dengan AWSCLI (contoh Wilayah adalah us-east-1):
  - Pengemudi OSS Nvidia:

```
aws ec2 describe-images --region us-east-1 \
    --owners amazon --filters 'Name=name,Values=Deep Learning OSS Nvidia Driver AMI
 GPU PyTorch 2.5.? (Amazon Linux 2023) ????????' 'Name=state,Values=available' \
    --query 'reverse(sort_by(Images, &CreationDate))[:1].ImageId' \
    --output text
```

Pemberitahuan

Instans P5/P5e:

- DeviceIndex unik untuk masing-masing NetworkCard, dan harus berupa bilangan bulat non-negatif kurang dari batas per. ENIs NetworkCard Pada P5, jumlah ENIs per NetworkCard adalah 2, yang berarti bahwa satu-satunya nilai yang valid untuk DeviceIndex adalah 0 atau 1. Di bawah ini adalah contoh perintah peluncuran instance EC2 P5 menggunakan awscli yang menunjukkan NetworkCardIndex dari nomor 0-31 dan DeviceIndex sebagai 0 untuk antarmuka pertama dan DeviceIndex sebagai 1 untuk istirahat 31 antarmuka.

```
aws ec2 run-instances --region $REGION \
    --instance-type $INSTANCETYPE \
    --image-id $AMI --key-name $KEYNAME \
    --iam-instance-profile "Name=dlami-builder" \
    --tag-specifications "ResourceType=instance,Tags=[{Key=Name,Value=$TAG}]" \
    --network-interfaces "NetworkCardIndex=0,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa" \
      "NetworkCardIndex=1,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      "NetworkCardIndex=2,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      "NetworkCardIndex=3,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      "NetworkCardIndex=4,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      ...
      "NetworkCardIndex=31,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
```

Kernel

- Versi kernel disematkan menggunakan perintah:

  ```
  sudo dnf versionlock kernel*
  ```

- Kami menyarankan pengguna untuk menghindari memperbarui versi kernel mereka (kecuali karena patch keamanan) untuk memastikan kompatibilitas dengan driver yang diinstal dan versi paket. Jika pengguna masih ingin memperbarui, mereka dapat menjalankan perintah berikut untuk melepas pin versi kernel mereka:

  ```
  sudo dnf versionlock delete kernel*
  sudo dnf update -y
  ```

- Untuk setiap versi baru DLAMI, kernel kompatibel terbaru yang tersedia digunakan.

Tanggal Rilis: 2025-02-17

Nama AMI: Driver OSS Nvidia Pembelajaran Mendalam AMI GPU PyTorch 2.5.1 (Amazon Linux 2023) 20250216

Diperbarui

- Diperbarui NVIDIA Container Toolkit dari versi 1.17.3 ke versi 1.17.4
  - Silakan lihat halaman catatan rilis di sini untuk informasi lebih lanjut: https://github.com/NVIDIA/nvidia-container-toolkit/releases/tag/v1.17.4
  - Di Container Toolkit versi 1.17.4, pemasangan pustaka compat CUDA sekarang dinonaktifkan. Untuk memastikan kompatibilitas dengan beberapa versi CUDA pada alur kerja kontainer, pastikan Anda memperbarui LD_LIBRARY_PATH Anda untuk menyertakan pustaka kompatibilitas CUDA Anda seperti yang ditunjukkan dalam tutorial Jika Anda menggunakan lapisan kompatibilitas CUDA.

Dihapus

- Pustaka ruang pengguna yang dihapus cuobj dan nvdisasm disediakan oleh toolkit NVIDIA CUDA untuk mengatasi yang CVEs ada di Buletin Keamanan NVIDIA CUDA Toolkit untuk 18 Februari 2025

Tanggal Rilis: 2025-01-08

Nama AMI: Driver OSS Nvidia Pembelajaran Mendalam AMI GPU PyTorch 2.5.1 (Amazon Linux 2023) 20250107

Ditambahkan

- Menambahkan Support untuk instance G4dn.

Tanggal Rilis: 2024-11-21

Nama AMI: Driver OSS Nvidia Pembelajaran Mendalam AMI GPU PyTorch 2.5.1 (Amazon Linux 2023) 20241120

Ditambahkan

- Rilis awal Deep Learning OSS Nvidia Driver AMI GPU PyTorch 2.5 untuk Amazon Linux 2023

Masalah yang Diketahui

- DLAMI ini tidak mendukung instans G4dn dan G5 saat ini. EC2 AWS menyadari ketidakcocokan yang dapat mengakibatkan kegagalan inisialisasi CUDA, yang memengaruhi keluarga instans G4dn dan G5 saat menggunakan driver NVIDIA open source bersama dengan kernel Linux versi 6.1 atau yang lebih baru. Masalah ini memengaruhi distribusi Linux seperti Amazon Linux 2023, Ubuntu 22.04 atau yang lebih baru, atau SUSE Linux Enterprise Server 15 SP6 atau yang lebih baru, antara lain.

AWS Pembelajaran Mendalam AMI GPU PyTorch 2.5 (Ubuntu 22.04)

Untuk bantuan memulai, lihatMemulai dengan DLAMI.

Format nama AMI

- Pembelajaran Mendalam OSS Nvidia Driver AMI GPU 2.5 PyTorch . $ {PATCH_VERSION} (Ubuntu 22.04) $ {YYYY-MM-DD}

EC2 Contoh yang didukung

- Silakan lihat Perubahan penting pada DLAMI.
- Pembelajaran Mendalam dengan OSS Nvidia Driver mendukung G4dn, G5, G6, Gr6, P4, P4de, P5, P5e, P5en.

AMI meliputi yang berikut:

- AWS Layanan yang Didukung: Amazon EC2
- Sistem Operasi: Ubuntu 22.04
- Arsitektur Komputasi: x86
- Python:/opt/conda/envs/pytorch/bin/python
- Pengemudi NVIDIA:
  - Pengemudi OSS Nvidia: 550.144.03
- NVIDIA CUDA12 .4 tumpukan:
  - Jalur instalasi CUDA, NCCL dan cudDN:/-12.4/usr/local/cuda
  - CUDA standar: 12.4
    - JALAN/usr/local/cuda points to /usr/local/cuda-12.4/

    - Diperbarui di bawah env vars:
      - LD_LIBRARY_PATH memiliki/usr/local/cuda/lib:/usr/local/cuda/lib64:/usr/local/cuda:/usr/local/cuda/targets/x86_64-linux/lib
      - PATH untuk memiliki/usr/local/cuda/bin/:/usr/local/cuda/include/
  - Sistem yang dikompilasi Versi NCCL hadir di/usr/local/cuda/: 2.21.5
  - PyTorch Versi NCCL yang dikompilasi dari lingkungan PyTorch conda: 2.21.5
- Lokasi Tes NCCL:
  - all_reduce, all_gather dan reduce_scatter:/-cuda-xx.x/ usr/local/cuda-xx.x/efa/test
  - Untuk menjalankan pengujian NCCL, LD_LIBRARY_PATH sudah diperbarui dengan jalur yang diperlukan.
    - Umum sudah PATHs ditambahkan ke LD_LIBRARY_PATH:
      - /opt/amazon/efa/lib:/opt/amazon/openmpi/lib:/opt/aws-ofi-nccl/lib:/usr/local/lib:/usr/lib
  - LD_LIBRARY_PATH diperbarui dengan jalur versi CUDA
    - /usr/local/cuda/lib:/usr/local/cuda/lib64:/usr/local/cuda:/usr/local/cud/targets/x86_64-linux/lib
- Pemasang EFA: 1.34.0
- Nvidia GDRCopy: 2.4.1
- Mesin Transformer Nvidia: v1.11.0
- AWS OFI NCCL: 1.11.0-aws
  - Jalur instalasi:/ditambahkan ke opt/aws-ofi-nccl/ . Path /opt/aws-ofi-nccl/lib LD_LIBRARY_PATH.
  - Jalur pengujian untuk dering, message_transfer:/opt/aws-ofi-nccl/tests
  - Catatan: PyTorch paket dilengkapi dengan plugin AWS OFI NCCL yang ditautkan secara dinamis sebagai paket paket conda juga dan PyTorch akan menggunakan aws-ofi-nccl-dlc paket itu alih-alih sistem OFI NCCL. AWS
- AWS CLI v2 sebagai aws2 dan AWS CLI v1 sebagai aws
- Jenis volume EBS: gp3
- Versi Python: 3.11
- Kueri AMI-ID dengan Parameter SSM (contoh Wilayah adalah us-east-1):
  - Pengemudi OSS Nvidia:

```
aws ssm get-parameter --region us-east-1 \
        --name /aws/service/deeplearning/ami/x86_64/oss-nvidia-driver-gpu-
pytorch-2.5-ubuntu-22.04/latest/ami-id  \
```

```
        --query "Parameter.Value" \
        --output text
```

- Kueri AMI-ID dengan AWSCLI (contoh Wilayah adalah us-east-1):
  - Pengemudi OSS Nvidia:

```
aws ec2 describe-images --region us-east-1 \
    --owners amazon --filters 'Name=name,Values=Deep Learning OSS Nvidia Driver AMI
 GPU PyTorch 2.5.? (Ubuntu 22.04) ????????' 'Name=state,Values=available' \
    --query 'reverse(sort_by(Images, &CreationDate))[:1].ImageId' \
    --output text
```

Pemberitahuan

Instans P5/P5e:

- DeviceIndex unik untuk masing-masing NetworkCard, dan harus berupa bilangan bulat non-negatif kurang dari batas per. ENIs NetworkCard Pada P5, jumlah ENIs per NetworkCard adalah 2, yang berarti bahwa satu-satunya nilai yang valid untuk DeviceIndex adalah 0 atau 1. Di bawah ini adalah contoh perintah peluncuran instance EC2 P5 menggunakan awscli yang menunjukkan NetworkCardIndex dari nomor 0-31 dan DeviceIndex sebagai 0 untuk antarmuka pertama dan DeviceIndex sebagai 1 untuk istirahat 31 antarmuka.

```
aws ec2 run-instances --region $REGION \
    --instance-type $INSTANCETYPE \
    --image-id $AMI --key-name $KEYNAME \
    --iam-instance-profile "Name=dlami-builder" \
    --tag-specifications "ResourceType=instance,Tags=[{Key=Name,Value=$TAG}]" \
    --network-interfaces "NetworkCardIndex=0,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa" \
     "NetworkCardIndex=1,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
     "NetworkCardIndex=2,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
     "NetworkCardIndex=3,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
     "NetworkCardIndex=4,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa" \
      ...
     "NetworkCardIndex=31,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
```

Kernel

- Versi kernel disematkan menggunakan perintah:

```
echo linux-aws hold | sudo dpkg –set-selections
echo linux-headers-aws hold | sudo dpkg –set-selections
echo linux-image-aws hold | sudo dpkg –set-selections
```

- Kami menyarankan pengguna untuk menghindari memperbarui versi kernel mereka (kecuali karena patch keamanan) untuk memastikan kompatibilitas dengan driver yang diinstal dan versi paket. Jika pengguna masih ingin memperbarui, mereka dapat menjalankan perintah berikut untuk melepas pin versi kernel mereka:

```
echo linux-aws install | sudo dpkg –set-selections
echo linux-headers-aws install | sudo dpkg –set-selections
echo linux-image-aws install | sudo dpkg –set-selections
apt-get upgrade -y
```

- Untuk setiap versi baru DLAMI, kernel kompatibel terbaru yang tersedia digunakan.

Tanggal Rilis: 2025-02-17

Nama AMI: Driver OSS Nvidia Pembelajaran Mendalam AMI GPU PyTorch 2.5.1 (Ubuntu 22.04) 20250216

Diperbarui

- Diperbarui NVIDIA Container Toolkit dari versi 1.17.3 ke versi 1.17.4
  - Silakan lihat halaman catatan rilis di sini untuk informasi lebih lanjut: https://github.com/NVIDIA/nvidia-container-toolkit/releases/tag/v1.17.4
  - Di Container Toolkit versi 1.17.4, pemasangan pustaka compat CUDA sekarang dinonaktifkan. Untuk memastikan kompatibilitas dengan beberapa versi CUDA pada alur kerja kontainer, pastikan Anda memperbarui LD_LIBRARY_PATH Anda untuk menyertakan pustaka kompatibilitas CUDA Anda seperti yang ditunjukkan dalam tutorial Jika Anda menggunakan lapisan kompatibilitas CUDA.

Dihapus

- Pustaka ruang pengguna yang dihapus cuobj dan nvdisasm disediakan oleh toolkit NVIDIA CUDA untuk mengatasi yang CVEs ada di Buletin Keamanan NVIDIA CUDA Toolkit untuk 18 Februari 2025

Tanggal Rilis: 2025-01-21

Nama AMI: Driver OSS Nvidia Pembelajaran Mendalam AMI GPU PyTorch 2.5.1 (Ubuntu 22.04) 20250119

Diperbarui

- Driver Nvidia yang ditingkatkan dari versi 550.127.05 ke 550.144.03 untuk alamat yang CVEs ada di Buletin Keamanan Driver Tampilan GPU NVIDIA untuk Januari 2025.

Tanggal Rilis: 2024-11-21

Nama AMI: Pembelajaran Mendalam OSS Nvidia Driver AMI GPU PyTorch 2.5.1 (Ubuntu 22.04) 20241121

Ditambahkan

- Rilis awal seri Deep Learning AMI GPU PyTorch 2.4.1 (Ubuntu 22.04). Termasuk pytorch lingkungan conda yang dilengkapi dengan NVIDIA Driver R550, CUDA = 12.4.1, cuDNN=8.9.7, NCCL=2.21.5, dan EFA = 1.37.0. PyTorch

Tetap

- Karena perubahan kernel Ubuntu untuk mengatasi cacat pada fungsionalitas Kernel Address Space Layout Randomization (KASLR), instance G4Dn/G5 tidak dapat menginisialisasi CUDA dengan benar pada driver OSS Nvidia. Untuk mengurangi masalah ini, DLAMI ini menyertakan fungsionalitas yang secara dinamis memuat driver berpemilik untuk instans G4Dn dan G5. Harap izinkan periode inisialisasi singkat untuk pemuatan ini untuk memastikan bahwa instans Anda dapat berfungsi dengan baik.
  - Untuk memeriksa status dan kesehatan layanan ini, Anda dapat menggunakan perintah berikut:

```
sudo systemctl is-active dynamic_driver_load.service
```

```
active
```

AWS Pembelajaran Mendalam AMI GPU PyTorch 2.4 (Ubuntu 22.04)

Untuk bantuan memulai, lihatMemulai dengan DLAMI.

Format nama AMI

- Pembelajaran Mendalam OSS Nvidia Driver AMI GPU 2.4 PyTorch . $ {PATCH_VERSION} (Ubuntu 22.04) $ {YYYY-MM-DD}

EC2 Contoh yang didukung

- Silakan lihat Perubahan penting pada DLAMI.
- Pembelajaran Mendalam dengan OSS Nvidia Driver mendukung G4dn, G5, G6, Gr6, P4, P4de, P5, P5e, P5en.

AMI meliputi yang berikut:

- AWS Layanan yang Didukung: EC2
- Sistem Operasi: Ubuntu 22.04
- Arsitektur Komputasi: x86
- Python:/opt/conda/envs/pytorch/bin/python
- Pengemudi NVIDIA:
  - Pengemudi OSS Nvidia: 550.144.03
- Tumpukan NVIDIA CUDA12 .1:
  - Jalur instalasi CUDA, NCCL dan cudDN:/-12.4/usr/local/cuda
  - CUDA standar: 12.4
    - JALAN/usr/local/cuda points to /usr/local/cuda-12.4/
    - Diperbarui di bawah env vars:
      - LD_LIBRARY_PATH memiliki/usr/local/cuda/lib:/usr/local/cuda/lib64:/usr/local/cuda:/usr/local/cuda/targets/x86_64-linux/lib
      - PATH untuk memiliki/usr/local/cuda/bin/:/usr/local/cuda/include/
  - Sistem terkompilasi Versi NCCL hadir di/usr/local/cuda/: 2.21.5
  - PyTorch Versi NCCL yang dikompilasi dari lingkungan PyTorch conda: 2.20.5

- Lokasi Tes NCCL:
  - all_reduce, all_gather dan reduce_scatter:/-cuda-xx.x/ usr/local/cuda-xx.x/efa/test
  - Untuk menjalankan pengujian NCCL, LD_LIBRARY_PATH sudah diperbarui dengan jalur yang diperlukan.
    - Umum sudah PATHs ditambahkan ke LD_LIBRARY_PATH:
      - /opt/amazon/efa/lib:/opt/amazon/openmpi/lib:/opt/aws-ofi-nccl/lib:/usr/local/lib:/usr/lib
  - LD_LIBRARY_PATH diperbarui dengan jalur versi CUDA
    - /usr/local/cuda/lib:/usr/local/cuda/lib64:/usr/local/cuda:/usr/local/cud/targets/x86_64-linux/lib
- Pemasang EFA: 1.34.0
- Nvidia GDRCopy: 2.4.1
- Mesin Transformer Nvidia: v1.11.0
- AWS OFI NCCL: 1.11.0-aws
  - Jalur instalasi:/ditambahkan ke opt/aws-ofi-nccl/ . Path /opt/aws-ofi-nccl/lib LD_LIBRARY_PATH.
  - Jalur pengujian untuk dering, message_transfer:/opt/aws-ofi-nccl/tests
  - Catatan: PyTorch paket dilengkapi dengan plugin AWS OFI NCCL yang ditautkan secara dinamis sebagai paket paket conda juga dan PyTorch akan menggunakan aws-ofi-nccl-dlc paket itu alih-alih sistem OFI NCCL. AWS
- AWS CLI v2 sebagai aws2 dan AWS CLI v1 sebagai aws
- Jenis volume EBS: gp3
- Versi Python: 3.11
- Kueri AMI-ID dengan Parameter SSM (contoh Wilayah adalah us-east-1):
  - Pengemudi OSS Nvidia:

```
aws ssm get-parameter --region us-east-1 \
        --name /aws/service/deeplearning/ami/x86_64/oss-nvidia-driver-gpu-
pytorch-2.4-ubuntu-22.04/latest/ami-id \
        --query "Parameter.Value" \
        --output text
```

- Kueri AMI-ID dengan AWSCLI (contoh Wilayah adalah us-east-1):
  - Pengemudi OSS Nvidia:

```
aws ec2 describe-images --region us-east-1 \
    --owners amazon \
```

```
    --filters 'Name=name,Values=Deep Learning OSS Nvidia Driver AMI GPU PyTorch
 2.4.? (Ubuntu 22.04) ????????' 'Name=state,Values=available' \
    --query 'reverse(sort_by(Images, &CreationDate))[:1].ImageId' \
    --output text
```

Pemberitahuan

Contoh P5/P5e

- DeviceIndex unik untuk masing-masing NetworkCard, dan harus berupa bilangan bulat non-negatif kurang dari batas per. ENIs NetworkCard Pada P5, jumlah ENIs per NetworkCard adalah 2, yang berarti bahwa satu-satunya nilai yang valid untuk DeviceIndex adalah 0 atau 1. Di bawah ini adalah contoh perintah peluncuran instance EC2 P5 menggunakan awscli yang menunjukkan NetworkCardIndex dari nomor 0-31 dan DeviceIndex sebagai 0 untuk antarmuka pertama dan DeviceIndex sebagai 1 untuk istirahat 31 antarmuka.

```
aws ec2 run-instances --region $REGION \
    --instance-type $INSTANCETYPE \
    --image-id $AMI --key-name $KEYNAME \
    --iam-instance-profile "Name=dlami-builder" \
    --tag-specifications "ResourceType=instance,Tags=[{Key=Name,Value=$TAG}]" \
    --network-interfaces "NetworkCardIndex=0,DeviceIndex=0,Groups=$SG,SubnetId=
$SUBNET,InterfaceType=efa" \
      "NetworkCardIndex=1,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      "NetworkCardIndex=2,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      "NetworkCardIndex=3,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      "NetworkCardIndex=4,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
 \
      ...
      "NetworkCardIndex=31,DeviceIndex=1,Groups=$SG,SubnetId=$SUBNET,InterfaceType=efa"
```

Tanggal Rilis: 2025-02-17

Nama AMI: Driver OSS Nvidia Pembelajaran Mendalam AMI GPU PyTorch 2.4.1 (Ubuntu 22.04) 20250216

Diperbarui

- Diperbarui NVIDIA Container Toolkit dari versi 1.17.3 ke versi 1.17.4
  - Silakan lihat halaman catatan rilis di sini untuk informasi lebih lanjut: https://github.com/NVIDIA/nvidia-container-toolkit/releases/tag/v1.17.4
  - Di Container Toolkit versi 1.17.4, pemasangan pustaka compat CUDA sekarang dinonaktifkan. Untuk memastikan kompatibilitas dengan beberapa versi CUDA pada alur kerja kontainer, pastikan Anda memperbarui LD_LIBRARY_PATH Anda untuk menyertakan pustaka kompatibilitas CUDA Anda seperti yang ditunjukkan dalam tutorial Jika Anda menggunakan lapisan kompatibilitas CUDA.

Tanggal Rilis: 2025-01-21

Nama AMI: Pembelajaran Mendalam OSS Nvidia Driver AMI GPU PyTorch 2.4.1 (Ubuntu 22.04) 20250119

Diperbarui

- Driver Nvidia yang ditingkatkan dari versi 550.127.05 ke 550.144.03 untuk mengatasi kehadiran CVE di Buletin Keamanan Driver Tampilan GPU NVIDIA untuk Januari 2025.

Tanggal Rilis: 2024-11-18

Nama AMI: Driver OSS Nvidia Pembelajaran Mendalam AMI GPU PyTorch 2.4.1 (Ubuntu 22.04) 20241116

Tetap

- Karena perubahan kernel Ubuntu untuk mengatasi cacat pada fungsionalitas Kernel Address Space Layout Randomization (KASLR), instance G4Dn/G5 tidak dapat menginisialisasi CUDA dengan benar pada driver OSS Nvidia. Untuk mengurangi masalah ini, DLAMI ini menyertakan fungsionalitas yang secara dinamis memuat driver berpemilik untuk instans G4Dn dan G5. Harap izinkan periode inisialisasi singkat untuk pemuatan ini untuk memastikan bahwa instans Anda dapat berfungsi dengan baik.
  - Untuk memeriksa status dan kesehatan layanan ini, Anda dapat menggunakan perintah berikut:

```
sudo systemctl is-active dynamic_driver_load.service
```

```
active
```

Tanggal Rilis: 2024-10-16

Nama AMI: Driver OSS Nvidia Pembelajaran Mendalam AMI GPU PyTorch 2.4.1 (Ubuntu 22.04) 20241016

Ditambahkan

- Menambahkan Nvidia TransformerEngine v1.11.0 untuk mempercepat model Transformer (Untuk lebih jelasnya, silakan merujuk ke https://docs.nvidia.com/deeplearning/transformator - .html) engine/user-guide/index

Tanggal Rilis: 2024-09-30

Nama AMI: Pembelajaran Mendalam OSS Nvidia Driver AMI GPU PyTorch 2.4.1 (Ubuntu 22.04) 20240929

Diperbarui

- Nvidia Container Toolkit yang ditingkatkan dari versi 1.16.1 ke 1.16.2, mengatasi kerentanan keamanan CVE-2024-0133.

Tanggal Rilis: 2024-09-26

Nama AMI: Pembelajaran Mendalam OSS Nvidia Driver AMI GPU PyTorch 2.4.1 (Ubuntu 22.04) 20240925

Ditambahkan

- Rilis awal seri Deep Learning AMI GPU PyTorch 2.4.1 (Ubuntu 22.04). Termasuk pytorch lingkungan conda yang dilengkapi dengan NVIDIA Driver R550, CUDA = 12.4.1, cuDNN=8.9.7, NCCL=2.20.5, dan EFA = 1.34.0. PyTorch

ARM64 PyTorch Catatan Rilis DLAMI

Di bawah ini adalah catatan Rilis untuk ARM64 PyTorch DLAMIs:

GPU

- AWS Pembelajaran Mendalam ARM64 AMI GPU PyTorch 2.7 (Amazon Linux 2023)
- AWS Pembelajaran Mendalam ARM64 AMI GPU PyTorch 2.7 (Ubuntu 22.04)
- AWS Pembelajaran Mendalam ARM64 AMI GPU PyTorch 2.6 (Amazon Linux 2023)
- AWS Pembelajaran Mendalam ARM64 AMI GPU PyTorch 2.6 (Ubuntu 22.04)
- AWS Pembelajaran Mendalam ARM64 AMI GPU PyTorch 2.5 (Ubuntu 22.04)
- AWS Pembelajaran Mendalam ARM64 AMI GPU PyTorch 2.4 (Ubuntu 22.04)

AWS Neuron

- Lihat Panduan Pengguna DLAMI Neuron

AWS Pembelajaran Mendalam ARM64 AMI OSS GPU PyTorch 2.7 (Amazon Linux 2023)

Untuk bantuan memulai, lihatMemulai dengan DLAMI.

Format nama AMI

- Pembelajaran Mendalam ARM64 AMI OSS Nvidia Driver GPU PyTorch 2.7 (Amazon Linux 2023) $ {YYYY-MM-DD}

EC2 Contoh yang didukung

- G5g

AMI meliputi yang berikut:

- AWS Layanan yang Didukung: Amazon EC2
- Sistem Operasi: Amazon Linux 2023
- Arsitektur Komputasi: ARM64
- Kernel Linux: 6.12
- Pengemudi NVIDIA: 570.133.20
- Tumpukan NVIDIA CUDA 12.8:
  - Direktori instalasi CUDA, NCCL dan cudDN:/-12.8/usr/local/cuda
  - CUDA standar: 12.8
    - PATH/usr/local/cudamenunjuk ke CUDA 12.8

    - Diperbarui di bawah env vars:
        - LD_LIBRARY_PATH memiliki/- usr/local/cuda/lib:/usr/local/cuda/lib64:/usr/local/cuda:/usr/local/cuda/targets/sbsa
        - PATH untuk memiliki/usr/local/cuda/bin/:/usr/local/cuda/include/
- AWS CLI v2 di/usr/local/bin/aws
- Jenis volume EBS: gp3
- Toolkit wadah Nvidia: 1.17.7
    - Perintah versi: nvidia-container-cli -V
- Docker: 25.0.8
- Python:/3.12 usr/bin/python
- Kueri AMI-ID dengan Parameter SSM (contoh wilayah adalah us-east-1):

```
aws ssm get-parameter --region us-east-1 \
    --name /aws/service/deeplearning/ami/arm64/oss-nvidia-driver-gpu-pytorch-2.7-amazon-linux-2023/latest/ami-id \
    --query "Parameter.Value" \
    --output text
```

- Kueri AMI-ID dengan AWSCLI (contoh wilayah adalah us-east-1):

```
aws ec2 describe-images --region us-east-1 --owners amazon --filters
 'Name=name,Values=Deep Learning ARM64 AMI OSS Nvidia Driver GPU PyTorch 2.7 (Amazon
 Linux 2023) ????????' 'Name=state,Values=available' --query 'reverse(sort_by(Images,
 &CreationDate))[:1].ImageId' --output text
```

Pemberitahuan

PyTorch Penutupan Saluran Anaconda

Dimulai dengan PyTorch 2.6, PyTorch telah menghentikan dukungan untuk Conda (lihat pengumuman resmi). Akibatnya, PyTorch 2.6 ke atas akan beralih menggunakan Lingkungan Virtual Python. Untuk mengaktifkan PyTorch venv, gunakan sumber/opt/pytorch/bin/activate

Tanggal Rilis: 2025-05-22

Nama AMI: Pembelajaran Mendalam ARM64 AMI OSS Nvidia Driver GPU PyTorch 2.7 (Amazon Linux 2023) 20250521

Ditambahkan

- Rilis awal seri Deep Learning ARM64 AMI OSS Nvidia Driver GPU PyTorch 2.7 (Amazon Linux 2023). Termasuk pytorch lingkungan virtual Python (sumber/opt/pytorch/bin/activate) yang dilengkapi dengan NVIDIA Driver R570, CUDA = 12.8, cuDNN = 9.10, dan NCCL = 2.26.2 PyTorch

AWS Pembelajaran Mendalam ARM64 AMI OSS GPU PyTorch 2.7 (Ubuntu 22.04)

Untuk bantuan memulai, lihatMemulai dengan DLAMI.

Format nama AMI

- Pembelajaran Mendalam ARM64 AMI OSS Nvidia Driver GPU PyTorch 2.7 (Ubuntu 22.04) $ {YYYY-MM-DD}

EC2 Contoh yang didukung

- G5g

AMI meliputi yang berikut:

- AWS Layanan yang Didukung: Amazon EC2
- Sistem Operasi: Ubuntu 22.04
- Arsitektur Komputasi: ARM64
- Kernel Linux: 6.8
- Pengemudi NVIDIA: 570.133.20
- Tumpukan NVIDIA CUDA 12.8:
  - Direktori instalasi CUDA, NCCL dan cudDN:/-12.8/usr/local/cuda
  - CUDA standar: 12.8
    - PATH/usr/local/cudamenunjuk ke CUDA 12.8
    - Diperbarui di bawah env vars:
      - LD_LIBRARY_PATH memiliki/- usr/local/cuda/lib:/usr/local/cuda/lib64:/usr/local/cuda:/usr/local/cuda/targets/sbsa
      - PATH untuk memiliki/usr/local/cuda/bin/:/usr/local/cuda/include/
- AWS CLI v2 di/usr/local/bin/aws

- Jenis volume EBS: gp3
- Toolkit wadah Nvidia: 1.17.7
  - Perintah versi: nvidia-container-cli -V
- Docker: 28.2.2
- Python:/3.12 usr/bin/python
- Kueri AMI-ID dengan Parameter SSM (contoh wilayah adalah us-east-1):

```
aws ssm get-parameter --region us-east-1 \
    --name /aws/service/deeplearning/ami/arm64/oss-nvidia-driver-gpu-pytorch-2.7-
ubuntu-22.04/latest/ami-id \
    --query "Parameter.Value" \
    --output text
```

- Kueri AMI-ID dengan AWSCLI (contoh wilayah adalah us-east-1):

```
aws ec2 describe-images --region us-east-1 --owners amazon --filters
 'Name=name,Values=Deep Learning ARM64 AMI OSS Nvidia Driver GPU PyTorch 2.7 (Ubuntu
 22.04) ????????' 'Name=state,Values=available' --query 'reverse(sort_by(Images,
 &CreationDate))[:1].ImageId' --output text
```

Pemberitahuan

PyTorch Penutupan Saluran Anaconda

Dimulai dengan PyTorch 2.6, PyTorch telah menghentikan dukungan untuk Conda (lihat pengumuman resmi). Akibatnya, PyTorch 2.6 ke atas akan beralih menggunakan Lingkungan Virtual Python. Untuk mengaktifkan PyTorch venv, gunakan sumber/opt/pytorch/bin/activate

Tanggal Rilis: 2025-05-22

Nama AMI: Pembelajaran Mendalam ARM64 AMI OSS Nvidia Driver GPU PyTorch 2.7 (Ubuntu 22.04) 20250521

Ditambahkan

- Rilis awal seri Deep Learning ARM64 AMI OSS Nvidia Driver GPU PyTorch 2.7 (Ubuntu 22.04). Termasuk pytorch lingkungan virtual Python (sumber/opt/pytorch/bin/activate) yang dilengkapi dengan NVIDIA Driver R570, CUDA = 12.8, cuDNN = 9.10, dan NCCL = 2.26.2 PyTorch

AWS Pembelajaran Mendalam ARM64 AMI GPU PyTorch 2.6 (Amazon Linux 2023)

Untuk bantuan memulai, lihatMemulai dengan DLAMI.

Format nama AMI

- Pembelajaran Mendalam ARM64 AMI OSS Nvidia Driver GPU 2.6 PyTorch . $ {VERSI TAMBALAN} (Amazon Linux 2023) $ {YYYY-MM-DD}

EC2 Contoh yang didukung

- G5g

AMI meliputi yang berikut:

- AWS Layanan yang Didukung: EC2
- Sistem Operasi: Amazon Linux 2023
- Arsitektur Komputasi: ARM64
- Python:/opt/pytorch/bin/python
- Versi Python: 3.12
- Pengemudi NVIDIA:
  - Pengemudi OSS Nvidia: 570.86.15
- NVIDIA CUDA12 .6 tumpukan:
  - Jalur instalasi CUDA, NCCL dan cudDN:/-12.6/usr/local/cuda
  - CUDA standar: 12.6
    - JALAN/usr/local/cuda points to /usr/local/cuda-12.6/
    - Diperbarui di bawah env vars:
      - LD_LIBRARY_PATH memiliki/64 usr/local/cuda/lib:/usr/local/cuda/lib64:/usr/local/cuda:/usr/local/cuda/targets/sbsa-linux/lib:/usr/local/cuda/nvvm/lib64:/usr/local/cuda/extras/CUPTI/lib
      - PATH untuk memiliki/usr/local/cuda/bin/:/usr/local/cuda/include/
  - Sistem terkompilasi Versi NCCL hadir di/usr/local/cuda/: 2.24.3
  - PyTorch Versi NCCL yang dikompilasi dari lingkungan PyTorch conda: 2.21.5
- AWS CLI v2 sebagai aws2 dan AWS CLI v1 sebagai aws
- Jenis volume EBS: gp3

- Kueri AMI-ID dengan Parameter SSM (contoh Wilayah adalah us-east-1):

```
aws ssm get-parameter --region us-east-1 \
    --name /aws/service/deeplearning/ami/arm64/oss-nvidia-driver-gpu-pytorch-2.6-
amazon-linux-2023/latest/ami-id  \
    --query "Parameter.Value" \
    --output text
```

- Kueri AMI-ID dengan AWSCLI (contoh Wilayah adalah us-east-1):

```
aws ec2 describe-images --region us-east-1 \
    --owners amazon \
    --filters 'Name=name,Values=Deep Learning ARM64 AMI OSS Nvidia Driver GPU PyTorch
 2.6.? (Amazon Linux 2023) ????????' 'Name=state,Values=available' \
    --query 'reverse(sort_by(Images, &CreationDate))[:1].ImageId' \
    --output text
```

Pemberitahuan

PyTorch Penutupan Saluran Anaconda

Dimulai dengan PyTorch 2.6, PyTorch telah menghentikan dukungan untuk Conda (lihat pengumuman resmi). Akibatnya, PyTorch 2.6 ke atas akan beralih menggunakan Lingkungan Virtual Python. Untuk mengaktifkan PyTorch venv, gunakan sumber/opt/pytorch/bin/activate

Tanggal Rilis: 2025-02-21

Nama AMI: Pembelajaran Mendalam ARM64 AMI OSS Nvidia Driver GPU PyTorch 2.6.0 (Amazon Linux 2023) 20250221

Ditambahkan

- Rilis awal seri Deep Learning ARM64 AMI OSS Nvidia Driver GPU PyTorch 2.6.0 (Amazon Linux 2023). Termasuk pytorch lingkungan virtual Python (sumber/opt/pytorch/bin/activate/), dilengkapi dengan NVIDIA Driver R570, CUDA = 12.6, cuDNN=9.7, NCCL=2.21.5. PyTorch

AWS Pembelajaran Mendalam ARM64 AMI GPU PyTorch 2.6 (Ubuntu 22.04)

Untuk bantuan memulai, lihatMemulai dengan DLAMI.

Format nama AMI

- Pembelajaran Mendalam ARM64 AMI OSS NVIDIA Driver GPU 2.6 PyTorch . $ {VERSI TAMBALAN} (Ubuntu 22.04) $ {YYYY-MM-DD}

EC2 Contoh yang didukung

- G5g

AMI meliputi yang berikut:

- AWS Layanan yang Didukung: Amazon EC2
- Sistem Operasi: Ubuntu 22.04
- Arsitektur Komputasi: ARM64
- Python:/opt/pytorch/bin/python
- Versi Python: 3.12
- Pengemudi NVIDIA:
  - Pengemudi OSS Nvidia: 570.86.15
- NVIDIA CUDA12 .6 tumpukan:
  - Jalur instalasi CUDA, NCCL dan cudDN:/-12.6/usr/local/cuda
  - CUDA standar: 12.6
    - JALAN/usr/local/cuda points to /usr/local/cuda-12.6/
    - Diperbarui di bawah env vars:
      - LD_LIBRARY_PATH memiliki/64 usr/local/cuda/lib:/usr/local/cuda/lib64:/usr/local/cuda:/usr/local/cuda/targets/sbsa-linux/lib:/usr/local/cuda/nvvm/lib64:/usr/local/cuda/extras/CUPTI/lib
      - PATH untuk memiliki/usr/local/cuda/bin/:/usr/local/cuda/include/
  - Sistem terkompilasi Versi NCCL hadir di/usr/local/cuda/: 2.24.3
  - PyTorch Versi NCCL yang dikompilasi dari lingkungan PyTorch venv: 2.21.5
- AWS CLI v2 sebagai aws2 dan AWS CLI v1 sebagai aws
- Jenis volume EBS: gp3
- Kueri AMI-ID dengan Parameter SSM (contoh wilayah adalah us-east-1):

```
aws ssm get-parameter --region us-east-1 \
```

```
    --name /aws/service/deeplearning/ami/arm64/oss-nvidia-driver-gpu-pytorch-2.6-
ubuntu-22.04/latest/ami-id  \
    --query "Parameter.Value" \
    --output text
```

- Kueri AMI-ID dengan AWSCLI (contoh wilayah adalah us-east-1):

```
aws ec2 describe-images --region us-east-1 \
    --owners amazon --filters 'Name=name,Values=Deep Learning ARM64 AMI OSS Nvidia
 Driver GPU PyTorch 2.6.? (Ubuntu 22.04) ????????' 'Name=state,Values=available' \
    --query 'reverse(sort_by(Images, &CreationDate))[:1].ImageId' \
    --output text
```

Pemberitahuan

PyTorch Penutupan Saluran Anaconda

Dimulai dengan PyTorch 2.6, PyTorch telah menghentikan dukungan untuk Conda (lihat pengumuman resmi). Akibatnya, PyTorch 2.6 ke atas akan beralih menggunakan Lingkungan Virtual Python. Untuk mengaktifkan PyTorch venv, gunakan sumber/opt/pytorch/bin/activate

Tanggal Rilis: 2025-02-21

Nama AMI: Pembelajaran Mendalam ARM64 AMI OSS NVIDIA Driver GPU PyTorch 2.6.0 (Ubuntu 22.04) 20250221

Ditambahkan

- Rilis awal seri Deep Learning ARM64 AMI OSS Nvidia Driver GPU PyTorch 2.6.0 (Ubuntu 22.04). Termasuk pytorch lingkungan virtual Python (sumber/opt/pytorch/bin/activate), dilengkapi dengan NVIDIA Driver R570, CUDA = 12.6, cuDNN = 9.7, NCCL = 2.21.5. PyTorch

AWS Pembelajaran Mendalam ARM64 AMI GPU PyTorch 2.5 (Ubuntu 22.04)

Untuk bantuan memulai, lihatMemulai dengan DLAMI.

Format nama AMI

- Pembelajaran Mendalam ARM64 AMI OSS Nvidia Driver GPU 2.5 PyTorch . $ {VERSI TAMBALAN} (Ubuntu 22.04) $ {YYYY-MM-DD}

EC2 Contoh yang didukung

- G5g

AMI meliputi yang berikut:

- AWS Layanan yang Didukung: Amazon EC2
- Sistem Operasi: Ubuntu 22.04
- Arsitektur Komputasi: ARM64
- Python:/opt/conda/envs/pytorch/bin/python
- Versi Python: 3.11
- Pengemudi NVIDIA:
  - Pengemudi OSS Nvidia: 550.144.03
- NVIDIA CUDA12 .4 tumpukan:
  - Jalur instalasi CUDA, NCCL dan cudDN:/-12.4/usr/local/cuda
  - CUDA standar: 12.4
    - JALAN/usr/local/cuda points to /usr/local/cuda-12.4/
    - Diperbarui di bawah env vars:
      - LD_LIBRARY_PATH memiliki/64 usr/local/cuda/lib:/usr/local/cuda/lib64:/usr/local/cuda:/usr/local/cuda/targets/sbsa-linux/lib:/usr/local/cuda/nvvm/lib64:/usr/local/cuda/extras/CUPTI/lib
      - PATH untuk memiliki/usr/local/cuda/bin/:/usr/local/cuda/include/
  - Sistem yang dikompilasi Versi NCCL hadir di/usr/local/cuda/: 2.21.5
  - PyTorch Versi NCCL yang dikompilasi dari lingkungan PyTorch conda: 2.21.5
- AWS CLI v2 sebagai aws2 dan AWS CLI v1 sebagai aws
- Jenis volume EBS: gp3
- Kueri AMI-ID dengan Parameter SSM (contoh Wilayah adalah us-east-1):

```
aws ssm get-parameter --region us-east-1 \
    --name /aws/service/deeplearning/ami/arm64/oss-nvidia-driver-gpu-pytorch-2.5-
ubuntu-22.04/latest/ami-id  \
    --query "Parameter.Value" \
    --output text
```

- Kueri AMI-ID dengan AWSCLI (contoh Wilayah adalah us-east-1):

```
aws ec2 describe-images --region us-east-1 \
    --owners amazon --filters \
    'Name=name,Values=Deep Learning ARM64 AMI OSS Nvidia Driver GPU PyTorch 2.5.?
 (Ubuntu 22.04) ????????' 'Name=state,Values=available' \
    --query 'reverse(sort_by(Images, &CreationDate))[:1].ImageId' \
    --output text
```

Tanggal Rilis: 2025-02-17

Nama AMI: Pembelajaran Mendalam ARM64 AMI OSS Nvidia Driver GPU PyTorch 2.5.1 (Ubuntu 22.04) 20250215

Diperbarui

- Diperbarui NVIDIA Container Toolkit dari versi 1.17.3 ke versi 1.17.4
  - Silakan lihat halaman catatan rilis di sini untuk informasi lebih lanjut: https://github.com/NVIDIA/nvidia-container-toolkit/releases/tag/v1.17.4
  - Di Container Toolkit versi 1.17.4, pemasangan pustaka compat CUDA sekarang dinonaktifkan. Untuk memastikan kompatibilitas dengan beberapa versi CUDA pada alur kerja kontainer, pastikan Anda memperbarui LD_LIBRARY_PATH Anda untuk menyertakan pustaka kompatibilitas CUDA Anda seperti yang ditunjukkan dalam tutorial Jika Anda menggunakan lapisan kompatibilitas CUDA.

Dihapus

- Pustaka ruang pengguna yang dihapus cuobj dan nvdisasm disediakan oleh toolkit NVIDIA CUDA untuk mengatasi yang CVEs ada di Buletin Keamanan NVIDIA CUDA Toolkit untuk 18 Februari 2025

Tanggal Rilis: 2025-01-21

Nama AMI: Pembelajaran Mendalam ARM64 AMI OSS Nvidia Driver GPU PyTorch 2.5.1 (Ubuntu 22.04) 20250117

Diperbarui

- Driver Nvidia yang ditingkatkan dari versi 550.127.05 ke 550.144.03 untuk alamat yang CVEs ada di Buletin Keamanan Driver Tampilan GPU NVIDIA untuk Januari 2025.

Tanggal Rilis: 2024-11-22

Nama AMI: Pembelajaran Mendalam ARM64 AMI OSS Nvidia Driver GPU PyTorch 2.5.1 (Ubuntu 22.04) 20241122

Ditambahkan

- Rilis awal seri Deep Learning ARM64 AMI OSS Nvidia Driver GPU PyTorch 2.5.1 (Ubuntu 22.04). Termasuk pytorch lingkungan conda yang dilengkapi dengan NVIDIA Driver R550, CUDA = 12.4, cuDNN=8.9.7, NCCL=2.21.5. PyTorch

AWS Pembelajaran Mendalam ARM64 AMI GPU PyTorch 2.4 (Ubuntu 22.04)

Untuk bantuan memulai, lihatMemulai dengan DLAMI.

Format nama AMI

- Pembelajaran Mendalam ARM64 AMI OSS Nvidia Driver GPU 2.4 PyTorch . $ {VERSI TAMBALAN} (Ubuntu 22.04) $ {YYYY-MM-DD}

EC2 Contoh yang didukung

- G5g

AMI meliputi yang berikut:

- AWS Layanan yang Didukung: Amazon EC2
- Sistem Operasi: Ubuntu 22.04
- Arsitektur Komputasi: ARM64
- Python:/opt/conda/envs/pytorch/bin/python
- Versi Python: 3.11
- Pengemudi NVIDIA:

    - Pengemudi OSS Nvidia: 550.144.03
- Tumpukan NVIDIA CUDA12 .1:
    - Jalur instalasi CUDA, NCCL dan cudDN:/-12.4/usr/local/cuda
    - CUDA standar: 12.4
        - JALAN/usr/local/cuda points to /usr/local/cuda-12.4/
        - Diperbarui di bawah env vars:
            - LD_LIBRARY_PATH memiliki/64 usr/local/cuda/lib:/usr/local/cuda/lib64:/usr/local/cuda:/usr/local/cuda/targets/sbsa-linux/lib:/usr/local/cuda/nvvm/lib64:/usr/local/cuda/extras/CUPTI/lib
            - PATH untuk memiliki/usr/local/cuda/bin/:/usr/local/cuda/include/
    - Sistem terkompilasi Versi NCCL hadir di/usr/local/cuda/: 2.21.5
    - PyTorch Versi NCCL yang dikompilasi dari lingkungan PyTorch conda: 2.20.5
- AWS CLI v2 sebagai aws2 dan AWS CLI v1 sebagai aws
- Jenis volume EBS: gp3
- Kueri AMI-ID dengan Parameter SSM (contoh Wilayah adalah us-east-1):

```
aws ssm get-parameter --region us-east-1 \
    --name /aws/service/deeplearning/ami/arm64/oss-nvidia-driver-gpu-pytorch-2.4-ubuntu-22.04/latest/ami-id  \
    --query "Parameter.Value" \
    --output text
```

- Kueri AMI-ID dengan AWSCLI (contoh Wilayah adalah us-east-1):

```
aws ec2 describe-images --region us-east-1 \
    --owners amazon \
    --filters 'Name=name,Values=Deep Learning ARM64 AMI OSS Nvidia Driver GPU PyTorch 2.4.? (Ubuntu 22.04) ????????' 'Name=state,Values=available' \
    --query 'reverse(sort_by(Images, &CreationDate))[:1].ImageId' \
    --output text
```

Tanggal Rilis: 2025-02-17

Nama AMI: Pembelajaran Mendalam ARM64 AMI OSS Nvidia Driver GPU PyTorch 2.4.0 (Ubuntu 22.04) 20250215

Diperbarui

- Diperbarui NVIDIA Container Toolkit dari versi 1.17.3 ke versi 1.17.4
  - Silakan lihat halaman catatan rilis di sini untuk informasi lebih lanjut: https://github.com/NVIDIA/nvidia-container-toolkit/releases/tag/v1.17.4
  - Di Container Toolkit versi 1.17.4, pemasangan pustaka compat CUDA sekarang dinonaktifkan. Untuk memastikan kompatibilitas dengan beberapa versi CUDA pada alur kerja kontainer, pastikan Anda memperbarui LD_LIBRARY_PATH Anda untuk menyertakan pustaka kompatibilitas CUDA Anda seperti yang ditunjukkan dalam tutorial Jika Anda menggunakan lapisan kompatibilitas CUDA.

Dihapus

- Pustaka ruang pengguna yang dihapus cuobj dan nvdisasm disediakan oleh toolkit NVIDIA CUDA untuk mengatasi yang CVEs ada di Buletin Keamanan NVIDIA CUDA Toolkit untuk 18 Februari 2025

Tanggal Rilis: 2025-01-21

Nama AMI: Pembelajaran Mendalam ARM64 AMI OSS Nvidia Driver GPU PyTorch 2.4.0 (Ubuntu 22.04) 20250117

Diperbarui

- Driver Nvidia yang ditingkatkan dari versi 550.127.05 ke 550.144.03 untuk alamat yang CVEs ada di Buletin Keamanan Driver Tampilan GPU NVIDIA untuk Januari 2025.

Tanggal Rilis: 2024-09-30

Nama AMI: Pembelajaran Mendalam ARM64 AMI OSS Nvidia Driver GPU PyTorch 2.4.0 (Ubuntu 22.04) 20240927

Diperbarui

- Nvidia Container Toolkit yang ditingkatkan dari versi 1.16.1 ke 1.16.2, mengatasi kerentanan keamanan CVE-2024-0133.

Tanggal Rilis: 2024-09-26

Nama AMI: Pembelajaran Mendalam ARM64 AMI OSS Nvidia Driver GPU PyTorch 2.4.0 (Ubuntu 22.04) 20240926

Ditambahkan

- Rilis awal seri Deep Learning ARM64 AMI OSS Nvidia Driver GPU PyTorch 2.4.0 (Ubuntu 22.04). Termasuk pytorch lingkungan conda yang dilengkapi dengan NVIDIA Driver R550, CUDA = 12.4, cuDNN=8.9.7, NCCL=2.20.5. PyTorch

TensorFlow DLAMIs

TensorFlow Catatan Rilis DLAMI

- Catatan Rilis X86 TensorFlow DLAMI

Catatan Rilis X86 TensorFlow DLAMI

Di bawah ini adalah catatan rilis untuk X86 TensorFlow DLAMI:

GPU

- AWS Pembelajaran Mendalam AMI GPU TensorFlow 2.18 (Amazon Linux 2023)
- AWS Pembelajaran Mendalam AMI GPU TensorFlow 2.18 (Ubuntu 22.04)
- AWS Pembelajaran Mendalam AMI GPU TensorFlow 2.17 (Ubuntu 22.04)

AWS Neuron

- Lihat Panduan DLAMI Neuron.

Pembelajaran Mendalam AMI GPU TensorFlow 2.18 (Amazon Linux 2023)

Untuk bantuan memulai, lihatMemulai dengan DLAMI.

Format nama AMI

- Pembelajaran Mendalam OSS Nvidia Driver AMI GPU TensorFlow 2.18 (Amazon Linux 2023) ${YYYY-MM-DD}

EC2 Contoh yang didukung

- Pembelajaran Mendalam dengan OSS Nvidia Driver mendukung G4dn, G5, G6, Gr6, G6e, P4d, P4de, P5, P5e, P5en

AMI meliputi yang berikut:

- AWS Layanan yang Didukung: Amazon EC2
- Sistem Operasi: Amazon Linux 2023
- Arsitektur Komputasi: x86
- Python:/3.12 opt/tensorflow/bin/python
- TensorFlow versi: 2.18
- Pengemudi NVIDIA:
  - Pengemudi OSS Nvidia: 560.35.03
- CUDA12 Tumpukan NVIDIA:
  - Jalur instalasi CUDA, NCCL dan cudDN:/-12.5/ usr/local/cuda
- Pemasang EFA: 1.37.0
- AWS CLI v2 sebagai aws2 dan AWS CLI v1 sebagai aws
- Jenis volume EBS: gp3
- Kueri AMI-ID dengan Parameter SSM (contoh Wilayah adalah us-east-1):
  - Pengemudi OSS Nvidia:

```
aws ssm get-parameter --region us-east-1 \
    --name /aws/service/deeplearning/ami/x86_64/oss-nvidia-driver-gpu-
tensorflow-2.18-amazon-linux-2023/latest/ami-id \
    --query "Parameter.Value" \
    --output text
```

- Kueri AMI-ID dengan AWSCLI (contoh Wilayah adalah us-east-1):
  - Pengemudi OSS Nvidia:

```
aws ec2 describe-images --region us-east-1 \
    --owners amazon \
    --filters 'Name=name,Values=Deep Learning OSS Nvidia Driver AMI GPU TensorFlow
 2.18 (Amazon Linux 2023) ????????' 'Name=state,Values=available' \
    --query 'reverse(sort_by(Images, &CreationDate))[:1].ImageId' \
```

```
    --output text
```

Tanggal Rilis: 2025-02-17

Nama AMI: Driver OSS Nvidia Pembelajaran Mendalam AMI GPU TensorFlow 2.18 (Amazon Linux 2023) 20241215

Diperbarui

- Diperbarui NVIDIA Container Toolkit dari versi 1.17.3 ke versi 1.17.4
  - Silakan lihat halaman catatan rilis di sini untuk informasi lebih lanjut: https://github.com/NVIDIA/nvidia-container-toolkit/releases/tag/v1.17.4
  - Di Container Toolkit versi 1.17.4, pemasangan pustaka compat CUDA sekarang dinonaktifkan. Untuk memastikan kompatibilitas dengan beberapa versi CUDA pada alur kerja kontainer, pastikan Anda memperbarui LD_LIBRARY_PATH Anda untuk menyertakan pustaka kompatibilitas CUDA Anda seperti yang ditunjukkan dalam tutorial Jika Anda menggunakan lapisan kompatibilitas CUDA.

Dihapus

- Pustaka ruang pengguna yang dihapus cuobj dan nvdisasm disediakan oleh toolkit NVIDIA CUDA untuk mengatasi yang CVEs ada di Buletin Keamanan NVIDIA CUDA Toolkit untuk 18 Februari 2025

Tanggal Rilis: 2024-12-09

Nama AMI: Driver OSS Nvidia Pembelajaran Mendalam AMI GPU TensorFlow 2.18 (Amazon Linux 2023) 20241206

Ditambahkan

- Rilis awal seri Deep Learning OSS Nvidia Driver AMI GPU TensorFlow 2.18 (Amazon Linux 2023).
  - Perangkat Lunak Termasuk yang Berikut:
    - “nvidia-driver=560.35.03"
    - “pengelola kain = 560.35.03"
    - “cuda = 12,5"
    - “cudnn=9.5.1"

    - “efa=1.37.0"
    - “nccl=2.23.4"
    - “aws-nccl-ofi-plugin= v1.13.0-aws”
- Lingkungan virtual Tensorflow (sumber perintah aktivasi/opt/tensorflow/bin/activate) meliputi yang berikut:
    - “tensorflow = 2.18.0”

Pembelajaran Mendalam AMI GPU TensorFlow 2.18 (Ubuntu 22.04)

Untuk bantuan memulai, lihatMemulai dengan DLAMI.

Format nama AMI

- Pembelajaran Mendalam OSS Nvidia Driver AMI GPU TensorFlow 2.18 (Ubuntu 22.04) $ {YYYY-MM-DD}

EC2 Contoh yang didukung

- Pembelajaran Mendalam dengan OSS Nvidia Driver mendukung G4dn, G5, G6, Gr6, G6e, P4d, P4de, P5, P5e, P5en.

AMI meliputi yang berikut:

- AWS Layanan yang Didukung: Amazon EC2
- Sistem Operasi: Ubuntu 22.04
- Arsitektur Komputasi: x86
- Python:/3.12 opt/tensorflow/bin/python
- TensorFlow versi: 2.18
- Pengemudi NVIDIA:
    - Pengemudi OSS Nvidia: 550.144.03
- CUDA12 Tumpukan NVIDIA:
    - Jalur instalasi CUDA, NCCL dan cudDN:/-12.5/ usr/local/cuda
- Pemasang EFA: 1.37.0
- AWS CLI v2 sebagai aws2 dan AWS CLI v1 sebagai aws

- Jenis volume EBS: gp3
- Kueri AMI-ID dengan Parameter SSM (contoh Wilayah adalah us-east-1):
  - Pengemudi OSS Nvidia:

```
aws ssm get-parameter --region us-east-1 \
    --name /aws/service/deeplearning/ami/x86_64/oss-nvidia-driver-gpu-
tensorflow-2.18-ubuntu-22.04/latest/ami-id \
    --query "Parameter.Value" \
    --output text
```

- Kueri AMI-ID dengan AWSCLI (contoh Wilayah adalah us-east-1):
  - Pengemudi OSS Nvidia:

```
aws ec2 describe-images --region us-east-1 \
    --owners amazon --filters 'Name=name,Values=Deep Learning OSS Nvidia Driver AMI
 GPU TensorFlow 2.18 (Ubuntu 22.04) ????????' 'Name=state,Values=available' \
    --query 'reverse(sort_by(Images, &CreationDate))[:1].ImageId' \
    --output text
```

Tanggal Rilis: 2025-02-17

Nama AMI: Driver OSS Nvidia Pembelajaran Mendalam AMI GPU TensorFlow 2.18 (Ubuntu 22.04) 20250215

Diperbarui

- Diperbarui NVIDIA Container Toolkit dari versi 1.17.3 ke versi 1.17.4
  - Silakan lihat halaman catatan rilis di sini untuk informasi lebih lanjut: https://github.com/NVIDIA/nvidia-container-toolkit/releases/tag/v1.17.4
  - Di Container Toolkit versi 1.17.4, pemasangan pustaka compat CUDA sekarang dinonaktifkan. Untuk memastikan kompatibilitas dengan beberapa versi CUDA pada alur kerja kontainer, pastikan Anda memperbarui LD_LIBRARY_PATH Anda untuk menyertakan pustaka kompatibilitas CUDA Anda seperti yang ditunjukkan dalam tutorial Jika Anda menggunakan lapisan kompatibilitas CUDA.

Dihapus

- Pustaka ruang pengguna yang dihapus cuobj dan nvdisasm disediakan oleh toolkit NVIDIA CUDA untuk mengatasi yang CVEs ada di Buletin Keamanan NVIDIA CUDA Toolkit untuk 18 Februari 2025

Tanggal Rilis: 2025-01-20

Nama AMI: Driver OSS Nvidia Pembelajaran Mendalam AMI GPU TensorFlow 2.18 (Ubuntu 22.04) 20250118

Diperbarui

- Driver Nvidia yang ditingkatkan dari versi 550.90.07 ke 550.127.05 untuk alamat yang CVEs ada di Buletin Keamanan Driver Tampilan GPU NVIDIA untuk Januari 2025

Tanggal Rilis: 2024-12-09

Nama AMI: Driver OSS Nvidia Pembelajaran Mendalam AMI GPU TensorFlow 2.18 (Ubuntu 22.04) 20241206

Ditambahkan

- Rilis awal seri Deep Learning OSS Nvidia Driver AMI GPU TensorFlow 2.18 (Ubuntu 22.04).
  - Perangkat Lunak Termasuk yang Berikut ini:
    - “nvidia-driver=550.127.05"
    - “pengelola kain = 550.127.05"
    - “cuda = 12,5"
    - “cudnn=9.5.1"
    - “efa=1.37.0"
    - “nccl=2.23.4"
    - “aws-nccl-ofi-plugin= v1.13.0-aws”
- Lingkungan virtual Tensorflow (sumber perintah aktivasi/opt/tensorflow/bin/activate) meliputi yang berikut:
  - “tensorflow = 2.18.0”

Tetap

- Karena perubahan kernel Ubuntu untuk mengatasi cacat pada fungsionalitas Kernel Address Space Layout Randomization (KASLR), instance G4Dn/G5 tidak dapat menginisialisasi CUDA dengan benar pada driver OSS Nvidia. Untuk mengurangi masalah ini, DLAMI ini menyertakan fungsionalitas yang secara dinamis memuat driver berpemilik untuk instans G4Dn dan G5. Harap izinkan periode inisialisasi singkat untuk pemuatan ini untuk memastikan bahwa instans Anda dapat berfungsi dengan baik.
  - Untuk memeriksa status dan kesehatan layanan ini, Anda dapat menggunakan perintah berikut:

```
sudo systemctl is-active dynamic_driver_load.service
active
```

Pembelajaran Mendalam AMI GPU TensorFlow 2.17 (Ubuntu 22.04)

Untuk bantuan memulai, lihatMemulai dengan DLAMI.

Format nama AMI

- Pembelajaran Mendalam OSS Nvidia Driver AMI GPU TensorFlow 2.17 (Ubuntu 22.04) $ {YYYY-MM-DD}

EC2 Contoh yang didukung

- Pembelajaran Mendalam dengan OSS Nvidia Driver mendukung G4dn, G5, G6, Gr6, G6e, P4d, P4de, P5, P5e. P5en.

AMI meliputi yang berikut:

- AWS Layanan yang Didukung: Amazon EC2
- Sistem Operasi: Ubuntu 22.04
- Arsitektur Komputasi: x86
- Python:/3.12 opt/tensorflow/bin/python
- TensorFlow versi: 2.17
- Pengemudi NVIDIA:
  - Pengemudi OSS Nvidia: 550.144.03

- CUDA12 Tumpukan NVIDIA:
  - Jalur instalasi CUDA, NCCL dan cudDN:/-12.3/usr/local/cuda
- Pemasang EFA: 1.34.0
- AWS CLI v2 sebagai aws2 dan AWS CLI v1 sebagai aws
- Jenis volume EBS: gp3
- Kueri AMI-ID dengan Parameter SSM (contoh Wilayah adalah us-east-1):
  - Pengemudi OSS Nvidia:

```
aws ssm get-parameter --region us-east-1 \
    --name /aws/service/deeplearning/ami/x86_64/oss-nvidia-driver-gpu-
tensorflow-2.17-ubuntu-22.04/latest/ami-id  \
    --query "Parameter.Value" \
    --output text
```

- Kueri AMI-ID dengan AWSCLI (contoh Wilayah adalah us-east-1):
  - Pengemudi OSS Nvidia:

```
aws ec2 describe-images --region us-east-1 \
    --owners amazon --filters 'Name=name,Values=Deep Learning OSS Nvidia Driver AMI
 GPU TensorFlow 2.17 (Ubuntu 22.04) ????????' 'Name=state,Values=available' \
    --query 'reverse(sort_by(Images, &CreationDate))[:1].ImageId' \
    --output text
```

Tanggal Rilis: 2025-02-17

Nama AMI: Driver OSS Nvidia Pembelajaran Mendalam AMI GPU TensorFlow 2.17 (Ubuntu 22.04) 20250215

Diperbarui

- Diperbarui NVIDIA Container Toolkit dari versi 1.17.3 ke versi 1.17.4
  - Silakan lihat halaman catatan rilis di sini untuk informasi lebih lanjut: https://github.com/NVIDIA/nvidia-container-toolkit/releases/tag/v1.17.4
  - Di Container Toolkit versi 1.17.4, pemasangan pustaka compat CUDA sekarang dinonaktifkan. Untuk memastikan kompatibilitas dengan beberapa versi CUDA pada alur kerja kontainer, pastikan Anda memperbarui LD_LIBRARY_PATH Anda untuk menyertakan pustaka

kompatibilitas CUDA Anda seperti yang ditunjukkan dalam tutorial Jika Anda menggunakan lapisan kompatibilitas CUDA.

Dihapus

- Pustaka ruang pengguna yang dihapus cuobj dan nvdisasm disediakan oleh toolkit NVIDIA CUDA untuk mengatasi yang CVEs ada di Buletin Keamanan NVIDIA CUDA Toolkit untuk 18 Februari 2025

Tanggal Rilis: 2025-01-20

Nama AMI: Driver OSS Nvidia Pembelajaran Mendalam AMI GPU TensorFlow 2.17 (Ubuntu 22.04) 20250118

Diperbarui

- Driver Nvidia yang ditingkatkan dari versi 550.127.05 ke 550.144.03 ke alamat yang CVEs ada di Buletin Keamanan Driver Tampilan GPU NVIDIA untuk Januari 2025

Versi 2.17.1

Tanggal rilis: 2024-11-18

Nama AMI: Driver OSS Nvidia Pembelajaran Mendalam AMI GPU TensorFlow 2.17 (Ubuntu 22.04) 20241115

Tetap

- Karena perubahan kernel Ubuntu untuk mengatasi cacat pada fungsionalitas Kernel Address Space Layout Randomization (KASLR), instance G4Dn/G5 tidak dapat menginisialisasi CUDA dengan benar pada driver OSS Nvidia. Untuk mengurangi masalah ini, DLAMI ini menyertakan fungsionalitas yang secara dinamis memuat driver berpemilik untuk instans G4Dn dan G5. Harap izinkan periode inisialisasi singkat untuk pemuatan ini untuk memastikan bahwa instans Anda dapat berfungsi dengan baik.
  - Untuk memeriksa status dan kesehatan layanan ini, Anda dapat menggunakan perintah berikut:

```
sudo systemctl is-active dynamic_driver_load.service
active
```

Versi 2.17.0

Tanggal rilis: 2024-09-25

Nama AMI: Driver OSS Nvidia Pembelajaran Mendalam AMI GPU TensorFlow 2.17 (Ubuntu 22.04) 20240924

Ditambahkan

- Rilis awal seri Deep Learning OSS Nvidia Driver AMI GPU TensorFlow 2.17 (Ubuntu 22.04).
  - Perangkat Lunak Termasuk yang Berikut ini:
    - “nvidia-driver=550.90.07"
    - “pengelola kain = 550.90.07"
    - “cuda = 12.3"
    - “cudnn=8.9.7"
    - “efa=1.34.0"
    - “nccl=2.22.3"
    - “aws-nccl-ofi-plugin= v1.11.0-aws”
- Lingkungan virtual Tensorflow (sumber perintah aktivasi/opt/tensorflow/bin/activate) meliputi yang berikut:
  - “tensorflow = 2.17.0”

Catatan Rilis untuk Multi-Framework DLAMIs

> **Tip**
>
> Jika Anda hanya menggunakan satu kerangka pembelajaran mesin, maka kami merekomendasikan DLAMI kerangka tunggal.

Catatan Rilis Multi Framework DLAMI

- Catatan Rilis DLAMI Multi-Framework

Catatan Rilis DLAMI Multi-Framework

Berikut adalah catatan rilis untuk Multi-Framework X86 DLAMI:

GPU

- AWS Pembelajaran Mendalam AMI (Amazon Linux 2)

AWS Neuron

- Lihat Panduan Pengguna DLAMI Neuron

AWS Pembelajaran Mendalam AMI (Amazon Linux 2)

> **Tip**
>
> Pelanggan yang menggunakan kerangka kerja tunggal seperti PyTorch atau TensorFlow didorong untuk menggunakan kerangka kerja tunggal yang DLAMIs disebutkan di sini

Untuk bantuan memulai, lihatMemulai dengan DLAMI.

Format nama AMI

- Driver Nvidia Proprietary Deep Learning AMI (Amazon Linux 2) Versi $ {XX.X}
- Pembelajaran Mendalam OSS Nvidia Driver AMI (Amazon Linux 2) Versi $ {XX.X}

EC2 Contoh yang didukung

- Silakan lihat Perubahan penting pada DLAMI.
- Pembelajaran Mendalam dengan OSS Nvidia Driver mendukung G4dn, G5, G6, Gr6, G6e, P4d, P4de, P5
- Pembelajaran Mendalam dengan Driver Nvidia Proprietary mendukung G3 (G3.16x tidak didukung), P3, P3dn

AMI meliputi yang berikut:

- AWS Layanan yang Didukung: Amazon EC2
- Sistem Operasi: Amazon Linux 2
- Arsitektur Komputasi: x86
- Kerangka kerja lingkungan Conda dan versi python:

  - Pembelajaran Mendalam OSS Nvidia Driver AMI (Amazon Linux 2):
    - python3: Python 3.10
    - tensorflow2_p310:2.16, Python 3.10 TensorFlow
    - pytorch_p310:2.2, Python 3.10 PyTorch
  - AMI Driver Nvidia Milik Pembelajaran Mendalam (Amazon Linux 2):
    - python3: Python 3.10
    - tensorflow2_p310:2.16, Python 3.10 TensorFlow
    - pytorch_p310:2.2, Python 3.10 PyTorch
- Pengemudi NVIDIA:
  - Pengemudi OSS Nvidia: 550.163.01
  - Driver Nvidia eksklusif: 550.163.01
- NVIDIA CUDA12 .1-12.4 tumpukan:
  - Jalur instalasi CUDA, NCCL dan cudDN:/-xx.x/ usr/local/cuda
  - CUDA standar: 12.1
    - PATH/usr/local/cudamenunjuk ke CUDA12 .1
    - Diperbarui di bawah env vars:
      - LD_LIBRARY_PATH memiliki/usr/local/cuda-12.1/lib:/usr/local/cuda-12.1/lib64:/usr/local/cuda-12.1:/usr/local/cuda-12.1/targets/x86_64-linux/lib
      - PATH untuk memiliki/usr/local/cuda-12.1/bin/:/usr/local/cuda-11.8/include/
    - Untuk versi CUDA yang berbeda, harap perbarui LD_LIBRARY_PATH yang sesuai.
  - Versi NCCL yang dikompilasi untuk CUDA 12.1-12.4:2.22.3
  - Lokasi Tes NCCL:
    - all_reduce, all_gather dan reduce_scatter:/-cuda-xx.x/ usr/local/cuda-xx.x/efa/test
    - Untuk menjalankan pengujian NCCL, LD_LIBRARY_PATH harus melewati pembaruan di bawah ini.
      - Umum sudah PATHs ditambahkan ke LD_LIBRARY_PATH:
        - /opt/amazon/efa/lib:/opt/amazon/openmpi/lib:/opt/aws-ofi-nccl/lib:/usr/local/lib:/usr/lib
      - Untuk versi CUDA yang berbeda, harap perbarui LD_LIBRARY_PATH yang sesuai.
- Pemasang EFA: 1.38.0
- GDRCopy: 2.4
- AWS NCCL: 1.13.2

  - Lokasi sistem:/usr/local/cuda-xx.x/efa
  - Ini ditambahkan untuk menjalankan tes NCCL yang terletak di/-cuda-xx.x/ usr/local/cuda-xx.x/efa/test
  - Juga, PyTorch paket dilengkapi dengan plugin AWS OFI NCCL yang ditautkan secara dinamis sebagai paket paket conda juga dan PyTorch akan menggunakan aws-ofi-nccl-dlc paket itu alih-alih sistem OFI NCCL. AWS
- Lokasi Tes NCCL:/-cuda-xx.x/ usr/local/cuda-xx.x/efa/test
- AWS CLI v2 di/usr/local/bin/aws2 dan AWS CLI v1 di/usr/local/bin/aws
- Jenis volume EBS: gp3
- Kueri AMI-ID dengan Parameter SSM (contoh wilayah adalah us-east-1):
  - Pengemudi OSS Nvidia:

```
aws ssm get-parameter --name /aws/service/deeplearning/ami/x86_64/multi-framework-
oss-nvidia-driver-amazon-linux-2/latest/ami-id --region us-east-1 --query
 "Parameter.Value" --output text
```

  - Pengemudi Nvidia Berpemilik:

```
aws ssm get-parameter --name /aws/service/deeplearning/ami/x86_64/multi-framework-
proprietary-nvidia-driver-amazon-linux-2/latest/ami-id --region us-east-1 --query
 "Parameter.Value" --output text
```

- Kueri AMI-ID dengan AWSCLI (contoh wilayah adalah us-east-1):
  - Pengemudi OSS Nvidia:

```
aws ec2 describe-images --region us-east-1 --owners amazon --filters
 'Name=name,Values=Deep Learning OSS Nvidia Driver AMI (Amazon Linux 2)
 Version ??.?' 'Name=state,Values=available' --query 'reverse(sort_by(Images,
 &CreationDate))[:1].ImageId' --output text
```

  - Pengemudi Nvidia Berpemilik:

```
aws ec2 describe-images --region us-east-1 --owners amazon --filters
 'Name=name,Values=Deep Learning Proprietary Nvidia Driver AMI (Amazon Linux 2)
 Version ??.?' 'Name=state,Values=available' --query 'reverse(sort_by(Images,
 &CreationDate))[:1].ImageId' --output text
```

Pemberitahuan

Pembaruan EFA dari 1.37 ke 1.38 (Rilis pada 2025-02-05)

- EFA sekarang menggabungkan plugin AWS OFI NCCL, yang sekarang dapat ditemukan di/-ofi-nccl/. opt/amazon/ofi-nccl rather than the original /opt/aws Jika memperbarui variabel LD_LIBRARY_PATH Anda, pastikan Anda memodifikasi lokasi OFI NCCL Anda dengan benar.

Penghapusan Lingkungan Neuron Conda

- Deep Learning Proprietary Nvidia Driver yang AMIs dirilis setelah 18 Juli 2024 akan dikirim tanpa lingkungan neuron conda untuk dan. PyTorch TensorFlow Silakan gunakan DLAMIs Neuron pada Catatan Rilis DLAMI sebagai gantinya, untuk memanfaatkan lingkungan neuron.

Penghapusan Paket Audit

- DLAMI yang dirilis antara 26 Maret 2024 (2024-03-26) dan 12 April 2024 (2024-04-12) dikirim tanpa paket audit. Jika Anda memerlukan paket khusus ini untuk kebutuhan pencatatan dan pemantauan Anda, silakan migrasi alur kerja Anda ke DLAMI terbaru untuk menggunakan paket audit yang diinstal.

Horovod

- Horovod dihapus dari lingkungan conda pytorch_p310 dan tensorflow2_p310 saat ini di DLAMI. Pelanggan akan dapat menginstal perpustakaan horovod dengan mengikuti pedoman horovod dan menginstalnya DLAMIs untuk pekerjaan pelatihan terdistribusi mereka.

Tanggal Rilis: 2025-04-22

Nama AMI

- Pembelajaran Mendalam OSS Nvidia Driver AMI (Amazon Linux 2) Versi 81.2
- Driver Nvidia Proprietary Deep Learning AMI (Amazon Linux 2) Versi 81.2

Diperbarui

- Driver Nvidia yang ditingkatkan dari versi 550.144.03 ke 550.163.01 untuk alamat yang CVEs ada di Buletin Keamanan Driver Tampilan GPU NVIDIA untuk April 2025

Tanggal Rilis: 2025-02-17

Nama AMI

- Pembelajaran Mendalam OSS Nvidia Driver AMI (Amazon Linux 2) Versi 80.6
- Driver Nvidia Proprietary Deep Learning AMI (Amazon Linux 2) Versi 80.4

Diperbarui

- Diperbarui NVIDIA Container Toolkit dari versi 1.17.3 ke versi 1.17.4
  - Silakan lihat halaman catatan rilis di sini untuk informasi lebih lanjut: https://github.com/NVIDIA/nvidia-container-toolkit/releases/tag/v1.17.4
  - Di Container Toolkit versi 1.17.4, pemasangan pustaka compat CUDA sekarang dinonaktifkan. Untuk memastikan kompatibilitas dengan beberapa versi CUDA pada alur kerja kontainer, pastikan Anda memperbarui LD_LIBRARY_PATH Anda untuk menyertakan pustaka kompatibilitas CUDA Anda seperti yang ditunjukkan di bawah tutorial “Jika Anda menggunakan lapisan kompatibilitas CUDA” di sini - -gpu-drivers.html# https://docs.aws.amazon.com/sagemaker/ latest/dg/inference collapsible-cuda-compat

Dihapus

- Pustaka ruang pengguna yang dihapus cuobj dan nvdisasm disediakan oleh toolkit NVIDIA CUDA untuk mengatasi yang CVEs ada di Buletin Keamanan NVIDIA CUDA Toolkit untuk 18 Februari 2025

Tanggal Rilis: 2025-02-05

Nama AMI

- Driver Nvidia Proprietary Deep Learning AMI (Amazon Linux 2) Versi 80.2
- Pembelajaran Mendalam OSS Nvidia Driver AMI (Amazon Linux 2) Versi 80.4

Diperbarui

- Versi EFA yang ditingkatkan dari 1.37.0 ke 1.38.0

- EFA sekarang menggabungkan plugin AWS OFI NCCL, yang sekarang dapat ditemukan di/-ofi-nccl/. opt/amazon/ofi-nccl rather than the original /opt/aws Jika memperbarui variabel LD_LIBRARY_PATH Anda, pastikan Anda memodifikasi lokasi OFI NCCL Anda dengan benar.

Tanggal Rilis: 2025-01-15

Nama AMI

- Pembelajaran Mendalam OSS Nvidia Driver AMI (Amazon Linux 2) Versi 80.3
- Driver Nvidia Proprietary Deep Learning AMI (Amazon Linux 2) Versi 80.1

Diperbarui

- Driver Nvidia yang ditingkatkan dari versi 550.127.05 ke 550.144.03 ke alamat yang CVEs ada di Buletin Keamanan Driver Tampilan GPU NVIDIA untuk Januari 2025

Tanggal Rilis: 2024-12-09

Nama AMI

- Pembelajaran Mendalam OSS Nvidia Driver AMI (Amazon Linux 2) Versi 80.1
- Driver Nvidia Proprietary Deep Learning AMI (Amazon Linux 2) Versi 79.9

Diperbarui

- Toolkit Kontainer Nvidia yang ditingkatkan dari versi 1.17.0 ke 1.17.3

Tanggal Rilis: 2024-11-11

Nama AMI

- Pembelajaran Mendalam OSS Nvidia Driver AMI (Amazon Linux 2) Versi 79.9
- Driver Nvidia Proprietary Deep Learning AMI (Amazon Linux 2) Versi 79.7

Diperbarui

- Nvidia Container Toolkit yang ditingkatkan dari versi 1.16.2 ke 1.17.0, mengatasi kerentanan keamanan CVE-2024-0134.

Tanggal Rilis: 2024-10-22

Nama AMI

- Pembelajaran Mendalam OSS Nvidia Driver AMI (Amazon Linux 2) Versi 79.6
- Driver Nvidia Proprietary Deep Learning AMI (Amazon Linux 2) Versi 79.6

Diperbarui

- Driver Nvidia yang ditingkatkan dari versi 550.90.07 ke 550.127.05 untuk alamat yang CVEs ada di Buletin Keamanan Tampilan GPU NVIDIA untuk Oktober 2024

Tanggal Rilis: 2024-10-03

Nama AMI

- Pembelajaran Mendalam OSS Nvidia Driver AMI (Amazon Linux 2) Versi 79.3
- Driver Nvidia Proprietary Deep Learning AMI (Amazon Linux 2) Versi 79.3

Diperbarui

- Nvidia Container Toolkit yang ditingkatkan dari versi 1.16.1 ke 1.16.2, mengatasi kerentanan keamanan CVE-2024-0133.

Tanggal Rilis: 2024-07-18

Nama AMI

- Pembelajaran Mendalam OSS Nvidia Driver AMI (Amazon Linux 2) Versi 78.6
- Driver Nvidia Proprietary Deep Learning AMI (Amazon Linux 2) Versi 78.7

Diperbarui

- Menghapus lingkungan conda aws_neuron_pytorch_p38 dan aws_neuron_tensorflow_p38 dari AMI Driver Nvidia Proprietary Deep Learning.
- Menghapus dukungan keluarga instans Inf1 dari AMI Driver Nvidia Proprietary Deep Learning.

Tanggal Rilis: 2024-06-06

Nama AMI

- Pembelajaran Mendalam OSS Nvidia Driver AMI (Amazon Linux 2) Versi 78.5
- Driver Nvidia Proprietary Deep Learning AMI (Amazon Linux 2) Versi 78.5

Diperbarui

- Diperbarui versi driver Nvidia ke 535.183.01 dari 535.161.08

Tanggal Rilis: 2024-05-17

Nama AMI

- Pembelajaran Mendalam OSS Nvidia Driver AMI (Amazon Linux 2) Versi 78.1
- Driver Nvidia Proprietary Deep Learning AMI (Amazon Linux 2) Versi 78.1

Diperbarui

- Torchserve yang diperbarui dari v0.8.2 ke v0.11.0 di lingkungan pytorch_p310.

Tanggal Rilis: 2024-05-07

Nama AMI

- Pembelajaran Mendalam OSS Nvidia Driver AMI (Amazon Linux 2) Versi 78.0
- Driver Nvidia Proprietary Deep Learning AMI (Amazon Linux 2) Versi 78.0

Diperbarui

- TensorFlow versi diperbarui dari 2.15 ke 2.16 di lingkungan tensorflow2_p310.
- Diperbarui versi EFA dari versi 1.30 ke versi 1.32
- Diperbarui plugin AWS OFI NCCL dari versi 1.7.4 ke versi 1.9.1
- Toolkit kontainer Nvidia yang diperbarui dari versi 1.13.5 ke versi 1.15.0
  - CATATAN: Versi 1.15.0 TIDAK menyertakan paket nvidia-container-runtime dan nvidia-docker2. Disarankan untuk menggunakan nvidia-container-toolkit paket secara langsung dengan mengikuti dokumen toolkit kontainer Nvidia.

Ditambahkan

- Ditambahkan CUDA12 .3 tumpukan CUDA12 dengan.3, NCCL 2.21.5, cuDNN 8.9.7

Dihapus

- Menghapus tumpukan CUDA11 .7, CUDA12 .0 yang ada di/-12.0 usr/local/cuda-11.7 and /usr/local/cuda
- Menghapus paket nvidia-docker2 dan perintahnya nvidia-docker sebagai bagian dari pembaruan toolkit kontainer Nvidia dari 1.13.5 ke 1.15.0 yang TIDAK menyertakan paket dan nvidia-docker2. nvidia-container-runtime

Tanggal Rilis: 2024-04-04

Nama AMI

- Pembelajaran Mendalam OSS Nvidia Driver AMI (Amazon Linux 2) Versi 77.0
- Driver Nvidia Proprietary Deep Learning AMI (Amazon Linux 2) Versi 77.0

Diperbarui

- PyTorch versi diperbarui dari 2.1 ke 2.2 di lingkungan pytorch_p310.
- Untuk driver OSS Nvidia DLAMIs, menambahkan dukungan instans G6 dan Gr6 EC2 . Silakan lihat halaman pemilihan EC2 contoh untuk informasi lebih lanjut.

Tanggal Rilis: 2024-03-29

Nama AMI

- Pembelajaran Mendalam OSS Nvidia Driver AMI (Amazon Linux 2) Versi 76.8
- Driver Nvidia Proprietary Deep Learning AMI (Amazon Linux 2) Versi 76.9

Diperbarui

- Driver Nvidia yang diperbarui dari 535.104.12 ke 535.161.08 di driver Proprietary dan OSS Nvidia. DLAMIs
- Instans baru yang didukung untuk setiap DLAMI adalah sebagai berikut:
  - Pembelajaran Mendalam dengan Driver Nvidia Proprietary mendukung G3 (G3.16x tidak didukung), P3, P3dn, Inf1
  - Pembelajaran Mendalam dengan OSS Nvidia Driver mendukung G4dn, G5, P4d, P4de.

Dihapus

- Dukungan EC2 instans G4dn, G5, G3.16x yang dihapus dari DLAMI driver Nvidia Proprietary.

Versi 76.8

Tanggal Rilis: 2024-03-20

Nama AMI

- Driver Nvidia Proprietary Deep Learning AMI (Amazon Linux 2) Versi 76.8

Ditambahkan

- Menambahkan awscliv2 di AMI sebagai usr/local/bin/aws2, alongside awscliv1 as /usr/local/bin/aws /pada AMI Driver Nvidia Proprietary

Versi 76.7

Tanggal Rilis: 2024-03-20

Nama AMI

- Pembelajaran Mendalam OSS Nvidia Driver AMI (Amazon Linux 2) Versi 76.7

Ditambahkan

- Menambahkan awscliv2 di AMI sebagai usr/local/bin/aws2, alongside awscliv1 as /usr/local/bin/aws /pada OSS Nvidia Driver AMI
- DLAMI driver OSS Nvidia yang diperbarui dengan dukungan G4dn dan G5, berdasarkan dukungan saat ini terlihat seperti di bawah ini:
  - Driver Nvidia Proprietary Deep Learning Base AMI (Amazon Linux 2) mendukung P3, P3dn, G3, G5, G4dn.
  - Basis Pembelajaran Mendalam OSS Nvidia Driver AMI (Amazon Linux 2) mendukung G4dn, G5, P4, P5.
- Driver OSS Nvidia DLAMIs direkomendasikan untuk digunakan untuk G4dn, G5, P4, P5.

Versi 76.3

Tanggal Rilis: 2024-02-14

Diperbarui

- Diperbarui TensorFlow dari 2.13.0 ke 2.15.0
- Diperbarui EFA dari 1.29.0 ke 1.30.0
- Diperbarui AWS-OFI-NCCL dari 1.7.3-aws ke 1.7.4-aws
- Driver Nvidia yang Diperbarui ke 535.104.12 pada AMI Driver Nvidia Proprietary Deep Learning
- Diperbarui Driver Nvidia ke 535.154.05 pada Deep Learning OSS Nvidia Driver AMI

Versi 76.2

Tanggal Rilis: 2024-02-02

Nama AMI

- Driver Nvidia Proprietary Deep Learning AMI (Amazon Linux 2) Versi 76.2
- Pembelajaran Mendalam OSS Nvidia Driver AMI (Amazon Linux 2) Versi 76.4

Keamanan

- Versi paket runc yang diperbarui untuk menggunakan patch untuk CVE-2024-21626.

Versi 76.1

Tanggal Rilis: 2023-12-27

Diperbarui

- Diperbarui PyTorch dari 2.0.1 ke 2.1.0

Versi 75.1

Tanggal Rilis: 2023-11-17

Silakan lihat Perubahan penting pada DLAMI

Nama AMI

- Pembelajaran Mendalam OSS Nvidia Driver AMI (Amazon Linux 2) Versi 75.1
- Driver Nvidia Proprietary Deep Learning AMI (Amazon Linux 2) Versi 75.1

Ditambahkan

- AWS Deep Learning AMI (DLAMI) dibagi menjadi dua kelompok terpisah:
  - DLAMI yang menggunakan Nvidia Proprietary Driver (untuk mendukung P3, P3dn, G3, G5, G4dn).
  - DLAMI yang menggunakan Nvidia OSS Driver untuk mengaktifkan EFA (untuk mendukung P4, P5).
- Silakan merujuk ke pengumuman publik untuk informasi lebih lanjut tentang DLAMI split.
- AWS kueri cli untuk di atas ada di catatan rilis di bawah bullet point Query AMI-ID dengan (AWSCLI contoh wilayah adalah us-east-1)

Diperbarui

- EFA diperbarui dari 1.26.1 ke 1.29.0
- GDRCopy diperbarui dari 2.3 ke 2.4

Versi 74.4

Tanggal Rilis: 2023-10-27

Diperbarui

- AWS OFI NCCL Plugin diperbarui dari versi 1.7.2 ke versi 1.7.3
- Direktori CUDA 12.0-12.1 yang diperbarui dengan NCCL versi 2.18.5
- CUDA12.1 diperbarui sebagai Versi CUDA default
  - Diperbarui LD_LIBRARY_PATH untuk memiliki//usr/local/cuda-12.1/targets/x86_64-linux/lib/:/usr/local/cuda-12.1/lib:/usr/local/cuda-12.1/lib64:/usr/local/cuda-12.1 and PATH to have /usr/local/cuda-12.1/bin
  - Untuk pelanggan yang ingin mengubah ke versi CUDA yang berbeda, harap tentukan variabel LD_LIBRARY_PATH dan PATH yang sesuai.
- Bantal yang diperbarui dari versi 9.4.0 hingga 10.1.0 untuk memperbaiki SNYK-PYTHON-PILLOW-5918878 di semua lingkungan conda
- Diperbarui opencv-python dari 4.8.0.74 ke 4.8.1.78 untuk memperbaiki SNYK-PYTHON-OPENCVPYTHON-5926695 di semua lingkungan conda

Ditambahkan

- Kernel Live Patching sekarang diaktifkan. Live patching memungkinkan pelanggan untuk menerapkan kerentanan keamanan dan patch bug kritis ke kernel Linux yang sedang berjalan, tanpa reboot atau gangguan pada aplikasi yang sedang berjalan.
  - Harap dicatat bahwa dukungan patching langsung untuk kernel 5.10.192 akan berakhir pada 11/30/23.
  - Untuk informasi lebih lanjut silahkan referensi AWS dokumen resmi di sini - https://docs.aws.amazon.com/AWSEC2/latest/UserGuide/al2-live-patching.html

Versi 74.0

Tanggal Rilis: 2023-07-19

Diperbarui

- Diperbarui TensorFlow dari 2.12 ke 2.13

- Horovod telah dihapus dari lingkungan conda dalam rilis ini. Lihat Pemberitahuan untuk detail tentang menginstal horovod.

Versi 73.1

Tanggal Rilis: 2023-06-12

Diperbarui

- Diperbarui PyTorch dari 2.0.0 ke 2.0.1

Memulai dengan DLAMI

Panduan ini mencakup tips tentang memilih DLAMI yang tepat untuk Anda, memilih jenis instans yang sesuai dengan kasus penggunaan dan anggaran Anda, Informasi terkait DLAMI dan yang menjelaskan pengaturan khusus yang mungkin menarik.

Jika Anda baru menggunakan AWS atau menggunakan Amazon EC2, mulailah denganPembelajaran Mendalam AMI dengan Conda. Jika Anda terbiasa dengan Amazon EC2 dan AWS layanan lain seperti Amazon EMR, Amazon EFS, atau Amazon S3, dan tertarik untuk mengintegrasikan layanan tersebut untuk proyek yang memerlukan pelatihan atau inferensi terdistribusi, Informasi terkait DLAMI periksa untuk melihat apakah sesuai dengan kasus penggunaan Anda.

Kami menyarankan Anda memeriksa Memilih DLAMI untuk mendapatkan gambaran tentang jenis instans mana yang terbaik untuk aplikasi Anda.

Langkah selanjutnya

Memilih DLAMI

Memilih DLAMI

Kami menawarkan berbagai opsi DLAMI seperti yang disebutkan dalam catatan rilis DLAMI GPU. Untuk membantu Anda memilih DLAMI yang benar untuk kasus penggunaan Anda, kami mengelompokkan gambar berdasarkan jenis perangkat keras atau fungsionalitas yang dikembangkan. Pengelompokan tingkat atas kami adalah:

- Jenis DLAMI: Basis, Kerangka Tunggal, Multi-Kerangka (Conda DLAMI)
- Arsitektur Komputasi: Graviton berbasis x86, berbasis ARM64 AWS
- Jenis Prosesor: GPU, CPU, Inferensia, Trainer
- SDK: CUDA, Neuron AWS
- OS: Amazon Linux, Ubuntu

Topik lainnya dalam panduan ini membantu memberi tahu Anda lebih lanjut dan masuk ke detail lebih lanjut.

Topik

- Instalasi CUDA dan Binding Kerangka Kerja

- Dasar Pembelajaran Mendalam AMI
- Pembelajaran Mendalam AMI dengan Conda
- Pilihan Arsitektur DLAMI
- Opsi Sistem Operasi DLAMI

Selanjutnya

Pembelajaran Mendalam AMI dengan Conda

Instalasi CUDA dan Binding Kerangka Kerja

Sementara pembelajaran mendalam semuanya cukup canggih, setiap kerangka kerja menawarkan versi “stabil”. Versi stabil ini mungkin tidak berfungsi dengan implementasi dan fitur CUDA atau cuDNN terbaru. Kasus penggunaan Anda dan fitur yang Anda butuhkan dapat membantu Anda memilih kerangka kerja. Jika Anda tidak yakin, maka gunakan AMI Pembelajaran Mendalam terbaru dengan Conda. Ini memiliki `pip` binari resmi untuk semua kerangka kerja dengan CUDA, menggunakan versi terbaru mana pun yang didukung oleh setiap kerangka kerja. Jika Anda menginginkan versi terbaru, dan untuk menyesuaikan lingkungan pembelajaran mendalam Anda, gunakan AMI Dasar Pembelajaran Mendalam.

Lihat panduan kami Kandidat Stabil Versus Rilis untuk panduan lebih lanjut.

Pilih DLAMI dengan CUDA

Dasar Pembelajaran Mendalam AMIMemiliki semua seri versi CUDA yang tersedia

Pembelajaran Mendalam AMI dengan CondaMemiliki semua seri versi CUDA yang tersedia

> **Note**
>
> Kami tidak lagi menyertakan lingkungan MXNet, CNTK, Caffe, Caffe2, Theano, Chainer, atau Keras Conda di. AWS Deep Learning AMIs

Untuk nomor versi kerangka kerja tertentu, lihat Catatan AMIs Rilis Deep Learning

Pilih jenis DLAMI ini atau pelajari lebih lanjut tentang DLAMIs perbedaan dengan opsi Berikutnya.

Pilih salah satu versi CUDA dan tinjau daftar lengkap DLAMIs yang memiliki versi itu di Lampiran, atau pelajari lebih lanjut tentang perbedaan DLAMIs dengan opsi Next Up.

Selanjutnya

Dasar Pembelajaran Mendalam AMI

Topik Terkait

- Untuk petunjuk tentang beralih antara versi CUDA, lihat Menggunakan Basis Pembelajaran Mendalam AMI tutorial.

Dasar Pembelajaran Mendalam AMI

AMI Basis Pembelajaran Mendalam seperti kanvas kosong untuk pembelajaran mendalam. Muncul dengan semua yang Anda butuhkan sampai titik instalasi kerangka kerja tertentu, dan memiliki pilihan versi CUDA Anda.

Mengapa Memilih DLAMI Dasar

Grup AMI ini berguna bagi kontributor proyek yang ingin melakukan fork project deep learning dan membangun yang terbaru. Ini untuk seseorang yang ingin menggulung lingkungan mereka sendiri dengan keyakinan bahwa perangkat lunak NVIDIA terbaru diinstal dan berfungsi sehingga mereka dapat fokus memilih kerangka kerja dan versi mana yang ingin mereka instal.

Pilih jenis DLAMI ini atau pelajari lebih lanjut tentang DLAMIs perbedaan dengan opsi Next Up.

Selanjutnya

DLAMI dengan Conda

Topik Terkait

- Menggunakan Basis Pembelajaran Mendalam AMI

Pembelajaran Mendalam AMI dengan Conda

Conda DLAMI `conda` menggunakan lingkungan virtual, mereka hadir baik multi-framework atau kerangka kerja tunggal. DLAMIs Lingkungan ini dikonfigurasi untuk menjaga instalasi kerangka kerja yang berbeda terpisah dan merampingkan peralihan antar kerangka kerja. Ini bagus untuk belajar dan bereksperimen dengan semua kerangka kerja yang ditawarkan DLAMI. Sebagian besar pengguna menemukan bahwa AMI Pembelajaran Mendalam baru dengan Conda sangat cocok untuk mereka.

Mereka sering diperbarui dengan versi terbaru dari kerangka kerja, dan memiliki driver dan perangkat lunak GPU terbaru. Mereka umumnya disebut sebagai AWS Deep Learning AMIs dalam sebagian besar dokumen. Ini DLAMIs mendukung sistem operasi Ubuntu 20.04, Ubuntu 22.04, Amazon Linux 2, Amazon Linux 2023. Dukungan sistem operasi tergantung pada dukungan dari OS upstream.

Kandidat Stabil Versus Rilis

Conda AMIs menggunakan binari yang dioptimalkan dari rilis formal terbaru dari setiap kerangka kerja. Kandidat rilis dan fitur eksperimental tidak diharapkan. Pengoptimalan tergantung pada dukungan kerangka kerja untuk teknologi akselerasi seperti Intel MKL DNN, yang mempercepat pelatihan dan inferensi pada jenis instans CPU C5 dan C4. Binari juga dikompilasi untuk mendukung set instruksi Intel tingkat lanjut termasuk namun tidak terbatas pada AVX, AVX-2, .1, dan SSE4 .2. SSE4 Ini mempercepat operasi vektor dan floating point pada arsitektur CPU Intel. Selain itu, untuk jenis instans GPU, CUDA dan cuDNN diperbarui dengan versi mana pun yang didukung rilis resmi terbaru.

AMI Pembelajaran Mendalam dengan Conda secara otomatis menginstal versi kerangka kerja yang paling dioptimalkan untuk EC2 instans Amazon Anda pada aktivasi pertama kerangka kerja. Untuk informasi lebih lanjut, lihatMenggunakan AMI Pembelajaran Mendalam dengan Conda.

Jika Anda ingin menginstal dari sumber, menggunakan opsi build khusus atau yang dioptimalkan, Dasar Pembelajaran Mendalam AMI s mungkin merupakan opsi yang lebih baik untuk Anda.

Pengakhiran Python 2

Komunitas open source Python telah secara resmi mengakhiri dukungan untuk Python 2 pada 1 Januari 2020. PyTorch Komunitas TensorFlow dan telah mengumumkan bahwa rilis TensorFlow 2.1 dan PyTorch 1.4 adalah yang terakhir mendukung Python 2. Rilis DLAMI sebelumnya (v26, v25, dll) yang berisi lingkungan Python 2 Conda terus tersedia. Namun, kami menyediakan pembaruan untuk lingkungan Python 2 Conda pada versi DLAMI yang diterbitkan sebelumnya hanya jika ada perbaikan keamanan yang diterbitkan oleh komunitas sumber terbuka untuk versi tersebut. Rilis DLAMI dengan versi terbaru PyTorch dan kerangka kerja tidak mengandung lingkungan Python 2 Conda. TensorFlow

Dukungan CUDA

Nomor versi CUDA tertentu dapat ditemukan di catatan rilis DLAMI GPU.

Selanjutnya

Pilihan Arsitektur DLAMI

Topik Terkait

- Untuk tutorial tentang menggunakan AMI Pembelajaran Mendalam dengan Conda, lihat Menggunakan AMI Pembelajaran Mendalam dengan Conda tutorialnya.

Pilihan Arsitektur DLAMI

AWS Deep Learning AMIss ditawarkan dengan arsitektur Graviton2 berbasis x86 atau berbasis AWS ARM64.

Untuk informasi tentang memulai dengan DLAMI ARM64 GPU, lihat. ARM64 DLAMI Untuk detail selengkapnya tentang jenis instans yang tersedia, lihatMemilih tipe instans DLAMI.

Selanjutnya

Opsi Sistem Operasi DLAMI

Opsi Sistem Operasi DLAMI

DLAMIs ditawarkan dalam sistem operasi berikut.

- Amazon Linux 2
- Amazon Linux 2023
- Ubuntu 20.04
- Ubuntu 22.04

Versi lama dari sistem operasi tersedia pada usang DLAMIs. Untuk informasi selengkapnya tentang penghentian DLAMI, lihat Deprecations for DLAMI

Sebelum memilih DLAMI, nilai jenis instans apa yang Anda butuhkan dan identifikasi Wilayah Anda. AWS

Selanjutnya

Memilih tipe instans DLAMI

Memilih tipe instans DLAMI

Secara lebih umum, pertimbangkan hal berikut ketika memilih jenis instance untuk DLAMI.

- Jika Anda baru mengenal pembelajaran mendalam, maka instance dengan satu GPU mungkin sesuai dengan kebutuhan Anda.
- Jika Anda sadar anggaran, maka Anda dapat menggunakan instance khusus CPU.
- Jika Anda ingin mengoptimalkan kinerja tinggi dan efisiensi biaya untuk inferensi model pembelajaran mendalam, maka Anda dapat menggunakan instance dengan chip AWS Inferentia.
- Jika Anda mencari instans GPU berkinerja tinggi dengan arsitektur CPU berbasis ARM64, maka Anda dapat menggunakan jenis instans G5G.
- Jika Anda tertarik untuk menjalankan model terlatih untuk inferensi dan prediksi, Anda dapat melampirkan Amazon Elastic Inference ke instans Amazon Anda. EC2 Amazon Elastic Inference memberi Anda akses ke akselerator dengan sebagian kecil dari GPU.
- Untuk layanan inferensi volume tinggi, satu instance CPU dengan banyak memori, atau sekelompok instance semacam itu, mungkin merupakan solusi yang lebih baik.
- Jika Anda menggunakan model besar dengan banyak data atau ukuran batch tinggi, maka Anda memerlukan instance yang lebih besar dengan lebih banyak memori. Anda juga dapat mendistribusikan model Anda ke sekelompok GPUs. Anda mungkin menemukan bahwa menggunakan instance dengan memori lebih sedikit adalah solusi yang lebih baik untuk Anda jika Anda mengurangi ukuran batch Anda. Ini dapat memengaruhi akurasi dan kecepatan pelatihan Anda.
- Jika Anda tertarik untuk menjalankan aplikasi pembelajaran mesin menggunakan NVIDIA Collective Communications Library (NCCL) yang membutuhkan komunikasi antar-simpul tingkat tinggi dalam skala besar, Anda mungkin ingin menggunakan Elastic Fabric Adapter (EFA).

Untuk detail selengkapnya tentang instance, lihat .

Topik berikut memberikan informasi tentang pertimbangan jenis instance.

> **Important**
>
> Deep Learning AMIs mencakup driver, perangkat lunak, atau toolkit yang dikembangkan, dimiliki, atau disediakan oleh NVIDIA Corporation. Anda setuju untuk menggunakan driver, perangkat lunak, atau toolkit NVIDIA ini hanya pada EC2 instans Amazon yang menyertakan perangkat keras NVIDIA.

Topik

Harga untuk DLAMI

Kerangka kerja pembelajaran mendalam yang termasuk dalam DLAMI gratis, dan masing-masing memiliki lisensi sumber terbuka sendiri. Meskipun perangkat lunak yang disertakan dalam DLAMI gratis, Anda masih harus membayar untuk perangkat keras instans Amazon EC2 yang mendasarinya.

Beberapa jenis EC2 instans Amazon diberi label gratis. Dimungkinkan untuk menjalankan DLAMI pada salah satu contoh gratis ini. Ini berarti bahwa menggunakan DLAMI sepenuhnya gratis ketika Anda hanya menggunakan kapasitas instance itu. Jika Anda membutuhkan instance yang lebih kuat dengan lebih banyak core CPU, lebih banyak ruang disk, lebih banyak RAM, atau satu atau lebih GPUs, maka Anda memerlukan instance yang tidak ada di kelas instance free-tier.

Untuk informasi selengkapnya tentang pilihan dan harga instans, lihat EC2 harga Amazon.

Ketersediaan Wilayah DLAMI

Setiap Wilayah mendukung berbagai jenis instans yang berbeda dan seringkali jenis instans memiliki biaya yang sedikit berbeda di Wilayah yang berbeda. DLAMIs tidak tersedia di setiap Wilayah, tetapi dimungkinkan untuk menyalin DLAMIs ke Wilayah pilihan Anda. Lihat Menyalin AMI untuk informasi selengkapnya. Perhatikan daftar pilihan Wilayah dan pastikan Anda memilih Wilayah yang dekat dengan Anda atau pelanggan Anda. Jika Anda berencana untuk menggunakan lebih dari satu DLAMI dan berpotensi membuat cluster, pastikan untuk menggunakan Region yang sama untuk semua node di cluster.

Untuk info lebih lanjut tentang Wilayah, kunjungi titik akhir EC2 layanan Amazon.

Selanjutnya

Instans GPU yang Direkomendasikan

Instans GPU yang Direkomendasikan

Kami merekomendasikan instance GPU untuk sebagian besar tujuan pembelajaran mendalam. Melatih model baru lebih cepat pada instance GPU daripada instance CPU. Anda dapat menskalakan secara sub-linier ketika Anda memiliki instans multi-GPU atau jika Anda menggunakan pelatihan terdistribusi di banyak instance dengan. GPUs

Jenis contoh berikut mendukung DLAMI. Untuk informasi tentang opsi tipe instans GPU dan kegunaannya, lihat dan pilih Accelerated Computing.

> **Note**
>
> Ukuran model Anda harus menjadi faktor dalam memilih instance. Jika model Anda melebihi RAM instans yang tersedia, pilih jenis instans yang berbeda dengan memori yang cukup untuk aplikasi Anda.

- Instans Amazon EC2 P6-B200 memiliki hingga 8 NVIDIA Blackwell B200. GPUs
- Amazon EC2 P6e- GB2 00 Instans memiliki hingga 4 NVIDIA Blackwell 00. GB2 GPUs
- Instans Amazon EC2 P5e memiliki hingga 8 NVIDIA Tesla H200. GPUs
- Instans Amazon EC2 P5 memiliki hingga 8 NVIDIA Tesla H100. GPUs
- Instans Amazon EC2 P4 memiliki hingga 8 NVIDIA Tesla A100. GPUs
- Instans Amazon EC2 P3 memiliki hingga 8 NVIDIA Tesla V100. GPUs
- Instans Amazon EC2 G3 memiliki hingga 4 NVIDIA Tesla M60. GPUs
- Instans Amazon EC2 G4 memiliki hingga 4 NVIDIA T4. GPUs
- Instans Amazon EC2 G5 memiliki hingga 8 NVIDIA A10G. GPUs
- Instans Amazon EC2 G6 memiliki hingga 8 NVIDIA L4. GPUs
- Instans Amazon EC2 G6e memiliki hingga 8 NVIDIA L40S Tensor Core. GPUs
- Instans Amazon EC2 G5G memiliki prosesor Graviton2 berbasis ARM64 AWS .

Instans DLAMI menyediakan perkakas untuk memantau dan mengoptimalkan proses GPU Anda. Untuk informasi selengkapnya tentang memantau proses GPU Anda, lihatPemantauan dan Optimasi GPU.

Untuk tutorial khusus tentang bekerja dengan instans G5G, lihat. ARM64 DLAMI

Selanjutnya

Instans CPU yang Direkomendasikan

Instans CPU yang Direkomendasikan

Baik Anda memiliki anggaran terbatas, belajar tentang pembelajaran mendalam, atau hanya ingin menjalankan layanan prediksi, Anda memiliki banyak opsi terjangkau dalam kategori CPU. Beberapa kerangka kerja memanfaatkan Intel MKL DNN, yang mempercepat pelatihan dan inferensi pada jenis instans CPU C5 (tidak tersedia di semua Wilayah). Untuk informasi tentang tipe instans CPU, lihat Instance dan pilih Compute Optimized.

> **Note**
>
> Ukuran model Anda harus menjadi faktor dalam memilih instance. Jika model Anda melebihi RAM instans yang tersedia, pilih jenis instans yang berbeda dengan memori yang cukup untuk aplikasi Anda.

- Instans Amazon EC2 C5 memiliki hingga 72 Intel v. CPUs Instans C5 unggul dalam pemodelan ilmiah, pemrosesan batch, analitik terdistribusi, komputasi kinerja tinggi (HPC), dan inferensi pembelajaran mesin dan mendalam.

Selanjutnya

Contoh Inferensia yang Direkomendasikan

Contoh Inferensia yang Direkomendasikan

AWS Instance inferensia dirancang untuk memberikan kinerja tinggi dan efisiensi biaya untuk beban kerja inferensi model pembelajaran mendalam. Secara khusus, jenis instans Inf2 menggunakan chip AWS Inferentia dan AWS Neuron SDK, yang terintegrasi dengan kerangka kerja pembelajaran mesin populer seperti dan. TensorFlow PyTorch

Pelanggan dapat menggunakan instans Inf2 untuk menjalankan aplikasi inferensi pembelajaran mesin skala besar seperti pencarian, mesin rekomendasi, visi komputer, pengenalan suara, pemrosesan bahasa alami, personalisasi, dan deteksi penipuan, dengan biaya terendah di cloud.

> **Note**
>
> Ukuran model Anda harus menjadi faktor dalam memilih instance. Jika model Anda melebihi RAM instans yang tersedia, pilih jenis instans yang berbeda dengan memori yang cukup untuk aplikasi Anda.

- Instans Amazon EC2 Inf2 memiliki hingga 16 chip AWS Inferentia dan throughput jaringan 100 Gbps.

Untuk informasi lebih lanjut tentang memulai dengan AWS Inferensia DLAMIs, lihatChip AWS Inferentia Dengan DLAMI.

Selanjutnya

Instans Trainium yang Direkomendasikan

Instans Trainium yang Direkomendasikan

AWS Instans Trainium dirancang untuk memberikan kinerja tinggi dan efisiensi biaya untuk beban kerja inferensi model pembelajaran mendalam. Secara khusus, jenis instans Trn1 menggunakan chip AWS Trainium dan AWS Neuron SDK, yang terintegrasi dengan kerangka kerja pembelajaran mesin populer seperti dan. TensorFlow PyTorch

Pelanggan dapat menggunakan instans Trn1 untuk menjalankan aplikasi inferensi pembelajaran mesin skala besar seperti pencarian, mesin rekomendasi, visi komputer, pengenalan suara, pemrosesan bahasa alami, personalisasi, dan deteksi penipuan, dengan biaya terendah di cloud.

> **Note**
>
> Ukuran model Anda harus menjadi faktor dalam memilih instance. Jika model Anda melebihi RAM instans yang tersedia, pilih jenis instans yang berbeda dengan memori yang cukup untuk aplikasi Anda.

- Instans Amazon EC2 Trn1 memiliki hingga 16 chip AWS Trainium dan throughput jaringan 100 Gbps.

Menyiapkan instance DLAMI

Setelah Anda memilih DLAMI dan memilih jenis instans Amazon Elastic Compute Cloud (EC2Amazon) yang ingin Anda gunakan, maka Anda siap untuk menyiapkan instans DLAMI baru Anda.

Jika Anda belum memilih jenis DLAMI EC2 dan instance, lihat. Memulai dengan DLAMI

Topik

- Menemukan ID DLAMI
- Meluncurkan instance DLAMI
- Menghubungkan ke instans DLAMI
- Menyiapkan server Jupyter Notebook pada instance DLAMI
- Membersihkan contoh DLAMI

Menemukan ID DLAMI

Setiap DLAMI memiliki pengenal unik (ID). Saat meluncurkan instans DLAMI menggunakan konsol EC2 Amazon, Anda dapat menggunakan ID DLAMI secara opsional untuk mencari DLAMI yang ingin Anda gunakan. Saat Anda meluncurkan instance DLAMI menggunakan AWS Command Line Interface AWS CLI(), ID ini diperlukan.

Anda dapat menemukan ID untuk DLAMI pilihan Anda dengan menggunakan AWS CLI perintah untuk EC2 Amazon atau Parameter Store, kemampuan dari. AWS Systems Manager Untuk petunjuk tentang menginstal dan mengonfigurasi AWS CLI, lihat Memulai dengan AWS CLI di Panduan AWS Command Line Interface Pengguna.

Using Parameter Store

Untuk menemukan ID DLAMI menggunakan ssm get-parameter

Dalam ssm get-parameterperintah berikut, untuk `--name` opsi, format nama parameter adalah*/aws/service/deeplearning/ami/$architecture/$ami_type/latest/ami-id*. Dalam format nama ini, *`architecture`* bisa berupa **`x86_64`** atau**`arm64`**. Tentukan *`ami_type`* dengan mengambil nama DLAMI dan menghapus kata kunci “mendalam”, “belajar”, dan “ami”. Nama AMI dapat ditemukan diCatatan AMIs Rilis Deep Learning.

> **Important**
>
> Untuk menggunakan perintah ini, prinsipal AWS Identity and Access Management (IAM) yang Anda gunakan harus memiliki `ssm:GetParameter` izin. Untuk informasi selengkapnya tentang prinsip IAM, lihat bagian Sumber daya tambahan dari peran IAM di Panduan Pengguna IAM.

- ```
  aws ssm get-parameter --name /aws/service/deeplearning/ami/x86_64/base-oss-nvidia-driver-ubuntu-22.04/latest/ami-id  \
  --region us-east-1 --query "Parameter.Value" --output text
  ```

  Outputnya akan serupa dengan yang berikut ini:

  ```
  ami-09ee1a996ac214ce7
  ```

  > **Tip**
  >
  > Untuk beberapa kerangka kerja DLAMI yang saat ini didukung, Anda dapat menemukan perintah contoh yang lebih spesifik di. ssm get-parameter Catatan AMIs Rilis Deep Learning Pilih tautan ke catatan rilis DLAMI pilihan Anda, lalu temukan kueri ID-nya di catatan rilis.

Using Amazon EC2 CLI

Untuk menemukan ID DLAMI menggunakan ec2 describe-images

Dalam ec2 describe-imagesperintah berikut, untuk nilai filter`Name=name`, masukkan nama DLAMI. Anda dapat menentukan versi rilis untuk kerangka kerja tertentu, atau Anda bisa mendapatkan rilis terbaru dengan mengganti nomor versi dengan tanda tanya (?).

- ```
  aws ec2 describe-images --region us-east-1 --owners amazon \
  --filters 'Name=name,Values=Deep Learning Base OSS Nvidia Driver GPU AMI (Ubuntu 22.04) ???????' 'Name=state,Values=available' \
  --query 'reverse(sort_by(Images, &amp;CreationDate))[:1].ImageId' --output text
  ```

  Outputnya akan serupa dengan yang berikut ini:

```
ami-09ee1a996ac214ce7
```

> **Tip**
>
> Untuk contoh ec2 describe-images perintah yang khusus untuk DLAMI pilihan Anda, lihat. Catatan AMIs Rilis Deep Learning Pilih tautan ke catatan rilis DLAMI pilihan Anda, lalu temukan kueri ID-nya di catatan rilis.

Langkah selanjutnya

Meluncurkan instance DLAMI

Meluncurkan instance DLAMI

Setelah Anda menemukan ID DLAMI yang ingin Anda gunakan untuk meluncurkan instance DLAMI, Anda siap untuk meluncurkan instance. Untuk meluncurkannya, Anda dapat menggunakan EC2 konsol Amazon atau AWS Command Line Interface (AWS CLI).

> **Note**
>
> Untuk panduan ini, kami mungkin membuat referensi khusus untuk Deep Learning Base OSS Nvidia Driver GPU AMI (Ubuntu 22.04). Bahkan jika Anda memilih DLAMI yang berbeda, Anda harus dapat mengikuti panduan ini.

EC2 console

> **Note**
>
> Untuk mempercepat aplikasi komputasi berkinerja tinggi (HPC) dan pembelajaran mesin, Anda dapat meluncurkan instans DLAMI dengan Elastic Fabric Adapter (EFA). Untuk instruksi khusus, lihatMeluncurkan AWS Deep Learning AMIs Instance Dengan EFA.

1. Buka EC2 konsol.

2. Perhatikan saat ini Wilayah AWS di navigasi paling atas. Jika ini bukan Wilayah yang Anda inginkan, maka ubah opsi ini sebelum Anda melanjutkan. Untuk informasi selengkapnya, lihat Titik akhir EC2 layanan Amazon EC2 di. Referensi Umum Amazon Web Services
3. Pilih Luncurkan Instans.
4. Masukkan nama untuk instans Anda dan pilih DLAMI yang tepat untuk Anda.

   a. Temukan DLAMI yang ada di AMIs My atau pilih Mulai Cepat.

   b. Cari berdasarkan ID DLAMI. Jelajahi opsi lalu pilih pilihan Anda.
5. Pilih jenis instance. Anda dapat menemukan keluarga contoh yang direkomendasikan untuk DLAMI Anda di. Catatan AMIs Rilis Deep Learning Untuk rekomendasi umum tentang jenis instans DLAMI, lihat. Memilih tipe instans DLAMI
6. Pilih Luncurkan Instans.

AWS CLI

- Untuk menggunakan AWS CLI, Anda harus memiliki ID DLAMI yang ingin Anda gunakan, jenis EC2 dan instance, Wilayah AWS dan informasi token keamanan Anda. Kemudian, Anda dapat meluncurkan instance menggunakan ec2 run-instances AWS CLI perintah.

  Untuk petunjuk tentang menginstal dan mengonfigurasi AWS CLI, lihat Memulai dengan AWS CLI di Panduan AWS Command Line Interface Pengguna. Untuk informasi selengkapnya, termasuk contoh perintah, lihat Meluncurkan, mencantumkan, dan menutup EC2 instans Amazon untuk. AWS CLI

Setelah meluncurkan instans menggunakan EC2 konsol Amazon atau AWS CLI, tunggu instans siap. Ini biasanya hanya membutuhkan beberapa menit. Anda dapat memverifikasi status instans di EC2 konsol Amazon. Untuk informasi selengkapnya, lihat Pemeriksaan status untuk EC2 instans Amazon di Panduan EC2 Pengguna Amazon.

Langkah selanjutnya

Menghubungkan ke instans DLAMI

Menghubungkan ke instans DLAMI

Setelah meluncurkan instans DLAMI dan instans sedang berjalan, Anda dapat menghubungkannya dari klien (Windows, macOS, atau Linux) menggunakan SSH. Untuk petunjuknya, lihat Connect ke instans Linux menggunakan SSH di Panduan EC2 Pengguna Amazon.

Simpan salinan perintah login SSH jika Anda ingin mengatur server Notebook Jupyter setelah Anda masuk. Untuk terhubung ke halaman web Jupyter, Anda menggunakan variasi dari perintah itu.

Langkah selanjutnya

Menyiapkan server Jupyter Notebook pada instance DLAMI

Menyiapkan server Jupyter Notebook pada instance DLAMI

Dengan server Jupyter Notebook, Anda dapat membuat dan menjalankan notebook Jupyter dari instance DLAMI Anda. Dengan notebook Jupyter, Anda dapat melakukan eksperimen pembelajaran mesin (ML) untuk pelatihan dan inferensi saat menggunakan AWS infrastruktur dan mengakses paket yang dibangun ke dalam DLAMI. Untuk informasi selengkapnya tentang notebook Jupyter, lihat Notebook Jupyter di situs web Dokumentasi Pengguna Jupyter.

Untuk menyiapkan server Jupyter Notebook, Anda harus:

- Konfigurasikan server Jupyter Notebook pada instance DLAMI Anda.
- Konfigurasikan klien Anda untuk terhubung ke server Jupyter Notebook. Kami menyediakan instruksi konfigurasi untuk klien Windows, macOS, dan Linux.
- Uji penyiapan dengan masuk ke server Jupyter Notebook.

Untuk menyelesaikan langkah-langkah ini, ikuti instruksi dalam topik berikut. Setelah menyiapkan server Jupyter Notebook, Anda dapat menjalankan contoh tutorial notebook yang dikirimkan di file. DLAMIs Untuk informasi selengkapnya, lihat Menjalankan Tutorial Notebook Jupyter.

Topik

- Mengamankan server Jupyter Notebook pada instance DLAMI
- Memulai server Jupyter Notebook pada instance DLAMI
- Menghubungkan klien ke server Jupyter Notebook pada instance DLAMI
- Masuk ke server Jupyter Notebook pada instance DLAMI

Mengamankan server Jupyter Notebook pada instance DLAMI

Agar server Jupyter Notebook Anda tetap aman, kami sarankan untuk menyiapkan kata sandi dan membuat sertifikat SSL untuk server. Untuk mengonfigurasi kata sandi dan SSL, pertama-tama sambungkan ke instans DLAMI Anda, lalu ikuti petunjuk ini.

Untuk mengamankan server Notebook Jupyter

1. Jupyter menyediakan utilitas kata sandi. Jalankan perintah berikut dan masukkan kata sandi pilihan Anda pada prompt.

   ```
   $ jupyter notebook password
   ```

   Outputnya akan terlihat seperti ini:

   ```
   Enter password:
        Verify password:
        [NotebookPasswordApp] Wrote hashed password to /home/ubuntu/.jupyter/
   jupyter_notebook_config.json
   ```

2. Buat sertifikat SSL yang ditandatangani sendiri. Ikuti petunjuk untuk mengisi wilayah Anda sesuai keinginan Anda. Anda harus masuk `.` jika Anda ingin membiarkan prompt kosong. Jawaban Anda tidak akan memengaruhi fungsionalitas sertifikat.

   ```
   $ cd ~
        $ mkdir ssl
        $ cd ssl
        $ openssl req -x509 -nodes -days 365 -newkey rsa:2048 -keyout mykey.key -out
    mycert.pem
   ```

> **Note**
>
> Anda mungkin tertarik untuk membuat sertifikat SSL reguler yang ditandatangani oleh pihak ketiga dan tidak menyebabkan browser memberi Anda peringatan keamanan. Proses ini jauh lebih terlibat. Untuk informasi selengkapnya, lihat Mengamankan server notebook di dokumentasi pengguna Jupyter Notebook.

Langkah selanjutnya

Memulai server Jupyter Notebook pada instance DLAMI

Memulai server Jupyter Notebook pada instance DLAMI

Setelah mengamankan server Jupyter Notebook dengan kata sandi dan SSL, Anda dapat memulai server. Masuk ke instans DLAMI Anda dan jalankan perintah berikut yang menggunakan sertifikat SSL yang Anda buat sebelumnya.

```
$ jupyter notebook --certfile=~/ssl/mycert.pem --keyfile ~/ssl/mykey.key
```

Dengan server dimulai, Anda sekarang dapat terhubung ke sana melalui terowongan SSH dari komputer klien Anda. Ketika server berjalan, Anda akan melihat beberapa output dari Jupyter yang mengonfirmasi bahwa server sedang berjalan. Pada titik ini, abaikan callout bahwa Anda dapat mengakses server melalui URL host lokal, karena itu tidak akan berfungsi sampai Anda membuat terowongan.

> **Note**
>
> Jupyter akan menangani lingkungan switching untuk Anda saat Anda mengganti kerangka kerja menggunakan antarmuka web Jupyter. Untuk informasi selengkapnya, lihat Beralih Lingkungan dengan Jupyter.

Langkah selanjutnya

Menghubungkan klien ke server Jupyter Notebook pada instance DLAMI

Menghubungkan klien ke server Jupyter Notebook pada instance DLAMI

Setelah Anda memulai server Jupyter Notebook pada instans DLAMI Anda, konfigurasikan klien Windows, macOS, atau Linux Anda untuk terhubung ke server. Saat Anda terhubung, Anda dapat membuat dan mengakses notebook Jupyter di server di ruang kerja Anda dan menjalankan kode pembelajaran mendalam Anda di server.

Prasyarat

Pastikan Anda memiliki yang berikut ini, yang Anda perlukan untuk mengatur terowongan SSH:

- Nama DNS publik dari EC2 instans Amazon Anda. Untuk informasi selengkapnya, lihat jenis nama host EC2 instans Amazon di Panduan EC2 Pengguna Amazon.
- Key pair untuk file kunci pribadi. Untuk informasi selengkapnya tentang mengakses key pair, lihat pasangan EC2 kunci Amazon dan EC2 instans Amazon di EC2 Panduan Pengguna Amazon.

Connect dari klien Windows, macOS, atau Linux

Untuk terhubung ke instans DLAMI Anda dari klien Windows, macOS, atau Linux, ikuti instruksi untuk sistem operasi klien Anda.

Windows

Untuk terhubung ke instans DLAMI Anda dari klien Windows menggunakan SSH

1. Gunakan klien SSH untuk Windows, seperti PuTTY. Untuk petunjuknya, lihat Connect ke instance Linux menggunakan PuTTY di EC2 Panduan Pengguna Amazon. Untuk opsi koneksi SSH lainnya, lihat Connect to Linux Anda menggunakan SSH.
2. (Opsional) Buat terowongan SSH ke server Jupyter yang sedang berjalan. Instal Git Bash di klien Windows Anda, lalu ikuti instruksi koneksi untuk klien macOS dan Linux.

macOS or Linux

Untuk terhubung ke instans DLAMI Anda dari klien macOS atau Linux menggunakan SSH

1. Buka terminal.
2. Jalankan perintah berikut untuk meneruskan semua permintaan pada port lokal 8888 ke port 8888 pada instans Amazon EC2 jarak jauh Anda. Perbarui perintah dengan mengganti lokasi kunci Anda untuk mengakses EC2 instans Amazon dan nama DNS publik EC2 instans Amazon Anda. Catatan, untuk Amazon Linux AMI, nama pengguna `ec2-user` bukan`ubuntu`.

   ```
   $ ssh -i ~/mykeypair.pem -N -f -L 8888:localhost:8888 ubuntu@ec2-###-##-##-
   ###.compute-1.amazonaws.com
   ```

   Perintah ini membuka terowongan antara klien Anda dan EC2 instans Amazon jarak jauh yang menjalankan server Jupyter Notebook.

Langkah selanjutnya

Masuk ke server Jupyter Notebook pada instance DLAMI

Masuk ke server Jupyter Notebook pada instance DLAMI

Setelah Anda menghubungkan klien Anda ke server Jupyter Notebook pada instance DLAMI Anda, Anda dapat masuk ke server.

Untuk masuk ke server di browser Anda

1. Di bilah alamat browser Anda, masukkan URL berikut, atau klik tautan ini: https://localhost:8888
2. Dengan sertifikat SSL yang ditandatangani sendiri, browser Anda akan memperingatkan Anda dan meminta Anda untuk menghindari terus mengunjungi situs web.

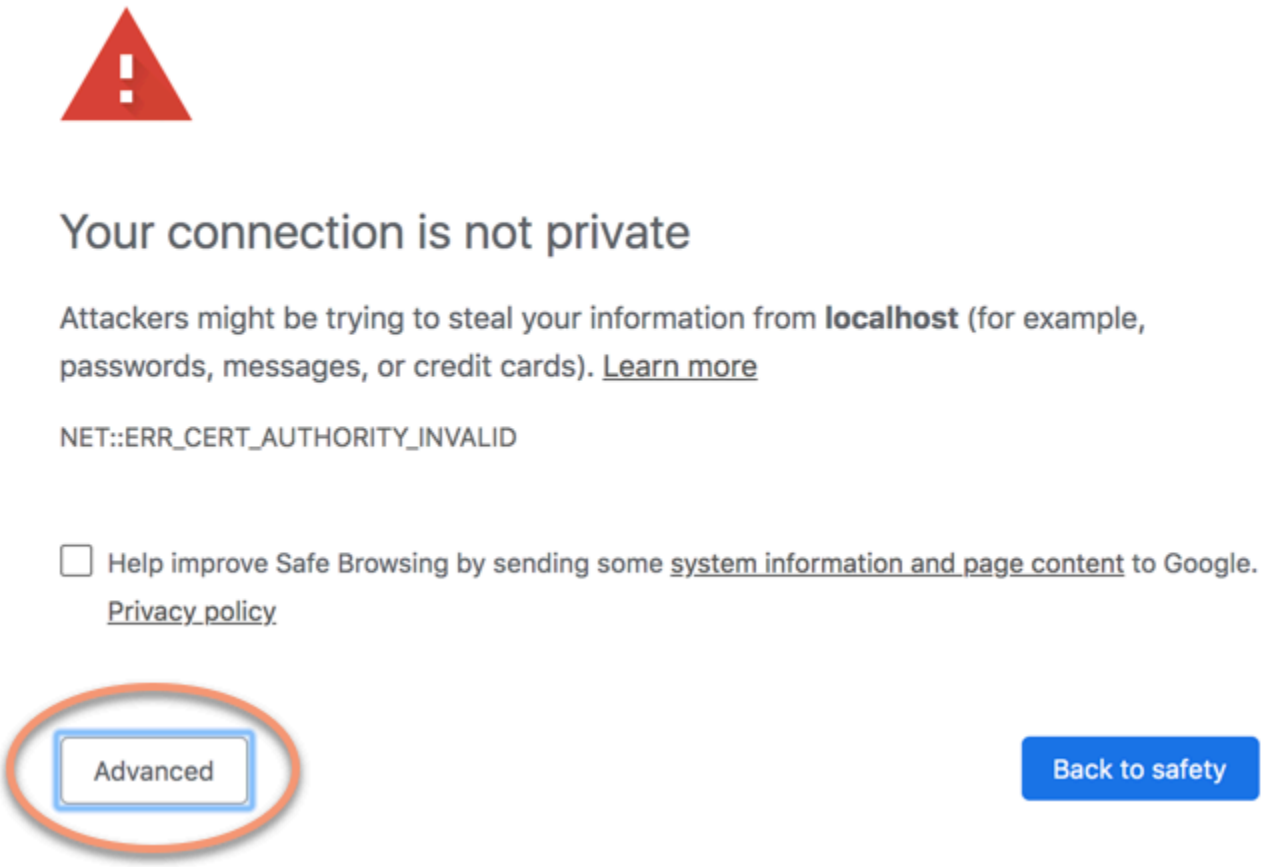

Karena Anda mengatur ini sendiri, aman untuk melanjutkan. Bergantung pada browser Anda, Anda akan mendapatkan tombol “lanjutan”, “tampilkan detail”, atau serupa.

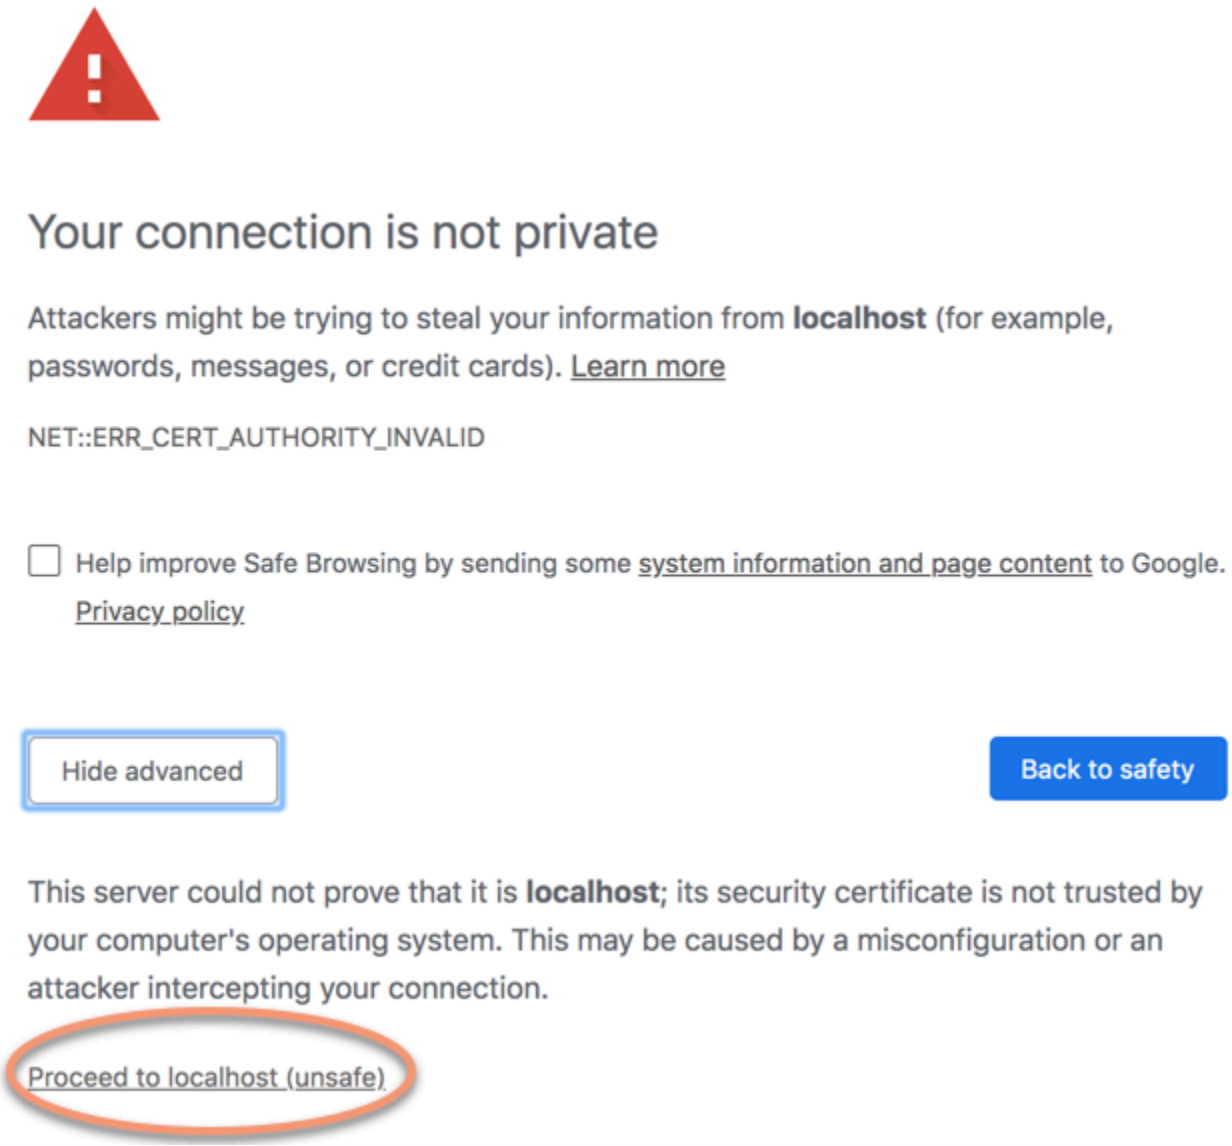

Klik ini, lalu klik tautan “lanjutkan ke localhost”. Jika koneksi berhasil, Anda melihat halaman web server Jupyter Notebook. Pada titik ini, Anda akan diminta kata sandi yang sebelumnya Anda atur.

Sekarang Anda memiliki akses ke server Jupyter Notebook yang berjalan pada instance DLAMI. Anda dapat membuat notebook baru atau menjalankan yang disediakanTutorial.

Membersihkan contoh DLAMI

Saat Anda tidak lagi membutuhkan instans DLAMI, Anda dapat menghentikannya atau menghentikannya di EC2 Amazon untuk menghindari biaya tak terduga.

Jika Anda menghentikan sebuah instance, Anda dapat menyimpannya dan memulainya nanti ketika Anda ingin menggunakannya lagi. Konfigurasi, file, dan informasi non-volatile lainnya disimpan dalam volume di Amazon Simple Storage Service (Amazon S3). Saat instans dihentikan, Anda dikenakan biaya S3 untuk mempertahankan volume, tetapi Anda tidak dikenakan biaya untuk sumber daya komputasi. Ketika Anda memulai instance lagi, itu akan memasang volume penyimpanan itu dengan data Anda.

Jika Anda menghentikan sebuah instance, itu hilang, dan Anda tidak dapat memulainya lagi. Tentu saja, Anda tidak akan dikenakan biaya lagi untuk sumber daya komputasi dengan instance yang dihentikan. Namun, data Anda masih berada di Amazon S3, dan Anda dapat terus dikenakan biaya S3. Untuk mencegah semua biaya lebih lanjut yang terkait dengan instans yang dihentikan, Anda juga harus menghapus volume penyimpanan di Amazon S3. Untuk petunjuk, lihat Menghentikan EC2 instans Amazon di EC2 Panduan Pengguna Amazon.

Untuk informasi selengkapnya tentang status EC2 instans Amazon, seperti `stopped` dan`terminated`, lihat perubahan status EC2 instans Amazon di Panduan EC2 Pengguna Amazon.

Menggunakan DLAMI

Topik

Bagian berikut menjelaskan bagaimana AMI Pembelajaran Mendalam dengan Conda dapat digunakan untuk beralih lingkungan, menjalankan kode sampel dari masing-masing kerangka kerja, dan menjalankan Jupyter sehingga Anda dapat mencoba berbagai tutorial notebook.

Menggunakan AMI Pembelajaran Mendalam dengan Conda

Topik

Pengantar AMI Pembelajaran Mendalam dengan Conda

Conda adalah sistem manajemen paket open source dan sistem manajemen lingkungan yang berjalan di Windows, macOS, dan Linux. Conda dengan cepat menginstal, menjalankan, dan memperbarui paket dan dependensinya. Conda dengan mudah membuat, menyimpan, memuat, dan beralih antar lingkungan di komputer lokal Anda.

AMI Pembelajaran Mendalam dengan Conda telah dikonfigurasi agar Anda dapat dengan mudah beralih di antara lingkungan pembelajaran yang mendalam. Instruksi berikut memandu Anda pada beberapa perintah dasar dengan`conda`. Mereka juga membantu Anda memverifikasi bahwa impor dasar kerangka kerja berfungsi, dan Anda dapat menjalankan beberapa operasi sederhana dengan

kerangka kerja. Anda kemudian dapat beralih ke tutorial yang lebih menyeluruh yang disediakan dengan DLAMI atau contoh kerangka kerja yang ditemukan di setiap situs proyek kerangka kerja.

Masuk ke DLAMI Anda

Setelah Anda masuk ke server Anda, Anda akan melihat server “message of the day” (MOTD) yang menjelaskan berbagai perintah Conda yang dapat Anda gunakan untuk beralih di antara kerangka kerja pembelajaran mendalam yang berbeda. Di bawah ini adalah contoh MOTD. MOTD spesifik Anda dapat bervariasi saat versi baru DLAMI dirilis.

```
=============================================================================
        AMI Name: Deep Learning OSS Nvidia Driver AMI (Amazon Linux 2) Version 77
        Supported EC2 instances: G4dn, G5, G6, Gr6, P4d, P4de, P5
            * To activate pre-built tensorflow environment, run: 'source activate
 tensorflow2_p310'
            * To activate pre-built pytorch environment, run: 'source activate
 pytorch_p310'
            * To activate pre-built python3 environment, run: 'source activate python3'

        NVIDIA driver version: 535.161.08

    CUDA versions available: cuda-11.7 cuda-11.8 cuda-12.0 cuda-12.1 cuda-12.2

    Default CUDA version is 12.1

    Release notes: https://docs.aws.amazon.com/dlami/latest/devguide/appendix-ami-
release-notes.html
    AWS Deep Learning AMI Homepage: https://aws.amazon.com/machine-learning/amis/
    Developer Guide and Release Notes: https://docs.aws.amazon.com/dlami/latest/
devguide/what-is-dlami.html
    Support: https://forums.aws.amazon.com/forum.jspa?forumID=263
    For a fully managed experience, check out Amazon SageMaker at https://
aws.amazon.com/sagemaker
    =============================================================================
```

Mulai TensorFlow Lingkungan

> **Note**
>
> Saat Anda meluncurkan lingkungan Conda pertama Anda, harap bersabar saat memuat. AMI Pembelajaran Mendalam dengan Conda secara otomatis menginstal versi kerangka kerja

yang paling dioptimalkan untuk EC2 instans Anda pada aktivasi pertama kerangka kerja. Anda seharusnya tidak mengharapkan penundaan berikutnya.

1. Aktifkan lingkungan TensorFlow virtual untuk Python 3.

```
$ source activate tensorflow2_p310
```

2. Mulai terminal IPython.

```
(tensorflow2_p310)$ ipython
```

3. Jalankan TensorFlow program cepat.

```
import tensorflow as tf
hello = tf.constant('Hello, TensorFlow!')
sess = tf.Session()
print(sess.run(hello))
```

Anda akan melihat “Halo, Tensorflow!”

Selanjutnya

Menjalankan Tutorial Notebook Jupyter

Beralih ke Lingkungan PyTorch Python 3

Jika Anda masih berada di konsol IPython, `quit()` gunakan, lalu bersiaplah untuk beralih lingkungan.

- Aktifkan lingkungan PyTorch virtual untuk Python 3.

```
$ source activate pytorch_p310
```

Uji Beberapa PyTorch Kode

Untuk menguji instalasi Anda, gunakan Python untuk menulis PyTorch kode yang membuat dan mencetak array.

1. Mulai terminal IPython.

```
(pytorch_p310)$ ipython
```

2. Impor PyTorch.

```
import torch
```

Anda mungkin melihat pesan peringatan tentang paket pihak ketiga. Anda dapat mengabaikannya.

3. Buat matriks 5x3 dengan elemen yang diinisialisasi secara acak. Cetak array.

```
x = torch.rand(5, 3)
print(x)
```

Verifikasi hasilnya.

```
tensor([[0.3105, 0.5983, 0.5410],
        [0.0234, 0.0934, 0.0371],
        [0.9740, 0.1439, 0.3107],
        [0.6461, 0.9035, 0.5715],
        [0.4401, 0.7990, 0.8913]])
```

Menghapus Lingkungan

Jika Anda kehabisan ruang pada DLAMI, Anda dapat memilih untuk menghapus paket Conda yang tidak Anda gunakan:

```
conda env list
conda env remove --name <env_name>
```

Menggunakan Basis Pembelajaran Mendalam AMI

Menggunakan Basis Pembelajaran Mendalam AMI

Base AMI hadir dengan platform dasar driver GPU dan pustaka akselerasi untuk menerapkan lingkungan pembelajaran mendalam Anda sendiri yang disesuaikan. Secara default AMI dikonfigurasi

dengan salah satu lingkungan versi NVIDIA CUDA. Anda juga dapat beralih di antara berbagai versi CUDA. Lihat instruksi berikut untuk cara melakukan ini.

Mengkonfigurasi Versi CUDA

Anda dapat memverifikasi versi CUDA dengan menjalankan `nvcc` program NVIDIA.

```
nvcc --version
```

Anda dapat memilih dan memverifikasi versi CUDA tertentu dengan perintah bash berikut:

```
sudo rm /usr/local/cuda
sudo ln -s /usr/local/cuda-12.0 /usr/local/cuda
```

Untuk informasi selengkapnya, lihat catatan rilis DLAMI Dasar.

Menjalankan Tutorial Notebook Jupyter

Tutorial dan contoh dikirimkan dengan masing-masing sumber proyek pembelajaran mendalam dan dalam banyak kasus mereka akan berjalan pada DLAMI apa pun. Jika Anda memilihPembelajaran Mendalam AMI dengan Conda, Anda mendapatkan manfaat tambahan dari beberapa tutorial pilihan yang sudah disiapkan dan siap untuk dicoba.

> **Important**
>
> Untuk menjalankan tutorial notebook Jupyter yang diinstal pada DLAMI, Anda harus melakukannya. Menyiapkan server Jupyter Notebook pada instance DLAMI

Setelah server Jupyter berjalan, Anda dapat menjalankan tutorial melalui browser web Anda. Jika Anda menjalankan AMI Pembelajaran Mendalam dengan Conda atau jika Anda telah menyiapkan lingkungan Python, Anda dapat mengganti kernel Python dari antarmuka notebook Jupyter. Pilih kernel yang sesuai sebelum mencoba menjalankan tutorial khusus kerangka kerja. Contoh lebih lanjut dari ini disediakan untuk pengguna AMI Pembelajaran Mendalam dengan Conda.

> **Note**
>
> Banyak tutorial memerlukan modul Python tambahan yang mungkin tidak diatur pada DLAMI Anda. Jika Anda mendapatkan kesalahan seperti`"xyz module not found"`, masuk ke DLAMI, aktifkan lingkungan seperti dijelaskan di atas, lalu instal modul yang diperlukan.

> **Tip**
>
> Tutorial dan contoh pembelajaran mendalam sering bergantung pada satu atau lebih GPUs. Jika tipe instans Anda tidak memiliki GPU, Anda mungkin perlu mengubah beberapa kode contoh untuk menjalankannya.

Menavigasi Tutorial yang Diinstal

Setelah Anda masuk ke server Jupyter dan dapat melihat direktori tutorial (pada Deep Learning AMI dengan Conda saja), Anda akan disajikan dengan folder tutorial dengan masing-masing nama kerangka kerja. Jika Anda tidak melihat kerangka kerja terdaftar, maka tutorial tidak tersedia untuk kerangka kerja itu pada DLAMI Anda saat ini. Klik pada nama framework untuk melihat tutorial yang terdaftar, lalu klik tutorial untuk meluncurkannya.

Pertama kali Anda menjalankan notebook pada AMI Pembelajaran Mendalam dengan Conda, ia akan ingin tahu lingkungan mana yang ingin Anda gunakan. Ini akan meminta Anda untuk memilih dari daftar. Setiap lingkungan diberi nama sesuai dengan pola ini:

`Environment (conda_framework_python-version)`

Misalnya, Anda mungkin melihat`Environment (conda_mxnet_p36)`, yang menandakan bahwa lingkungan memiliki MXNet dan Python 3. Variasi lain dari ini adalah`Environment (conda_mxnet_p27)`, yang menandakan bahwa lingkungan memiliki MXNet dan Python 2.

> **Tip**
>
> Jika Anda khawatir tentang versi CUDA mana yang aktif, salah satu cara untuk melihatnya adalah di MOTD saat Anda pertama kali masuk ke DLAMI.

Beralih Lingkungan dengan Jupyter

Jika Anda memutuskan untuk mencoba tutorial untuk kerangka kerja yang berbeda, pastikan untuk memverifikasi kernel yang sedang berjalan. Info ini dapat dilihat di kanan atas antarmuka Jupyter, tepat di bawah tombol logout. Anda dapat mengubah kernel pada notebook yang terbuka dengan mengklik item menu Jupyter Kernel, lalu Change Kernel, dan kemudian mengklik lingkungan yang sesuai dengan notebook yang sedang Anda jalankan.

Pada titik ini Anda harus menjalankan ulang sel apa pun karena perubahan pada kernel akan menghapus status apa pun yang telah Anda jalankan sebelumnya.

> **Tip**
>
> Beralih antar kerangka kerja bisa menyenangkan dan mendidik, namun Anda bisa kehabisan memori. Jika Anda mulai mengalami kesalahan, lihat jendela terminal yang menjalankan server Jupyter. Ada pesan bermanfaat dan pencatatan kesalahan di sini, dan Anda mungkin melihat out-of-memory kesalahan. Untuk memperbaikinya, Anda dapat pergi ke halaman beranda server Jupyter Anda, klik tab Running, lalu klik Shutdown untuk setiap tutorial yang mungkin masih berjalan di latar belakang dan memakan semua memori Anda.

Tutorial

Berikut ini adalah tutorial tentang cara menggunakan AMI Pembelajaran Mendalam dengan perangkat lunak Conda.

Topik

- Mengaktifkan Kerangka Kerja
- Pelatihan terdistribusi menggunakan Adaptor Kain Elastis
- Pemantauan dan Optimasi GPU
- Chip AWS Inferentia Dengan DLAMI
- ARM64 DLAMI
- Inferensi
- Penyajian Model

Mengaktifkan Kerangka Kerja

Berikut ini adalah kerangka kerja pembelajaran mendalam yang diinstal pada AMI Pembelajaran Mendalam dengan Conda. Klik pada kerangka kerja untuk mempelajari cara mengaktifkannya.

Topik

PyTorch

Mengaktifkan PyTorch

Ketika paket Conda stabil dari kerangka kerja dirilis, itu diuji dan diinstal sebelumnya pada DLAMI. Jika Anda ingin menjalankan build malam terbaru yang belum teruji, Anda dapat secara manual. Instal PyTorch Nightly Build (eksperimental)

Untuk mengaktifkan kerangka kerja yang saat ini diinstal, ikuti petunjuk ini pada AMI Pembelajaran Mendalam Anda dengan Conda.

Untuk PyTorch pada Python 3 dengan CUDA dan MKL-DNN, jalankan perintah ini:

```
$ source activate pytorch_p310
```

Mulai terminal IPython.

```
(pytorch_p310)$ ipython
```

Jalankan PyTorch program cepat.

```
import torch
x = torch.rand(5, 3)
print(x)
print(x.size())
y = torch.rand(5, 3)
print(torch.add(x, y))
```

Anda akan melihat array acak awal dicetak, kemudian ukurannya, dan kemudian penambahan array acak lainnya.

Instal PyTorch Nightly Build (eksperimental)

Cara menginstal PyTorch dari build malam

Anda dapat menginstal PyTorch build terbaru ke salah satu atau kedua lingkungan PyTorch Conda di AMI Pembelajaran Mendalam Anda dengan Conda.

1. • (Opsi untuk Python 3) - Aktifkan lingkungan Python 3: PyTorch

   ```
   $ source activate pytorch_p310
   ```

2. Langkah-langkah yang tersisa mengasumsikan Anda menggunakan `pytorch_p310` lingkungan. Hapus yang saat ini diinstal PyTorch:

   ```
   (pytorch_p310)$ pip uninstall torch
   ```

3. • (Opsi untuk instance GPU) - Instal build malam terbaru dengan CUDA.0: PyTorch

   ```
   (pytorch_p310)$ pip install torch_nightly -f https://download.pytorch.org/whl/
   nightly/cu100/torch_nightly.html
   ```

   • (Opsi untuk instance CPU) - Instal build malam terbaru PyTorch untuk instance tanpa: GPUs

   ```
   (pytorch_p310)$ pip install torch_nightly -f https://download.pytorch.org/whl/
   nightly/cpu/torch_nightly.html
   ```

4. Untuk memverifikasi bahwa Anda telah berhasil menginstal build nightly terbaru, mulai IPython terminal dan periksa versi. PyTorch

   ```
   (pytorch_p310)$ ipython
   ```

   ```
   import torch
   print (torch.__version__)
   ```

   Output harus mencetak sesuatu yang mirip dengan `1.0.0.dev20180922`

5. Untuk memverifikasi bahwa PyTorch nightly build berfungsi dengan baik dengan contoh MNIST, Anda dapat menjalankan skrip pengujian dari PyTorch repositori contoh:

   ```
   (pytorch_p310)$ cd ~
   (pytorch_p310)$ git clone https://github.com/pytorch/examples.git pytorch_examples
   ```

```
(pytorch_p310)$ cd pytorch_examples/mnist
(pytorch_p310)$ python main.py || exit 1
```

Lebih Banyak Tutorial

Untuk tutorial dan contoh lebih lanjut, lihat dokumen resmi kerangka kerja, PyTorch dokumentasi, dan PyTorchsitus web.

TensorFlow 2

Tutorial ini menunjukkan cara mengaktifkan TensorFlow 2 pada instance yang menjalankan AMI Pembelajaran Mendalam dengan Conda (DLAMI di Conda) dan menjalankan program 2. TensorFlow

Ketika paket Conda stabil dari kerangka kerja dirilis, itu diuji dan diinstal sebelumnya pada DLAMI.

Mengaktifkan 2 TensorFlow

Untuk menjalankan TensorFlow DLAMI dengan Conda

1. Untuk mengaktifkan TensorFlow 2, buka instance Amazon Elastic Compute Cloud (Amazon EC2) dari DLAMI dengan Conda.
2. Untuk TensorFlow 2 dan Keras 2 pada Python 3 dengan CUDA 10.1 dan MKL-DNN, jalankan perintah ini:

   ```
   $ source activate tensorflow2_p310
   ```
3. Mulai terminal IPython:

   ```
   (tensorflow2_p310)$ ipython
   ```
4. Jalankan program TensorFlow 2 untuk memverifikasi bahwa itu berfungsi dengan baik:

   ```
   import tensorflow as tf
   hello = tf.constant('Hello, TensorFlow!')
   tf.print(hello)
   ```

   `Hello, TensorFlow!`akan muncul di layar Anda.

Lebih Banyak Tutorial

Untuk tutorial dan contoh lainnya, lihat TensorFlow dokumentasi untuk API TensorFlow Python atau lihat situs webnya. TensorFlow

Pelatihan terdistribusi menggunakan Adaptor Kain Elastis

Elastic Fabric Adapter (EFA) adalah perangkat jaringan yang dapat Anda lampirkan ke instans DLAMI Anda untuk mempercepat aplikasi High Performance Computing (HPC). EFA memungkinkan Anda mencapai kinerja aplikasi klaster HPC lokal, dengan skalabilitas, fleksibilitas, dan elastisitas yang disediakan oleh Cloud. AWS

Topik berikut menunjukkan kepada Anda bagaimana memulai menggunakan EFA dengan DLAMI.

> **Note**
>
> Pilih DLAMI Anda dari daftar DLAMI GPU Dasar ini

Topik

- Meluncurkan AWS Deep Learning AMIs Instance Dengan EFA
- Menggunakan EFA pada DLAMI

Meluncurkan AWS Deep Learning AMIs Instance Dengan EFA

Base DLAMI terbaru siap digunakan dengan EFA dan dilengkapi dengan driver yang diperlukan, modul kernel, libfabric, openmpi dan plugin NCCL OFI untuk instance GPU.

Anda dapat menemukan versi CUDA yang didukung dari DLAMI Dasar di catatan rilis.

Catatan:

- Saat menjalankan Aplikasi NCCL menggunakan `mpirun` EFA, Anda harus menentukan jalur lengkap ke instalasi yang didukung EFA sebagai:

```
/opt/amazon/openmpi/bin/mpirun <command>
```

- Untuk mengaktifkan aplikasi Anda menggunakan EFA, tambahkan `FI_PROVIDER="efa"` ke `mpirun` perintah seperti yang ditunjukkan padaMenggunakan EFA pada DLAMI.

Topik

- Mempersiapkan Grup Keamanan Berkemampuan EFA
- Luncurkan Instance Anda
- Verifikasi Lampiran EFA

Mempersiapkan Grup Keamanan Berkemampuan EFA

EFA membutuhkan grup keamanan yang memungkinkan semua lalu lintas masuk dan keluar ke dan dari grup keamanan itu sendiri. Untuk informasi selengkapnya, lihat Dokumentasi EFA.

1. Buka EC2 konsol Amazon di https://console.aws.amazon.com/ec2/.
2. Di panel navigasi, pilih Grup Keamanan lalu pilih Buat Grup Keamanan.
3. Di jendela Buat Grup Keamanan, lakukan hal berikut:
   - Untuk Nama grup keamanan, masukkan nama deskriptif untuk grup keamanan, seperti `EFA-enabled security group`.
   - (Opsional) Untuk Deskripsi, masukkan deskripsi singkat grup keamanan.
   - Untuk VPC, pilih VPC untuk tujuan peluncuran instans Anda yang didukung EFA.
   - Pilih Buat.
4. Pilih grup keamanan yang Anda buat, dan pada tab Deskripsi, salin ID Grup.
5. Pada tab Inbound dan Outbound, lakukan hal berikut:
   - Pilih Edit.
   - Untuk Jenis, pilih Semua lalu lintas.
   - Untuk Sumber, pilih Kustom.
   - Rekatkan ID grup keamanan yang Anda salin ke bidang.
   - Pilih Simpan.
6. Aktifkan lalu lintas masuk yang mengacu pada Otorisasi Lalu Lintas Masuk untuk Instans Linux Anda. Jika Anda melewati langkah ini, Anda tidak akan dapat berkomunikasi dengan instans DLAMI Anda.

Luncurkan Instance Anda

EFA pada saat AWS Deep Learning AMIs ini didukung dengan jenis instance dan sistem operasi berikut:

- P3dn: Amazon Linux 2, Ubuntu 20.04
- P4d, P4de: Amazon Linux 2, Amazon Linux 2023, Ubuntu 20.04, Ubuntu 22.04
- P5, P5e, P5en: Amazon Linux 2, Amazon Linux 2023, Ubuntu 20.04, Ubuntu 22.04

Bagian berikut menunjukkan cara meluncurkan instance DLAMI yang diaktifkan EFA. Untuk informasi selengkapnya tentang meluncurkan instans berkemampuan EFA, lihat Meluncurkan Instans Berkemampuan EFA ke dalam Grup Penempatan Cluster.

1. Buka EC2 konsol Amazon di https://console.aws.amazon.com/ec2/.
2. Pilih Luncurkan Instans.
3. Pada halaman Pilih AMI, pilih DLAMI yang didukung yang ditemukan di Halaman Catatan Rilis DLAMI
4. Pada halaman Pilih Jenis Instance, pilih salah satu jenis instans yang didukung berikut, lalu pilih Berikutnya: Konfigurasi Detail Instance. Lihat tautan ini untuk daftar instans yang didukung: Memulai EFA dan MPI
5. Pada halaman Konfigurasi Detail Instans, lakukan langkah berikut:
   - Untuk Jumlah instans, masukkan jumlah instans yang diaktifkan EFA yang ingin Anda luncurkan.
   - Untuk Jaringan dan Subnet, pilih VPC dan subnet sebagai tujuan peluncuran instans.
   - [Opsional] Untuk grup Penempatan, pilih Tambahkan instance ke grup penempatan. Untuk performa terbaik, luncurkan instance dalam grup penempatan.
   - [Opsional] Untuk nama grup Penempatan, pilih Tambahkan ke grup penempatan baru, masukkan nama deskriptif untuk grup penempatan, lalu untuk strategi grup Penempatan, pilih klaster.
   - Pastikan untuk mengaktifkan “Adaptor Kain Elastis” di halaman ini. Jika opsi ini dinonaktifkan, ubah subnet menjadi subnet yang mendukung jenis instans yang Anda pilih.
   - Di bagian Antarmuka Jaringan, untuk perangkat eth0, pilih Antarmuka jaringan baru. Anda dapat secara opsional menentukan IPv4 alamat utama dan satu atau lebih IPv4 alamat sekunder. Jika Anda meluncurkan instance ke subnet yang memiliki blok IPv6 CIDR terkait, Anda dapat secara opsional menentukan IPv6 alamat utama dan satu atau beberapa alamat sekunder. IPv6
   - Pilih Berikutnya: Tambahkan Penyimpanan.

6. Di halaman Tambahkan Penyimpanan, tentukan volume yang akan dilampirkan ke instans selain volume yang ditentukan oleh AMI (seperti volume perangkat root), lalu pilih Selanjutnya: Tambahkan Tanda.
7. Di halaman Tambahkan Tanda, tentukan tanda untuk instans, seperti nama yang mudah digunakan, lalu pilih Selanjutnya: Konfigurasikan Grup Keamanan.
8. Pada halaman Konfigurasi Grup Keamanan, untuk Menetapkan grup keamanan, pilih Pilih grup keamanan yang ada, lalu pilih grup keamanan yang Anda buat sebelumnya.
9. Pilih Tinjau dan Luncurkan.
10. Di halaman Tinjau Peluncuran Instans, tinjau pengaturannya, lalu pilih Luncurkan untuk memilih pasangan kunci dan meluncurkan instans Anda.

Verifikasi Lampiran EFA

Dari Konsol

Setelah meluncurkan instance, periksa detail instance di AWS Console. Untuk melakukan ini, pilih instance di EC2 konsol dan lihat Tab Deskripsi di panel bawah pada halaman. Temukan parameter 'Network Interfaces: eth0' dan klik eth0 yang membuka pop-up. Pastikan 'Adaptor Kain Elastis' diaktifkan.

Jika EFA tidak diaktifkan, Anda dapat memperbaikinya dengan:

- Mengakhiri EC2 instance dan meluncurkan yang baru dengan langkah yang sama. Pastikan EFA terpasang.
- Lampirkan EFA ke instance yang ada.

  1. Di EC2 konsol, buka Network Interfaces.
  2. Klik Buat Antarmuka Jaringan.
  3. Pilih subnet yang sama dengan instans Anda.
  4. Pastikan untuk mengaktifkan 'Adaptor Kain Elastis' dan klik Buat.
  5. Kembali ke Tab EC2 Instances dan pilih instance Anda.
  6. Buka Actions: Instance State dan hentikan instance sebelum Anda melampirkan EFA.
  7. Dari Tindakan, pilih Jaringan: Lampirkan Antarmuka Jaringan.
  8. Pilih antarmuka yang baru saja Anda buat dan klik lampirkan.
  9. Mulai ulang instans Anda.

Dari Instance

Skrip pengujian berikut sudah ada di DLAMI. Jalankan untuk memastikan bahwa modul kernel dimuat dengan benar.

```
$ fi_info -p efa
```

Output-nya semestinya mirip dengan yang berikut.

```
provider: efa
    fabric: EFA-fe80::e5:56ff:fe34:56a8
    domain: efa_0-rdm
    version: 2.0
    type: FI_EP_RDM
    protocol: FI_PROTO_EFA
provider: efa
    fabric: EFA-fe80::e5:56ff:fe34:56a8
    domain: efa_0-dgrm
    version: 2.0
    type: FI_EP_DGRAM
    protocol: FI_PROTO_EFA
provider: efa;ofi_rxd
    fabric: EFA-fe80::e5:56ff:fe34:56a8
    domain: efa_0-dgrm
    version: 1.0
    type: FI_EP_RDM
    protocol: FI_PROTO_RXD
```

Verifikasi Konfigurasi Grup Keamanan

Skrip pengujian berikut sudah ada di DLAMI. Jalankan untuk memastikan bahwa grup keamanan yang Anda buat dikonfigurasi dengan benar.

```
$ cd /opt/amazon/efa/test/
$ ./efa_test.sh
```

Output-nya semestinya mirip dengan yang berikut.

```
Starting server...
Starting client...
bytes   #sent   #ack     total       time     MB/sec    usec/xfer   Mxfers/sec
```

```
64      10      =10     1.2k        0.02s      0.06    1123.55       0.00
256     10      =10     5k          0.00s     17.66      14.50       0.07
1k      10      =10     20k         0.00s     67.81      15.10       0.07
4k      10      =10     80k         0.00s    237.45      17.25       0.06
64k     10      =10     1.2m        0.00s    921.10      71.15       0.01
1m      10      =10     20m         0.01s   2122.41     494.05       0.00
```

Jika berhenti merespons atau tidak selesai, pastikan grup keamanan Anda memiliki inbound/outbound aturan yang benar.

Menggunakan EFA pada DLAMI

Bagian berikut menjelaskan cara menggunakan EFA untuk menjalankan aplikasi multi-node pada. AWS Deep Learning AMIs

Menjalankan Aplikasi Multi-Node dengan EFA

Untuk menjalankan aplikasi di seluruh cluster node konfigurasi berikut diperlukan

Topik

- Aktifkan SSH Tanpa Kata Sandi
- Buat File Host
- Tes NCCL

Aktifkan SSH Tanpa Kata Sandi

Pilih satu node di cluster Anda sebagai node pemimpin. Node yang tersisa disebut sebagai node anggota.

1. Pada node pemimpin, hasilkan keypair RSA.

   ```
   ssh-keygen -t rsa -N "" -f ~/.ssh/id_rsa
   ```

2. Ubah izin kunci privat pada simpul pemimpin.

   ```
   chmod 600 ~/.ssh/id_rsa
   ```

3. Salin kunci publik `~/.ssh/id_rsa.pub` ke dan tambahkan ke `~/.ssh/authorized_keys` node anggota di cluster.

4. Anda sekarang harus dapat langsung masuk ke node anggota dari node pemimpin menggunakan ip pribadi.

```
ssh <member private ip>
```

5. Nonaktifkan strictHostKey Memeriksa dan mengaktifkan penerusan agen pada node pemimpin dengan menambahkan yang berikut ini ke file ~/.ssh/config pada node pemimpin:

```
Host *
    ForwardAgent yes
Host *
    StrictHostKeyChecking no
```

6. Pada instans Amazon Linux 2, jalankan perintah berikut pada node pemimpin untuk memberikan izin yang benar ke file konfigurasi:

```
chmod 600 ~/.ssh/config
```

Buat File Host

Pada node pemimpin, buat file host untuk mengidentifikasi node di cluster. File host harus memiliki entri untuk setiap node di cluster. Buat file ~/hosts dan tambahkan setiap node menggunakan ip pribadi sebagai berikut:

```
localhost slots=8
<private ip of node 1> slots=8
<private ip of node 2> slots=8
```

Tes NCCL

> **Note**
>
> Tes ini telah dijalankan menggunakan EFA versi 1.38.0 dan OFI NCCL Plugin 1.13.2.

Di bawah ini adalah subset dari Tes NCCL yang disediakan oleh Nvidia untuk menguji fungsionalitas dan kinerja melalui beberapa node komputasi

Instans yang Didukung: P3dn, P4, P5, P5e, P5en

Tes Kinerja

Uji Kinerja NCCL Multi-node pada P4D.24xlarge

Untuk memeriksa Kinerja NCCL dengan EFA, jalankan uji Kinerja NCCL standar yang tersedia di Repo Pengujian NCCL resmi. DLAMI dilengkapi dengan tes ini yang sudah dibangun untuk CUDA XX.X. Anda juga dapat menjalankan skrip Anda sendiri dengan EFA.

Saat membuat skrip Anda sendiri, lihat panduan berikut:

- Gunakan jalur lengkap ke mpirun seperti yang ditunjukkan pada contoh saat menjalankan aplikasi NCCL dengan EFA.
- Ubah params np dan N berdasarkan jumlah instance dan GPUs di cluster Anda.
- Tambahkan flag NCCL_DEBUG=INFO dan pastikan bahwa log menunjukkan penggunaan EFA sebagai “Penyedia Terpilih adalah EFA”.
- Mengatur Lokasi Log Pelatihan untuk mengurai validasi

```
TRAINING_LOG="testEFA_$(date +"%N").log"
```

Gunakan perintah `watch nvidia-smi` pada salah satu node anggota untuk memantau penggunaan GPU. `watch nvidia-smi`Perintah berikut adalah untuk versi CUDA xx.x generik dan bergantung pada Sistem Operasi instance Anda. Anda dapat menjalankan perintah untuk versi CUDA yang tersedia di EC2 instans Amazon Anda dengan mengganti versi CUDA dalam skrip.

- Amazon Linux 2, Amazon Linux 2023:

```
 $ /opt/amazon/openmpi/bin/mpirun -n 16 -N 8 \
-x NCCL_DEBUG=INFO --mca pml ^cm \
-x LD_LIBRARY_PATH=/usr/local/cuda-xx.x/efa/lib:/usr/local/cuda-xx.x/lib:/usr/
local/cuda-xx.x/lib64:/usr/local/cuda-xx.x:/opt/amazon/efa/lib64:/opt/amazon/openmpi/
lib64:$LD_LIBRARY_PATH \
--hostfile hosts --mca btl tcp,self --mca btl_tcp_if_exclude lo,docker0 --bind-to
 none \
/usr/local/cuda-xx.x/efa/test-cuda-xx.x/all_reduce_perf -b 8 -e 1G -f 2 -g 1 -c 1 -n
 100 | tee ${TRAINING_LOG}
```

- Ubuntu 20.04, Ubuntu 20.04:

```
$ /opt/amazon/openmpi/bin/mpirun -n 16 -N 8 \
```

```
-x NCCL_DEBUG=INFO --mca pml ^cm \
-x LD_LIBRARY_PATH=/usr/local/cuda-xx.x/efa/lib:/usr/local/cuda-xx.x/lib:/usr/
local/cuda-xx.x/lib64:/usr/local/cuda-xx.x:/opt/amazon/efa/lib:/opt/amazon/openmpi/
lib:$LD_LIBRARY_PATH \
--hostfile hosts --mca btl tcp,self --mca btl_tcp_if_exclude lo,docker0 --bind-to
 none \
/usr/local/cuda-xx.x/efa/test-cuda-xx.x/all_reduce_perf -b 8 -e 1G -f 2 -g 1 -c 1 -n
 100 | tee ${TRAINING_LOG}
```

Output Anda akan terlihat seperti berikut:

```
# nThread 1 nGpus 1 minBytes 8 maxBytes 1073741824 step: 2(factor) warmup iters: 5
 iters: 100 agg iters: 1 validation: 1 graph: 0
#
# Using devices
#  Rank  0 Group  0 Pid  33378 on ip-172-31-42-25 device  0 [0x10] NVIDIA A100-
SXM4-40GB
#  Rank  1 Group  0 Pid  33379 on ip-172-31-42-25 device  1 [0x10] NVIDIA A100-
SXM4-40GB
#  Rank  2 Group  0 Pid  33380 on ip-172-31-42-25 device  2 [0x20] NVIDIA A100-
SXM4-40GB
#  Rank  3 Group  0 Pid  33381 on ip-172-31-42-25 device  3 [0x20] NVIDIA A100-
SXM4-40GB
#  Rank  4 Group  0 Pid  33382 on ip-172-31-42-25 device  4 [0x90] NVIDIA A100-
SXM4-40GB
#  Rank  5 Group  0 Pid  33383 on ip-172-31-42-25 device  5 [0x90] NVIDIA A100-
SXM4-40GB
#  Rank  6 Group  0 Pid  33384 on ip-172-31-42-25 device  6 [0xa0] NVIDIA A100-
SXM4-40GB
#  Rank  7 Group  0 Pid  33385 on ip-172-31-42-25 device  7 [0xa0] NVIDIA A100-
SXM4-40GB
#  Rank  8 Group  0 Pid  30378 on ip-172-31-43-8 device  0 [0x10] NVIDIA A100-SXM4-40GB
#  Rank  9 Group  0 Pid  30379 on ip-172-31-43-8 device  1 [0x10] NVIDIA A100-SXM4-40GB
#  Rank 10 Group  0 Pid  30380 on ip-172-31-43-8 device  2 [0x20] NVIDIA A100-SXM4-40GB
#  Rank 11 Group  0 Pid  30381 on ip-172-31-43-8 device  3 [0x20] NVIDIA A100-SXM4-40GB
#  Rank 12 Group  0 Pid  30382 on ip-172-31-43-8 device  4 [0x90] NVIDIA A100-SXM4-40GB
#  Rank 13 Group  0 Pid  30383 on ip-172-31-43-8 device  5 [0x90] NVIDIA A100-SXM4-40GB
#  Rank 14 Group  0 Pid  30384 on ip-172-31-43-8 device  6 [0xa0] NVIDIA A100-SXM4-40GB
#  Rank 15 Group  0 Pid  30385 on ip-172-31-43-8 device  7 [0xa0] NVIDIA A100-SXM4-40GB
ip-172-31-42-25:33385:33385 [7] NCCL INFO cudaDriverVersion 12060
ip-172-31-43-8:30383:30383 [5] NCCL INFO Bootstrap : Using ens32:172.31.43.8
ip-172-31-43-8:30383:30383 [5] NCCL INFO NCCL version 2.23.4+cuda12.5
```

```
...
ip-172-31-42-25:33384:33451 [6] NCCL INFO NET/OFI Initializing aws-ofi-nccl 1.13.2-aws
ip-172-31-42-25:33384:33451 [6] NCCL INFO NET/OFI Using Libfabric version 1.22
ip-172-31-42-25:33384:33451 [6] NCCL INFO NET/OFI Using CUDA driver version 12060 with
 runtime 12050
ip-172-31-42-25:33384:33451 [6] NCCL INFO NET/OFI Configuring AWS-specific options
ip-172-31-42-25:33384:33451 [6] NCCL INFO NET/OFI Setting provider_filter to efa
ip-172-31-42-25:33384:33451 [6] NCCL INFO NET/OFI Setting FI_EFA_FORK_SAFE environment
 variable to 1
ip-172-31-42-25:33384:33451 [6] NCCL INFO NET/OFI Setting NCCL_NVLSTREE_MAX_CHUNKSIZE
 to 512KiB
ip-172-31-42-25:33384:33451 [6] NCCL INFO NET/OFI Setting NCCL_NVLS_CHUNKSIZE to 512KiB
ip-172-31-42-25:33384:33451 [6] NCCL INFO NET/OFI Running on p4d.24xlarge platform,
 Setting NCCL_TOPO_FILE environment variable to /opt/amazon/ofi-nccl/share/aws-ofi-
nccl/xml/p4d-24xl-topo.xml
...
------------------------------some output truncated----------------------------------
#                                                              out-of-place
          in-place
#       size         count      type   redop    root     time   algbw   busbw #wrong
  time   algbw   busbw #wrong
#        (B)    (elements)                               (us)  (GB/s)  (GB/s)
  (us)  (GB/s)  (GB/s)
           8             2     float     sum      -1    180.3    0.00    0.00      0
 179.3    0.00    0.00      0
          16             4     float     sum      -1    178.1    0.00    0.00      0
 177.6    0.00    0.00      0
          32             8     float     sum      -1    178.5    0.00    0.00      0
 177.9    0.00    0.00      0
          64            16     float     sum      -1    178.8    0.00    0.00      0
 178.7    0.00    0.00      0
         128            32     float     sum      -1    178.2    0.00    0.00      0
 177.8    0.00    0.00      0
         256            64     float     sum      -1    178.6    0.00    0.00      0
 178.8    0.00    0.00      0
         512           128     float     sum      -1    177.2    0.00    0.01      0
 177.1    0.00    0.01      0
        1024           256     float     sum      -1    179.2    0.01    0.01      0
 179.3    0.01    0.01      0
        2048           512     float     sum      -1    181.3    0.01    0.02      0
 181.2    0.01    0.02      0
        4096          1024     float     sum      -1    184.2    0.02    0.04      0
 183.9    0.02    0.04      0
```

```
        8192          2048     float     sum      -1    191.2    0.04    0.08       0
 190.6    0.04    0.08      0
       16384          4096     float     sum      -1    202.5    0.08    0.15       0
 202.3    0.08    0.15      0
       32768          8192     float     sum      -1    233.0    0.14    0.26       0
 232.1    0.14    0.26      0
       65536         16384     float     sum      -1    238.6    0.27    0.51       0
 235.1    0.28    0.52      0
      131072         32768     float     sum      -1    237.2    0.55    1.04       0
 236.8    0.55    1.04      0
      262144         65536     float     sum      -1    248.3    1.06    1.98       0
 247.0    1.06    1.99      0
      524288        131072     float     sum      -1    309.2    1.70    3.18       0
 307.7    1.70    3.20      0
     1048576        262144     float     sum      -1    408.7    2.57    4.81       0
 404.3    2.59    4.86      0
     2097152        524288     float     sum      -1    613.5    3.42    6.41       0
 607.9    3.45    6.47      0
     4194304       1048576     float     sum      -1    924.5    4.54    8.51       0
 914.8    4.58    8.60      0
     8388608       2097152     float     sum      -1   1059.5    7.92   14.85       0
 1054.3    7.96   14.92      0
    16777216       4194304     float     sum      -1   1269.9   13.21   24.77       0
 1272.0   13.19   24.73      0
    33554432       8388608     float     sum      -1   1642.7   20.43   38.30       0
 1636.7   20.50   38.44      0
    67108864      16777216     float     sum      -1   2446.7   27.43   51.43       0
 2445.8   27.44   51.45      0
   134217728      33554432     float     sum      -1   4143.6   32.39   60.73       0
 4142.4   32.40   60.75      0
   268435456      67108864     float     sum      -1   7351.9   36.51   68.46       0
 7346.7   36.54   68.51      0
   536870912     134217728     float     sum      -1    13717   39.14   73.39       0
 13703   39.18   73.46      0
  1073741824     268435456     float     sum      -1    26416   40.65   76.21       0
 26420   40.64   76.20      0
...
# Out of bounds values : 0 OK
# Avg bus bandwidth    : 15.5514
```

Tes Validasi

Untuk memvalidasi bahwa tes EFA mengembalikan hasil yang valid, silakan gunakan tes berikut untuk mengonfirmasi:

- Dapatkan jenis instance menggunakan EC2 Metadata Instance:

```
TOKEN=$(curl -X PUT "http://169.254.169.254/latest/api/token" -H "X-aws-ec2-metadata-
token-ttl-seconds: 21600")
INSTANCE_TYPE=$(curl -H "X-aws-ec2-metadata-token: $TOKEN" -v http://169.254.169.254/
latest/meta-data/instance-type)
```

- Jalankan Tes Kinerja
- Mengatur Parameter Berikut

```
CUDA_VERSION
CUDA_RUNTIME_VERSION
NCCL_VERSION
```

- Validasi Hasil seperti yang ditunjukkan:

```
RETURN_VAL=`echo $?`
if [ ${RETURN_VAL} -eq 0 ]; then

    # [0] NCCL INFO NET/OFI Initializing aws-ofi-nccl 1.13.2-aws
    # [0] NCCL INFO NET/OFI Using CUDA driver version 12060 with runtime 12010

    # cudaDriverVersion 12060  --> This is max supported cuda version by nvidia
 driver
    # NCCL version 2.23.4+cuda12.5 --> This is NCCL version compiled with cuda
 version

    # Validation of logs
    grep "NET/OFI Configuring AWS-specific options" ${TRAINING_LOG} || { echo "AWS-
specific options text not found"; exit 1; }
    grep "busbw" ${TRAINING_LOG} || { echo "busbw text not found"; exit 1; }
    grep "Avg bus bandwidth " ${TRAINING_LOG} || { echo "Avg bus bandwidth text not
 found"; exit 1; }
    grep "NCCL version $NCCL_VERSION" ${TRAINING_LOG} || { echo "Text not found: NCCL
 version $NCCL_VERSION"; exit 1; }
    if [[ ${INSTANCE_TYPE} == "p4d.24xlarge" ]]; then
        grep "NET/Libfabric/0/GDRDMA" ${TRAINING_LOG} || { echo "Text not found: NET/
Libfabric/0/GDRDMA"; exit 1; }
```

```
        grep "NET/OFI Selected Provider is efa (found 4 nics)" ${TRAINING_LOG} ||
 { echo "Selected Provider is efa text not found"; exit 1; }
    elif [[ ${INSTANCE_TYPE} == "p4de.24xlarge" ]]; then
        grep "NET/Libfabric/0/GDRDMA" ${TRAINING_LOG} || { echo "Avg bus bandwidth
 text not found"; exit 1; }
        grep "NET/OFI Selected Provider is efa (found 4 nics)" ${TRAINING_LOG} ||
 { echo "Avg bus bandwidth text not found"; exit 1; }
    elif [[ ${INSTANCE_TYPE} == "p5.48xlarge" ]]; then
        grep "NET/Libfabric/0/GDRDMA" ${TRAINING_LOG} || { echo "Avg bus bandwidth
 text not found"; exit 1; }
        grep "NET/OFI Selected Provider is efa (found 32 nics)" ${TRAINING_LOG} ||
 { echo "Avg bus bandwidth text not found"; exit 1; }
    elif [[ ${INSTANCE_TYPE} == "p5e.48xlarge" ]]; then
        grep "NET/Libfabric/0/GDRDMA" ${TRAINING_LOG} || { echo "Avg bus bandwidth
 text not found"; exit 1; }
        grep "NET/OFI Selected Provider is efa (found 32 nics)" ${TRAINING_LOG} ||
 { echo "Avg bus bandwidth text not found"; exit 1; }
    elif [[ ${INSTANCE_TYPE} == "p5en.48xlarge" ]]; then
        grep "NET/Libfabric/0/GDRDMA" ${TRAINING_LOG} || { echo "Avg bus bandwidth
 text not found"; exit 1; }
        grep "NET/OFI Selected Provider is efa (found 16 nics)" ${TRAINING_LOG} ||
 { echo "Avg bus bandwidth text not found"; exit 1; }
    elif [[ ${INSTANCE_TYPE} == "p3dn.24xlarge" ]]; then
        grep "NET/OFI Selected Provider is efa (found 4 nics)" ${TRAINING_LOG} ||
 { echo "Selected Provider is efa text not found"; exit 1; }
    fi
    echo "***************************** check_efa_nccl_all_reduce passed for cuda
 version ${CUDA_VERSION} *****************************"
else
    echo "***************************** check_efa_nccl_all_reduce failed for cuda
 version ${CUDA_VERSION} *****************************"
fi
```

- Untuk mengakses data benchmark, kita dapat mengurai baris terakhir dari output tabel dari tes Multi Node all_reduce:

```
benchmark=$(sudo cat ${TRAINING_LOG} | grep '1073741824' | tail -n1 | awk -F " "
 '{{print $12}}' | sed 's/ //' | sed  's/  5e-07//')
if [[ -z "${benchmark}" ]]; then
  echo "benchmark variable is empty"
  exit 1
fi
```

```
echo "Benchmark throughput: ${benchmark}"
```

Pemantauan dan Optimasi GPU

Bagian berikut akan memandu Anda melalui opsi pengoptimalan dan pemantauan GPU. Bagian ini diatur seperti alur kerja biasa dengan pemantauan mengawasi prapemrosesan dan pelatihan.

- Pemantauan
  - Monitor GPUs dengan CloudWatch
- Pengoptimalan
  - Pemrosesan awal
  - Pelatihan

Pemantauan

DLAMI Anda sudah diinstal sebelumnya dengan beberapa alat pemantauan GPU. Panduan ini juga menyebutkan alat yang tersedia untuk diunduh dan dipasang.

- Monitor GPUs dengan CloudWatch- utilitas prainstal yang melaporkan statistik penggunaan GPU ke Amazon. CloudWatch
- nvidia-smi CLI - utilitas untuk memantau komputasi GPU secara keseluruhan dan pemanfaatan memori. Ini sudah diinstal pada Anda AWS Deep Learning AMIs (DLAMI).
- Pustaka NVMLC - API berbasis C untuk mengakses fungsi pemantauan dan manajemen GPU secara langsung. Ini digunakan oleh CLI nvidia-smi di bawah kap dan sudah diinstal sebelumnya pada DLAMI Anda. Ini juga memiliki ikatan Python dan Perl untuk memfasilitasi pengembangan dalam bahasa-bahasa tersebut. Utilitas gpumon.py yang sudah diinstal sebelumnya pada DLAMI Anda menggunakan paket pynvml. dari. nvidia-ml-py
- NVIDIA DCGM - Alat manajemen cluster. Kunjungi halaman pengembang untuk mempelajari cara menginstal dan mengkonfigurasi alat ini.

> **Tip**
>
> Lihat blog pengembang NVIDIA untuk info terbaru tentang penggunaan alat CUDA yang diinstal DLAMI Anda:

- Pemantauan TensorCore pemanfaatan menggunakan Nsight IDE dan nvprof.

Monitor GPUs dengan CloudWatch

Saat Anda menggunakan DLAMI dengan GPU, Anda mungkin menemukan bahwa Anda mencari cara untuk melacak penggunaannya selama pelatihan atau inferensi. Ini dapat berguna untuk mengoptimalkan pipeline data Anda, dan menyetel jaringan pembelajaran mendalam Anda.

Ada dua cara untuk mengonfigurasi metrik GPU dengan: CloudWatch

- Konfigurasikan metrik dengan AWS CloudWatch agen (Disarankan)
- Konfigurasikan metrik dengan skrip yang sudah diinstal sebelumnya `gpumon.py`

Konfigurasikan metrik dengan AWS CloudWatch agen (Disarankan)

Integrasikan DLAMI Anda dengan agen CloudWatch terpadu untuk mengonfigurasi metrik GPU dan memantau pemanfaatan proses bersama GPU di instans akselerasi Amazon. EC2

Ada empat cara untuk mengonfigurasi metrik GPU dengan DLAMI Anda:

- Konfigurasikan metrik GPU minimal
- Konfigurasikan metrik GPU sebagian
- Konfigurasikan semua metrik GPU yang tersedia
- Konfigurasikan metrik GPU khusus

Untuk informasi tentang pembaruan dan patch keamanan, lihat Penambalan keamanan untuk agen AWS CloudWatch

Prasyarat

Untuk memulai, Anda harus mengonfigurasi izin IAM EC2 instans Amazon yang memungkinkan instans Anda mendorong metrik. CloudWatch Untuk langkah-langkah mendetail, lihat Membuat peran IAM dan pengguna untuk digunakan dengan CloudWatch agen.

Konfigurasikan metrik GPU minimal

Konfigurasikan metrik GPU minimal menggunakan layanan. `dlami-cloudwatch-agent@minimal systemd` Layanan ini mengonfigurasi metrik berikut:

- `utilization_gpu`
- `utilization_memory`

Anda dapat menemukan `systemd` layanan untuk metrik GPU minimal yang telah dikonfigurasi sebelumnya di lokasi berikut:

```
/opt/aws/amazon-cloudwatch-agent/etc/dlami-amazon-cloudwatch-agent-minimal.json
```

Aktifkan dan mulai `systemd` layanan dengan perintah berikut:

```
sudo systemctl enable dlami-cloudwatch-agent@minimal
sudo systemctl start dlami-cloudwatch-agent@minimal
```

Konfigurasikan metrik GPU sebagian

Konfigurasikan metrik GPU sebagian menggunakan layanan. `dlami-cloudwatch-agent@partial` `systemd` Layanan ini mengonfigurasi metrik berikut:

- `utilization_gpu`
- `utilization_memory`
- `memory_total`
- `memory_used`
- `memory_free`

Anda dapat menemukan `systemd` layanan untuk metrik GPU sebagian yang telah dikonfigurasi sebelumnya di lokasi berikut:

```
/opt/aws/amazon-cloudwatch-agent/etc/dlami-amazon-cloudwatch-agent-partial.json
```

Aktifkan dan mulai `systemd` layanan dengan perintah berikut:

```
sudo systemctl enable dlami-cloudwatch-agent@partial
sudo systemctl start dlami-cloudwatch-agent@partial
```

Konfigurasikan semua metrik GPU yang tersedia

Konfigurasikan semua metrik GPU yang tersedia menggunakan layanan. `dlami-cloudwatch-agent@all` `systemd` Layanan ini mengonfigurasi metrik berikut:

- `utilization_gpu`
- `utilization_memory`
- `memory_total`
- `memory_used`
- `memory_free`
- `temperature_gpu`
- `power_draw`
- `fan_speed`
- `pcie_link_gen_current`
- `pcie_link_width_current`
- `encoder_stats_session_count`
- `encoder_stats_average_fps`
- `encoder_stats_average_latency`
- `clocks_current_graphics`
- `clocks_current_sm`
- `clocks_current_memory`
- `clocks_current_video`

Anda dapat menemukan `systemd` layanan untuk semua metrik GPU yang telah dikonfigurasi sebelumnya di lokasi berikut:

```
/opt/aws/amazon-cloudwatch-agent/etc/dlami-amazon-cloudwatch-agent-all.json
```

Aktifkan dan mulai `systemd` layanan dengan perintah berikut:

```
sudo systemctl enable dlami-cloudwatch-agent@all
sudo systemctl start dlami-cloudwatch-agent@all
```

Konfigurasikan metrik GPU khusus

Jika metrik yang telah dikonfigurasi sebelumnya tidak memenuhi persyaratan Anda, Anda dapat membuat file konfigurasi CloudWatch agen kustom.

Buat file konfigurasi khusus

Untuk membuat file konfigurasi khusus, lihat langkah-langkah terperinci di Buat atau edit file konfigurasi CloudWatch agen secara manual.

Untuk contoh ini, asumsikan bahwa definisi skema terletak di`/opt/aws/amazon-cloudwatch-agent/etc/amazon-cloudwatch-agent.json`.

Konfigurasikan metrik dengan file kustom Anda

Jalankan perintah berikut untuk mengkonfigurasi CloudWatch agen sesuai dengan file kustom Anda:

```
sudo /opt/aws/amazon-cloudwatch-agent/bin/amazon-cloudwatch-agent-ctl \
-a fetch-config -m ec2 -s -c \
file:/opt/aws/amazon-cloudwatch-agent/etc/amazon-cloudwatch-agent.json
```

Penambalan keamanan untuk agen AWS CloudWatch

Baru dirilis DLAMIs dikonfigurasi dengan patch keamanan AWS CloudWatch agen terbaru yang tersedia. Lihat bagian berikut untuk memperbarui DLAMI Anda saat ini dengan patch keamanan terbaru tergantung pada sistem operasi pilihan Anda.

Amazon Linux 2

Gunakan `yum` untuk mendapatkan patch keamanan AWS CloudWatch agen terbaru untuk Amazon Linux 2 DLAMI.

```
sudo yum update
```

Ubuntu

Untuk mendapatkan patch AWS CloudWatch keamanan terbaru untuk DLAMI dengan Ubuntu, Anda perlu menginstal ulang agen AWS CloudWatch menggunakan tautan unduhan Amazon S3.

```
wget https://s3.region.amazonaws.com/amazoncloudwatch-agent-region/ubuntu/arm64/latest/
amazon-cloudwatch-agent.deb
```

Untuk informasi selengkapnya tentang menginstal AWS CloudWatch agen menggunakan tautan unduhan Amazon S3, lihat Menginstal dan menjalankan CloudWatch agen di server Anda.

Konfigurasikan metrik dengan skrip yang sudah diinstal sebelumnya **`gpumon.py`**

Sebuah utilitas bernama gpumon.py sudah diinstal pada DLAMI Anda. Ini terintegrasi dengan CloudWatch dan mendukung pemantauan penggunaan per GPU: memori GPU, suhu GPU, dan Daya GPU. Script secara berkala mengirimkan data yang dipantau ke CloudWatch. Anda dapat mengonfigurasi tingkat perincian untuk data yang dikirim CloudWatch dengan mengubah beberapa pengaturan dalam skrip. Namun, sebelum memulai skrip, Anda harus mengatur CloudWatch untuk menerima metrik.

Cara mengatur dan menjalankan pemantauan GPU dengan CloudWatch

1. Buat pengguna IAM, atau ubah pengguna yang sudah ada agar memiliki kebijakan untuk memublikasikan metrik ke CloudWatch. Jika Anda membuat pengguna baru, harap perhatikan kredensialnya karena Anda akan membutuhkannya di langkah berikutnya.

   Kebijakan IAM untuk mencari adalah “cloudwatch:”. PutMetricData Kebijakan yang ditambahkan adalah sebagai berikut:

   ```
   {
      "Version": "2012-10-17",
      "Statement": [
           {
               "Action": [
                   "cloudwatch:PutMetricData"
                ],
                "Effect": "Allow",
                "Resource": "*"
           }
      ]
   }
   ```

   > **Tip**
   >
   > Untuk informasi selengkapnya tentang membuat pengguna IAM dan menambahkan kebijakan untuk CloudWatch, lihat CloudWatch dokumentasi.

2. Pada DLAMI Anda, AWS jalankan configure dan tentukan kredenal pengguna IAM.

```
$ aws configure
```

3. Anda mungkin perlu membuat beberapa modifikasi pada utilitas gpumon sebelum menjalankannya. Anda dapat menemukan utilitas gpumon dan README di lokasi yang ditentukan dalam blok kode berikut. Untuk informasi selengkapnya tentang `gpumon.py` skrip, lihat lokasi skrip Amazon S3.

```
Folder: ~/tools/GPUCloudWatchMonitor
Files:  ~/tools/GPUCloudWatchMonitor/gpumon.py
       ~/tools/GPUCloudWatchMonitor/README
```

   Opsi:

   - Ubah wilayah di gpumon.py jika instance Anda TIDAK ada di us-east-1.
   - Ubah parameter lain seperti CloudWatch `namespace` atau periode pelaporan dengan`store_reso`.

4. Saat ini skrip hanya mendukung Python 3. Aktifkan lingkungan Python 3 kerangka kerja pilihan Anda atau aktifkan lingkungan umum Python 3 DLAMI.

```
$ source activate python3
```

5. Jalankan utilitas gpumon di latar belakang.

```
(python3)$ python gpumon.py &
```

6. Buka browser Anda ke metrik https://console.aws.amazon.com/cloudwatch/lalu pilih. Ini akan memiliki namespace ". DeepLearningTrain

> **Tip**
>
> Anda dapat mengubah namespace dengan memodifikasi gpumon.py. Anda juga dapat mengubah interval pelaporan dengan menyesuaikan`store_reso`.

Berikut ini adalah contoh CloudWatch bagan pelaporan pada menjalankan gpumon.py memantau pekerjaan pelatihan pada instance p2.8xlarge.

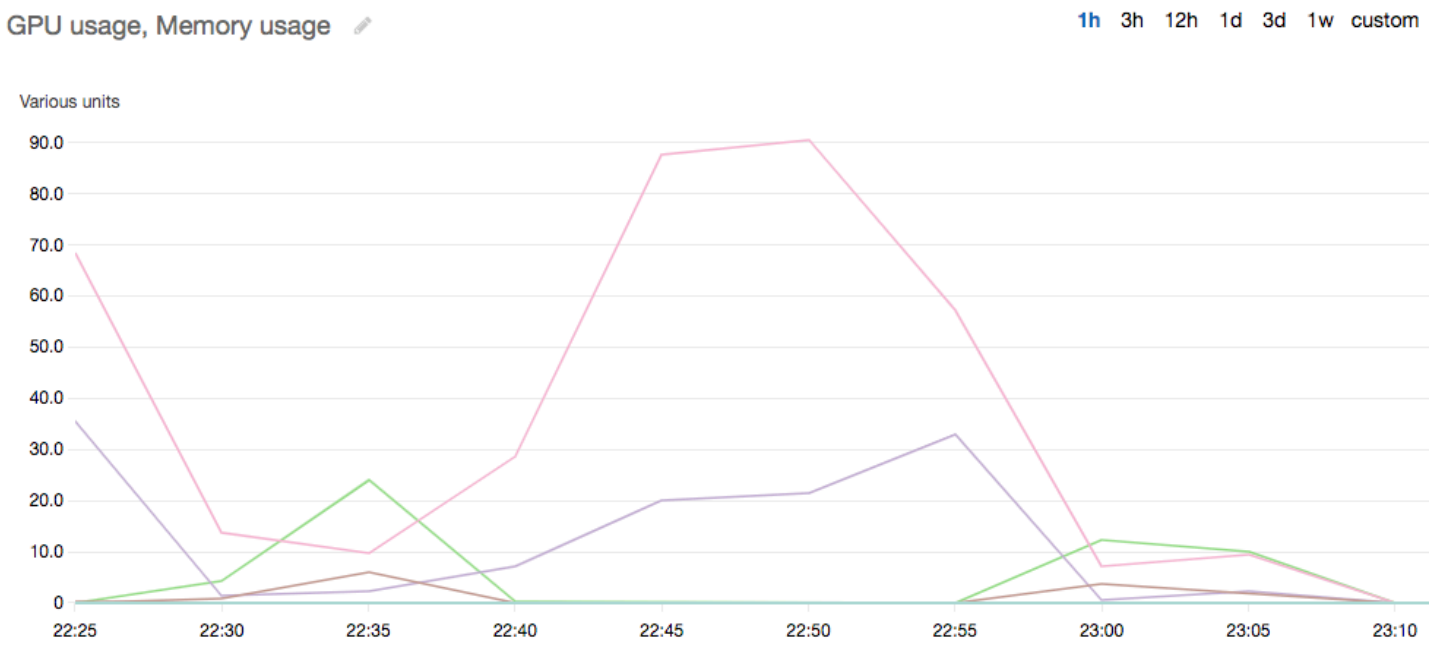

Anda mungkin tertarik dengan topik lain tentang pemantauan dan pengoptimalan GPU ini:

- Pemantauan
  - Monitor GPUs dengan CloudWatch
- Pengoptimalan
  - Pemrosesan awal
  - Pelatihan

Pengoptimalan

Untuk memaksimalkan GPUs, Anda dapat mengoptimalkan pipeline data dan menyetel jaringan pembelajaran mendalam Anda. Seperti yang dijelaskan bagan berikut, implementasi naif atau dasar dari jaringan saraf mungkin menggunakan GPU secara tidak konsisten dan tidak secara maksimal. Saat Anda mengoptimalkan preprocessing dan pemuatan data, Anda dapat mengurangi hambatan dari CPU ke GPU Anda. Anda dapat menyesuaikan jaringan saraf itu sendiri, dengan menggunakan hibridisasi (bila didukung oleh kerangka kerja), menyesuaikan ukuran batch, dan menyinkronkan panggilan. Anda juga dapat menggunakan pelatihan presisi ganda (float16 atau int8) di sebagian besar kerangka kerja, yang dapat memiliki efek dramatis pada peningkatan throughput.

Bagan berikut menunjukkan peningkatan kinerja kumulatif saat menerapkan pengoptimalan yang berbeda. Hasil Anda akan tergantung pada data yang Anda proses dan jaringan yang Anda optimalkan.

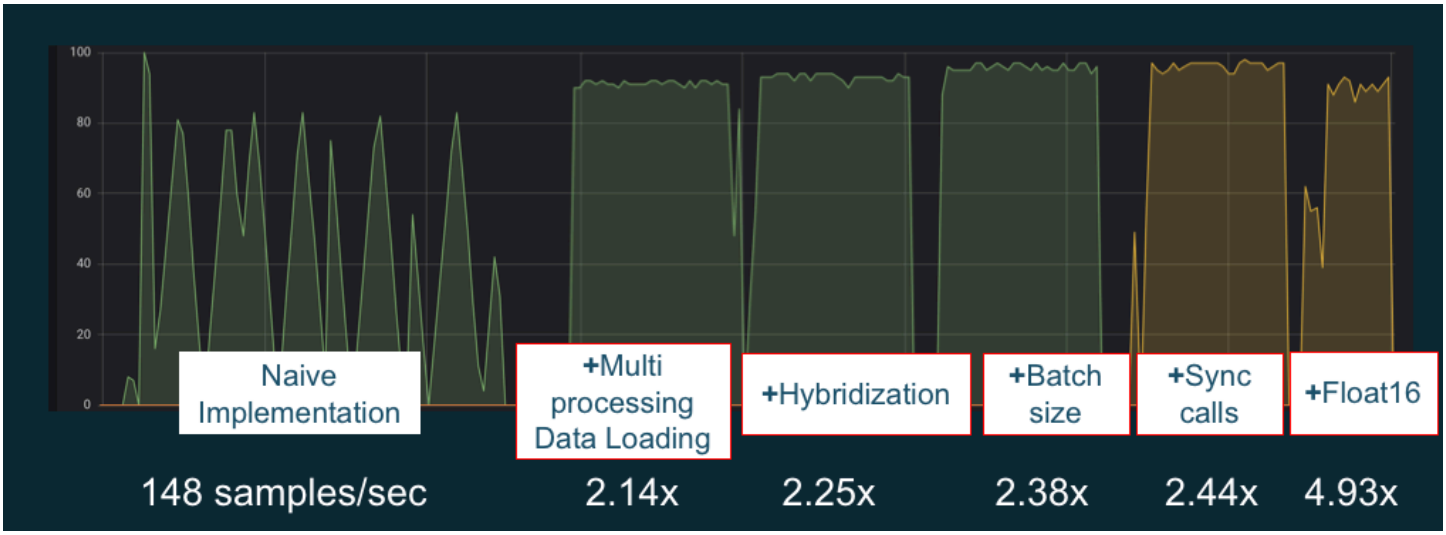

Contoh optimasi kinerja GPU. Sumber bagan: Trik Kinerja dengan MXNet Gluon

Panduan berikut memperkenalkan opsi yang akan bekerja dengan DLAMI Anda dan membantu Anda meningkatkan kinerja GPU.

Topik

- Pemrosesan awal
- Pelatihan

Pemrosesan awal

Preprocessing data melalui transformasi atau augmentasi seringkali dapat menjadi proses yang terikat CPU, dan ini bisa menjadi hambatan dalam keseluruhan pipeline Anda. Kerangka kerja memiliki operator bawaan untuk pemrosesan gambar, tetapi DALI (Data Augmentation Library) menunjukkan peningkatan kinerja dibandingkan opsi bawaan kerangka kerja.

- Perpustakaan Augmentasi Data NVIDIA (DALI): DALI membongkar augmentasi data ke GPU. Ini tidak diinstal sebelumnya pada DLAMI, tetapi Anda dapat mengaksesnya dengan menginstalnya atau memuat wadah kerangka kerja yang didukung pada DLAMI Anda atau instans Amazon Elastic Compute Cloud lainnya. Lihat halaman proyek DALI di situs web NVIDIA untuk detailnya. Untuk contoh kasus penggunaan dan untuk mengunduh contoh kode, lihat contoh Kinerja Pelatihan SageMaker Preprocessing.
- NVJPEG: perpustakaan dekoder JPEG yang dipercepat GPU untuk pemrogram C. Ini mendukung decoding gambar tunggal atau batch serta operasi transformasi berikutnya yang umum dalam

pembelajaran mendalam. nvJpeg dilengkapi dengan DALI, atau Anda dapat mengunduh dari halaman nvjpeg situs web NVIDIA dan menggunakannya secara terpisah.

Anda mungkin tertarik dengan topik lain tentang pemantauan dan pengoptimalan GPU ini:

- Pemantauan
  - Monitor GPUs dengan CloudWatch
- Pengoptimalan
  - Pemrosesan awal
  - Pelatihan

Pelatihan

Dengan pelatihan presisi campuran, Anda dapat menggunakan jaringan yang lebih besar dengan jumlah memori yang sama, atau mengurangi penggunaan memori dibandingkan dengan jaringan presisi tunggal atau ganda Anda, dan Anda akan melihat peningkatan kinerja komputasi. Anda juga mendapatkan manfaat dari transfer data yang lebih kecil dan lebih cepat, faktor penting dalam pelatihan terdistribusi beberapa node. Untuk memanfaatkan pelatihan presisi campuran, Anda perlu menyesuaikan pengecoran data dan penskalaan kerugian. Berikut ini adalah panduan yang menjelaskan cara melakukan ini untuk kerangka kerja yang mendukung presisi campuran.

- NVIDIA Deep Learning SDK - dokumen di situs web NVIDIA yang menjelaskan implementasi presisi campuran untuk,, dan. MXNet PyTorch TensorFlow

> **Tip**
>
> Pastikan untuk memeriksa situs web untuk kerangka pilihan Anda, dan cari “presisi campuran” atau “fp16" untuk teknik pengoptimalan terbaru. Berikut adalah beberapa panduan presisi campuran yang mungkin berguna bagi Anda:
>
> - Pelatihan presisi campuran dengan TensorFlow (video) - di situs blog NVIDIA.
> - Pelatihan presisi campuran menggunakan float16 dengan MXNet - artikel FAQ di situs web. MXNet
> - NVIDIA Apex: alat untuk pelatihan presisi campuran yang mudah dengan PyTorch - artikel blog di situs web NVIDIA.

Anda mungkin tertarik dengan topik lain tentang pemantauan dan pengoptimalan GPU ini:

- Pemantauan
  - Monitor GPUs dengan CloudWatch
- Pengoptimalan
  - Pemrosesan awal
  - Pelatihan

Chip AWS Inferentia Dengan DLAMI

AWS Inferentia adalah chip pembelajaran mesin khusus yang dirancang oleh AWS yang dapat Anda gunakan untuk prediksi inferensi kinerja tinggi. Untuk menggunakan chip, siapkan instans Amazon Elastic Compute Cloud dan gunakan kit pengembangan perangkat lunak AWS Neuron (SDK) untuk memanggil chip Inferentia. Untuk memberikan pengalaman Inferensia terbaik kepada pelanggan, Neuron telah dibangun ke dalam AWS Deep Learning AMIs (DLAMI).

Topik berikut menunjukkan kepada Anda bagaimana memulai menggunakan Inferentia dengan DLAMI.

Daftar Isi

Meluncurkan Instance DLAMI dengan Neuron AWS

DLAMI terbaru siap digunakan AWS dengan Inferentia dan dilengkapi dengan AWS paket Neuron API. Untuk meluncurkan instans DLAMI, lihat Meluncurkan dan Mengonfigurasi DLAMI. Setelah Anda memiliki DLAMI, gunakan langkah-langkah di sini untuk memastikan bahwa chip Inferentia AWS dan sumber daya Neuron AWS Anda aktif.

Daftar Isi

Verifikasi Instance Anda

Sebelum menggunakan instance Anda, verifikasi bahwa itu diatur dan dikonfigurasi dengan benar dengan Neuron.

Mengidentifikasi Perangkat AWS Inferensia

Untuk mengidentifikasi jumlah perangkat Inferentia pada instans Anda, gunakan perintah berikut:

```
neuron-ls
```

Jika instans Anda memiliki perangkat Inferentia yang terpasang padanya, output Anda akan terlihat mirip dengan yang berikut ini:

```
+--------+--------+--------+-----------+--------------+
| NEURON | NEURON | NEURON | CONNECTED |     PCI      |
| DEVICE | CORES  | MEMORY |  DEVICES  |     BDF      |
+--------+--------+--------+-----------+--------------+
| 0      | 4      | 8 GB   | 1         | 0000:00:1c.0 |
| 1      | 4      | 8 GB   | 2, 0      | 0000:00:1d.0 |
| 2      | 4      | 8 GB   | 3, 1      | 0000:00:1e.0 |
| 3      | 4      | 8 GB   | 2         | 0000:00:1f.0 |
+--------+--------+--------+-----------+--------------+
```

Output yang disediakan diambil dari instance INF1.6xLarge dan menyertakan kolom berikut:

- PERANGKAT NEURON: ID logis yang ditetapkan ke NeuronDevice. ID ini digunakan saat mengonfigurasi beberapa runtime untuk menggunakan yang berbeda. NeuronDevices
- NEURON CORES: Jumlah NeuronCores hadir di NeuronDevice.
- MEMORI NEURON: Jumlah memori DRAM di. NeuronDevice
- PERANGKAT YANG TERHUBUNG: Lainnya NeuronDevices terhubung ke NeuronDevice.
- PCI BDF: ID Fungsi Perangkat Bus PCI (BDF) dari file. NeuronDevice

Lihat Penggunaan Sumber Daya

Lihat informasi yang berguna tentang NeuronCore dan pemanfaatan vCPU, penggunaan memori, model yang dimuat, dan aplikasi Neuron dengan perintah. `neuron-top` `neuron-top`Peluncuran tanpa argumen akan menampilkan data untuk semua aplikasi pembelajaran mesin yang memanfaatkan NeuronCores.

```
neuron-top
```

Ketika aplikasi menggunakan empat NeuronCores, output akan terlihat mirip dengan gambar berikut:

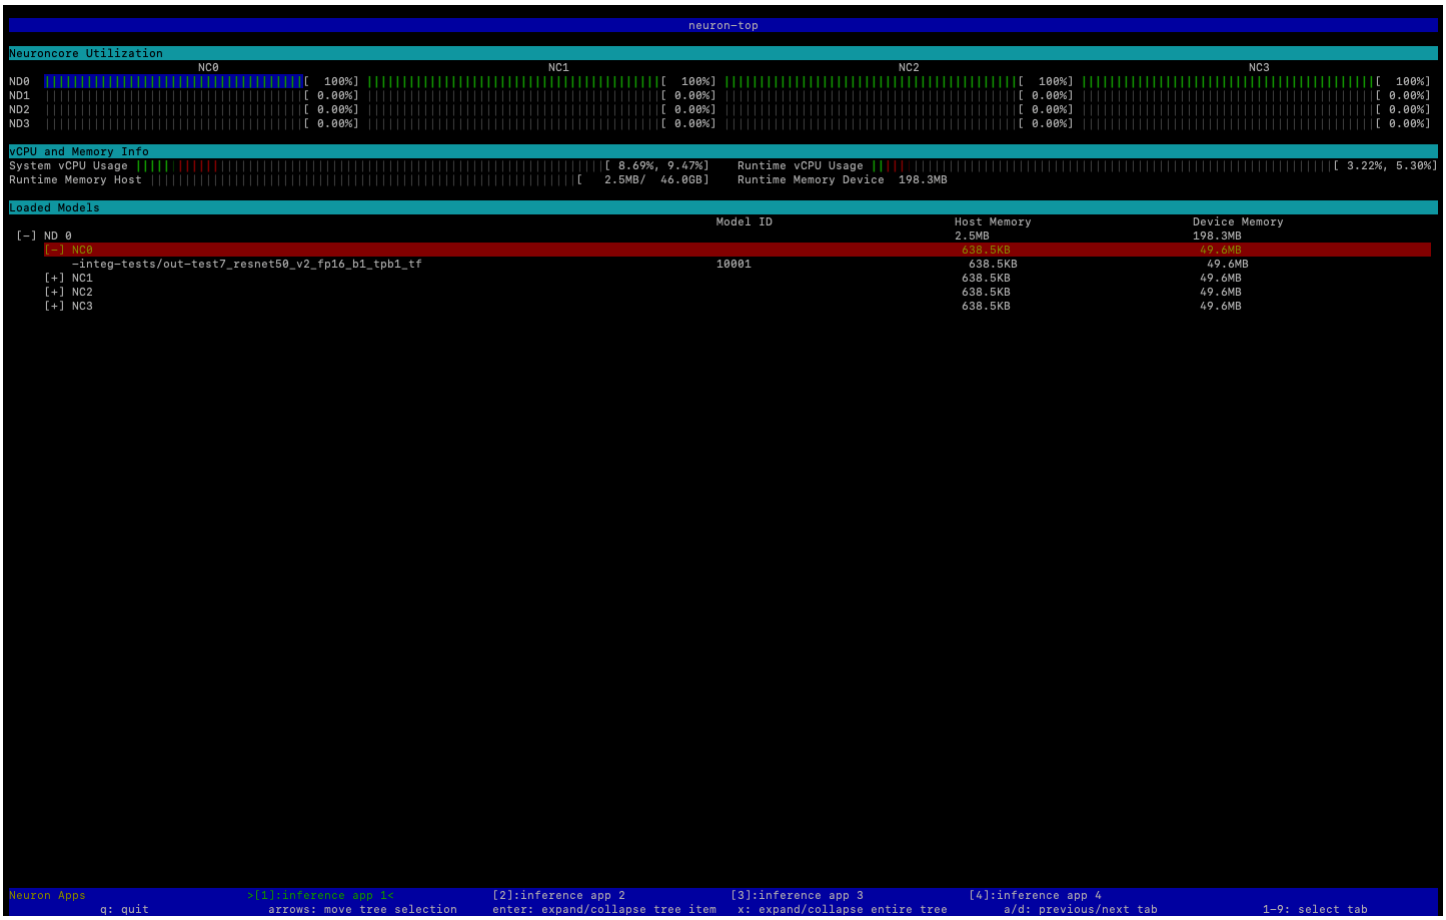

Untuk informasi lebih lanjut tentang sumber daya untuk memantau dan mengoptimalkan aplikasi inferensi berbasis Neuron, lihat Alat Neuron.

Menggunakan Neuron Monitor (neuron-monitor)

Neuron Monitor mengumpulkan metrik dari runtime Neuron yang berjalan di sistem dan mengalirkan data yang dikumpulkan ke stdout dalam format JSON. Metrik ini diatur ke dalam grup metrik yang Anda konfigurasikan dengan menyediakan file konfigurasi. Untuk informasi lebih lanjut tentang Monitor Neuron, lihat Panduan Pengguna untuk Monitor Neuron.

Meningkatkan Perangkat Lunak Neuron

Untuk informasi tentang cara memperbarui perangkat lunak Neuron SDK dalam DLAMI, lihat AWS Panduan Pengaturan Neuron.

Langkah Selanjutnya

Menggunakan DLAMI dengan Neuron AWS

Menggunakan DLAMI dengan Neuron AWS

Alur kerja khas dengan AWS Neuron SDK adalah mengkompilasi model pembelajaran mesin yang dilatih sebelumnya di server kompilasi. Setelah ini, distribusikan artefak ke instance Inf1 untuk dieksekusi. AWS Deep Learning AMIs (DLAMI) sudah diinstal sebelumnya dengan semua yang Anda butuhkan untuk mengkompilasi dan menjalankan inferensi dalam instance Inf1 yang menggunakan Inferentia.

Bagian berikut menjelaskan cara menggunakan DLAMI dengan Inferentia.

Daftar Isi

Menggunakan TensorFlow -Neuron dan Kompiler AWS Neuron

Tutorial ini menunjukkan cara menggunakan kompiler AWS Neuron untuk mengkompilasi model Keras ResNet -50 dan mengekspornya sebagai model yang disimpan dalam format. SavedModel Format ini adalah format TensorFlow model yang dapat dipertukarkan khas. Anda juga belajar cara menjalankan inferensi pada instance Inf1 dengan input contoh.

Untuk informasi lebih lanjut tentang Neuron SDK, lihat dokumentasi AWS Neuron SDK.

Daftar Isi

Prasyarat

Sebelum menggunakan tutorial ini, Anda seharusnya telah menyelesaikan langkah-langkah pengaturan diMeluncurkan Instance DLAMI dengan Neuron AWS. Anda juga harus memiliki keakraban dengan pembelajaran mendalam dan menggunakan DLAMI.

Aktifkan lingkungan Conda

Aktifkan lingkungan conda TensorFlow -Neuron menggunakan perintah berikut:

```
source activate aws_neuron_tensorflow_p36
```

Untuk keluar dari lingkungan conda saat ini, jalankan perintah berikut:

```
source deactivate
```

Resnet50 Kompilasi

Buat skrip Python yang disebut **`tensorflow_compile_resnet50.py`** yang memiliki konten berikut. Skrip Python ini mengkompilasi model Keras ResNet 50 dan mengekspornya sebagai model yang disimpan.

```
import os
import time
import shutil
import tensorflow as tf
import tensorflow.neuron as tfn
import tensorflow.compat.v1.keras as keras
from tensorflow.keras.applications.resnet50 import ResNet50
from tensorflow.keras.applications.resnet50 import preprocess_input

# Create a workspace
WORKSPACE = './ws_resnet50'
os.makedirs(WORKSPACE, exist_ok=True)

# Prepare export directory (old one removed)
model_dir = os.path.join(WORKSPACE, 'resnet50')
compiled_model_dir = os.path.join(WORKSPACE, 'resnet50_neuron')
shutil.rmtree(model_dir, ignore_errors=True)
```

```
shutil.rmtree(compiled_model_dir, ignore_errors=True)

# Instantiate Keras ResNet50 model
keras.backend.set_learning_phase(0)
model = ResNet50(weights='imagenet')

# Export SavedModel
tf.saved_model.simple_save(
 session            = keras.backend.get_session(),
 export_dir         = model_dir,
 inputs             = {'input': model.inputs[0]},
 outputs            = {'output': model.outputs[0]})

# Compile using Neuron
tfn.saved_model.compile(model_dir, compiled_model_dir)

# Prepare SavedModel for uploading to Inf1 instance
shutil.make_archive(compiled_model_dir, 'zip', WORKSPACE, 'resnet50_neuron')
```

Kompilasi model menggunakan perintah berikut:

```
python tensorflow_compile_resnet50.py
```

Proses kompilasi akan memakan waktu beberapa menit. Ketika selesai, output Anda akan terlihat seperti berikut:

```
...
INFO:tensorflow:fusing subgraph neuron_op_d6f098c01c780733 with neuron-cc
INFO:tensorflow:Number of operations in TensorFlow session: 4638
INFO:tensorflow:Number of operations after tf.neuron optimizations: 556
INFO:tensorflow:Number of operations placed on Neuron runtime: 554
INFO:tensorflow:Successfully converted ./ws_resnet50/resnet50 to ./ws_resnet50/
resnet50_neuron
...
```

Setelah kompilasi, model yang disimpan di-zip di**`ws_resnet50/resnet50_neuron.zip`**. Buka zip model dan unduh gambar sampel untuk inferensi menggunakan perintah berikut:

```
unzip ws_resnet50/resnet50_neuron.zip -d .
curl -O https://raw.githubusercontent.com/awslabs/mxnet-model-server/master/docs/
images/kitten_small.jpg
```

ResNet50 Inferensi

Buat skrip Python yang disebut **`tensorflow_infer_resnet50.py`** yang memiliki konten berikut. Skrip ini menjalankan inferensi pada model yang diunduh menggunakan model inferensi yang dikompilasi sebelumnya.

```
import os
import numpy as np
import tensorflow as tf
from tensorflow.keras.preprocessing import image
from tensorflow.keras.applications import resnet50

# Create input from image
img_sgl = image.load_img('kitten_small.jpg', target_size=(224, 224))
img_arr = image.img_to_array(img_sgl)
img_arr2 = np.expand_dims(img_arr, axis=0)
img_arr3 = resnet50.preprocess_input(img_arr2)
# Load model
COMPILED_MODEL_DIR = './ws_resnet50/resnet50_neuron/'
predictor_inferentia = tf.contrib.predictor.from_saved_model(COMPILED_MODEL_DIR)
# Run inference
model_feed_dict={'input': img_arr3}
infa_rslts = predictor_inferentia(model_feed_dict);
# Display results
print(resnet50.decode_predictions(infa_rslts["output"], top=5)[0])
```

Jalankan inferensi pada model menggunakan perintah berikut:

```
python tensorflow_infer_resnet50.py
```

Output Anda akan terlihat seperti berikut:

```
...
```

```
[('n02123045', 'tabby', 0.6918919), ('n02127052', 'lynx', 0.12770271), ('n02123159',
 'tiger_cat', 0.08277027), ('n02124075', 'Egyptian_cat', 0.06418919), ('n02128757',
 'snow_leopard', 0.009290541)]
```

Langkah Selanjutnya

Menggunakan TensorFlow Penyajian AWS Neuron

Menggunakan TensorFlow Penyajian AWS Neuron

Tutorial ini menunjukkan cara membuat grafik dan menambahkan langkah kompilasi AWS Neuron sebelum mengekspor model yang disimpan untuk digunakan dengan TensorFlow Serving. TensorFlow Melayani adalah sistem penyajian yang memungkinkan Anda meningkatkan inferensi di seluruh jaringan. Neuron TensorFlow Serving menggunakan API yang sama dengan TensorFlow Serving normal. Satu-satunya perbedaan adalah bahwa model yang disimpan harus dikompilasi untuk AWS Inferentia dan titik masuknya adalah biner yang berbeda bernama`tensorflow_model_server_neuron`. Biner ditemukan di `/usr/local/bin/tensorflow_model_server_neuron` dan sudah diinstal sebelumnya di DLAMI.

Untuk informasi lebih lanjut tentang Neuron SDK, lihat dokumentasi AWS Neuron SDK.

Daftar Isi

Prasyarat

Sebelum menggunakan tutorial ini, Anda seharusnya telah menyelesaikan langkah-langkah pengaturan diMeluncurkan Instance DLAMI dengan Neuron AWS. Anda juga harus memiliki keakraban dengan pembelajaran mendalam dan menggunakan DLAMI.

Aktifkan lingkungan Conda

Aktifkan lingkungan conda TensorFlow -Neuron menggunakan perintah berikut:

```
source activate aws_neuron_tensorflow_p36
```

Jika Anda perlu keluar dari lingkungan conda saat ini, jalankan:

```
source deactivate
```

Kompilasi dan Ekspor Model Tersimpan

Buat skrip Python yang disebut `tensorflow-model-server-compile.py` dengan konten berikut. Skrip ini membuat grafik dan mengkompilasinya menggunakan Neuron. Kemudian mengekspor grafik yang dikompilasi sebagai model yang disimpan.

```
import tensorflow as tf
import tensorflow.neuron
import os

tf.keras.backend.set_learning_phase(0)
model = tf.keras.applications.ResNet50(weights='imagenet')
sess = tf.keras.backend.get_session()
inputs = {'input': model.inputs[0]}
outputs = {'output': model.outputs[0]}

# save the model using tf.saved_model.simple_save
modeldir = "./resnet50/1"
tf.saved_model.simple_save(sess, modeldir, inputs, outputs)

# compile the model for Inferentia
neuron_modeldir = os.path.join(os.path.expanduser('~'), 'resnet50_inf1', '1')
tf.neuron.saved_model.compile(modeldir, neuron_modeldir, batch_size=1)
```

Kompilasi model menggunakan perintah berikut:

```
python tensorflow-model-server-compile.py
```

Output Anda akan terlihat seperti berikut:

```
...
```

```
INFO:tensorflow:fusing subgraph neuron_op_d6f098c01c780733 with neuron-cc
INFO:tensorflow:Number of operations in TensorFlow session: 4638
INFO:tensorflow:Number of operations after tf.neuron optimizations: 556
INFO:tensorflow:Number of operations placed on Neuron runtime: 554
INFO:tensorflow:Successfully converted ./resnet50/1 to /home/ubuntu/resnet50_inf1/1
```

Melayani Model Tersimpan

Setelah model dikompilasi, Anda dapat menggunakan perintah berikut untuk menyajikan model yang disimpan dengan biner tensorflow_model_server_neuron:

```
tensorflow_model_server_neuron --model_name=resnet50_inf1 \
    --model_base_path=$HOME/resnet50_inf1/ --port=8500 &
```

Output Anda akan terlihat seperti berikut ini. Model yang dikompilasi dipentaskan di DRAM perangkat Inferentia oleh server untuk mempersiapkan inferensi.

```
...
2019-11-22 01:20:32.075856: I external/org_tensorflow/tensorflow/cc/saved_model/
loader.cc:311] SavedModel load for tags { serve }; Status: success. Took 40764
 microseconds.
2019-11-22 01:20:32.075888: I tensorflow_serving/servables/tensorflow/
saved_model_warmup.cc:105] No warmup data file found at /home/ubuntu/resnet50_inf1/1/
assets.extra/tf_serving_warmup_requests
2019-11-22 01:20:32.075950: I tensorflow_serving/core/loader_harness.cc:87]
 Successfully loaded servable version {name: resnet50_inf1 version: 1}
2019-11-22 01:20:32.077859: I tensorflow_serving/model_servers/
server.cc:353] Running gRPC ModelServer at 0.0.0.0:8500 ...
```

Hasilkan permintaan inferensi ke server model

Membuat skrip Python yang disebut `tensorflow-model-server-infer.py` dengan konten berikut. Skrip ini menjalankan inferensi melalui gRPC, yang merupakan kerangka kerja layanan.

```
import numpy as np
import grpc
import tensorflow as tf
from tensorflow.keras.preprocessing import image
from tensorflow.keras.applications.resnet50 import preprocess_input
```

```
from tensorflow_serving.apis import predict_pb2
from tensorflow_serving.apis import prediction_service_pb2_grpc
from tensorflow.keras.applications.resnet50 import decode_predictions

if __name__ == '__main__':
    channel = grpc.insecure_channel('localhost:8500')
    stub = prediction_service_pb2_grpc.PredictionServiceStub(channel)
    img_file = tf.keras.utils.get_file(
        "./kitten_small.jpg",
        "https://raw.githubusercontent.com/awslabs/mxnet-model-server/master/docs/
images/kitten_small.jpg")
    img = image.load_img(img_file, target_size=(224, 224))
    img_array = preprocess_input(image.img_to_array(img)[None, ...])
    request = predict_pb2.PredictRequest()
    request.model_spec.name = 'resnet50_inf1'
    request.inputs['input'].CopyFrom(
        tf.contrib.util.make_tensor_proto(img_array, shape=img_array.shape))
    result = stub.Predict(request)
    prediction = tf.make_ndarray(result.outputs['output'])
    print(decode_predictions(prediction))
```

Jalankan inferensi pada model dengan menggunakan gRPC dengan perintah berikut:

```
python tensorflow-model-server-infer.py
```

Output Anda akan terlihat seperti berikut:

```
[[('n02123045', 'tabby', 0.6918919), ('n02127052', 'lynx', 0.12770271), ('n02123159',
 'tiger_cat', 0.08277027), ('n02124075', 'Egyptian_cat', 0.06418919), ('n02128757',
 'snow_leopard', 0.009290541)]]
```

Menggunakan MXNet -Neuron dan Kompiler AWS Neuron

API kompilasi MXNet -Neuron menyediakan metode untuk mengkompilasi grafik model yang dapat Anda jalankan pada perangkat AWS Inferentia.

Dalam contoh ini, Anda menggunakan API untuk mengkompilasi model ResNet -50 dan menggunakannya untuk menjalankan inferensi.

Untuk informasi lebih lanjut tentang Neuron SDK, lihat dokumentasi AWS Neuron SDK.

Daftar Isi

Prasyarat

Sebelum menggunakan tutorial ini, Anda seharusnya telah menyelesaikan langkah-langkah pengaturan diMeluncurkan Instance DLAMI dengan Neuron AWS. Anda juga harus memiliki keakraban dengan pembelajaran mendalam dan menggunakan DLAMI.

Aktifkan Lingkungan Conda

Aktifkan lingkungan conda MXNet -Neuron menggunakan perintah berikut:

```
source activate aws_neuron_mxnet_p36
```

Untuk keluar dari lingkungan conda saat ini, jalankan:

```
source deactivate
```

Resnet50 Kompilasi

Membuat skrip Python yang disebut **`mxnet_compile_resnet50.py`** dengan konten berikut. Skrip ini menggunakan kompilasi MXNet -Neuron Python API untuk mengkompilasi ResNet model -50.

```
import mxnet as mx
import numpy as np

print("downloading...")
path='http://data.mxnet.io/models/imagenet/'
mx.test_utils.download(path+'resnet/50-layers/resnet-50-0000.params')
mx.test_utils.download(path+'resnet/50-layers/resnet-50-symbol.json')
print("download finished.")

sym, args, aux = mx.model.load_checkpoint('resnet-50', 0)
```

```
print("compile for inferentia using neuron... this will take a few minutes...")
inputs = { "data" : mx.nd.ones([1,3,224,224], name='data', dtype='float32') }

sym, args, aux = mx.contrib.neuron.compile(sym, args, aux, inputs)

print("save compiled model...")
mx.model.save_checkpoint("compiled_resnet50", 0, sym, args, aux)
```

Kompilasi model menggunakan perintah berikut:

```
python mxnet_compile_resnet50.py
```

Kompilasi akan memakan waktu beberapa menit. Ketika kompilasi telah selesai, file-file berikut akan berada di direktori Anda saat ini:

```
resnet-50-0000.params
resnet-50-symbol.json
compiled_resnet50-0000.params
compiled_resnet50-symbol.json
```

ResNet50 Inferensi

Membuat skrip Python yang disebut **`mxnet_infer_resnet50.py`** dengan konten berikut. Skrip ini mengunduh gambar sampel dan menggunakannya untuk menjalankan inferensi dengan model yang dikompilasi.

```
import mxnet as mx
import numpy as np

path='http://data.mxnet.io/models/imagenet/'
mx.test_utils.download(path+'synset.txt')

fname = mx.test_utils.download('https://raw.githubusercontent.com/awslabs/mxnet-model-
server/master/docs/images/kitten_small.jpg')
img = mx.image.imread(fname)

# convert into format (batch, RGB, width, height)
img = mx.image.imresize(img, 224, 224)
```

```
# resize
img = img.transpose((2, 0, 1))
# Channel first
img = img.expand_dims(axis=0)
# batchify
img = img.astype(dtype='float32')

sym, args, aux = mx.model.load_checkpoint('compiled_resnet50', 0)
softmax = mx.nd.random_normal(shape=(1,))
args['softmax_label'] = softmax
args['data'] = img
# Inferentia context
ctx = mx.neuron()

exe = sym.bind(ctx=ctx, args=args, aux_states=aux, grad_req='null')
with open('synset.txt', 'r') as f:
    labels = [l.rstrip() for l in f]

exe.forward(data=img)
prob = exe.outputs[0].asnumpy()
# print the top-5
prob = np.squeeze(prob)
a = np.argsort(prob)[::-1]
for i in a[0:5]:
    print('probability=%f, class=%s' %(prob[i], labels[i]))
```

Jalankan inferensi dengan model yang dikompilasi menggunakan perintah berikut:

```
python mxnet_infer_resnet50.py
```

Output Anda akan terlihat seperti berikut:

```
probability=0.642454, class=n02123045 tabby, tabby cat
probability=0.189407, class=n02123159 tiger cat
probability=0.100798, class=n02124075 Egyptian cat
probability=0.030649, class=n02127052 lynx, catamount
probability=0.016278, class=n02129604 tiger, Panthera tigris
```

Langkah Selanjutnya

Menggunakan Penyajian Model MXNet -Neuron

Menggunakan Penyajian Model MXNet -Neuron

Dalam tutorial ini, Anda belajar menggunakan MXNet model pra-terlatih untuk melakukan klasifikasi gambar real-time dengan Multi Model Server (MMS). MMS adalah easy-to-use alat yang fleksibel dan untuk melayani model pembelajaran mendalam yang dilatih menggunakan pembelajaran mesin atau kerangka pembelajaran mendalam. Tutorial ini mencakup langkah kompilasi menggunakan AWS Neuron dan implementasi MMS menggunakan MXNet.

Untuk informasi lebih lanjut tentang Neuron SDK, lihat dokumentasi AWS Neuron SDK.

Daftar Isi

Prasyarat

Sebelum menggunakan tutorial ini, Anda seharusnya telah menyelesaikan langkah-langkah pengaturan diMeluncurkan Instance DLAMI dengan Neuron AWS. Anda juga harus memiliki keakraban dengan pembelajaran mendalam dan menggunakan DLAMI.

Aktifkan Lingkungan Conda

Aktifkan lingkungan conda MXNet -Neuron dengan menggunakan perintah berikut:

```
source activate aws_neuron_mxnet_p36
```

Untuk keluar dari lingkungan conda saat ini, jalankan:

```
source deactivate
```

Unduh Kode Contoh

Untuk menjalankan contoh ini, unduh kode contoh menggunakan perintah berikut:

```
git clone https://github.com/awslabs/multi-model-server
cd multi-model-server/examples/mxnet_vision
```

Kompilasi Model

Membuat skrip Python yang disebut `multi-model-server-compile.py` dengan konten berikut. Skrip ini mengkompilasi model ResNet 50 ke target perangkat Inferentia.

```
import mxnet as mx
from mxnet.contrib import neuron
import numpy as np

path='http://data.mxnet.io/models/imagenet/'
mx.test_utils.download(path+'resnet/50-layers/resnet-50-0000.params')
mx.test_utils.download(path+'resnet/50-layers/resnet-50-symbol.json')
mx.test_utils.download(path+'synset.txt')

nn_name = "resnet-50"

#Load a model
sym, args, auxs = mx.model.load_checkpoint(nn_name, 0)

#Define compilation parameters#  - input shape and dtype
inputs = {'data' : mx.nd.zeros([1,3,224,224], dtype='float32') }

# compile graph to inferentia target
csym, cargs, cauxs = neuron.compile(sym, args, auxs, inputs)

# save compiled model
mx.model.save_checkpoint(nn_name + "_compiled", 0, csym, cargs, cauxs)
```

Untuk mengkompilasi model, gunakan perintah berikut:

```
python multi-model-server-compile.py
```

Output Anda akan terlihat seperti berikut:

```
...
[21:18:40] src/nnvm/legacy_json_util.cc:209: Loading symbol saved by previous version
 v0.8.0. Attempting to upgrade...
[21:18:40] src/nnvm/legacy_json_util.cc:217: Symbol successfully upgraded!
[21:19:00] src/operator/subgraph/build_subgraph.cc:698: start to execute partition
 graph.
[21:19:00] src/nnvm/legacy_json_util.cc:209: Loading symbol saved by previous version
 v0.8.0. Attempting to upgrade...
```

```
[21:19:00] src/nnvm/legacy_json_util.cc:217: Symbol successfully upgraded!
```

Buat file bernama `signature.json` dengan konten berikut untuk mengkonfigurasi nama input dan bentuk:

```
{
  "inputs": [
    {
      "data_name": "data",
      "data_shape": [
        1,
        3,
        224,
        224
      ]
    }
  ]
}
```

Download `synset.txt` file dengan menggunakan perintah berikut. File ini adalah daftar nama untuk kelas ImageNet prediksi.

```
curl -O https://s3.amazonaws.com/model-server/model_archive_1.0/examples/
squeezenet_v1.1/synset.txt
```

Buat kelas layanan kustom mengikuti template di `model_server_template` folder. Salin template ke direktori kerja Anda saat ini dengan menggunakan perintah berikut:

```
cp -r ../model_service_template/* .
```

Edit `mxnet_model_service.py` modul untuk mengganti `mx.cpu()` konteks dengan `mx.neuron()` konteks sebagai berikut. Anda juga perlu mengomentari salinan data yang tidak perlu `model_input` karena MXNet -Neuron tidak mendukung NDArray dan APIs Gluon.

```
...
self.mxnet_ctx = mx.neuron() if gpu_id is None else mx.gpu(gpu_id)
...
#model_input = [item.as_in_context(self.mxnet_ctx) for item in model_input]
```

Package model dengan model-archiver menggunakan perintah berikut:

```
cd ~/multi-model-server/examples
model-archiver --force --model-name resnet-50_compiled --model-path mxnet_vision --
handler mxnet_vision_service:handle
```

Jalankan Inferensi

Mulai Multi Model Server dan muat model yang menggunakan RESTful API dengan menggunakan perintah berikut. Pastikan neuron-rtd itu berjalan dengan pengaturan default.

```
cd ~/multi-model-server/
multi-model-server --start --model-store examples > /dev/null # Pipe to log file if you
 want to keep a log of MMS
curl -v -X POST "http://localhost:8081/models?
initial_workers=1&max_workers=4&synchronous=true&url=resnet-50_compiled.mar"
sleep 10 # allow sufficient time to load model
```

Jalankan inferensi menggunakan contoh gambar dengan perintah berikut:

```
curl -O https://raw.githubusercontent.com/awslabs/multi-model-server/master/docs/
images/kitten_small.jpg
curl -X POST http://127.0.0.1:8080/predictions/resnet-50_compiled -T kitten_small.jpg
```

Output Anda akan terlihat seperti berikut:

```
[
  {
    "probability": 0.6388034820556641,
    "class": "n02123045 tabby, tabby cat"
  },
  {
    "probability": 0.16900072991847992,
    "class": "n02123159 tiger cat"
  },
  {
    "probability": 0.12221276015043259,
    "class": "n02124075 Egyptian cat"
  },
  {
    "probability": 0.028706775978207588,
    "class": "n02127052 lynx, catamount"
  },
  {
```

```
    "probability": 0.01915954425930977,
    "class": "n02129604 tiger, Panthera tigris"
  }
]
```

Untuk membersihkan setelah pengujian, keluarkan perintah delete melalui RESTful API dan hentikan server model menggunakan perintah berikut:

```
curl -X DELETE http://127.0.0.1:8081/models/resnet-50_compiled

multi-model-server --stop
```

Anda akan melihat output berikut:

```
{
  "status": "Model \"resnet-50_compiled\" unregistered"
}
Model server stopped.
Found 1 models and 1 NCGs.
Unloading 10001 (MODEL_STATUS_STARTED) :: success
Destroying NCG 1 :: success
```

Menggunakan PyTorch -Neuron dan Kompiler AWS Neuron

API kompilasi PyTorch -Neuron menyediakan metode untuk mengkompilasi grafik model yang dapat Anda jalankan pada perangkat AWS Inferentia.

Model terlatih harus dikompilasi ke target Inferentia sebelum dapat digunakan pada instance Inf1. Tutorial berikut mengkompilasi model torchvision ResNet 50 dan mengekspornya sebagai modul yang disimpan. TorchScript Model ini kemudian digunakan untuk menjalankan inferensi.

Untuk kenyamanan, tutorial ini menggunakan instance Inf1 untuk kompilasi dan inferensi. Dalam praktiknya, Anda dapat mengkompilasi model Anda menggunakan tipe instance lain, seperti keluarga instance c5. Anda kemudian harus menerapkan model yang dikompilasi ke server inferensi Inf1. Untuk informasi lebih lanjut, lihat Dokumentasi AWS Neuron PyTorch SDK.

Daftar Isi

- ResNet50 Inferensi

Prasyarat

Sebelum menggunakan tutorial ini, Anda seharusnya telah menyelesaikan langkah-langkah pengaturan diMeluncurkan Instance DLAMI dengan Neuron AWS. Anda juga harus memiliki keakraban dengan pembelajaran mendalam dan menggunakan DLAMI.

Aktifkan Lingkungan Conda

Aktifkan lingkungan conda PyTorch -Neuron menggunakan perintah berikut:

```
source activate aws_neuron_pytorch_p36
```

Untuk keluar dari lingkungan conda saat ini, jalankan:

```
source deactivate
```

Resnet50 Kompilasi

Membuat skrip Python yang disebut **`pytorch_trace_resnet50.py`** dengan konten berikut. Skrip ini menggunakan kompilasi PyTorch -Neuron Python API untuk mengkompilasi ResNet model -50.

> **Note**
>
> Ada ketergantungan antara versi torchvision dan paket obor yang harus Anda ketahui saat mengkompilasi model torchvision. Aturan ketergantungan ini dapat dikelola melalui pip. Torchvision==0.6.1 cocok dengan rilis torch==1.5.1, sedangkan torchvision==0.8.2 cocok dengan rilis torch==1.7.1.

```
import torch
import numpy as np
import os
import torch_neuron
from torchvision import models

image = torch.zeros([1, 3, 224, 224], dtype=torch.float32)
```

```
## Load a pretrained ResNet50 model
model = models.resnet50(pretrained=True)

## Tell the model we are using it for evaluation (not training)
model.eval()
model_neuron = torch.neuron.trace(model, example_inputs=[image])

## Export to saved model
model_neuron.save("resnet50_neuron.pt")
```

Jalankan skrip kompilasi.

```
python pytorch_trace_resnet50.py
```

Kompilasi akan memakan waktu beberapa menit. Ketika kompilasi selesai, model yang dikompilasi disimpan seperti `resnet50_neuron.pt` di direktori lokal.

ResNet50 Inferensi

Membuat skrip Python yang disebut **`pytorch_infer_resnet50.py`** dengan konten berikut. Skrip ini mengunduh gambar sampel dan menggunakannya untuk menjalankan inferensi dengan model yang dikompilasi.

```
import os
import time
import torch
import torch_neuron
import json
import numpy as np

from urllib import request

from torchvision import models, transforms, datasets

## Create an image directory containing a small kitten
os.makedirs("./torch_neuron_test/images", exist_ok=True)
request.urlretrieve("https://raw.githubusercontent.com/awslabs/mxnet-model-server/
master/docs/images/kitten_small.jpg",
                    "./torch_neuron_test/images/kitten_small.jpg")


## Fetch labels to output the top classifications
```

```
request.urlretrieve("https://s3.amazonaws.com/deep-learning-models/image-models/
imagenet_class_index.json","imagenet_class_index.json")
idx2label = []

with open("imagenet_class_index.json", "r") as read_file:
    class_idx = json.load(read_file)
    idx2label = [class_idx[str(k)][1] for k in range(len(class_idx))]

## Import a sample image and normalize it into a tensor
normalize = transforms.Normalize(
    mean=[0.485, 0.456, 0.406],
    std=[0.229, 0.224, 0.225])

eval_dataset = datasets.ImageFolder(
    os.path.dirname("./torch_neuron_test/"),
    transforms.Compose([
    transforms.Resize([224, 224]),
    transforms.ToTensor(),
    normalize,
    ])
)

image, _ = eval_dataset[0]
image = torch.tensor(image.numpy()[np.newaxis, ...])

## Load model
model_neuron = torch.jit.load( 'resnet50_neuron.pt' )

## Predict
results = model_neuron( image )

# Get the top 5 results
top5_idx = results[0].sort()[1][-5:]

# Lookup and print the top 5 labels
top5_labels = [idx2label[idx] for idx in top5_idx]

print("Top 5 labels:\n {}".format(top5_labels) )
```

Jalankan inferensi dengan model yang dikompilasi menggunakan perintah berikut:

```
python pytorch_infer_resnet50.py
```

Output Anda akan terlihat seperti berikut:

```
Top 5 labels:
 ['tiger', 'lynx', 'tiger_cat', 'Egyptian_cat', 'tabby']
```

ARM64 DLAMI

AWS ARM64 GPU DLAMIs dirancang untuk memberikan kinerja tinggi dan efisiensi biaya untuk beban kerja pembelajaran mendalam. Secara khusus, tipe instans G5G menampilkan prosesor AWS Graviton2 berbasis ARM64, yang dibangun dari bawah ke atas AWS dan dioptimalkan untuk bagaimana pelanggan menjalankan beban kerja mereka di cloud. AWS ARM64 GPU sudah DLAMIs dikonfigurasi sebelumnya dengan Docker, NVIDIA Docker, NVIDIA Driver, CUDA, cuDNN, NCCL, serta kerangka kerja pembelajaran mesin populer seperti dan. TensorFlow PyTorch

Dengan tipe instans G5G, Anda dapat memanfaatkan manfaat harga dan kinerja Graviton2 untuk menerapkan model pembelajaran mendalam yang dipercepat GPU dengan biaya yang jauh lebih rendah jika dibandingkan dengan instans berbasis x86 dengan akselerasi GPU.

Pilih ARM64 DLAMI

Luncurkan instans G5G dengan ARM64 DLAMI pilihan Anda.

Untuk step-by-step petunjuk tentang meluncurkan DLAMI, lihat Meluncurkan dan Mengonfigurasi DLAMI.

Untuk daftar yang terbaru ARM64 DLAMIs, lihat Catatan Rilis untuk DLAMI.

Mulai

Topik berikut menunjukkan cara memulai menggunakan ARM64 DLAMI.

Daftar Isi

Menggunakan ARM64 DLAMI GPU PyTorch

AWS Deep Learning AMIs Ini siap digunakan dengan berbasis prosesor Arm64 GPUs, dan dioptimalkan untuk. PyTorch PyTorch DLAMI ARM64 GPU mencakup lingkungan Python yang

PyTorchtelah dikonfigurasi sebelumnya TorchVisiondengan, TorchServe, dan untuk pelatihan pembelajaran mendalam dan kasus penggunaan inferensi.

Daftar Isi

Verifikasi PyTorch Lingkungan Python

Hubungkan ke instans G5G Anda dan aktifkan lingkungan dasar Conda dengan perintah berikut:

```
source activate base
```

Prompt perintah Anda harus menunjukkan bahwa Anda bekerja di lingkungan dasar Conda, yang berisi PyTorch TorchVision, dan pustaka lainnya.

```
(base) $
```

Verifikasi jalur alat default PyTorch lingkungan:

```
(base) $ which python
(base) $ which pip
(base) $ which conda
(base) $ which mamba
>>> import torch, torchvision
>>> torch.__version__
>>> torchvision.__version__
>>> v = torch.autograd.Variable(torch.randn(10, 3, 224, 224))
>>> v = torch.autograd.Variable(torch.randn(10, 3, 224, 224)).cuda()
>>> assert isinstance(v, torch.Tensor)
```

Jalankan Sampel Pelatihan dengan PyTorch

Jalankan contoh pekerjaan pelatihan MNIST:

```
git clone https://github.com/pytorch/examples.git
cd examples/mnist
python main.py
```

Output-nya semestinya mirip dengan yang berikut:

```
...
Train Epoch: 14 [56320/60000 (94%)]    Loss: 0.021424
Train Epoch: 14 [56960/60000 (95%)]    Loss: 0.023695
Train Epoch: 14 [57600/60000 (96%)]    Loss: 0.001973
Train Epoch: 14 [58240/60000 (97%)]    Loss: 0.007121
Train Epoch: 14 [58880/60000 (98%)]    Loss: 0.003717
Train Epoch: 14 [59520/60000 (99%)]    Loss: 0.001729
Test set: Average loss: 0.0275, Accuracy: 9916/10000 (99%)
```

Jalankan Sampel Inferensi dengan PyTorch

Gunakan perintah berikut untuk mengunduh model densenet161 yang telah dilatih sebelumnya dan jalankan inferensi menggunakan: TorchServe

```
# Set up TorchServe
cd $HOME
git clone https://github.com/pytorch/serve.git
mkdir -p serve/model_store
cd serve

# Download a pre-trained densenet161 model
wget https://download.pytorch.org/models/densenet161-8d451a50.pth >/dev/null

# Save the model using torch-model-archiver
torch-model-archiver --model-name densenet161 \
    --version 1.0 \
    --model-file examples/image_classifier/densenet_161/model.py \
    --serialized-file densenet161-8d451a50.pth \
    --handler image_classifier \
    --extra-files examples/image_classifier/index_to_name.json  \
    --export-path model_store

# Start the model server
torchserve --start --no-config-snapshots \
    --model-store model_store \
    --models densenet161=densenet161.mar &> torchserve.log

# Wait for the model server to start
sleep 30

# Run a prediction request
```

```
curl http://127.0.0.1:8080/predictions/densenet161 -T examples/image_classifier/
kitten.jpg
```

Output-nya semestinya mirip dengan yang berikut:

```
{
  "tiger_cat": 0.4693363308906555,
  "tabby": 0.4633873701095581,
  "Egyptian_cat": 0.06456123292446136,
  "lynx": 0.0012828150065615773,
  "plastic_bag": 0.00023322898778133094
}
```

Gunakan perintah berikut untuk membatalkan pendaftaran model densenet161 dan menghentikan server:

```
curl -X DELETE http://localhost:8081/models/densenet161/1.0
torchserve --stop
```

Output-nya semestinya mirip dengan yang berikut:

```
{
  "status": "Model \"densenet161\" unregistered"
}
TorchServe has stopped.
```

Inferensi

Bagian ini menyediakan tutorial tentang cara menjalankan inferensi menggunakan kerangka kerja dan alat DLAMI.

Alat Inferensi

- TensorFlow Melayani

Penyajian Model

Berikut ini adalah opsi penyajian model yang diinstal pada AMI Pembelajaran Mendalam dengan Conda. Klik salah satu opsi untuk mempelajari cara menggunakannya.

Topik

TensorFlow Melayani

TensorFlow Melayani adalah sistem penyajian yang fleksibel dan berkinerja tinggi untuk model pembelajaran mesin.

`tensorflow-serving-api`Ini sudah diinstal sebelumnya dengan DLAMI framwork tunggal. Untuk menggunakan penyajian tensorflow, aktifkan lingkungan terlebih dahulu. TensorFlow

```
$ source /opt/tensorflow/bin/activate
```

Kemudian gunakan editor teks pilihan Anda untuk membuat skrip yang memiliki konten berikut. Nama itu`test_train_mnist.py`. Skrip ini direferensikan dari TensorFlow Tutorial yang akan melatih dan mengevaluasi model pembelajaran mesin jaringan saraf yang mengklasifikasikan gambar.

```
import tensorflow as tf
mnist = tf.keras.datasets.mnist

(x_train, y_train),(x_test, y_test) = mnist.load_data()
x_train, x_test = x_train / 255.0, x_test / 255.0

model = tf.keras.models.Sequential([
  tf.keras.layers.Flatten(input_shape=(28, 28)),
  tf.keras.layers.Dense(128, activation='relu'),
  tf.keras.layers.Dropout(0.2),
  tf.keras.layers.Dense(10, activation='softmax')
])

model.compile(optimizer='adam',
              loss='sparse_categorical_crossentropy',
              metrics=['accuracy'])

model.fit(x_train, y_train, epochs=5)
model.evaluate(x_test, y_test)
```

Sekarang jalankan skrip melewati lokasi server dan port dan nama file foto husky sebagai parameter.

```
$ /opt/tensorflow/bin/python3 test_train_mnist.py
```

Bersabarlah, karena skrip ini mungkin memakan waktu beberapa saat sebelum memberikan output apa pun. Ketika pelatihan selesai, Anda harus melihat yang berikut:

```
I0000 00:00:1739482012.389276    4284 device_compiler.h:188] Compiled cluster using
 XLA!  This line is logged at most once for the lifetime of the process.
1875/1875 [==============================] - 24s 2ms/step - loss: 0.2973 - accuracy:
 0.9134
Epoch 2/5
1875/1875 [==============================] - 3s 2ms/step - loss: 0.1422 - accuracy:
 0.9582
Epoch 3/5
1875/1875 [==============================] - 3s 1ms/step - loss: 0.1076 - accuracy:
 0.9687
Epoch 4/5
1875/1875 [==============================] - 3s 2ms/step - loss: 0.0872 - accuracy:
 0.9731
Epoch 5/5
1875/1875 [==============================] - 3s 1ms/step - loss: 0.0731 - accuracy:
 0.9771
313/313 [==============================] - 0s 1ms/step - loss: 0.0749 - accuracy:
 0.9780
```

Lebih Banyak Fitur dan Contoh

Jika Anda tertarik untuk mempelajari lebih lanjut tentang TensorFlow Melayani, lihat TensorFlow situs webnya.

TorchServe

TorchServe adalah alat yang fleksibel untuk melayani model pembelajaran mendalam yang telah diekspor dari PyTorch. TorchServe datang pra-instal dengan AMI Pembelajaran Mendalam dengan Conda.

Untuk informasi selengkapnya tentang penggunaan TorchServe, lihat Server Model untuk PyTorch Dokumentasi.

Topik

Sajikan Model Klasifikasi Gambar pada TorchServe

Tutorial ini menunjukkan cara menyajikan model klasifikasi gambar dengan TorchServe. Ini menggunakan model DenseNet -161 yang disediakan oleh. PyTorch Setelah server berjalan, ia mendengarkan permintaan prediksi. Saat Anda mengunggah gambar, dalam hal ini, gambar anak kucing, server mengembalikan prediksi 5 kelas pencocokan teratas dari kelas tempat model dilatih.

Untuk menyajikan contoh model klasifikasi gambar pada TorchServe

1. Connect ke instans Amazon Elastic Compute Cloud (Amazon EC2) dengan Deep Learning AMI dengan Conda v34 atau versi lebih baru.
2. Aktifkan `pytorch_p310` lingkungan.

```
source activate pytorch_p310
```

3. Kloning TorchServe repositori, lalu buat direktori untuk menyimpan model Anda.

```
git clone https://github.com/pytorch/serve.git
mkdir model_store
```

4. Arsipkan model menggunakan pengarsipan model. `extra-files`Param menggunakan file dari `TorchServe` repo, jadi perbarui jalur jika perlu. Untuk informasi selengkapnya tentang pengarsipan model, lihat Pengarsip Model Obor untuk. TorchServe

```
wget https://download.pytorch.org/models/densenet161-8d451a50.pth
torch-model-archiver --model-name densenet161 --version 1.0 --model-file ./
serve/examples/image_classifier/densenet_161/model.py --serialized-file
 densenet161-8d451a50.pth --export-path model_store --extra-files ./serve/examples/
image_classifier/index_to_name.json --handler image_classifier
```

5. Jalankan TorchServe untuk memulai titik akhir. Menambahkan `> /dev/null` menenangkan output log.

```
torchserve --start --ncs --model-store model_store --models densenet161.mar > /dev/
null
```

6. Unduh gambar anak kucing dan kirimkan ke titik akhir TorchServe prediksi:

```
curl -O https://s3.amazonaws.com/model-server/inputs/kitten.jpg
curl http://127.0.0.1:8080/predictions/densenet161 -T kitten.jpg
```

Titik akhir prediksi mengembalikan prediksi di JSON yang mirip dengan lima prediksi teratas berikut, di mana gambar memiliki probabilitas 47% mengandung kucing Mesir, diikuti oleh kemungkinan 46% memiliki kucing kucing kucing.

```
{
 "tiger_cat": 0.46933576464653015,
 "tabby": 0.463387668132782,
 "Egyptian_cat": 0.0645613968372345,
 "lynx": 0.0012828196631744504,
 "plastic_bag": 0.00023323058849200606
}
```

7. Setelah Anda selesai menguji, hentikan server:

```
torchserve --stop
```

Contoh Lain

TorchServe memiliki berbagai contoh yang dapat Anda jalankan pada instance DLAMI Anda. Anda dapat melihatnya di halaman contoh repositori TorchServe proyek.

Info Lebih Lanjut

Untuk TorchServe dokumentasi lebih lanjut, termasuk cara mengatur TorchServe dengan Docker dan TorchServe fitur terbaru, lihat halaman TorchServe proyek di GitHub.

Meningkatkan DLAMI Anda

Di sini Anda akan menemukan informasi tentang meningkatkan DLAMI Anda dan tips memperbarui perangkat lunak pada DLAMI Anda.

Selalu perbarui sistem operasi Anda dan perangkat lunak terinstal lainnya dengan menerapkan tambalan dan pembaruan segera setelah tersedia.

Jika Anda menggunakan Amazon Linux atau Ubuntu, ketika Anda masuk ke DLAMI Anda, Anda akan diberi tahu jika pembaruan tersedia dan melihat instruksi untuk memperbarui. Untuk informasi lebih lanjut tentang pemeliharaan Amazon Linux, lihat Memperbarui Perangkat Lunak Instans. Untuk contoh Ubuntu, lihat dokumentasi resmi Ubuntu.

Di Windows, periksa Pembaruan Windows secara teratur untuk pembaruan perangkat lunak dan keamanan. Jika Anda mau, sediakan pembaruan secara otomatis.

> **Important**
>
> Untuk informasi tentang kerentanan Meltdown dan Spectre dan cara menambal sistem operasi Anda untuk mengatasinya, lihat Buletin Keamanan -2018-013. AWS

Topik

Upgrade ke Versi DLAMI Baru

Gambar sistem DLAMI diperbarui secara teratur untuk memanfaatkan rilis kerangka pembelajaran mendalam baru, CUDA dan pembaruan perangkat lunak lainnya, dan penyetelan kinerja. Jika Anda telah menggunakan DLAMI untuk beberapa waktu dan ingin memanfaatkan pembaruan, Anda perlu meluncurkan instance baru. Anda juga harus mentransfer kumpulan data, pos pemeriksaan, atau data berharga lainnya secara manual. Sebagai gantinya, Anda dapat menggunakan Amazon EBS untuk menyimpan data Anda dan melampirkannya ke DLAMI baru. Dengan cara ini, Anda dapat sering meningkatkan, sambil meminimalkan waktu yang diperlukan untuk mentransisikan data Anda.

> **Note**
>
> Saat melampirkan dan memindahkan volume Amazon EBS di antaranya DLAMIs, Anda harus memiliki volume DLAMIs dan volume baru di Availability Zone yang sama.

1. Gunakan Amazon EC2console untuk membuat volume Amazon EBS baru. Untuk petunjuk mendetail, lihat Membuat Volume Amazon EBS.
2. Lampirkan volume Amazon EBS yang baru dibuat ke DLAMI yang sudah ada. Untuk petunjuk mendetail, lihat Melampirkan Volume Amazon EBS.
3. Transfer data Anda, seperti dataset, pos pemeriksaan, dan file konfigurasi.
4. Luncurkan DLAMI. Untuk petunjuk terperinci, lihat Menyiapkan instance DLAMI.
5. Lepaskan volume Amazon EBS dari DLAMI lama Anda. Untuk petunjuk mendetail, lihat Melepaskan Volume Amazon EBS.
6. Lampirkan volume Amazon EBS ke DLAMI baru Anda. Ikuti instruksi dari Langkah 2 untuk melampirkan volume.
7. Setelah Anda memverifikasi bahwa data Anda tersedia di DLAMI baru Anda, hentikan dan hentikan DLAMI lama Anda. Untuk instruksi pembersihan terperinci, lihat. Membersihkan contoh DLAMI

Kiat untuk Pembaruan Perangkat Lunak

Dari waktu ke waktu, Anda mungkin ingin memperbarui perangkat lunak secara manual pada DLAMI Anda. Hal ini umumnya dianjurkan bahwa Anda menggunakan `pip` untuk memperbarui paket Python. Anda juga harus menggunakan `pip` untuk memperbarui paket dalam lingkungan Conda pada AMI Pembelajaran Mendalam dengan Conda. Lihat situs web kerangka kerja atau perangkat lunak tertentu untuk instruksi peningkatan dan penginstalan.

> **Note**
>
> Kami tidak dapat menjamin bahwa pembaruan paket akan berhasil. Mencoba memperbarui paket di lingkungan dengan dependensi yang tidak kompatibel dapat mengakibatkan kegagalan. Dalam kasus seperti itu, Anda harus menghubungi pengelola perpustakaan untuk melihat apakah mungkin untuk memperbarui dependensi paket. Atau, Anda dapat mencoba memodifikasi lingkungan sedemikian rupa sehingga memungkinkan pembaruan. Namun,

modifikasi ini kemungkinan berarti menghapus atau memperbarui paket yang ada, yang berarti bahwa kami tidak dapat lagi menjamin stabilitas lingkungan ini.

AWS Deep Learning AMIs Muncul dengan banyak lingkungan Conda dan banyak paket yang sudah diinstal sebelumnya. Karena jumlah paket yang sudah diinstal sebelumnya, sulit menemukan satu set paket yang dijamin kompatibel. Anda mungkin melihat peringatan “Lingkungan tidak konsisten, silakan periksa paket paket dengan cermat”. DLAMI memastikan bahwa semua lingkungan yang disediakan DLAMI sudah benar, tetapi tidak dapat menjamin bahwa setiap paket yang diinstal pengguna akan berfungsi dengan benar.

Menerima Pemberitahuan tentang Pembaruan Baru

Note

AWS Deep Learning AMIs memiliki irama rilis mingguan untuk patch keamanan. Pemberitahuan rilis akan dikirim untuk tambalan keamanan tambahan ini meskipun mungkin tidak disertakan dalam catatan rilis resmi.

Anda dapat menerima pemberitahuan setiap kali DLAMI baru dirilis. Pemberitahuan diterbitkan dengan Amazon SNS menggunakan topik berikut.

```
arn:aws:sns:us-west-2:767397762724:dlami-updates
```

Pesan diposting di sini ketika DLAMI baru diterbitkan. Versi, metadata, dan ID AMI regional dari AMI akan disertakan dalam pesan.

Pesan-pesan ini dapat diterima menggunakan beberapa metode berbeda. Kami menyarankan Anda menggunakan metode berikut.

1. Buka konsol Amazon SNS.
2. Di bilah navigasi, ubah AWS Wilayah ke AS Barat (Oregon), jika perlu. Anda harus memilih wilayah tempat notifikasi SNS yang Anda berlangganan dibuat.
3. Di panel navigasi, pilih Langganan, Buat langganan.
4. Untuk kotak dialog Buat langganan, lakukan hal berikut:

a. Untuk Topik ARN, salin dan tempel Nama Sumber Daya Amazon (ARN) berikut: **`arn:aws:sns:us-west-2:767397762724:dlami-updates`**

b. Untuk Protokol, pilih salah satu dari [Amazon SQS, AWS Lamda, Email, Email-JSON]

c. Untuk Endpoint, masukkan alamat email atau Nama Sumber Daya Amazon (ARN) sumber daya yang akan Anda gunakan untuk menerima notifikasi.

d. Pilih Buat langganan.

5. Anda menerima email konfirmasi dengan baris subjek AWS Pemberitahuan - Konfirmasi Langganan. Buka email dan pilih Konfirmasi berlangganan untuk menyelesaikan langganan Anda.

Keamanan di AWS Deep Learning AMIs

Keamanan cloud di AWS adalah prioritas tertinggi. Sebagai AWS pelanggan, Anda mendapat manfaat dari pusat data dan arsitektur jaringan yang dibangun untuk memenuhi persyaratan organisasi yang paling sensitif terhadap keamanan.

Keamanan adalah tanggung jawab bersama antara Anda AWS dan Anda. Model tanggung jawab bersama menjelaskan hal ini sebagai keamanan dari cloud dan keamanan dalam cloud:

- Keamanan cloud — AWS bertanggung jawab untuk melindungi infrastruktur yang berjalan Layanan AWS di dalamnya AWS Cloud. AWS juga memberi Anda layanan yang dapat Anda gunakan dengan aman. Auditor pihak ketiga secara teratur menguji dan memverifikasi efektivitas keamanan kami sebagai bagian dari Program AWS Kepatuhan Program AWS Kepatuhan . Untuk mempelajari tentang program kepatuhan yang berlaku AWS Deep Learning AMIs, lihat AWS Layanan dalam Lingkup oleh AWS Layanan Program Kepatuhan .
- Keamanan di cloud — Tanggung jawab Anda ditentukan oleh Layanan AWS yang Anda gunakan. Anda juga bertanggung jawab atas faktor lain, termasuk sensitivitas data Anda, persyaratan perusahaan Anda, serta undang-undang dan peraturan yang berlaku.

Dokumentasi ini membantu Anda memahami cara menerapkan model tanggung jawab bersama saat menggunakan DLAMI. Topik berikut menunjukkan cara mengonfigurasi DLAMI untuk memenuhi tujuan keamanan dan kepatuhan Anda. Anda juga belajar cara menggunakan Layanan AWS yang lain yang membantu Anda memantau dan mengamankan sumber daya DLAMI Anda.

Untuk informasi selengkapnya, lihat Keamanan EC2 di Amazon di Panduan EC2 Pengguna Amazon.

Topik

Perlindungan data di AWS Deep Learning AMIs

Model tanggung jawab AWS bersama model berlaku untuk perlindungan data di AWS Deep Learning AMIs. Seperti yang dijelaskan dalam model AWS ini, bertanggung jawab untuk melindungi infrastruktur global yang menjalankan semua AWS Cloud. Anda bertanggung jawab untuk mempertahankan kendali atas konten yang di-host pada infrastruktur ini. Anda juga bertanggung jawab atas tugas-tugas konfigurasi dan manajemen keamanan untuk Layanan AWS yang Anda gunakan. Lihat informasi yang lebih lengkap tentang privasi data dalam Pertanyaan Umum Privasi Data. Lihat informasi tentang perlindungan data di Eropa di pos blog Model Tanggung Jawab Bersama dan GDPR AWS di Blog Keamanan AWS .

Untuk tujuan perlindungan data, kami menyarankan Anda melindungi Akun AWS kredensil dan mengatur pengguna individu dengan AWS IAM Identity Center atau AWS Identity and Access Management (IAM). Dengan cara itu, setiap pengguna hanya diberi izin yang diperlukan untuk memenuhi tanggung jawab tugasnya. Kami juga menyarankan supaya Anda mengamankan data dengan cara-cara berikut:

- Gunakan autentikasi multi-faktor (MFA) pada setiap akun.
- Gunakan SSL/TLS untuk berkomunikasi dengan AWS sumber daya. Kami mensyaratkan TLS 1.2 dan menganjurkan TLS 1.3.
- Siapkan API dan logging aktivitas pengguna dengan AWS CloudTrail. Untuk informasi tentang penggunaan CloudTrail jejak untuk menangkap AWS aktivitas, lihat Bekerja dengan CloudTrail jejak di AWS CloudTrail Panduan Pengguna.
- Gunakan solusi AWS enkripsi, bersama dengan semua kontrol keamanan default di dalamnya Layanan AWS.
- Gunakan layanan keamanan terkelola tingkat lanjut seperti Amazon Macie, yang membantu menemukan dan mengamankan data sensitif yang disimpan di Amazon S3.
- Jika Anda memerlukan modul kriptografi tervalidasi FIPS 140-3 saat mengakses AWS melalui antarmuka baris perintah atau API, gunakan titik akhir FIPS. Lihat informasi selengkapnya tentang titik akhir FIPS yang tersedia di Standar Pemrosesan Informasi Federal (FIPS) 140-3.

Kami sangat merekomendasikan agar Anda tidak pernah memasukkan informasi identifikasi yang sensitif, seperti nomor rekening pelanggan Anda, ke dalam tanda atau bidang isian bebas seperti bidang Nama. Ini termasuk saat Anda bekerja dengan DLAMI atau Layanan AWS lainnya menggunakan konsol, API AWS CLI, atau. AWS SDKs Data apa pun yang Anda masukkan ke dalam tanda atau bidang isian bebas yang digunakan untuk nama dapat digunakan untuk log penagihan

atau log diagnostik. Saat Anda memberikan URL ke server eksternal, kami sangat menganjurkan supaya Anda tidak menyertakan informasi kredensial di dalam URL untuk memvalidasi permintaan Anda ke server itu.

Manajemen identitas dan akses untuk AWS Deep Learning AMIs

AWS Identity and Access Management (IAM) adalah Layanan AWS yang membantu administrator mengontrol akses ke AWS sumber daya dengan aman. Administrator IAM mengontrol siapa yang dapat diautentikasi (masuk) dan diotorisasi (memiliki izin) untuk menggunakan sumber daya DLAMI. IAM adalah Layanan AWS yang dapat Anda gunakan tanpa biaya tambahan.

Untuk informasi selengkapnya tentang identitas dan manajemen akses, lihat Identitas dan manajemen akses untuk Amazon EC2.

Topik

- Mengautentikasi dengan identitas
- Mengelola akses menggunakan kebijakan
- IAM dengan Amazon EMR

Mengautentikasi dengan identitas

Otentikasi adalah cara Anda masuk AWS menggunakan kredensi identitas Anda. Anda harus diautentikasi (masuk ke AWS) sebagai Pengguna root akun AWS, sebagai pengguna IAM, atau dengan mengasumsikan peran IAM.

Anda dapat masuk AWS sebagai identitas federasi dengan menggunakan kredensil yang disediakan melalui sumber identitas. AWS IAM Identity Center Pengguna (IAM Identity Center), autentikasi masuk tunggal perusahaan Anda, dan kredensyal Google atau Facebook Anda adalah contoh identitas federasi. Saat Anda masuk sebagai identitas terfederasi, administrator Anda sebelumnya menyiapkan federasi identitas menggunakan peran IAM. Ketika Anda mengakses AWS dengan menggunakan federasi, Anda secara tidak langsung mengambil peran.

Bergantung pada jenis pengguna Anda, Anda dapat masuk ke AWS Management Console atau portal AWS akses. Untuk informasi selengkapnya tentang masuk AWS, lihat Cara masuk ke Panduan AWS Sign-In Pengguna Anda Akun AWS.

Jika Anda mengakses AWS secara terprogram, AWS sediakan kit pengembangan perangkat lunak (SDK) dan antarmuka baris perintah (CLI) untuk menandatangani permintaan Anda secara

kriptografis dengan menggunakan kredensyal Anda. Jika Anda tidak menggunakan AWS alat, Anda harus menandatangani permintaan sendiri. Guna mengetahui informasi selengkapnya tentang penggunaan metode yang disarankan untuk menandatangani permintaan sendiri, lihat AWS Signature Version 4 untuk permintaan API dalam Panduan Pengguna IAM.

Apa pun metode autentikasi yang digunakan, Anda mungkin diminta untuk menyediakan informasi keamanan tambahan. Misalnya, AWS merekomendasikan agar Anda menggunakan otentikasi multi-faktor (MFA) untuk meningkatkan keamanan akun Anda. Untuk mempelajari selengkapnya, lihat Autentikasi multi-faktor dalam Panduan Pengguna AWS IAM Identity Center dan Autentikasi multi-faktor AWS di IAM dalam Panduan Pengguna IAM.

Akun AWS pengguna root

Saat Anda membuat Akun AWS, Anda mulai dengan satu identitas masuk yang memiliki akses lengkap ke semua Layanan AWS dan sumber daya di akun. Identitas ini disebut pengguna Akun AWS root dan diakses dengan masuk dengan alamat email dan kata sandi yang Anda gunakan untuk membuat akun. Kami sangat menyarankan agar Anda tidak menggunakan pengguna root untuk tugas sehari-hari. Lindungi kredensial pengguna root Anda dan gunakan kredensial tersebut untuk melakukan tugas yang hanya dapat dilakukan pengguna root. Untuk daftar lengkap tugas yang mengharuskan Anda masuk sebagai pengguna root, lihat Tugas yang memerlukan kredensial pengguna root dalam Panduan Pengguna IAM.

Pengguna dan grup IAM

Pengguna IAM adalah identitas dalam diri Anda Akun AWS yang memiliki izin khusus untuk satu orang atau aplikasi. Jika memungkinkan, kami merekomendasikan untuk mengandalkan kredensial sementara, bukan membuat pengguna IAM yang memiliki kredensial jangka panjang seperti kata sandi dan kunci akses. Namun, jika Anda memiliki kasus penggunaan tertentu yang memerlukan kredensial jangka panjang dengan pengguna IAM, kami merekomendasikan Anda merotasi kunci akses. Untuk informasi selengkapnya, lihat Merotasi kunci akses secara teratur untuk kasus penggunaan yang memerlukan kredensial jangka panjang dalam Panduan Pengguna IAM.

Grup IAM adalah identitas yang menentukan sekumpulan pengguna IAM. Anda tidak dapat masuk sebagai grup. Anda dapat menggunakan grup untuk menentukan izin bagi beberapa pengguna sekaligus. Grup mempermudah manajemen izin untuk sejumlah besar pengguna sekaligus. Misalnya, Anda dapat meminta kelompok untuk menyebutkan IAMAdmins dan memberikan izin kepada grup tersebut untuk mengelola sumber daya IAM.

Pengguna berbeda dari peran. Pengguna secara unik terkait dengan satu orang atau aplikasi, tetapi peran dimaksudkan untuk dapat digunakan oleh siapa pun yang membutuhkannya. Pengguna memiliki kredensial jangka panjang permanen, tetapi peran memberikan kredensial sementara. Untuk mempelajari selengkapnya, lihat Kasus penggunaan untuk pengguna IAM dalam Panduan Pengguna IAM.

Peran IAM

Peran IAM adalah identitas dalam diri Anda Akun AWS yang memiliki izin khusus. Peran ini mirip dengan pengguna IAM, tetapi tidak terkait dengan orang tertentu. Untuk mengambil peran IAM sementara AWS Management Console, Anda dapat beralih dari pengguna ke peran IAM (konsol). Anda dapat mengambil peran dengan memanggil operasi AWS CLI atau AWS API atau dengan menggunakan URL kustom. Untuk informasi selengkapnya tentang cara menggunakan peran, lihat Metode untuk mengambil peran dalam Panduan Pengguna IAM.

Peran IAM dengan kredensial sementara berguna dalam situasi berikut:

- Akses pengguna terfederasi – Untuk menetapkan izin ke identitas terfederasi, Anda membuat peran dan menentukan izin untuk peran tersebut. Ketika identitas terfederasi mengautentikasi, identitas tersebut terhubung dengan peran dan diberi izin yang ditentukan oleh peran. Untuk informasi tentang peran untuk federasi, lihat Buat peran untuk penyedia identitas pihak ketiga dalam Panduan Pengguna IAM. Jika menggunakan Pusat Identitas IAM, Anda harus mengonfigurasi set izin. Untuk mengontrol apa yang dapat diakses identitas Anda setelah identitas tersebut diautentikasi, Pusat Identitas IAM akan mengorelasikan set izin ke peran dalam IAM. Untuk informasi tentang set izin, lihat Set izin dalam Panduan Pengguna AWS IAM Identity Center .
- Izin pengguna IAM sementara – Pengguna atau peran IAM dapat mengambil peran IAM guna mendapatkan berbagai izin secara sementara untuk tugas tertentu.
- Akses lintas akun – Anda dapat menggunakan peran IAM untuk mengizinkan seseorang (prinsipal tepercaya) di akun lain untuk mengakses sumber daya di akun Anda. Peran adalah cara utama untuk memberikan akses lintas akun. Namun, dengan beberapa Layanan AWS, Anda dapat melampirkan kebijakan secara langsung ke sumber daya (alih-alih menggunakan peran sebagai proxy). Untuk mempelajari perbedaan antara peran dan kebijakan berbasis sumber daya untuk akses lintas akun, lihat Akses sumber daya lintas akun di IAM dalam Panduan Pengguna IAM.
- Akses lintas layanan — Beberapa Layanan AWS menggunakan fitur lain Layanan AWS. Misalnya, saat Anda melakukan panggilan dalam suatu layanan, biasanya layanan tersebut menjalankan aplikasi di Amazon EC2 atau menyimpan objek di Amazon S3. Sebuah layanan mungkin

melakukannya menggunakan izin prinsipal yang memanggil, menggunakan peran layanan, atau peran terkait layanan.

- Sesi akses teruskan (FAS) — Saat Anda menggunakan pengguna atau peran IAM untuk melakukan tindakan AWS, Anda dianggap sebagai prinsipal. Ketika Anda menggunakan beberapa layanan, Anda mungkin melakukan sebuah tindakan yang kemudian menginisiasi tindakan lain di layanan yang berbeda. FAS menggunakan izin dari pemanggilan utama Layanan AWS, dikombinasikan dengan permintaan Layanan AWS untuk membuat permintaan ke layanan hilir. Permintaan FAS hanya dibuat ketika layanan menerima permintaan yang memerlukan interaksi dengan orang lain Layanan AWS atau sumber daya untuk menyelesaikannya. Dalam hal ini, Anda harus memiliki izin untuk melakukan kedua tindakan tersebut. Untuk detail kebijakan ketika mengajukan permintaan FAS, lihat Sesi akses maju.
- Peran layanan – Peran layanan adalah peran IAM yang dijalankan oleh layanan untuk melakukan tindakan atas nama Anda. Administrator IAM dapat membuat, mengubah, dan menghapus peran layanan dari dalam IAM. Untuk informasi selengkapnya, lihat Buat sebuah peran untuk mendelegasikan izin ke Layanan AWS dalam Panduan pengguna IAM.
- Peran terkait layanan — Peran terkait layanan adalah jenis peran layanan yang ditautkan ke. Layanan AWS Layanan tersebut dapat menjalankan peran untuk melakukan tindakan atas nama Anda. Peran terkait layanan muncul di Anda Akun AWS dan dimiliki oleh layanan. Administrator IAM dapat melihat, tetapi tidak dapat mengedit izin untuk peran terkait layanan.

- Aplikasi yang berjalan di Amazon EC2 — Anda dapat menggunakan peran IAM untuk mengelola kredensyal sementara untuk aplikasi yang berjalan pada EC2 instance dan membuat AWS CLI atau AWS permintaan API. Ini lebih baik untuk menyimpan kunci akses dalam EC2 instance. Untuk menetapkan AWS peran ke EC2 instance dan membuatnya tersedia untuk semua aplikasinya, Anda membuat profil instance yang dilampirkan ke instance. Profil instance berisi peran dan memungkinkan program yang berjalan pada EC2 instance untuk mendapatkan kredensi sementara. Untuk informasi selengkapnya, lihat Menggunakan peran IAM untuk memberikan izin ke aplikasi yang berjalan di EC2 instans Amazon di Panduan Pengguna IAM.

Mengelola akses menggunakan kebijakan

Anda mengontrol akses AWS dengan membuat kebijakan dan melampirkannya ke AWS identitas atau sumber daya. Kebijakan adalah objek AWS yang, ketika dikaitkan dengan identitas atau sumber daya, menentukan izinnya. AWS mengevaluasi kebijakan ini ketika prinsipal (pengguna, pengguna root, atau sesi peran) membuat permintaan. Izin dalam kebijakan menentukan apakah permintaan diizinkan atau ditolak. Sebagian besar kebijakan disimpan AWS sebagai dokumen JSON. Untuk

informasi selengkapnya tentang struktur dan isi dokumen kebijakan JSON, lihat Gambaran umum kebijakan JSON dalam Panduan Pengguna IAM.

Administrator dapat menggunakan kebijakan AWS JSON untuk menentukan siapa yang memiliki akses ke apa. Artinya, prinsipal manakah yang dapat melakukan tindakan pada sumber daya apa, dan dengan kondisi apa.

Secara default, pengguna dan peran tidak memiliki izin. Untuk memberikan izin kepada pengguna untuk melakukan tindakan di sumber daya yang mereka perlukan, administrator IAM dapat membuat kebijakan IAM. Administrator kemudian dapat menambahkan kebijakan IAM ke peran, dan pengguna dapat mengambil peran.

Kebijakan IAM mendefinisikan izin untuk suatu tindakan terlepas dari metode yang Anda gunakan untuk melakukan operasinya. Misalnya, anggaplah Anda memiliki kebijakan yang mengizinkan tindakan `iam:GetRole`. Pengguna dengan kebijakan tersebut bisa mendapatkan informasi peran dari AWS Management Console, API AWS CLI, atau AWS API.

Kebijakan berbasis identitas

Kebijakan berbasis identitas adalah dokumen kebijakan izin JSON yang dapat Anda lampirkan ke sebuah identitas, seperti pengguna IAM, grup pengguna IAM, atau peran IAM. Kebijakan ini mengontrol jenis tindakan yang dapat dilakukan oleh pengguna dan peran, di sumber daya mana, dan berdasarkan kondisi seperti apa. Untuk mempelajari cara membuat kebijakan berbasis identitas, lihat Tentukan izin IAM kustom dengan kebijakan terkelola pelanggan dalam Panduan Pengguna IAM.

Kebijakan berbasis identitas dapat dikategorikan lebih lanjut sebagai kebijakan inline atau kebijakan yang dikelola. Kebijakan inline disematkan langsung ke satu pengguna, grup, atau peran. Kebijakan terkelola adalah kebijakan mandiri yang dapat dilampirkan ke beberapa pengguna, grup, dan peran dalam. Akun AWS Kebijakan AWS terkelola mencakup kebijakan terkelola dan kebijakan yang dikelola pelanggan. Untuk mempelajari cara memilih antara kebijakan yang dikelola atau kebijakan inline, lihat Pilih antara kebijakan yang dikelola dan kebijakan inline dalam Panduan Pengguna IAM.

Kebijakan berbasis sumber daya

Kebijakan berbasis sumber daya adalah dokumen kebijakan JSON yang Anda lampirkan ke sumber daya. Contoh kebijakan berbasis sumber daya adalah kebijakan kepercayaan peran IAM dan kebijakan bucket Amazon S3. Dalam layanan yang mendukung kebijakan berbasis sumber daya, administrator layanan dapat menggunakannya untuk mengontrol akses ke sumber daya tertentu.

Untuk sumber daya tempat kebijakan dilampirkan, kebijakan menentukan tindakan apa yang dapat dilakukan oleh prinsipal tertentu pada sumber daya tersebut dan dalam kondisi apa. Anda harus menentukan prinsipal dalam kebijakan berbasis sumber daya. Prinsipal dapat mencakup akun, pengguna, peran, pengguna federasi, atau. Layanan AWS

Kebijakan berbasis sumber daya merupakan kebijakan inline yang terletak di layanan tersebut. Anda tidak dapat menggunakan kebijakan AWS terkelola dari IAM dalam kebijakan berbasis sumber daya.

Daftar kontrol akses (ACLs)

Access control lists (ACLs) mengontrol prinsipal mana (anggota akun, pengguna, atau peran) yang memiliki izin untuk mengakses sumber daya. ACLs mirip dengan kebijakan berbasis sumber daya, meskipun mereka tidak menggunakan format dokumen kebijakan JSON.

Amazon S3, AWS WAF, dan Amazon VPC adalah contoh layanan yang mendukung. ACLs Untuk mempelajari selengkapnya ACLs, lihat Ringkasan daftar kontrol akses (ACL) di Panduan Pengembang Layanan Penyimpanan Sederhana Amazon.

Jenis-jenis kebijakan lain

AWS mendukung jenis kebijakan tambahan yang kurang umum. Jenis-jenis kebijakan ini dapat mengatur izin maksimum yang diberikan kepada Anda oleh jenis kebijakan yang lebih umum.

- Batasan izin – Batasan izin adalah fitur lanjutan tempat Anda mengatur izin maksimum yang dapat diberikan oleh kebijakan berbasis identitas ke entitas IAM (pengguna IAM atau peran IAM). Anda dapat menetapkan batasan izin untuk suatu entitas. Izin yang dihasilkan adalah perpotongan antara kebijakan berbasis identitas milik entitas dan batasan izinnya. Kebijakan berbasis sumber daya yang menentukan pengguna atau peran dalam bidang `Principal` tidak dibatasi oleh batasan izin. Penolakan eksplisit dalam salah satu kebijakan ini akan menggantikan pemberian izin. Untuk informasi selengkapnya tentang batasan izin, lihat Batasan izin untuk entitas IAM dalam Panduan Pengguna IAM.
- Kebijakan kontrol layanan (SCPs) — SCPs adalah kebijakan JSON yang menentukan izin maksimum untuk organisasi atau unit organisasi (OU) di. AWS Organizations AWS Organizations adalah layanan untuk mengelompokkan dan mengelola secara terpusat beberapa Akun AWS yang dimiliki bisnis Anda. Jika Anda mengaktifkan semua fitur dalam organisasi, Anda dapat menerapkan kebijakan kontrol layanan (SCPs) ke salah satu atau semua akun Anda. SCP membatasi izin untuk entitas di akun anggota, termasuk masing-masing. Pengguna root akun AWS Untuk informasi selengkapnya tentang Organizations dan SCPs, lihat Kebijakan kontrol layanan di Panduan AWS Organizations Pengguna.

- Kebijakan kontrol sumber daya (RCPs) — RCPs adalah kebijakan JSON yang dapat Anda gunakan untuk menetapkan izin maksimum yang tersedia untuk sumber daya di akun Anda tanpa memperbarui kebijakan IAM yang dilampirkan ke setiap sumber daya yang Anda miliki. RCP membatasi izin untuk sumber daya di akun anggota dan dapat memengaruhi izin efektif untuk identitas, termasuk Pengguna root akun AWS, terlepas dari apakah itu milik organisasi Anda. Untuk informasi selengkapnya tentang Organizations dan RCPs, termasuk daftar dukungan Layanan AWS tersebut RCPs, lihat Kebijakan kontrol sumber daya (RCPs) di Panduan AWS Organizations Pengguna.
- Kebijakan sesi – Kebijakan sesi adalah kebijakan lanjutan yang Anda berikan sebagai parameter ketika Anda membuat sesi sementara secara programatis untuk peran atau pengguna terfederasi. Izin sesi yang dihasilkan adalah perpotongan antara kebijakan berbasis identitas pengguna atau peran dan kebijakan sesi. Izin juga bisa datang dari kebijakan berbasis sumber daya. Penolakan eksplisit dalam salah satu kebijakan ini akan menggantikan pemberian izin. Untuk informasi selengkapnya, lihat Kebijakan sesi dalam Panduan Pengguna IAM.

Berbagai jenis kebijakan

Ketika beberapa jenis kebijakan berlaku pada suatu permintaan, izin yang dihasilkan lebih rumit untuk dipahami. Untuk mempelajari cara AWS menentukan apakah akan mengizinkan permintaan saat beberapa jenis kebijakan terlibat, lihat Logika evaluasi kebijakan di Panduan Pengguna IAM.

IAM dengan Amazon EMR

Anda dapat menggunakan IAM dengan Amazon EMR untuk menentukan pengguna AWS , sumber daya, grup, peran, dan kebijakan. Anda juga dapat mengontrol pengguna dan peran mana Layanan AWS yang dapat diakses.

Untuk informasi selengkapnya tentang penggunaan IAM dengan Amazon EMR, lihat Amazon AWS Identity and Access Management EMR.

Validasi kepatuhan untuk AWS Deep Learning AMIs

Auditor pihak ketiga menilai keamanan dan kepatuhan AWS Deep Learning AMIs sebagai bagian dari beberapa program AWS kepatuhan. Untuk informasi tentang program kepatuhan yang didukung, lihat Validasi kepatuhan untuk Amazon EC2.

Untuk daftar cakupan program kepatuhan tertentu, lihat AWS Layanan dalam Lingkup menurut AWS Layanan Program Kepatuhan . Layanan AWS Untuk informasi umum, lihat Program AWS Kepatuhan Program AWS .

Anda dapat mengunduh laporan audit pihak ketiga menggunakan AWS Artifact. Untuk informasi selengkapnya, lihat Mengunduh Laporan di Laporan Artefak di. AWS Artifact

Tanggung jawab kepatuhan Anda saat menggunakan DLAMI ditentukan oleh sensitivitas data Anda, tujuan kepatuhan perusahaan Anda, dan hukum dan peraturan yang berlaku. AWS menyediakan sumber daya berikut untuk membantu kepatuhan:

- Panduan Quick Start Keamanan dan Kepatuhan – Panduan deployment ini membahas pertimbangan arsitektur dan menyediakan langkah–langkah untuk melakukan deployment terhadap lingkungan dasar di AWS yang menjadi fokus keamanan dan kepatuhan.
- AWS Sumber Daya AWS — Kumpulan buku kerja dan panduan ini mungkin berlaku untuk industri dan lokasi Anda.
- Mengevaluasi Sumber Daya dengan AWS Config Aturan dalam Panduan AWS Config Pengembang — AWS Config Layanan menilai seberapa baik konfigurasi sumber daya Anda mematuhi praktik internal, pedoman industri, dan peraturan.
- AWS Security Hub— Ini Layanan AWS memberikan pandangan komprehensif tentang keadaan keamanan Anda di dalamnya AWS. Security Hub menggunakan kontrol keamanan untuk mengevaluasi AWS sumber daya Anda dan untuk memeriksa kepatuhan Anda terhadap standar industri keamanan dan praktik terbaik.

Ketahanan di AWS Deep Learning AMIs

Infrastruktur AWS global dibangun di sekitar Wilayah AWS dan Availability Zones. Wilayah AWS menyediakan beberapa Availability Zone yang terpisah secara fisik dan terisolasi, yang terhubung dengan latensi rendah, throughput tinggi, dan jaringan yang sangat redundan. Dengan Zona Ketersediaan, Anda dapat merancang serta mengoperasikan aplikasi dan basis data yang secara otomatis melakukan fail over di antara zona tanpa gangguan. Zona Ketersediaan memiliki ketersediaan dan toleransi kesalahan yang lebih baik, dan dapat diskalakan dibandingkan infrastruktur pusat data tunggal atau multi tradisional.

Untuk informasi selengkapnya tentang Wilayah AWS dan Availability Zone, lihat Infrastruktur AWS Global.

Untuk informasi tentang EC2 fitur Amazon untuk membantu mendukung ketahanan data dan kebutuhan pencadangan, lihat Ketahanan di Amazon EC2 di Panduan Pengguna Amazon EC2 .

Keamanan infrastruktur di AWS Deep Learning AMIs

Keamanan infrastruktur AWS Deep Learning AMIs didukung oleh Amazon EC2. Untuk informasi selengkapnya, lihat Keamanan infrastruktur EC2 di Amazon di Panduan EC2 Pengguna Amazon.

AWS Deep Learning AMIs Contoh pemantauan

Pemantauan adalah bagian penting untuk menjaga keandalan, ketersediaan, dan kinerja AWS Deep Learning AMIs instans Anda dan AWS solusi Anda yang lain. Instans DLAMI Anda dilengkapi dengan beberapa alat pemantauan GPU, termasuk utilitas yang melaporkan statistik penggunaan GPU ke Amazon. CloudWatch Untuk informasi selengkapnya, lihatPemantauan dan Optimasi GPU, dan lihat Memantau EC2 sumber daya Amazon di Panduan EC2 Pengguna Amazon.

Memilih keluar dari pelacakan penggunaan untuk instans DLAMI

Distribusi sistem AWS Deep Learning AMIs operasi berikut mencakup kode yang memungkinkan AWS untuk mengumpulkan jenis instance, ID instance, tipe DLAMI, dan informasi OS.

> **Note**
>
> AWS tidak mengumpulkan atau menyimpan informasi lain tentang DLAMI, seperti perintah yang Anda gunakan dalam DLAMI.

- Amazon Linux 2
- Amazon Linux 2023
- Ubuntu 20.04
- Ubuntu 22.04

Untuk memilih keluar dari pelacakan penggunaan

Jika Anda memilih, Anda dapat memilih keluar dari pelacakan penggunaan untuk instans DLAMI baru. Untuk memilih keluar, Anda harus menambahkan tag ke EC2 instans Amazon Anda selama peluncuran. Tag harus menggunakan kunci `OPT_OUT_TRACKING` dengan nilai terkait yang disetel

`ketrue`. Untuk informasi selengkapnya, lihat Menandai EC2 sumber daya Amazon Anda di Panduan EC2 Pengguna Amazon.

Kebijakan Dukungan DLAMI

Di sini Anda dapat menemukan rincian kebijakan dukungan untuk AWS Deep Learning AMIs (DLAMI).

Untuk daftar kerangka kerja DLAMI dan sistem operasi AWS yang saat ini mendukung, lihat halaman Kebijakan Dukungan DLAMI. Terminologi berikut berlaku untuk semua DLAMIs yang disebutkan di halaman Kebijakan Dukungan dan halaman ini:

- Versi saat ini menentukan versi kerangka kerja dalam format x.y.z. Dalam format ini, x mengacu pada versi utama, y mengacu pada versi minor, dan z mengacu pada versi patch. Misalnya, untuk TensorFlow 2.10.1, versi utama adalah 2, versi minor adalah 10, dan versi patch adalah 1.
- Akhir patch menentukan berapa lama AWS mendukung kerangka kerja atau versi sistem operasi tertentu.

Untuk informasi rinci tentang spesifik DLAMIs, lihatCatatan AMIs Rilis Deep Learning.

DLAMI Support FAQs

- Versi kerangka kerja apa yang mendapatkan tambalan keamanan?
- Sistem operasi mana yang mendapatkan patch keamanan?
- Gambar apa yang AWS dipublikasikan saat versi kerangka kerja baru dirilis?
- Gambar apa yang mendapatkan AWS fitur SageMaker AI/baru?
- Bagaimana versi saat ini didefinisikan dalam tabel Kerangka Kerja yang Didukung?
- Bagaimana jika saya menjalankan versi yang tidak ada di tabel yang Didukung?
- Apakah DLAMIs mendukung versi patch sebelumnya dari Versi Kerangka?
- Bagaimana cara menemukan gambar tambalan terbaru untuk versi kerangka kerja yang didukung?
- Seberapa sering gambar baru dirilis?
- Apakah instance saya akan ditambal di tempat saat beban kerja saya berjalan?
- Apa yang terjadi ketika versi kerangka kerja baru yang ditambal atau diperbarui tersedia?
- Apakah dependensi diperbarui tanpa mengubah versi kerangka kerja?
- Kapan dukungan aktif untuk versi kerangka kerja saya berakhir?

- Akankah gambar dengan versi kerangka kerja yang tidak lagi dipelihara secara aktif ditambal?
- Bagaimana cara menggunakan versi kerangka kerja yang lebih lama?
- Bagaimana cara saya tetap up-to-date dengan perubahan dukungan dalam kerangka kerja dan versinya?
- Apakah saya memerlukan lisensi komersial untuk menggunakan Repositori Anaconda?

Versi kerangka kerja apa yang mendapatkan tambalan keamanan?

Jika versi framework berada di bawah Supported Framework Versions dalam tabel AWS Deep Learning AMIs Support Policy, maka akan mendapat patch keamanan.

Sistem operasi mana yang mendapatkan patch keamanan?

Jika sistem operasi tercantum di bawah Versi Sistem Operasi yang Didukung dalam tabel Kebijakan AWS Deep Learning AMIs Dukungan, itu akan mendapatkan patch keamanan.

Gambar apa yang AWS dipublikasikan saat versi kerangka kerja baru dirilis?

Kami menerbitkan baru DLAMIs segera setelah versi baru TensorFlow dan PyTorch dirilis. Ini termasuk versi mayor, versi mayor-minor, dan major-minor-patch versi kerangka kerja. Kami juga memperbarui gambar saat versi driver dan pustaka baru tersedia. Untuk informasi lebih lanjut tentang pemeliharaan gambar, lihat Kapan dukungan aktif untuk versi kerangka kerja saya berakhir?

Gambar apa yang mendapatkan AWS fitur SageMaker AI/baru?

Fitur baru biasanya dirilis dalam versi terbaru DLAMIs untuk PyTorch dan TensorFlow. Lihat catatan rilis untuk gambar tertentu untuk detail tentang SageMaker AI atau AWS fitur baru. Untuk daftar yang tersedia DLAMIs, lihat Catatan Rilis untuk DLAMI. Untuk informasi lebih lanjut tentang pemeliharaan gambar, lihat Kapan dukungan aktif untuk versi kerangka kerja saya berakhir?

Bagaimana versi saat ini didefinisikan dalam tabel Kerangka Kerja yang Didukung?

Versi saat ini dalam tabel Kebijakan AWS Deep Learning AMIs Dukungan mengacu pada versi kerangka kerja terbaru yang AWS tersedia di GitHub. Setiap rilis terbaru mencakup pembaruan

untuk driver, perpustakaan, dan paket yang relevan di DLAMI. Untuk informasi tentang pemeliharaan gambar, lihat Kapan dukungan aktif untuk versi kerangka kerja saya berakhir?

Bagaimana jika saya menjalankan versi yang tidak ada di tabel yang Didukung?

Jika Anda menjalankan versi yang tidak ada dalam tabel Kebijakan AWS Deep Learning AMIs Dukungan, Anda mungkin tidak memiliki driver, pustaka, dan paket yang relevan yang paling diperbarui. Untuk up-to-date versi yang lebih, kami sarankan Anda meningkatkan ke salah satu kerangka kerja atau sistem operasi yang didukung yang tersedia menggunakan DLAMI terbaru pilihan Anda. Untuk daftar yang tersedia DLAMIs, lihat Catatan Rilis untuk DLAMI.

Apakah DLAMIs mendukung versi patch sebelumnya dari Versi Kerangka?

Tidak. Kami mendukung versi patch terbaru dari setiap versi utama terbaru framework yang dirilis 365 hari dari GitHub rilis awal seperti yang dinyatakan dalam tabel Kebijakan AWS Deep Learning AMIs Dukungan. Untuk informasi selengkapnya, lihat Bagaimana jika saya menjalankan versi yang tidak ada di tabel yang Didukung?

Bagaimana cara menemukan gambar tambalan terbaru untuk versi kerangka kerja yang didukung?

Untuk menggunakan DLAMI dengan versi kerangka kerja terbaru, Anda dapat menggunakan parameter AWS CLI atau SSM untuk mengambil ID DLAMI dan menggunakannya untuk meluncurkan DLAMI menggunakan Konsol. EC2 Untuk contoh perintah parameter AWS CLI atau SSM untuk mengambil AWS Deep Learning AMIs ID, lihat catatan rilis DLAMI halaman catatan rilis kerangka tunggal DLAMI catatan rilis. Versi kerangka kerja yang Anda pilih harus tercantum di bawah Versi Kerangka yang AWS Deep Learning AMIs Didukung dalam tabel Kebijakan Dukungan.

Seberapa sering gambar baru dirilis?

Menyediakan versi tambalan yang diperbarui adalah prioritas tertinggi kami. Kami secara rutin membuat gambar yang ditambal pada kesempatan paling awal. Kami memantau versi kerangka kerja yang baru ditambal (mis. TensorFlow 2.9 hingga TensorFlow 2.9.1) dan versi rilis minor baru (mis. TensorFlow 2.9 hingga TensorFlow 2.10) dan membuatnya tersedia pada kesempatan paling awal. Ketika versi yang TensorFlow ada dirilis dengan versi baru CUDA, kami merilis DLAMI baru untuk versi tersebut dengan dukungan untuk versi TensorFlow CUDA baru.

Apakah instance saya akan ditambal di tempat saat beban kerja saya berjalan?

Tidak. Pembaruan tambalan untuk DLAMI bukan pembaruan “di tempat”.

Anda harus mengaktifkan EC2 instance baru, memigrasikan beban kerja dan skrip, lalu mematikan instance sebelumnya.

Apa yang terjadi ketika versi kerangka kerja baru yang ditambal atau diperbarui tersedia?

Untuk diberitahu tentang perubahan dalam DLAMI, silakan berlangganan pemberitahuan untuk DLAMI yang relevan, lihat Menerima Pemberitahuan tentang Pembaruan Baru.

Apakah dependensi diperbarui tanpa mengubah versi kerangka kerja?

Kami memperbarui dependensi tanpa mengubah versi kerangka kerja. Namun, jika pembaruan ketergantungan menyebabkan ketidakcocokan, kami membuat gambar dengan versi yang berbeda. Pastikan untuk memeriksa Catatan Rilis untuk DLAMI untuk informasi ketergantungan yang diperbarui.

Kapan dukungan aktif untuk versi kerangka kerja saya berakhir?

Gambar DLAMI tidak dapat diubah. Begitu mereka diciptakan, mereka tidak berubah. Ada empat alasan utama mengapa dukungan aktif untuk versi kerangka kerja berakhir:

- Versi kerangka kerja (patch) upgrade
- AWS patch keamanan
- Akhir tanggal tambalan (Aging out)
- Ketergantungan end-of-support

> **Note**
>
> Karena frekuensi upgrade versi patch dan patch keamanan, kami sarankan memeriksa halaman catatan rilis untuk DLAMI Anda sering, dan upgrade ketika perubahan dilakukan.

Versi kerangka kerja (patch) upgrade

Jika Anda memiliki beban kerja DLAMI TensorFlow berdasarkan 2.7.0 TensorFlow dan merilis versi 2.7.1, kemudian merilis DLAMI baru dengan 2.7.1 GitHub. AWS TensorFlow Gambar sebelumnya dengan 2.7.0 tidak lagi aktif dipertahankan setelah gambar baru dengan TensorFlow 2.7.1 dirilis. DLAMI TensorFlow dengan 2.7.0 tidak menerima tambalan lebih lanjut. Halaman catatan rilis DLAMI TensorFlow untuk 2.7 kemudian diperbarui dengan informasi terbaru. Tidak ada halaman catatan rilis individual untuk setiap tambalan kecil.

Baru DLAMIs dibuat karena upgrade patch ditetapkan dengan ID AMI baru.

AWS patch keamanan

Jika Anda memiliki beban kerja berdasarkan gambar dengan TensorFlow 2.7.0 dan AWS membuat patch keamanan, maka versi baru DLAMI dirilis untuk 2.7.0. TensorFlow Versi gambar sebelumnya dengan TensorFlow 2.7.0 tidak lagi dipertahankan secara aktif. Untuk informasi selengkapnya, lihat Apakah instance saya akan ditambal di tempat saat beban kerja saya berjalan? Untuk langkah-langkah menemukan DLAMI terbaru, lihat Bagaimana cara menemukan gambar tambalan terbaru untuk versi kerangka kerja yang didukung?

Baru DLAMIs dibuat karena upgrade patch ditetapkan dengan ID AMI baru.

Akhir tanggal tambalan (Aging out)

DLAMIs mencapai akhir tanggal patch mereka 365 hari setelah tanggal GitHub rilis.

Untuk multi-kerangka kerja DLAMIs, ketika salah satu versi kerangka diperbarui, DLAMI baru dengan versi yang diperbarui diperlukan. DLAMI dengan versi kerangka kerja lama tidak lagi dipertahankan secara aktif.

> **Important**
>
> Kami membuat pengecualian ketika ada pembaruan kerangka kerja utama. Sebagai contoh. jika TensorFlow 1.15 memperbarui ke TensorFlow 2.0, maka kami terus mendukung versi terbaru TensorFlow 1.15 untuk jangka waktu dua tahun sejak tanggal GitHub rilis atau enam bulan setelah tim pemeliharaan kerangka kerja asal menjatuhkan dukungan, tanggal mana pun yang lebih awal.

Ketergantungan end-of-support

Jika Anda menjalankan beban kerja pada gambar DLAMI TensorFlow 2.7.0 dengan Python 3.6 dan versi Python ditandai, end-of-support maka semua gambar DLAMI berdasarkan Python 3.6 tidak akan lagi dipertahankan secara aktif. Demikian pula, jika versi OS seperti Ubuntu 16.04 ditandai untuk end-of-support, maka semua gambar DLAMI yang bergantung pada Ubuntu 16.04 tidak akan lagi dipertahankan secara aktif.

Akankah gambar dengan versi kerangka kerja yang tidak lagi dipelihara secara aktif ditambal?

Tidak. Gambar yang tidak lagi dipelihara secara aktif tidak akan memiliki rilis baru.

Bagaimana cara menggunakan versi kerangka kerja yang lebih lama?

Untuk menggunakan DLAMI dengan versi kerangka kerja yang lebih lama, ambil ID DLAMI dan gunakan untuk meluncurkan DLAMI menggunakan Konsol. EC2 Untuk perintah AWS CLI untuk mengambil ID AMI, lihat halaman catatan rilis dalam catatan rilis DLAMI kerangka tunggal.

Bagaimana cara saya tetap up-to-date dengan perubahan dukungan dalam kerangka kerja dan versinya?

Tetap up-to-date dengan kerangka kerja dan versi DLAMI menggunakan tabel Kebijakan Dukungan AWS Deep Learning AMIs Kerangka Kerja, catatan rilis DLAMI.

Apakah saya memerlukan lisensi komersial untuk menggunakan Repositori Anaconda?

Anaconda beralih ke model lisensi komersial untuk pengguna tertentu. Dipelihara secara aktif DLAMIs telah dimigrasikan ke versi open-source Conda (conda-forge) yang tersedia untuk umum dari saluran Anaconda.

Tabel Kebijakan Dukungan DLAMI

Untuk detail selengkapnya lihat Kebijakan Dukungan.

Versi Kerangka yang Didukung

Kerangka Kerja	Versi saat ini	Versi CUDA	GitHub GA	Akhir tambalan
PyTorch	2.7.0	12.8	2025-04-23	2026-04-23
PyTorch	2.6.0	12.6	2025-01-29	2026-01-29
PyTorch	2.5.1	12.4	2024-11-24	2025-11-24
PyTorch	2.4.1	12.4	2024-07-24	2025-07-24
TensorFlow	2.18.0	12,5	2024-10-24	2025-10-24
TensorFlow	2.17.0	12.3	2024-11-07	2025-11-07

Versi Sistem Operasi yang Didukung

Sistem Operasi	Akhir tambalan
Amazon Linux 2023	2029-06-30
Amazon Linux 2	2026-06-30
Ubuntu 24.04	2029-04-30
Ubuntu 22.04	2027-04-30

Versi Kerangka Tidak Didukung

Versi yang tercantum dalam tabel ini akan muncul selama 2 tahun setelah tanggal dukungannya.

Kerangka Kerja	Versi saat ini	Versi CUDA	GitHub GA	Akhir tambalan
PyTorch	2.3.0	12.1	2024-04-24	2025-04-24
PyTorch	2.2.0	12.1	2024-01-30	2025-01-30
PyTorch	1.13.1	11.7	2022-10-28	2024-10-28
PyTorch	2.1.0	12.1	2023-10-04	2024-10-04
PyTorch	2.0.0	12.1	2023-03-15	2024-03-15
PyTorch	1.12.1	11.6	2022-07-01	2023-07-01
PyTorch	1.11.0	11.5	2022-03-10	2023-03-10
TensorFlow	2.16.0	12.3	2024-03-07	2025-03-07
TensorFlow	2.15.0	12.2	2023-11-14	2024-11-14
TensorFlow	2.13.0	11.8	2023-07-19	2024-07-19
TensorFlow	2.12.0	11.8	2023-03-23	2024-03-23
TensorFlow	2.11.0	11.2	2022-11-18	2023-11-18
TensorFlow	2.10.1	11.2	2022-09-06	2023-09-06
TensorFlow	2.9.3	11.2	2022-05-17	2023-05-17

Versi Sistem Operasi yang Tidak Didukung

Sistem Operasi	Akhir tambalan
Ubuntu 20.04	2025-05-31
Ubuntu 18.04	2023-05-31

Arsip Catatan Rilis DLAMI yang Tidak Didukung

Basis

GPU

- AWS AMI Dasar Pembelajaran Mendalam (Ubuntu 20.04)
- AWS AMI Dasar Pembelajaran Mendalam (Ubuntu 18.04)

Kerangka Tunggal

PyTorch AMI Spesifik

GPU

- AWS Pembelajaran Mendalam AMI GPU PyTorch 2.3 (Ubuntu 20.04)
- AWS Pembelajaran Mendalam AMI GPU PyTorch 2.3 (Amazon Linux 2)
- AWS Pembelajaran Mendalam ARM64 AMI GPU PyTorch 2.3 (Ubuntu 22.04)
- AWS Pembelajaran Mendalam AMI GPU PyTorch 2.2 (Amazon Linux 2)
- AWS Pembelajaran Mendalam AMI GPU PyTorch 2.2 (Ubuntu 20.04)
- AWS Pembelajaran Mendalam AMI GPU PyTorch 2.1 (Ubuntu 20.04)
- AWS Pembelajaran Mendalam AMI GPU PyTorch 2.0 (Amazon Linux 2)
- AWS Pembelajaran Mendalam AMI GPU PyTorch 2.0 (Ubuntu 20.04)
- AWS Pembelajaran Mendalam AMI GPU PyTorch 1.13 (Amazon Linux 2)
- AWS Pembelajaran Mendalam AMI GPU PyTorch 1.13 (Ubuntu 20.04)
- AWS Pembelajaran Mendalam AMI GPU PyTorch 1.12 (Amazon Linux 2)
- AWS Pembelajaran Mendalam AMI GPU PyTorch 1.12 (Ubuntu 20.04)
- AWS Pembelajaran Mendalam AMI GPU PyTorch 1.11 (Amazon Linux 2)
- AWS Pembelajaran Mendalam AMI GPU PyTorch 1.11 (Ubuntu 20.04)
- AWS Pembelajaran Mendalam AMI GPU PyTorch 1.10 (Amazon Linux 2)
- AWS Pembelajaran Mendalam AMI GPU PyTorch 1.10 (Ubuntu 20.04)
- AWS Pembelajaran Mendalam AMI Graviton GPU PyTorch 1.10 (Ubuntu 20.04)
- AWS Pembelajaran Mendalam AMI GPU PyTorch 1.10 (Ubuntu 18.04)

- AWS Pembelajaran Mendalam AMI GPU PyTorch 1.9 (Amazon Linux 2)
- AWS Pembelajaran Mendalam AMI GPU PyTorch 1.9 (Ubuntu 20.04)
- AWS Pembelajaran Mendalam AMI GPU PyTorch 1.9 (Ubuntu 18.04)

TensorFlow AMI Spesifik

GPU

- AWS Pembelajaran Mendalam AMI GPU TensorFlow 2.16 (Amazon Linux 2)
- AWS Pembelajaran Mendalam AMI GPU TensorFlow 2.16 (Ubuntu 20.04)
- AWS Pembelajaran Mendalam AMI GPU TensorFlow 2.15 (Amazon Linux 2)
- AWS Pembelajaran Mendalam AMI GPU TensorFlow 2.15 (Ubuntu 20.04)
- AWS Pembelajaran Mendalam AMI GPU TensorFlow 2.13 (Amazon Linux 2)
- AWS Pembelajaran Mendalam AMI GPU TensorFlow 2.13 (Ubuntu 20.04)
- AWS Pembelajaran Mendalam AMI GPU TensorFlow 2.12 (Amazon Linux 2)
- AWS Pembelajaran Mendalam AMI GPU TensorFlow 2.12 (Ubuntu 20.04)
- AWS Pembelajaran Mendalam AMI GPU TensorFlow 2.11 (Amazon Linux 2)
- AWS Pembelajaran Mendalam AMI GPU TensorFlow 2.11 (Ubuntu 20.04)
- AWS Pembelajaran Mendalam AMI GPU TensorFlow 2.10 (Amazon Linux 2)
- AWS Pembelajaran Mendalam AMI GPU TensorFlow 2.10 (Ubuntu 20.04)
- AWS Pembelajaran Mendalam AMI GPU TensorFlow 2.9 (Amazon Linux 2)
- AWS Pembelajaran Mendalam AMI GPU TensorFlow 2.9 (Ubuntu 20.04)
- AWS Pembelajaran Mendalam AMI GPU TensorFlow 2.8 (Amazon Linux 2)
- AWS Pembelajaran Mendalam AMI GPU TensorFlow 2.8 (Ubuntu 20.04)
- AWS Pembelajaran Mendalam AMI GPU TensorFlow 2.7 (Amazon Linux 2)
- AWS Pembelajaran Mendalam AMI GPU TensorFlow 2.7 (Ubuntu 20.04)
- AWS Pembelajaran Mendalam AMI GPU TensorFlow 2.6 (Amazon Linux 2)
- AWS Pembelajaran Mendalam AMI GPU TensorFlow 2.6 (Ubuntu 20.04)
- AWS Pembelajaran Mendalam AMI Graviton GPU TensorFlow 2.6 (Ubuntu 20.04)
- AWS Pembelajaran Mendalam AMI GPU TensorFlow 2.6 (Ubuntu 18.04)
- AWS Pembelajaran Mendalam AMI GPU TensorFlow 2.5 (Amazon Linux 2)
- AWS Pembelajaran Mendalam AMI GPU TensorFlow 2.5 (Ubuntu 20.04)

Multi Kerangka

GPU

- AWS AMI Pembelajaran Mendalam (Ubuntu 18.04)

Driver NVIDIA penting berubah menjadi DLAMIs

Pada 15 November 2023, AWS membuat perubahan penting pada AWS Deep Learning AMIs (DLAMI) terkait dengan driver NIVIDA yang menggunakan. DLAMIs Untuk informasi tentang apa yang berubah dan apakah itu memengaruhi penggunaan Anda DLAMIs, lihatPerubahan driver DLAMI NVIDIA FAQs.

Perubahan driver DLAMI NVIDIA FAQs

Apa yang berubah?

Kami membagi DLAMIs menjadi dua kelompok terpisah:

- DLAMIs yang menggunakan driver berpemilik NVIDIA (untuk mendukung P3, P3dn, G3)
- DLAMIs yang menggunakan driver NVIDIA OSS (untuk mendukung G4dn, G5, P4, P5)

Hasilnya, kami membuat baru DLAMIs untuk masing-masing dari dua kategori dengan nama baru dan AMI baru IDs. Ini DLAMIs tidak bisa dipertukarkan. Artinya, DLAMIs dari satu grup tidak mendukung contoh yang didukung grup lain. Misalnya, DLAMI yang mendukung P5 tidak mendukung G3, dan DLAMI yang mendukung G3 tidak mendukung P5.

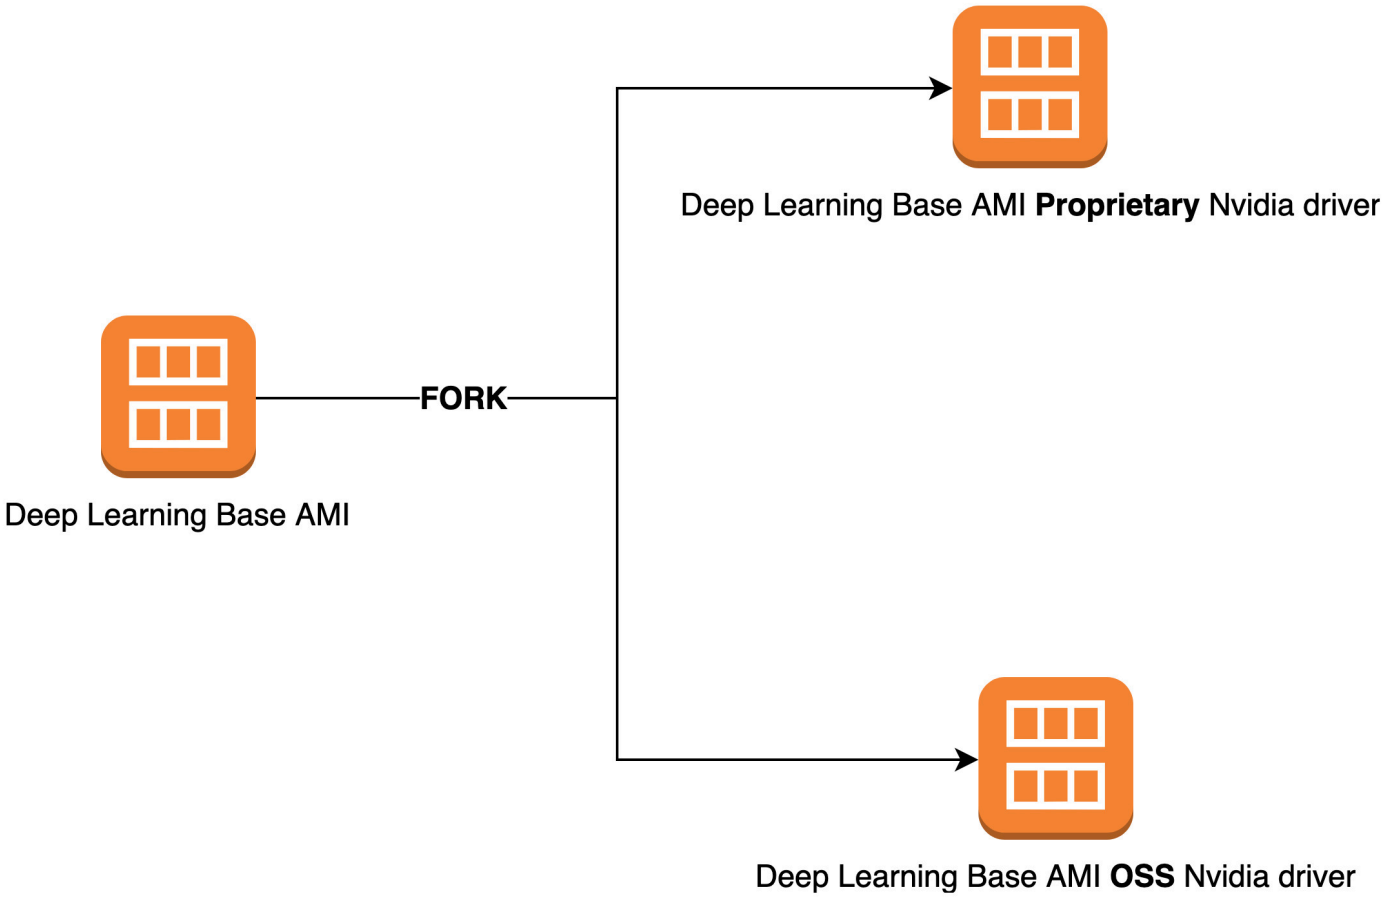

Mengapa perubahan ini diperlukan?

Sebelumnya, DLAMIs untuk NVIDIA GPUs termasuk driver kernel berpemilik dari NVIDIA. Namun, komunitas kernel Linux hulu menerima perubahan yang mengisolasi driver kernel berpemilik, seperti driver GPU NVIDIA, dari berkomunikasi dengan driver kernel lainnya. Perubahan ini menonaktifkan GPUDirect RDMA pada instance seri P4 dan P5, yang merupakan mekanisme yang memungkinkan penggunaan EFA secara efisien GPUs untuk pelatihan terdistribusi. Akibatnya, DLAMIs sekarang gunakan driver OpenRM (driver open source NVIDIA), yang ditautkan dengan driver EFA open source untuk mendukung G4dn, G5, P4, dan P5. Namun, driver OpenRM ini tidak mendukung instance lama (seperti P3 dan G3). Oleh karena itu, untuk memastikan bahwa kami terus menyediakan arus, berkinerja, dan aman DLAMIs yang mendukung kedua jenis instans, kami membagi DLAMIs menjadi dua kelompok: satu dengan driver OpenRM (yang mendukung G4dn, G5, P4, dan P5), dan satu dengan driver berpemilik yang lebih lama (yang mendukung P3, P3dn, dan G3).

DLAMIs Apa yang mempengaruhi perubahan ini?

Perubahan ini mempengaruhi semua DLAMIs.

Apa artinya ini bagi Anda?

Semua DLAMIs akan terus menyediakan fungsionalitas, kinerja, dan keamanan selama Anda menjalankannya pada jenis instans Amazon Elastic Compute Cloud (Amazon EC2) yang didukung. Untuk menentukan jenis EC2 instance yang didukung DLAMI, periksa catatan rilis untuk DLAMI tersebut, lalu cari Instans yang Didukung. EC2 Untuk daftar opsi DLAMI yang saat ini didukung dan tautan ke catatan rilis mereka, lihat. Catatan AMIs Rilis Deep Learning

Selain itu, Anda harus menggunakan perintah AWS Command Line Interface (AWS CLI) yang benar untuk memanggil arus DLAMIs.

Untuk basis DLAMIs yang mendukung P3, P3dn, dan G3, gunakan perintah ini:

```
aws ec2 describe-images --region us-east-1 --owners amazon \
--filters 'Name=name,Values=Deep Learning Base Proprietary Nvidia Driver AMI (Amazon
 Linux 2) Version ??.?' 'Name=state,Values=available' \
--query 'reverse(sort_by(Images, &CreationDate))[:1].ImageId' --output text
```

Untuk basis DLAMIs yang mendukung G4dn, G5, P4, dan P5, gunakan perintah ini:

```
aws ec2 describe-images --region us-east-1 --owners amazon \
--filters 'Name=name,Values=Deep Learning Base OSS Nvidia Driver AMI (Amazon Linux 2)
 Version ??.?' 'Name=state,Values=available' \
--query 'reverse(sort_by(Images, &CreationDate))[:1].ImageId' --output text
```

Apakah ada kehilangan fungsionalitas dengan yang lebih baru? DLAMIs

Tidak, tidak ada kehilangan fungsionalitas. Saat ini DLAMIs menyediakan semua fungsionalitas, kinerja, dan keamanan yang sebelumnya DLAMIs, asalkan Anda menjalankannya pada jenis EC2 instans yang didukung.

Apakah perubahan ini memengaruhi Deep Learning Containers?

Tidak, perubahan ini tidak memengaruhi AWS Deep Learning Containers, karena tidak menyertakan driver NVIDIA. Namun, pastikan untuk menjalankan Deep Learning Containers AMIs yang kompatibel dengan instance yang mendasarinya.

Informasi terkait DLAMI

Anda dapat menemukan sumber daya lain dengan informasi terkait tentang DLAMI di luar Panduan Pengembang AWS Deep Learning AMIs . Pada AWS re:Post, lihat pertanyaan tentang DLAMI dari pelanggan lain, atau ajukan pertanyaan Anda sendiri. Di Blog AWS Machine Learning dan AWS blog lainnya, baca posting resmi tentang DLAMI.

AWS re:Post

Tag: AWS Deep Learning AMIs

AWS Blog

- AWS Machine Learning Blog | Kategori: AWS Deep Learning AMIs
- AWS Machine Learning Blog | Pelatihan lebih cepat dengan TensorFlow 1.6 yang dioptimalkan di instans Amazon EC2 C5 dan P3
- AWS Machine Learning Blog | Baru AWS Deep Learning AMIs untuk Praktisi Machine Learning
- AWS Partner Network (APN) Blog | Kursus Pelatihan Baru Tersedia: Pengantar Machine Learning & Deep Learning on AWS
- AWS Blog Berita | Perjalanan ke Pembelajaran Mendalam dengan AWS

Fitur DLAMI yang tidak digunakan lagi

Tabel berikut mencantumkan fitur yang tidak digunakan lagi dari (AWS Deep Learning AMIs DLAMI), tanggal yang kita tidak digunakan lagi, dan detail tentang mengapa kita tidak menggunakannya lagi.

Fitur	Tanggal	Detail
Ubuntu 16.04	10/07/2021	Ubuntu Linux 16.04 LTS mencapai akhir jendela LTS lima tahun pada 30 April 2021 dan tidak lagi didukung oleh vendornya. Tidak ada lagi pembaruan untuk Deep Learning Base AMI (Ubuntu 16.04) dalam rilis baru per Oktober 2021. Rilis sebelumnya akan terus tersedia.
Amazon Linux	10/07/2021	Amazon Linux adalah end-of-lifepada Desember 2020. Tidak ada lagi pembaruan untuk Deep Learning AMI (Amazon Linux) dalam rilis baru per Oktober 2021. Rilis Deep Learning AMI (Amazon Linux) sebelumny a akan terus tersedia.
Chainer	07/01/2020	Chainer telah mengumumk an akhir rilis utama pada Desember 2019. Akibatnya , kami tidak akan lagi memasukkan lingkungan Chainer Conda di DLAMI mulai Juli 2020. Rilis DLAMI sebelumnya yang

Fitur	Tanggal	Detail
		berisi lingkungan ini akan terus tersedia. Kami akan memberikan pembaruan untuk lingkungan ini hanya jika ada perbaikan keamanan yang diterbitkan oleh komunitas open source untuk kerangka kerja ini.
Python 3.6	06/15/2020	Karena permintaan pelanggan, kami pindah ke Python 3.7 untuk rilis baru. TF/MX/PT
Python 2	01/01/2020	Komunitas open source Python telah secara resmi mengakhiri dukungan untuk Python 2. The TensorFlow, PyTorch, and MXNet community juga telah mengumumk an bahwa rilis TensorFlo w 1.15, TensorFlow 2.1, PyTorch 1.4, dan MXNet 1.6.0 akan menjadi yang terakhir mendukung Python 2.

Riwayat dokumen untuk DLAMI

Tabel berikut memberikan riwayat rilis DLAMI terbaru dan perubahan terkait dengan Panduan Pengembang AWS Deep Learning AMIs .

Perubahan terbaru

Perubahan	Deskripsi	Tanggal
Menggunakan TensorFlow Melayani untuk Melatih Model MNIST	Contoh untuk menggunakan Tensorflow yang berfungsi untuk melatih model MNIST.	Februari 14, 2025
ARM64 DLAMI	AWS Deep Learning AMIs Sekarang mendukung gambar berbasis prosesor GPUs Arm64.	29 November 2021
TensorFlow 2	AMI Pembelajaran Mendalam dengan Conda sekarang hadir dengan TensorFlow 2 dengan CUDA 10.	3 Desember 2019
AWS Inferensia	Deep Learning AMI sekarang mendukung perangkat keras AWS Inferentia dan AWS Neuron SDK.	3 Desember 2019
Menginstal PyTorch dari Nightly Build	Sebuah tutorial telah ditambahkan yang mencakup bagaimana Anda dapat menghapus instalasi PyTorch, lalu menginstal build malam PyTorch pada AMI Pembelajaran Mendalam Anda dengan Conda.	25 September 2018

Conda Tutorial	Contoh MOTD diperbarui untuk mencerminkan rilis yang lebih baru.	Juli 23, 2018

Perubahan sebelumnya

Tabel berikut memberikan riwayat rilis DLAMI sebelumnya dan perubahan terkait sebelum Juli 2018.

Perubahan	Deskripsi	Tanggal
TensorFlow dengan Horovod	Ditambahkan tutorial untuk pelatihan ImageNet dengan TensorFlow dan Horovod.	Selasa, 06 Juni 2018
Panduan peningkatan	Menambahkan panduan peningkatan.	15 Mei 2018
Daerah baru dan tutorial 10 menit baru	Wilayah baru ditambahkan: AS Barat (California N.), Amerika Selatan, Kanada (Tengah), UE (London), dan UE (Paris). Juga, rilis pertama dari tutorial 10 menit berjudul: “Memulai dengan Deep Learning AMI”.	26 April 2018
Tutorial rantai	Tutorial untuk menggunakan Chainer dalam mode multi-GPU, GPU tunggal, dan CPU ditambahkan. Integrasi CUDA ditingkatkan dari CUDA 8 ke CUDA 9 untuk beberapa kerangka kerja.	28 Februari 2018
Linux AMIs v3.0, ditambah pengenalan MXNet Model	Menambahkan tutorial untuk Conda AMIs dengan model baru dan kemampuan	25 Januari 2018

Perubahan	Deskripsi	Tanggal
Server, TensorFlow Serving, dan TensorBoard	penyajian visualisasi menggunakan MXNet Model Server v0.1.5, TensorFlo w Melayani v1.4.0, dan v0.4.0. TensorBoard AMI dan kerangka kerja kemampuan CUDA dijelaskan dalam ikhtisar Conda dan CUDA. Catatan rilis terbaru dipindahk an ke https://aws.amazo n.com/releasenotes/	
Linux AMIs v2.0	Base, Source, dan Conda AMIs diperbarui dengan NCCL 2.1. Sumber dan Conda AMIs diperbarui dengan MXNet v1.0, PyTorch 0.3.0, dan Keras 2.0.9.	11 Desember 2017
Dua opsi AMI Windows ditambahkan	Windows 2012 R2 dan 2016 AMIs dirilis: ditambahkan ke panduan pemilihan AMI dan ditambahkan ke catatan rilis.	30 November 2017
Rilis dokumentasi awal	Penjelasan rinci tentang perubahan dengan tautan ke topik/bagian yang diubah.	15 November 2017

Terjemahan disediakan oleh mesin penerjemah. Jika konten terjemahan yang diberikan bertentangan dengan versi bahasa Inggris aslinya, utamakan versi bahasa Inggris.