aws

開發人員指南

深度學習 AMI

深度學習 AMI: 開發人員指南

Table of Contents

是什麼 AWS Deep Learning AMI？

歡迎使用 AWS Deep Learning AMI使用者指南，

AWS Deep Learning AMI (DLAMI) 是您在雲端中進行深度學習的一站式商店。此自訂機器映像在大多數 Amazon EC2 區域適用於各種執行個體類型，從僅限 CPU 的小型執行個體到最新的高功能多 GPU 執行個體。它已預先配置 NVIDIA CUDA 和 NVIDIA CUDNN，以及最受歡迎的深度學習架構的最新版本。

關於本指南

本指南將幫助您啟動和使用 DLAMI。本指南涵蓋深度學習訓練和推論中幾個常見的使用案例。也涵蓋如何選擇適合您用途的正確 AMI，以及您可能偏好的執行個體類型。DLAMI 為每個框架提供了幾個教程。它還 AWS 提供有關分佈式培訓，調試，使用 AWS 推論和培訓以及其他關鍵概念的教程。您可以找到如何在瀏覽器中設定 Jupyter 以執行教學課程的說明。

必要條件

您應該熟悉命令行工具和基本 Python 才能成功運行 DLAMI。架構本身會提供如何使用每個架構的教學課程，不過，本指南也會說明如何啟用每個架構，以及如何找到適當的入門教學課程。

DLAMI 用途示例

深度學習：DLAMI 是學習或教授機器學習和深度學習架構的絕佳選擇。它讓您無須花心力對每個架構的安裝進行疑難排解，也無須費神讓這些架構在相同電腦上共同運作。DLAMI 隨附 Jupyter 筆記本，可讓您輕鬆為剛接觸機器學習和深度學習的人員執行架構提供的教學課程。

應用程序開發：如果您是應用程序開發人員，並且有興趣使您的應用程序利用 AI 的最新進展，那麼 DLAMI 是您的理想測試平台。每個架構都隨附如何開始使用深度學習的教學課程，其中多數提供 Model Zoo，讓您無需自行建立神經網路或進行任何模型訓練，就能輕鬆試用深度學習。有些範例會說明如何在幾分鐘內建置影像偵測應用程式，或是如何為您自己的聊天機器人建置語音辨識應用程式。

機器學習和資料分析：如果您是資料科學家或有興趣使用深度學習來處理您的資料，您會發現許多架構支援 R 和 Spark。您可以找到如何執行簡單迴歸的教學課程，一路到如何為個人化和預測系統建置可擴展性資料處理系統的教學課程。

研究：如果您是研究人員，並且想要嘗試新框架，測試新模型或訓練新模型，則 DLAMI 和擴展 AWS 功能可以減輕繁瑣安裝和管理多個培訓節點的痛苦。

> **Note**
>
> 雖然您最初的選擇可能是將執行個體類型升級為具有更多 GPU (最多 8 個) 的較大執行個體，但您也可以建立 DLAMI 執行個體叢集，以水平擴展。如需叢集建置的詳細資訊，請查看相關資訊。

DLAMI 語的特點

預先安裝架構

目前 DLAMI 有兩種主要風格，以及與操作系統（OS）和軟件版本相關的其他變化：

- 使用康達的深度學習 AMI - 使用 conda 套件和單獨 Python 環境，分別安裝架構
- 深度學習基礎 AMI-沒有安裝框架; 只有 NVIDIA CUDA 和其他依賴關係

具有 Conda 的深度學習 AMI 使用conda環境隔離每個框架，因此您可以隨意在它們之間切換，而不必擔心它們的依賴關係發生衝突。

以下是與 Conda 搭配的深度學習 AMI 支援架構的完整清單：

- PyTorch
- TensorFlow 2

> **Note**
>
> 我們不再支持 MXNet，CNTK，咖啡，咖啡 2，西亞諾，鏈，或喀拉斯在. AWS Deep Learning AMI

預先安裝的 GPU 軟體

即使您使用僅限 CPU 的執行個體，DLAMI 也會擁有 NVIDIA CUDA 和 NVIDIA 固定 cu DNN 置。無論執行個體類型為何，安裝的軟體都相同。請記住，GPU 特定工具只適用於至少有一個 GPU 的執行個體。選取 DLAMI 的例證類型中提供更多詳細資訊。

如需 CUDA 安裝的詳細資訊，請參閱。CUDA 安裝和架構連結

模型服務和視覺化

具有 Conda 的深度學習 AMI 已預先安裝模型伺服器 TensorFlow，以及 TensorBoard用於模型視覺化。

- TensorFlow 服務

開始使用

如何開始使用 DLAMI

本指南包含如何挑選適合您的 DLAMI、選取適合您使用案例和預算的執行個體類型，以及相關資訊說明可能感興趣的自訂設定的秘訣。

如果您不熟悉使用 AWS 或使用 Amazon EC2，請從使用康達的深度學習 AMI. 如果您熟悉 Amazon EC2 和 Amazon EMR、Amazon EFS 或 Amazon S3 等其他 AWS 服務，並且對於需要分散式訓練或推論的專案整合這些服務感興趣，請查相關資訊看是否適合您的使用案例。

我們建議您先查看選擇您的 DLAMI，了解哪些執行個體類型可能最適合您的應用程式。

另一個選擇是這個快速教程：啟動一個 AWS Deep Learning AMI （在 10 分鐘內）。

後續步驟

選擇您的 DLAMI

選擇您的 DLAMI

我們提供一系列的 DLAMI 選項。為了協助您針對使用案例選擇正確的 DLAMI，我們會依照開發映像的硬體類型或功能來分組映像。我們的頂級分組是：

- DLAMI 類型：CUDA 與基礎與單框架與多框架（康達 DLAMI）
- 運算架構：x86 型與基於 ARM64 的重力子AWS
- 處理器類型：GPU 與 CPU 與推論
- SDK: CUDA 與神經元AWS
- 操作系統：Amazon Linux 與 Ubuntu

本指南中的其餘主題有助於進一步通知您並進入更多詳細信息。

主題

- CUDA 安裝和架構連結
- 深度學習基礎 AMI
- 使用康達的深度學習 AMI
- DLAMI 架構選項

- DLAMI 作業系統選項

接下來

使用康達的深度學習 AMI

CUDA 安裝和架構連結

雖然深度學習都是相當前沿的，但每個框架都提供了「穩定」的版本。這些穩定版本可能無法使用最新的 CUDA 或 cuDNN 實作和功能。您的使用案例和所需的功能可協助您選擇架構。如果您不確定，請搭配 Conda 使用最新的深度學習 AMI。它具有 CUDA 所有框架的官方pip二進製文件，使用每個框架支持的最新版本。如果您想要最新版本，並自訂您的深度學習環境，請使用深度學習基礎 AMI。

請查看穩定版與發行候選上的指南，以獲得進一步指導。

選擇帶有 CUDA 的 DLAMI

深度學習基礎 AMI擁有所有可用的 CUDA 版本系列

使用康達的深度學習 AMI擁有所有可用的 CUDA 版本系列

> **Note**
>
> 我們不再包括 MXNet，CNTK，咖啡，咖啡 2，西亞諾，鏈，或凱拉斯康達環境中的. AWS Deep Learning AMI

如需特定架構版本號碼，請參閱 特拉米的發行公告

選擇此 DLAMI 類型，或使用「下一步」選項了解有關不同 DLAMI 的更多信息。

選擇其中一個 CUDA 版本，並查看附錄中具有該版本的 DLAMI 的完整列表，或使用「下一步」選項了解有關不同 DLAMI 的更多信息。

接下來

深度學習基礎 AMI

相關主題

- 如需在 CUDA 版本間切換的說明，請參閱 使用深度學習基礎 AMI 教學課程。

深度學習基礎 AMI

深度學習基礎 AMI 就像是用於深度學習的空白畫布。它配備了您需要的一切，直到安裝特定框架的點，並可以選擇 CUDA 版本。

為什麼選擇基地 DLAMI

這個 AMI 群組適合希望延伸深度學習專案和建置最新版本的專案參與者。也適合想開發自己環境的人，並確信最新的 NVIDIA 軟體已安裝和運作，讓他們可以專注在選擇他們要安裝的架構和版本。

選擇此 DLAMI 類型，或使用「下一步」選項了解有關不同 DLAMI 的更多信息。

接下來

DLAMI 與康達

相關主題

- 使用深度學習基礎 AMI

使用康達的深度學習 AMI

康達 DLAMI 使用conda虛擬環境，它們存在多框架或單個框架 DLAMI。這些環境的設定是為了讓不同的架構安裝分開，並簡化架構之間的切換作業。這對於學習和嘗試 DLAMI 必須提供的所有框架非常有用。大多數用戶發現，帶有 Conda 的新深度學習 AMI 非常適合他們。

它們經常使用框架的最新版本進行更新，並具有最新的 GPU 驅動程序和軟件。它們通常被稱為 AWS Deep Learning AMI 在大多數文件中。這些 DLAMI 支援 Amazon Linux 2 作業系統。操作系統支持取決於上游操作系統的支持。

穩定版與發行候選

Conda AMI 使用每個架構最新正式版本的最佳化二進位程式碼。不預期使用版本候選項目和實驗性功能。最佳化取決於架構對 Intel MKL DNN 等加速技術的支援，可加速 C5 和 C4 CPU 執行個體類型的訓練和推論。這些二進製文件也被編譯為支持高級英特爾指令集，包括但不限於 AVX，AVX-2，SSE4.1 和 SSE4.2。這些項目可加速 Intel CPU 架構上的向量和浮點操作。此外，對於 GPU 執行個體類型，CUDA 和 cuDNN 會以最新官方發行版本支援的任何版本進行更新。

搭配 Conda 的深度學習 AMI 會在架構首次啟用時，自動為您的 Amazon EC2 執行個體安裝最佳化的架構版本。如需詳細資訊，請參閱 搭配康達使用深度學習 AMI。

如果您想使用自定義或優化構建選項從源代碼安裝，那麼 深度學習基礎 AMI s 可能是您更好的選擇。

Python 2 棄用

Python 開放原始碼社群已於 2020 年 1 月 1 日正式終止支援 Python 2。 TensorFlow 和 PyTorch 社區已經宣布 TensorFlow 2.1 和 PyTorch 1.4 版本是最後一個支持 Python 2 的版本。包含 Python 2 Conda 環境的舊版本 (v26、v25 等) 仍然可供使用。不過，只有在開放原始碼社群針對這些版本發佈的安全性修正程式時，我們才會在先前發佈的 DLAMI 版本上提供 Python 2 Conda 環境的更新。具有最新版本 TensorFlow 和 PyTorch 框架的 DLAMI 發行版本不包含 Python 2 Conda 環境。

CUDA 支援

您可以在 GPU DLAMI 版本說明中找到特定的 CUDA 版本號碼。

接下來

DLAMI 架構選項

相關主題

- 如需搭配 Conda 使用深度學習 AMI 的教學課程，請參閱搭配康達使用深度學習 AMI教學課程。

DLAMI 架構選項

AWS Deep Learning AMI提供基於 x86 或基於 ARM AWS 64 的重力 on2 架構。

如需有關開始使用 ARM64 GPU DLAMI 的詳細資訊，請參閱。《ARM64 DLAMI》如需可用執行個體類型的詳細資訊，請參閱選取 DLAMI 的例證類型。

接下來

DLAMI 作業系統選項

DLAMI 作業系統選項

DLAMI 在以下操作系統中提供。

- Amazon Linux 2
- Ubuntu 20.04
- Ubuntu

舊版作業系統可在已淘汰的 DLAMI 上使用。有關 DLAMI 棄用的更多信息，請參閱 DLAMI 的棄用

在選擇 DLAMI 之前，請先評估您需要的執行個體類型，並識別您的 AWS 區域。

接下來

選取 DLAMI 的例證類型

選取 DLAMI 的例證類型

更一般地說，在為 DLAMI 選取例證類型時，請考慮下列事項。

- 如果您是深度學習的新手，那麼具有單一 GPU 的執行個體可能會符合您的需求。
- 如果您注重預算，則可以使用僅限 CPU 的執行個體。
- 如果您想要針對深度學習模型推論最佳化高效能和成本效益，則可以搭配 AWS Inferentia 晶片使用執行個體。
- 如果您正在尋找採用 ARM64 CPU 架構的高效能 GPU 執行個體，則可以使用 G5G 執行個體類型。
- 如果您有興趣執行預先訓練的推論和預測模型，可以將 Amazon E lastic Inference 附加到 Amazon EC2 執行個體。Amazon Elastic Inference 可讓您使用 GPU 的一小部分存取加速器。
- 對於大量推論服務而言，具有大量記憶體的單一 CPU 執行個體或這類執行個體的叢集可能是更好的解決方案。
- 如果您使用的是具有大量資料或批次大小較大的大型模型，則需要具有更多記憶體的大型執行個體。您也可以將模型分發到 GPU 叢集。您可能會發現，如果您減少了批次大小，使用具有較少記憶體的執行個體會是更好的解決方案。這可能會影響準確度和訓練速度。
- 如果您有興趣使用 NVIDIA 集體通訊庫 (NCCL) 執行機器學習應用程式，需要大規模的節點間通訊，您可能需要使用 E lastic Fabric Adapter (EFA)。

如需執行個體的詳細資訊，請參閱 EC2 執行個體類型

下列主題提供執行個體類型考量的相關資訊。

> **Important**
>
> 深度學習 AMI 包括由 NVIDIA Corporation 開發、擁有或提供的驅動程式、軟體或工具組。您同意只在包含 NVIDIA 硬體的 Amazon EC2 執行個體上使用這些 NVIDIA 驅動程式、軟體或工具組。

主題

特殊護理 DLAMI 價

DLAMI 中包含的深度學習框架是免費的，每個框架都有自己的開源許可證。雖然 DLAMI 中包含的軟體是免費的，但您仍然需要為基礎的 Amazon EC2 執行個體硬體付費。

某些 Amazon EC2 執行個體類型會標示為免費。您可以在其中一個免費執行個體上執行 DLAMI。這意味著當您僅使用該實例的容量時，使用 DLAMI 是完全免費的。如果您需要具有更多 CPU 核心、更多磁碟空間、更多 RAM 或一或多個 GPU 的功能更強大的執行個體，則您需要一個不在免費層執行個體類別中的執行個體。

如需執行個體選擇和定價的詳細資訊，請參閱 Amazon EC2 定價。

DLAMI 區域可用性

每個區域都支援不同範圍的執行個體類型，而且執行個體類型在不同區域的成本通常會略有不同。並非每個區域都可以使用 DLAMI，但您可以將 DLAMI 複製到您選擇的區域。如需詳細資訊，請參閱複製 AMI。請記下「區域」選取清單，並確定您挑選的區域距離您或您的客戶很近。如果您打算使用一個以上的 DLAMI 並可能建立叢集，請務必針對叢集中的所有節點使用相同的區域。

如需區域的詳細資訊，請瀏覽 EC2 區域。

接下來

建議的 GPU 執行個體

建議的 GPU 執行個體

我們建議您使用 GPU 執行個體，用於大部分的深度學習 在 GPU 執行個體上訓練新模型的速度比 CPU 執行個體更快。當您有多重 GPU 執行個體或想跨多個具 GPU 執行個體使用分散式訓練時，可以用子線性方式擴展。

下列執行個體類型支援 DLAMI。如需 GPU 執行個體類型選項及其用途的詳細資訊，請參閱 EC2 執行個體類型並選取加速運算。

> **Note**
>
> 模型大小應為選取執行個體時所需考量的因素。如果模型超過執行個體的可用 RAM，請選取具有適用於應用程式的足夠記憶體的不同執行個體類型。

- Amazon EC2 P3 執行個體擁有多達 8 個 NVIDIA 特斯拉 V100 GPU。
- Amazon EC2 P4 實例最多有 8 個 NVIDIA 特斯拉 A100 GPU。
- Amazon EC2 P5 實例最多有 8 個 NVIDIA 特斯拉 H100 GPU。
- Amazon EC2 G3 實例最多有 4 個 NVIDIA 特斯拉 M60 GPU。
- Amazon EC2 G4 執行個體擁有多達 4 個 NVIDIA T4 GPU。
- Amazon EC2 G5 執行個體擁有多達 8 個 NVIDIA A10 G GPU。
- Amazon EC2 G6 執行個體擁有多達 8 個 NVIDIA L4 GPU。
- Amazon EC2 G5G 執行個體具有以 ARM64 為基礎AWS 的重力敦 2 處理器。

DLAMI 執行個體提供用於監控和最佳化 GPU 程序的工具。如需監視 GPU 處理程序的詳細資訊，請參閱GPU 監控和最佳化。

如需使用 G5G 執行個體的特定教學課程，請參閱《ARM64 DLAMI》。

接下來

建議的 CPU 執行個體

建議的 CPU 執行個體

無論您是預算有限、正在了解深度學習，或是只想要執行預測服務，CPU 類別都提供許多價格合理的選項。有些架構會利用 Intel 的 MKL DNN，加速 C5 (並非所有區域皆提供) CPU 執行個體類型的訓練與推論。如需 CPU 執行個體類型的相關資訊，請參閱 EC2 執行個體類型並選取運算優化

> **Note**
>
> 模型大小應為選取執行個體時所需考量的因素。如果模型超過執行個體的可用 RAM，請選取具有適用於應用程式的足夠記憶體的不同執行個體類型。

- Amazon EC2 C5 執行個體擁有多達 72 個英特爾 vCPUs。C5 執行個體在科學建模、批次處理、分散式分析、高效能運算 (HPC) 以及機器和深度學習推論方面表現卓越。

接下來

建議的推論執行個體

建議的推論執行個體

AWS Inferentia 執行個體旨在為深度學習模型推論工作負載提供高效能和成本效益。具體來說，Inf2 執行個體類型使用 AWS 推論晶片和 AWS Neuron SDK，這與熱門的機器學習架構 (例如和) 整合。TensorFlow PyTorch

客戶可以使用 Inv2 執行個體，以最低的成本在雲端執行大規模的機器學習推論應用程式，例如搜尋、推薦引擎、電腦視覺、語音辨識、自然語言處理、個人化和詐騙偵測等。

> **Note**
>
> 模型大小應為選取執行個體時所需考量的因素。如果模型超過執行個體的可用 RAM，請選取具有適用於應用程式的足夠記憶體的不同執行個體類型。

- Amazon EC2 Inf2 執行個體具有高達 16 個 AWS 推論晶片和 100 Gbps 的聯網輸送量。

如需開始使用 AWS 推論 DLAMI 的詳細資訊，請參閱。具有 DL AWS AMI 的推論芯片

接下來

推薦的培根執行個體

推薦的培根執行個體

AWS Trainium 執行個體旨在為深度學習模型推論工作負載提供高效能和成本效益。具體來說，Trn1 執行個體類型使用 AWS Trainium 晶片和 N AWS euron SDK，這與熱門的機器學習架構 (例如和) 整合。 TensorFlow PyTorch

客戶可以使用 Trn1 執行個體，在雲端中以最低的成本執行大規模的機器學習推論應用程式，例如搜尋、推薦引擎、電腦視覺、語音辨識、自然語言處理、個人化和詐騙偵測。

> **Note**
>
> 模型大小應為選取執行個體時所需考量的因素。如果模型超過執行個體的可用 RAM，請選取具有適用於應用程式的足夠記憶體的不同執行個體類型。

- Amazon EC2 Trn1 執行個體具有高達 16 個 AWS 晶片和 100 Gbps 的聯網輸送量。

框架 Support 政策

AWS Deep Learning AMIs (DLAMI) 可簡化深度學習工作負載的映像組態，並透過最新的架構、硬體、驅動程式、程式庫和作業系統進行最佳化。本頁詳細介紹了 DLAMI 的框架支持策略。如需可用 DLAMI 的清單，請參閱 DLAMI 的版本說明。

支援的架構

請參考下列AWS Deep Learning AMI架構 Support 援原則表格，以檢查主動支援的架構和版本。

請參閱修補程式結束，瞭解原始架構維護團隊主動AWS支援的目前版本支援的時間長度。架構和版本可在單一架構 DLAMI 或多架構 DLAMI 中使用。

> **Note**
>
> 在框架版本 x.y.z 中，x 指的是主要版本，y 指的是次要版本，z 指的是補丁版本。例如，對於 TensorFlow 2.6.5，主要版本是 2，次要版本為 6，修補程式版本為 5。

如需特定影像的詳細資訊，請參閱版本說明：

- 單一架構 DLAMI 發行說明
- 多架構 DLAMI 發行說明

常見問答集

- 哪些框架版本可以獲得安全補丁？
- AWS發布新框架版本時會發布哪些圖像？
- 哪些圖像獲得新的 SageMaker/AWS功能？
- 如何在支持的框架表中定義當前版本？
- 如果我正在運行的版本不在支持框架表中怎麼辦？
- DLAMI 是否支持以前版本的？ TensorFlow
- 如何找到支持的框架版本的最新補丁圖像？
- 新影像的發行頻率是多久？

哪些框架版本可以獲得安全補丁？

如果架構版本在「架構支援政策」表格中AWS Deep Learning AMI標示為「Support 援」，則會取得安全性修補程式。

AWS發布新框架版本時會發布哪些圖像？

我們在新版本的 TensorFlow 和 PyTorch發布後不久發布新的 DLAMI。這包括主要版本，主要次要版本和框架 major-minor-patch 版本。我們也會在新版本的驅動程式和程式庫上市時更新映像檔。如需影像維護的更多資訊，請參閱 我的框架版本的主動支持何時結束？

哪些圖像獲得新的 SageMaker/AWS功能？

新功能通常會在最新版本的 DLAMis 中發行，適用於 PyTorch 和. TensorFlow 如需AWS有關新功能 SageMaker 或功能的詳細資訊，請參閱特定影像的版本說明。如需可用 DLAMI 的清單，請參閱 DLAMI 的版本說明。如需影像維護的更多資訊，請參閱 我的框架版本的主動支持何時結束？

如何在支持的框架表中定義當前版本？

「AWS Deep Learning AMI架構 Support 政策」表中的目前版本是指在上提供的AWS最新架構版本 GitHub。每個最新版本都包含 DLAMI 中的驅動程式、程式庫和相關套件的更新。如需影像維護的資訊，請參閱 我的框架版本的主動支持何時結束？

如果我正在運行的版本不在支持框架表中怎麼辦？

如果您執行的版本不在 AWS Deep Learning AMIFramework Support 原則表格中，您可能沒有最新的驅動程式、程式庫和相關套件。如需更多 up-to-date 版本，建議您使用您選擇的最新 DLAMI 升級至其中一個可支援的架構。如需可用 DLAMI 的清單，請參閱 DLAMI 的版本說明。

DLAMI 是否支持以前版本的？ TensorFlow

沒有 我們 Support 每個架構最新主要版本的最新修補程式版本，從AWS Deep Learning AMI架構支援原則表格中所述 365 天起發 GitHub 行。如需更多資訊，請參閱 如果我正在運行的版本不在支持框架表中怎麼辦？

如何找到支持的框架版本的最新補丁圖像？

若要將 DLAMI 與最新的架構版本搭配使用，請擷取 DLAMI ID 並使用它來使用 EC2 主控台啟動 DLAMI。如需擷取 AWS Deep Learning AMI ID 的 AWS CLI 命令範例，請參閱AWS Deep Learning AMI目錄中的深度學習架構一節。 AWSCLI AMI 識別碼查詢也包含在單一架構 DLAMI 發行說明中。您選擇的架構版本必須在「AWS Deep Learning AMI架構支援政策」表格中標示為「Support 援」。

新影像的發行頻率是多久？

提供更新的補丁版本是我們的首要任務。我們通常會在最早的機會中創建修補的圖像。我們監控新修補的框架版本（例如， TensorFlow 2.9 至 TensorFlow 2.9.1) 和新的次要發行版本 (例如 TensorFlow 2.9 到 TensorFlow 2.10），並在最早的機會提供它們。當使用新版 CUDA 發行的 TensorFlow 現有版本時，我們會針對該版本發行新的 DLAMI，並支援新的 TensorFlow CUDA 版本。

當我的工作負載執行時，我的執行個體是否會被修補？

沒有 DLAMI 的修補程式更新不是「就地」更新。

您必須開啟新的 EC2 執行個體、遷移工作負載和指令碼，然後關閉先前的執行個體。

當新的修補或更新的框架版本可用時會發生什麼情況？

定期查看映像檔的版本說明頁面。我們建議您在有新的修補或更新的框架可用時升級到它們。如需可用 DLAMI 的清單，請參閱 DLAMI 的版本說明。

依賴關係是否更新而不更改框架版本？

我們更新依賴關係而不更改框架版本。不過，如果相依性更新造成不相容性，我們會建立不同版本的映像檔。請務必查看 DLAMI 的版本說明，以取得更新的相依性資訊。

我的框架版本的主動支持何時結束？

DLAMI 圖像是不可變的。一旦它們被創建，它們不會改變。對框架版本的主動支持結束有四個主要原因：

- 架構版本 (修補程式) 升級
- AWS安全性修補
- 修補程式日期結束 (過期)
- 相依性 end-of-support

> **Note**
>
> 由於版本修補程式升級和安全性修補程式的頻率，我們建議您經常查看 DLAMI 的版本說明頁面，並在進行變更時進行升級。

架構版本 (修補程式) 升級

如果您有以 TensorFlow 2.7.0 為基礎的 DLAMI 工作負載，且 TensorFlow版本為 2.7.1 GitHub，則會AWS發行具有 2.7.1 的新 DLAMI。 TensorFlow 2. TensorFlow 7.1 版的新影像發行後，先前的 2.7.0 影像將不再有效維護。含 TensorFlow 2.7.0 的 DLAMI 不會收到進一步的修補程式。然後，TensorFlow 2.7 的 DLAMI 發行說明頁面會更新為最新資訊。每個次要修補程式都沒有個別的版本說明頁面。

由於修補程式升級而建立的新 DLAMI 會使用新的 AMI ID 指定。

AWS安全性修補

如果您有以 TensorFlow 2.7.0 的映像為基礎的工作負載並AWS製作了安全性修補程式，則 DLAMI 的新版本會針對 2.7.0 發行。 TensorFlow 先前版本 TensorFlow 2.7.0 的影像不再維護。如需詳細資訊，請參閱當我的工作負載執行時，我的執行個體是否會被修補？如需尋找最新 DLAMI 的步驟，請參閱 如何找到支持的框架版本的最新補丁圖像？

由於修補程式升級而建立的新 DLAMI 會使用新的 AMI ID 指定。

修補程式日期結束 (過期)

DLAMI 在 GitHub 發布日期後 365 天結束補丁日期。

對於多框架 DLAMI，當其中一個框架版本更新時，需要具有更新版本的新 DLAMI。舊框架版本的 DLAMI 不再積極維護。

> **Important**
>
> 當有一個重大的框架更新時，我們做一個例外。例如。如果 TensorFlow 1.15 更新為 TensorFlow 2.0，則我們會繼續支援最新版本的 TensorFlow 1.15 版本，為期兩年，或原始架構維護團隊退出支援後六個月，以較早的日期為準。 GitHub

相依性 end-of-support

如果您在使用 Python 3.6 的 TensorFlow 2.7.0 DLAMI 映像檔上執行工作負載，且該版本的 Python 已標記為 end-of-support，則將不再維護以 Python 3.6 為基礎的所有 DLAMI 映像檔。同樣，如果像 Ubuntu 16.04 這樣的操作系統版本被標記為 end-of-support，那麼依賴於 Ubuntu 16.04 的所有 DLAMI 映像將不再被積極維護。

具有不再積極維護的框架版本的圖像是否會被修補？

沒有 不再主動維護的映像將不會有新版本。

如何使用較舊的框架版本？

要使用帶有較舊框架版本的 DLAMI，請檢索 DLAMI ID 並使用它使用 EC2 控制台啟動 DLAMI。如需擷取 AMI ID 的 AWS CLI 命令，請參閱深度學習 AMI 目錄中的AWS深度學習架構一節。 AWSCLI AMI 識別碼查詢也包含在單一架構 DLAMI 發行說明中。

如何保持 up-to-date 框架及其版本的支持更改？

使 up-to-date 用架構 Sup port 原則表格 (DLAMI 發行說明)，繼續使用 DLAM I AWS Deep Learning AMI 架構和版本。

我是否需要商業授權才能使用 Anaconda 軟體庫？

Anaconda 轉向某些使用者的商業授權模式。積極維護的 DLAMI 已從 Anaconda 頻道遷移到公開可用的開源版本康達（康達鍛造）。

啟動和設定 DLAMI

如果您的進度已到這裡，您應該對於想啟動哪些 AMI 已有一些好主意。如果沒有，請在中尋找 DLAMI 及其相關硬體、架構和 ID 擷取。特拉米的發行公告

您也應該知道您要選擇哪種執行個體類型和區域。如果沒有，請瀏覽選取 DLAMI 的例證類型。

> **Note**
>
> 我們將在實例中使用 p3.16xlarge 作為默認實例類型。您只需將其取代為您想使用的任何執行個體類型。

> **Important**
>
> 如果您打算使用 Elastic Inference，您必須在啟動 DLAMI 之前完成 E lastic Inference 設定。

主題

第 1 步：啟動 DLAMI

> **Note**
>
> 在本逐步解說中，我們可能會針對深度學習 AMI (Ubuntu 18.04) 提供參考資料。即使您選擇了其他 DLAMI，也應該能夠遵循本指南。

1. 找到您的 DLAMI 的身份證

2. 從您的 DLAMI 啟動 Amazon EC2 實例

   您將使用 Amazon EC2 控制台。按照中詳細說明進行操作 從 Amazon EC2 控制台啟動

   > **Tip**
   >
   > CLI 選項：如果您選擇使用 AWS CLI 啟動 DLAMI，則需要 AMI 的 ID、區域和執行個體類型以及安全性權杖資訊。請確認您已準備好 AMI 和執行個體 ID。如果尚未設定 AWS CLI，請先使用安裝 AWS 命令列介面的指南執行此動作。

3. 完成其中一個選項的步驟後，請等待執行個體準備就緒。這通常只需要幾分鐘的時間。您可以在 EC2 主控台中驗證執行個體的狀態。

擷取特殊字串識別碼

每個 AMI 都有一個唯一的標識符（ID）。您可以使用 AWS 命令列介面 (AWS CLI) 查詢您選擇的 DLAMI 的識別碼。如果您尚未 AWS CLI 安裝，請參閱開始使用 AWS CLI。

> **Note**
>
> 提醒：您可以在目錄中找到所有 DLAMI 及其相關處理器/加速器、作業系統、運算架構、推薦的 Amazon EC2 執行個體系列、支援狀態和 ID 擷取查詢。AWS Deep Learning AMI特拉米的發行公告如需其他資訊 (驅動程式、Python 版本、Amazon EBS 類型)，請參閱中的 DLAMI 版本說明。

1. 請確定已設定您的 AWS 認證。

```
aws configure
```

2. 使用以下命令檢索 DLAMI 的 ID 或查找目錄中提供的 AWS Deep Learning AMI 查詢。

```
aws ec2 describe-images --region us-east-1 --owners amazon \
--filters 'Name=name,Values=Deep Learning AMI (Ubuntu 18.04) Version ??.?'
 'Name=state,Values=available' \
--query 'reverse(sort_by(Images, &CreationDate))[:1].ImageId' --output text
```

> **Note**
>
> 您可以為特定架構指定發行版本，或以問號取代版本號碼以取得最新版本。

3. 輸出格式應類似以下內容：

```
ami-094c089c38ed069f2
```

複製此 DLAMI ID，然後按退q出提示。

後續步驟

[從 Amazon EC2 控制台啟動]

從 Amazon EC2 控制台啟動

> **Note**
>
> 若要使用 Elastic Fabric Adapter (EFA) 啟動執行個體，請參閱下列步驟。

1. 開啟 EC2 主控台。
2. 請注意最上層導覽中您目前的區域。如果這不是您想要的 AWS 區域，請在繼續之前更改此選項。如需詳細資訊，請參閱 EC2 區域。
3. 選擇 Launch Instance (啟動執行個體)。
4. 輸入執行個體的名稱，然後選取適合您的 DLAMI。
   a. 在「我的 AMI」中尋找現有的 DLAM I，或選擇「快速入門」。
   b. 通過 DLAMI ID 搜索。瀏覽選項，然後選擇您的選擇。
5. 選擇執行個體類型。您可以在目錄中找到 DLAMI 的建議例證族群。 AWS Deep Learning AMI 如需 DLAMI 執行個體類型的一般建議，請參閱執行個體選擇。

> **Note**
>
> 如果要使用 E lastic Inference (EI)，請按一下設定執行個體詳細資訊，選取新增 Amazon EI 加速器，然後選取 Amazon EI 加速器的大小。

6. 選擇 Launch Instance (啟動執行個體)。

> **Tip**
>
> 查看使用深度學習 AMI 開始使用 AWS 深度學習，透過螢幕擷取畫面逐步解說。

後續步驟

第 2 步：Connect 到 DLAMI

第 2 步：Connect 到 DLAMI

Connect 至您從用戶端 (視窗、MacOS 或 Linux) 啟動的 DLAMI。如需詳細資訊，請參閱 Amazon EC2 使用者指南中的 Connect 到 Linux 執行個體。

如果您想在登入後設定 Jupyter，請將 SSH 登入命令的副本保持在方便取得之處。您將使用其變化版本來連接到 Jupyter 網頁。

後續步驟

步驟 3：測試您的 DLAMI

步驟 3：測試您的 DLAMI

根據您的 DLAMI 版本，您有不同的測試選項：

- 使用康達的深度學習 AMI— 去搭配康達使用深度學習 AMI.
- 深度學習基礎 AMI— 請參閱所需架構的安裝文件。

您也可以建立 Jupyter 筆記本、試用教學課程，或開始在 Python 中編輯程式碼。如需詳細資訊，請參閱 設定 Jupyter 筆記本伺服器。

步驟 4：管理您的 DLAMI 實例

當有可用的修補程式與更新時請務必立即套用，以保持您的作業系統和其他已安裝軟體處於最新狀態。

如果您使用的是 Amazon Linux 或 Ubuntu，當您登錄到 DLAMI 時，系統會通知您是否有更新，並查看更新說明。如需 Amazon Linux 維護的詳細資訊，請參閱更新執行個體軟體。對於 Ubuntu 執行個體，請參閱官方 Ubuntu 文件。

在 Windows 上，請定期檢查 Windows Update 是否有軟體和安全性更新。如果您願意，可以讓更新自動套用。

> **Important**
>
> 如需有關崩潰和幽靈漏洞以及如何修補作業系統以防範這些漏洞的詳細資訊，請參閱安全性公告 -2018-013。 AWS

清除

當您不再需要 DLAMI 時，您可以停止或終止它，以避免產生持續收費。停止執行個體仍會予以保留，因此您可以稍後恢復它。您的組態、檔案和其他非揮發性資訊會存放在 Amazon S3 上的磁碟區中。您需要支付小型 S3 費用以便在執行個體停止時保留磁碟區，但您無需支付當其處於已停止狀態時的運算資源費用。當您再次啟動執行個體，它會掛載該磁碟區，您的資料即可供使用。如果您終止執行個體，它就會消失，您再也無法將其啟動。您的資料實際上仍存放在 S3 中，因此，若要防止任何進一步的費用，您需要同時刪除磁碟區。如需詳細指示，請參閱 Amazon EC2 使用者指南中的終止執行個體。

設定 Jupyter 筆記本伺服器

Jupyter 筆記本伺服器可讓您從 DLAMI 執行個體建立和執行 Jupyter 筆記本。使用 Jupyter 筆記本，您可以在使用AWS基礎結構和存取 DLAMI 中內建的套件時，進行機器學習 (ML) 實驗以進行訓練和推論。如需 Jupyter 筆記本的詳細資訊，請參閱 Jupyter 筆記本文件。

若要設定 Jupyter 筆記本伺服器，您必須：

- 在您的 Amazon EC2 DLAMI 執行個體上設定 Jupyter 筆記型電腦伺服器。
- 設定用戶端，讓您可以連接到 Jupyter 筆記本伺服器。我們提供適用於 Windows、macOS 和 Linux 用戶端的設定說明。
- 登入 Jupyter 筆記本伺服器，測試設定。

若要完成設定 Jupyter 的步驟，請遵循下列主題中的指示。設定 Jupyter 筆記本伺服器後，請參閱以執行 Jupyter 筆記本教學課程取得有關執行 DLAMI 中出貨的範例筆記本的資訊。

主題

保護您的 Jupyter 伺服器

我們在此以 SSL 和自訂密碼設定 Jupyter。

Connect 到 Amazon EC2 執行個體，然後完成下列程序。

設定 Jupyter 伺服器

1. Jupyter 會提供密碼公用程式。執行以下命令，並在系統提示時輸入您慣用的密碼。

   ```
   $ jupyter notebook password
   ```

   輸出看起來像這樣：

   ```
   Enter password:
   Verify password:
   [NotebookPasswordApp] Wrote hashed password to /home/ubuntu/.jupyter/
   jupyter_notebook_config.json
   ```

2. 建立自簽 SSL 憑證。依照提示填寫您認為適合的地區。如果您希望將提示保留空白，您必須輸入 `.`。您的答案不會影響憑證的功能。

   ```
   $ cd ~
   $ mkdir ssl
   $ cd ssl
   $ openssl req -x509 -nodes -days 365 -newkey rsa:2048 -keyout mykey.key -out
    mycert.pem
   ```

> **Note**
>
> 您可能想要建立第三方所簽署的一般 SSL 憑證，這不會導致瀏覽器向您顯示安全警告。此程序涉及更多層面。如需詳細資訊，請瀏覽 Jupyter 的文件。

後續步驟

啟動 Jupyter 筆記本伺服器

啟動 Jupyter 筆記本伺服器

您現在可以登入執行個體並執行以下命令 (使用您在上一個步驟建立的 SSL 憑證)，藉此啟動 Jupyter 伺服器。

```
$ jupyter notebook --certfile=~/ssl/mycert.pem --keyfile ~/ssl/mykey.key
```

伺服器啟動後，您現在可以從您的用戶端電腦透過 SSH 通道連接到該伺服器。當伺服器執行時，您會看到 Jupyter 的一些輸出，確認伺服器正在執行中。此時，請忽略您可以透過 localhost URL 存取伺服器的標註，因為在您建立通道前，該動作並不可行。

> **Note**
>
> 當您使用 Jupyter Web 界面切換架構時，Jupyter 會為您處理環境切換。您可以在使用 Jupyter 切換環境中找到更多資訊。

後續步驟

設定用戶端以連接到 Jupyter 伺服器

設定用戶端以連接到 Jupyter 伺服器

設定用戶端連接到 Jupyter 筆記本伺服器後，您可以在您的工作空間中建立和存取該伺服器上的筆記本，並在伺服器上執行您的深度學習程式碼。

如需設定資訊，請選擇以下其中一個連結。

主題

- 設定 Windows 用戶端
- 設定 Linux 或 macOS 用戶端

設定 Windows 用戶端

準備

請確認您具備設定 SSH 通道所需的以下資訊：

- Amazon EC2 執行個體的 Amazon EC2 執行個體的公有 DNS 名稱。您可以在 EC2 主控台中找到公有 DNS 名稱。
- 私有金鑰檔案的金鑰對。如需存取 key pair 的詳細資訊，請參閱適用於 Linux 執行個體的 Amazon EC2 Linux EC2 Linux EC2 執行個體的 Amazon EC2 Linux EC2 Linux EC2 執行個體。

從 Windows 用戶端使用 Jupyter 筆記本

請參閱這些從 Windows EC2 Windows Client Windows Amazon EC2 執行個體的 Windows EC2。

1. 疑難排解連線至執行個體
2. 使用 PuTTY 從 Windows 連接至您的 Linux 執行個體

若要建立執行中 Jupyter 伺服器的通道，建議方法是在 Windows 用戶端上安裝 Git Bash，然後依照 Linux/macOS 用戶端指示操作。不過，您可以使用您所要的方法，透過連接埠映射開啟 SSH 通道。如需詳細資訊，請參閱 Jupyter 的文件。

後續步驟

設定 Linux 或 macOS 用戶端

設定 Linux 或 macOS 用戶端

1. 開啟 終端機。
2. 執行下列命令，將本機連接埠 8888 上的所有請求轉送到遠端 Amazon EC2 執行個體上的連接埠 8888。取代金鑰的位置以存取 Amazon EC2 執行個體和 Amazon EC2 執行個體的公有 DNS 名稱，以更新命令。請注意，對於 Amazon Linux AMI，使用者名稱為 `ec2-user` 而非 `ubuntu`。

```
$ ssh -i ~/mykeypair.pem -N -f -L 8888:localhost:8888 ubuntu@ec2-###-##-##-###.compute-1.amazonaws.com
```

此命令，即可開啟正在執行 Jupyter 筆記本伺服器的客戶端和正在執行 Jupyter 筆記本伺服器的 Amazon EC2 執行個體。

後續步驟

登入 Jupyter 筆記本伺服器進行測試

登入 Jupyter 筆記本伺服器進行測試

現在您已準備好登入 Jupyter 筆記本伺服器。

您的下一個步驟是透過您的瀏覽器，測試伺服器的連線。

1. 在瀏覽器的位址列中輸入下列 URL，或按一下此連結：https://localhost:8888
2. 使用自簽 SSL 憑證，您的瀏覽器會警告您並提示您避免繼續瀏覽網站。

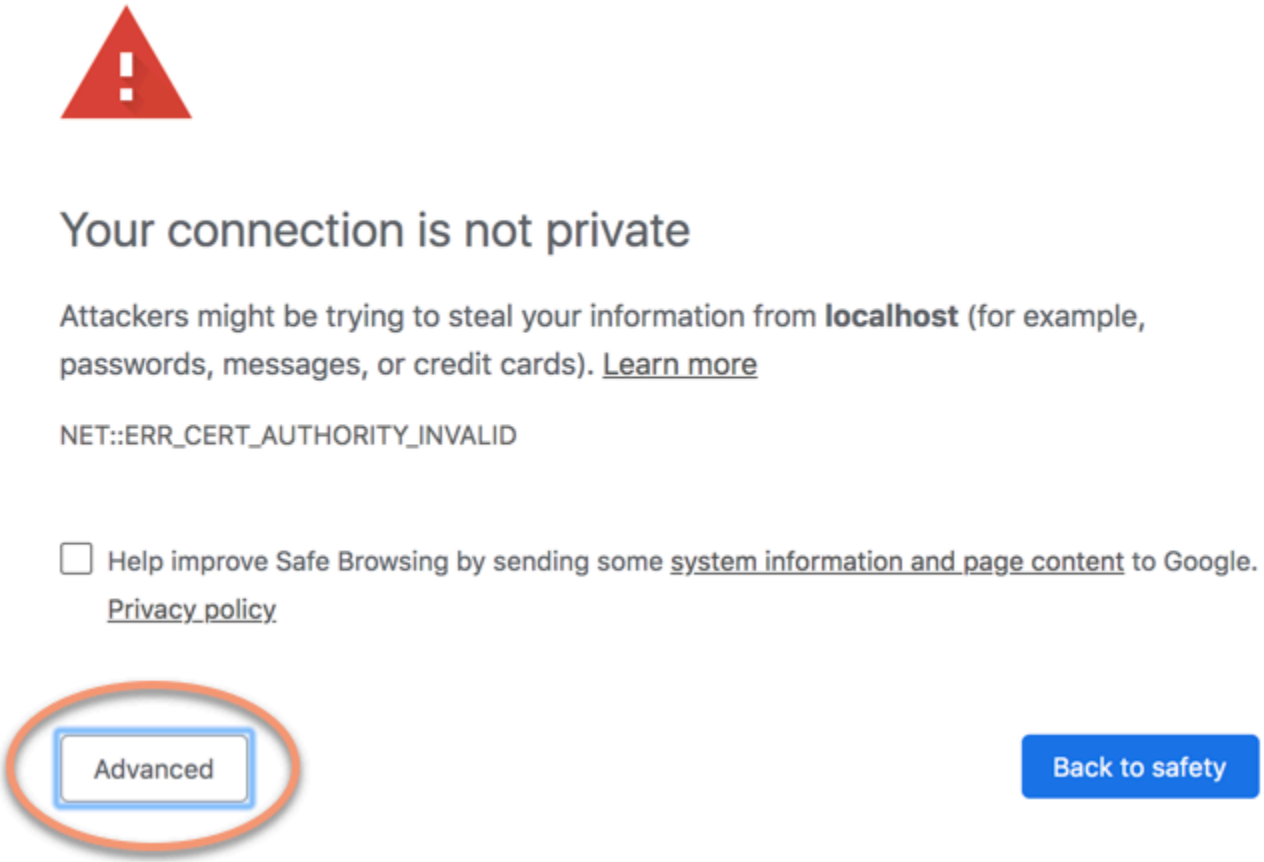

因為您自行這麼設定，所以繼續操作安全無虞。視您的瀏覽器而定，您會收到「進階」、「顯示詳細資訊」或類似按鈕。

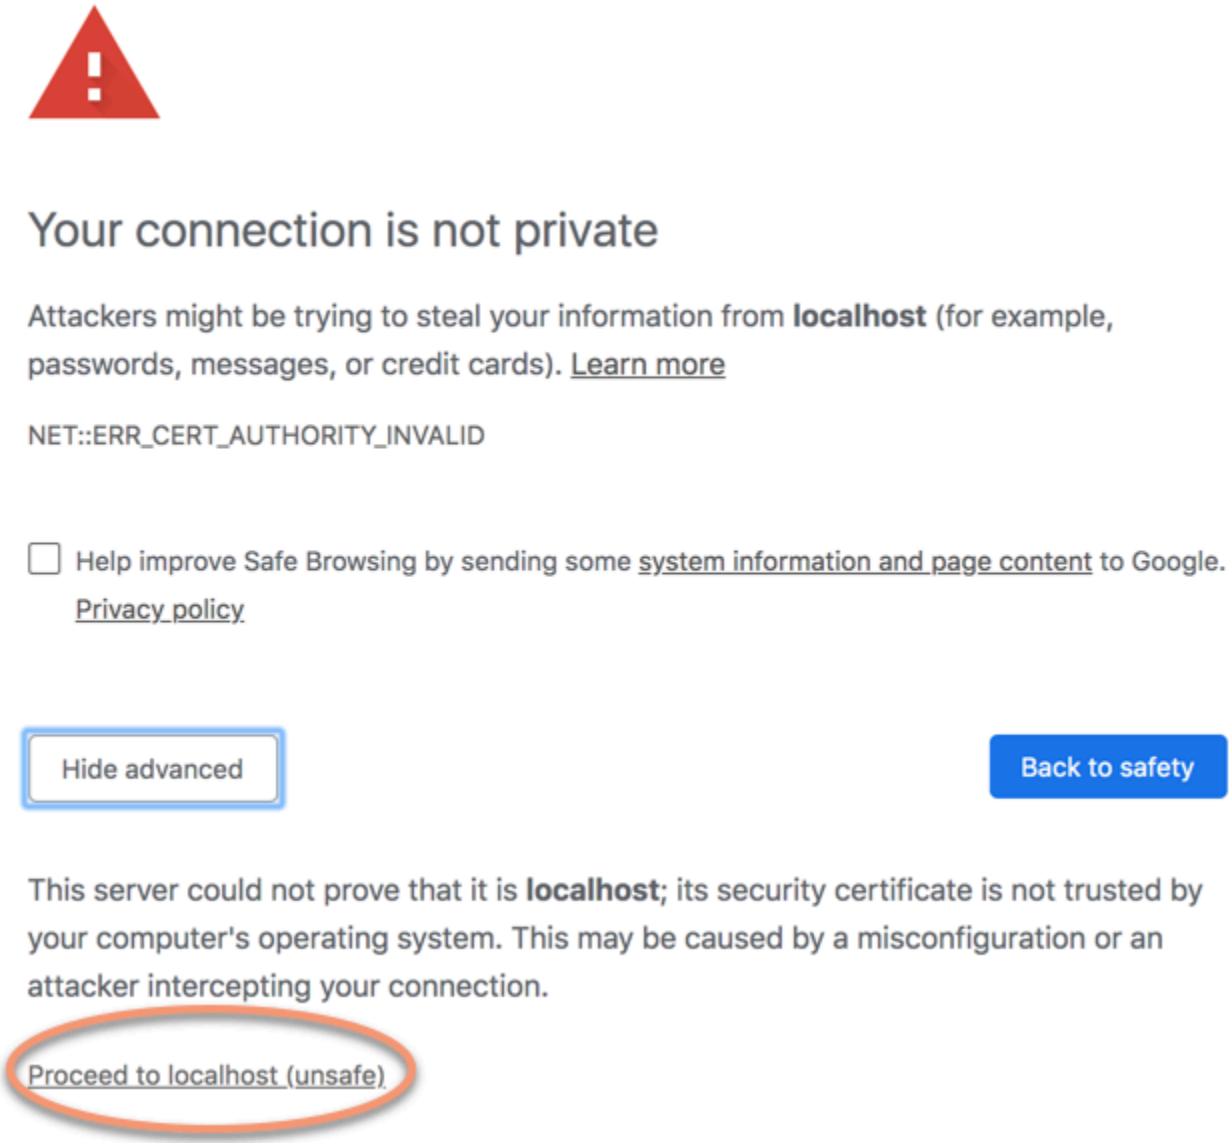

按一下此項，然後按一下「繼續 localhost」連結。如果連線成功，您會看到 Jupyter 筆記本伺服器網頁。此時，系統會要求您提供先前設定的密碼。

現在您可以存取在 DLAMI 上執行的 Jupyter 筆記型電腦伺服器。您可以建立新的筆記本或執行所提供的教學課程。

使用 DLAMI

主題

下列各節說明如何使用具有 Conda 的深度學習 AMI 來切換環境、從每個架構執行範例程式碼，以及執行 Jupyter，以便您嘗試不同的筆記本教學課程。

搭配康達使用深度學習 AMI

主題

使用康達介紹深度學習 AMI

Conda 是一套可在 Windows、macOS 和 Linux 上執行的開放原始碼套件管理系統以及環境管理系統。Conda 可快速安裝、執行和更新套件及其相依性。Conda 能輕鬆地建立、儲存、載入並在本機電腦的環境之間切換。

配備 Conda 的深度學習 AMI 已經設定，可讓您輕鬆在深度學習環境之間切換。以下說明引導您使用 conda 的一些基本命令。這些說明也協助您確認架構的基本匯入是否運作中，您是否可以使用架構執行幾個簡單操作。然後，您可以繼續閱讀 DLAMI 提供的更徹底的教程，或者在每個框架的項目站點上找到的框架示例。

登錄到您的 DLAMI

登入伺服器後，您會看到伺服器的「當日訊息」(MOTD)，描述您可用來切換不同深度學習架構的各種 Conda 命令。以下為範例 MOTD。您的特定 MOTD 可能會隨著 DLAMI 的新版本發布而有所不同。

```
=============================================================================
        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
    =============================================================================
```

啟動 TensorFlow 環境

> **Note**
>
> 當您啟動第一個 Conda 環境時，請耐心等候它載入。搭配 Conda 的深度學習 AMI 會在架構第一次啟用時，自動為您的 EC2 執行個體安裝最佳化的架構版本。您應該不會遇到後續延遲。

1. 激活 Python 3 的 TensorFlow 虛擬環境。

   ```
   $ source activate tensorflow2_p310
   ```

2. 啟動 iPython 終端機。

```
(tensorflow2_p310)$ ipython
```

3. 運行一個快速 TensorFlow 程序。

```
import tensorflow as tf
hello = tf.constant('Hello, TensorFlow!')
sess = tf.Session()
print(sess.run(hello))
```

您應該會看到「Hello, Tensorflow!」

接下來

執行 Jupyter 筆記本教學課程

切換到 PyTorch Python 環境

如果您仍在 IPython 控制台中，請使用`quit()`，然後準備切換環境。

- 激活 Python 3 的 PyTorch 虛擬環境。

```
$ source activate pytorch_p310
```

測試一些 PyTorch 代碼

若要測試您的安裝，請使用 Python 撰寫建立並列印陣列的 PyTorch 程式碼。

1. 啟動 iPython 終端機。

```
(pytorch_p310)$ ipython
```

2. 匯入 PyTorch。

```
import torch
```

   您可能會看到有關第三方套件的警告訊息。您可以忽略。

3. 使用隨機初始化的元素創建一個 5x3 矩陣。列印陣列。

```
x = torch.rand(5, 3)
print(x)
```

確認結果。

```
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]])
```

移除環境

如果 DLAMI 上的空間不足，您可以選擇解除安裝不使用的 Conda 套件：

```
conda env list
conda env remove --name <env_name>
```

使用深度學習基礎 AMI

使用深度學習基礎 AMI

基礎 AMI 隨附一個 GPU 驅動程式的基礎平台和加速程式庫，可用以部署您自己的自訂深度學習環境。默認情況下，AMI 配置為任何一個 NVIDIA CUDA 版本環境。您也可以在不同版本的 CUDA 之間切換。請參閱下列關於如何操作的說明。

設定 CUDA 版本

您可以通過運行 NVIDIA 的nvcc程序來驗證 CUDA 版本。

```
nvcc --version
```

您可以使用以下 bash 命令選擇並驗證特定的 CUDA 版本：

```
sudo rm /usr/local/cuda
sudo ln -s /usr/local/cuda-12.0 /usr/local/cuda
```

如需詳細資訊，請參閱基本 DLAMI 版本說明。

執行 Jupyter 筆記本教學課程

教程和示例隨每個深度學習項目的來源一起提供，在大多數情況下，它們將在任何 DLAMI 上運行。如果您選擇使用康達的深度學習 AMI，您可以獲得數個已設定好可供試用的精選教學課程的額外好處。

> **Important**
>
> 若要執行 DLAMI 上安裝的 Jupyter 筆記本教學課程，您必須執行。設定 Jupyter 筆記本伺服器

Jupyter 伺服器開始執行後，您可以透過 Web 瀏覽器執行教學課程。如果您使用 Conda 執行深度學習 AMI，或者您已經設定了 Python 環境，您可以從 Jupyter 筆記本介面切換 Python 核心。選擇適當的核心，再嘗試執行架構特定的教學課程。為使用 Conda 的深度學習 AMI 的使用者提供了進一步的範例。

> **Note**
>
> 許多教程都需要額外的 Python 模塊，這些模塊可能不會在 DLAMI 上設置。如果出現類似的錯誤`"xyz module not found"`，請登入 DLAMI，如上所述啟動環境，然後安裝必要的模組。

> **Tip**
>
> 深度學習教學課程和範例通常依賴一或多個 GPU。如果您的執行個體類型沒有 GPU，您可能需要變更一些範例中的程式碼，才能讓其執行。

瀏覽安裝教學課程

一旦您登錄到 Jupyter 服務器並可以看到教程目錄（僅在具有 Conda 的深度學習 AMI 上），您將看到每個框架名稱的教程文件夾。如果您沒有看到列出的框架，那麼當前 DLAMI 上該框架的教程不可用。按一下架構的名稱以查看列出的教學課程，然後按一下教學課程來啟動它。

第一次使用 Conda 在深度學習 AMI 上執行筆記型電腦時，它會想要知道您想要使用哪個環境。它會提示您從清單中選取。每個環境都根據此模式命名：

```
Environment (conda_framework_python-version)
```

例如，您可能會看到 `Environment (conda_mxnet_p36)`，這表示該環境有 MXNet 和 Python 3。此項目的其他變化包括 `Environment (conda_mxnet_p27)`，表示環境具有 MXNet 和 Python 2。

> **Tip**
>
> 如果您擔心哪個版本的 CUDA 處於作用中狀態，其中一種方法是在您第一次登入 DLAMI 時在 MOTD 中。

使用 Jupyter 切換環境

如果您決定試用不同架構的教學課程，請務必確認目前執行的核心。此資訊可以在 Jupyter 界面的右上方查看，位於登出按鈕下方。您可以按一下 Jupyter 功能表項目 Kernel (核心)、按一下 Change Kernel (變更核心)，然後按一下最適合您正在執行之筆記本的環境，即可變更任何開啟筆記本的核心。

此時，您必須重新執行任何儲存格，因為核心中的變更將會清除您先前執行之任何項目的狀態。

> **Tip**
>
> 在架構之間切換或許很有趣也富有教育意義，但您可能會用盡記憶體。如果開始出現錯誤，請查看 Jupyter 伺服器正在執行的終端機視窗。這裡有有用的消息和錯誤記錄，您可能會看到錯 out-of-memory誤。若要修正此問題，您可以移至 Jupyter 伺服器首頁，按一下 Running (執行中) 標籤，然後按一下每個可能仍在背景執行並耗盡所有記憶體之教學課程的 Shutdown (關閉)。

教學課程

以下是如何搭配 Conda 軟體使用深度學習 AMI 的教學課程。

主題

- 10 分鐘教學課程
- 啟用架構
- 使用彈性織物適配器的分佈式
- GPU 監控和最佳化
- 具有 DL AWS AMI 的推論芯片
- 《ARM64 DLAMI》

- Inference
- 模型服務

10 分鐘教學課程

- 啟動一個 AWS Deep Learning AMI（在 10 分鐘內）
- 在 Amazon EC2 上使用 DLC 訓練深度學習模型 (只需 10 分鐘)

啟用架構

以下是使用 Conda 在深度學習 AMI 上安裝的深度學習架構。按一下某個架構，以了解如何啟用。

主題

- PyTorch
- TensorFlow 2

PyTorch

啟動 PyTorch

當框架的穩定 Conda 軟件包發布時，它已在 DLAMI 上進行測試並預先安裝。如果您想要執行最新、未經測試的每夜組建，您可以手動安裝 PyTorch的夜間構建（實驗性）。

若要啟用目前安裝的架構，請依照 Conda 的深度學習 AMI 上的這些指示進行。

對 PyTorch 於使用 CUDA 和 MKL-DNN 的 Python 3，請運行以下命令：

```
$ source activate pytorch_p310
```

啟動 iPython 終端機。

```
(pytorch_p310)$ ipython
```

運行一個快速 PyTorch 程序。

```
import torch
x = torch.rand(5, 3)
print(x)
```

```
print(x.size())
y = torch.rand(5, 3)
print(torch.add(x, y))
```

您應該會看到列印初始隨機陣列、接著是其大小，然後新增另一個隨機陣列。

安裝 PyTorch的夜間構建（實驗性）

如何 PyTorch 從夜間構建安裝

您可以使用 Conda 將最新 PyTorch 版本安裝到深度學習 AMI 上的一個或兩個 PyTorch Conda 環境中。

1. • （Python 3 的選項）-激活 Python 3 PyTorch 環境：

   ```
   $ source activate pytorch_p310
   ```

2. 其餘步驟假設您使用的是 `pytorch_p310` 環境。刪除當前安裝的 PyTorch：

   ```
   (pytorch_p310)$ pip uninstall torch
   ```

3. • (GPU 執行個體的選項)- PyTorch 使用 CUDA.0 安裝最新的夜間版本：

   ```
   (pytorch_p310)$ pip install torch_nightly -f https://download.pytorch.org/whl/
   nightly/cu100/torch_nightly.html
   ```

   • (CPU 執行個體的選項)-針對沒有 GPU 的執行個體安裝最新 PyTorch 的夜間組建：

   ```
   (pytorch_p310)$ pip install torch_nightly -f https://download.pytorch.org/whl/
   nightly/cpu/torch_nightly.html
   ```

4. 要驗證您是否成功安裝了最新的夜間構建，請啟動 IPython 終端並檢查. PyTorch

   ```
   (pytorch_p310)$ ipython
   ```

   ```
   import torch
   print (torch.__version__)
   ```

   輸出應該會列印類似於 `1.0.0.dev20180922` 的內容

5. 要驗證 PyTorch 每晚構建 PyTorch是否與 MNIST 示例一起運行良好，您可以從的示例存儲庫中運行測試腳本：

```
(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
```

其他教學

有關更多教程和示例，請參閱框架的官方PyTorch 文檔，文檔和PyTorch網站。

TensorFlow 2

本教學課程說明如何在執行深度學習 AMI (Conda 上的 DLAMI) 執行深度學習 AMI 的執行個體上啟動 TensorFlow 2，並執行 2 程式。 TensorFlow

當框架的穩定 Conda 軟件包發布時，它已在 DLAMI 上進行測試並預先安裝。

啟動中 TensorFlow 2

與康達一起 TensorFlow 在 DLAMI 上運行

1. 若要啟用 TensorFlow 2，請使用 Conda 開啟 DLAMI 的 Amazon 彈性運算雲端 (亞馬遜 EC2) 執行個體。
2. 對於 TensorFlow 使用 CUDA 10.1 和 MKL-DNN 的 Python 3 上的 2 和克拉斯 2，請運行以下命令：

   ```
   $ source activate tensorflow2_p310
   ```
3. 啟動 iPython 終端機：

   ```
   (tensorflow2_p310)$ ipython
   ```
4. 運行一個 TensorFlow 2 程序來驗證它是否正常工作：

   ```


   import tensorflow as tf
   hello = tf.constant('Hello, TensorFlow!')
   tf.print(hello)
   ```

   Hello, TensorFlow! 應該會出現在您的畫面上。

其他教學

有關更多教程和示例，請參閱 TensorFlow Python API 的 TensorFlow 文檔或訪問TensorFlow網站。

使用彈性織物適配器的分佈式

彈性網狀架構介面卡 (EFA) 是一種網路裝置，您可以連接至 DLAMI 執行個體，以加速高效能運算 (HPC) 應用程式。EFA 可讓您透過雲端提供的延展性、彈性和彈性，達到內部部署 HPC 叢集的應用程式效能。 AWS

下列主題說明如何開始使用 EFA 搭配 DLAMI。

> **Note**
>
> 從此基本 GPU Dlami 列表中選擇您的 DLAMI

主題

- 使用 EFA 啟動 AWS Deep Learning AMI 執行個體
- 使用全民福利局於全面 DLAMI

使用 EFA 啟動 AWS Deep Learning AMI 執行個體

最新的基礎 DLAMI 已準備好與 EFA 搭配使用，並隨附適用於 GPU 執行個體的必要驅動程式、核心模組、libFabric、openmpi 和 N CCL OFI 外掛程式。

您可以在發行說明中找到支援的基礎 DLAMI 的 CUDA 版本。

請注意：

- `mpirun`在 EFA 上使用執行 NCCL 應用程式時，您必須將 EFA 支援安裝的完整路徑指定為：

  ```
  /opt/amazon/openmpi/bin/mpirun <command>
  ```

- 若要讓您的應用程式能夠使用 EFA，請新增 `FI_PROVIDER="efa"` 至 `mpirun` 命令，如 使用全民福利局於全面 DLAMI 中所示。

主題

- 準備已啟用 EFA 的安全性群組

- 啟動您的執行個體
- 驗證 EFA 附件

準備已啟用 EFA 的安全性群組

EFA 需要一個安全性群組，允許進出安全性群組本身的所有輸入和輸出流量。如需詳細資訊，請參閱 EFA 文件。

1. 在 https://console.aws.amazon.com/ec2/ 開啟 Amazon EC2 主控台。
2. 在導覽窗格中，選擇 Security Groups (安全群組)，然後選擇 Create Security Group (建立安全群組)。
3. 在 Create Security Group (建立安全群組) 視窗中，執行下列動作：
   - 對於 Security group name (安全群組名稱)，輸入安全群組的描述性名稱，例如 `EFA-enabled security group`。
   - (選用) 對於 Description (描述)，輸入安全群組的簡短描述。
   - 對於 VPC，選取您打算讓具備 EFA 功能的執行個體在其中啟動的 VPC。
   - 選擇 Create (建立)。
4. 選取您建立的安全群組，在 Description (描述) 索引標籤上，複製 Group ID (群組 ID)。
5. 在「入埠」和「出埠」索引標籤上，執行下列動作：
   - 選擇 Edit (編輯)。
   - 針對 Type (類型)，選擇 All traffic (所有流量)。
   - 對於 Source (資源)，選擇 Custom (自訂)。
   - 將您複製的安全群組 ID 貼到欄位中。
   - 選擇儲存。
6. 參照 授權 Linux 執行個體的傳入流量來啟用傳入流量。如果跳過此步驟，將無法與 DLAMI 執行個體進行通訊。

啟動您的執行個體

上的 EFA 目前支援下列執行個體類型和作業系統： AWS Deep Learning AMI

- 全天候:Amazon Linux 2
- 大型:Amazon Linux 2

- 大:Amazon Linux 2,

下一節說明如何啟動已啟用 EFA 的 DLAMI 執行個體。如需啟動 EFA 啟用執行個體的詳細資訊，請參閱將啟用 EFA 的執行個體啟動至叢集置放群組。

1. 在 https://console.aws.amazon.com/ec2/ 開啟 Amazon EC2 主控台。
2. 選擇 Launch Instance (啟動執行個體)。
3. 在「選擇 AMI」頁面上，選取 DLAMI 版本說明頁面上支援的 DLAM I
4. 在 [選擇執行個體類型] 頁面上，選取下列其中一個支援的執行個體類型，然後選擇下一步：設定執行個體詳細資訊 如需支援的執行個體清單，請參閱此連結：開始使用 EFA 和 MPI
5. 在 Configure Instance Details (設定執行個體詳細資訊) 頁面上，執行下列操作：
   - 對於 Number of instances (執行個體的數目)，輸入要啟動的具備 EFA 功能的執行個體數。
   - 對於 Network (網路) 和 Subnet (子網)，選取要在其中啟動執行個體的 VPC 和子網。
   - [選擇性] 對於「放置」群組，選取「將例證新增至放置群組」。為獲得最佳效能，請在置放群組內啟動執行個體。
   - [選擇性] 在「放置群組名稱」中，選取「新增至新的放置群組」，輸入放置群組的描述性名稱，然後針對「放置群組策略」選取叢集。
   - 確保在此頁面上啟用 「彈性織物適配器」。如果停用此選項，請將子網路變更為支援您所選執行個體類型的子網路。
   - 在 Network Interfaces (網路介面) 區段中，針對裝置 eth0，選擇 New network interface (新網路介面)。您可以選擇性指定一個主要 IPv4 地址，以及一或多個次要 IPv4 地址。如果您在有相關聯 IPv6 CIDR 區塊的子網中啟動執行個體，您可以選擇性指定一個主要 IPv6 地址，以及一或多個次要 IPv6 地址。
   - 選擇 Next: Add Storage (下一步：新增儲存體)。
6. 在 Add Storage (新增儲存體) 頁面上，除了 AMI 指定的磁碟區 (例如根設備磁碟區)，指定要連接到執行個體的磁碟區，然後選擇 Next: Add Tags (下一步：新增標籤)。
7. 在 Add Tags (新增標籤) 頁面上，為執行個體指定標籤 (例如使用者易記的名稱)，然後選擇 Next: Configure Security Group (下一步：設定安全群組)。
8. 在 [設定安全性群組] 頁面上，對於 [指派安全性群組]，選取 [選取現有的安全性群組]，然後選取先前建立的安全性群組。
9. 選擇 Review and Launch (檢閱和啟動)。
10. 在 Review Instance Launch (檢閱執行個體啟動) 頁面上，檢閱設定，然後選擇 Launch (啟動)，以選擇金鑰對並啟動執行個體。

驗證 EFA 附件

從主控台

啟動執行個體之後，請在 AWS 主控台中檢查執行個體詳細資料。若要執行此操作，在 EC2 主控台中選取執行個體，然後查看頁面下方窗格中的 [Description (描述)] 索引標籤。尋找參數 “網路界面：eth0”，然後按一下 eth0 開啟一個彈出式畫面。確保「彈性織物適配器」已啟用。

如果未啟用 EFA，您可以透過以下任一方式修正此問題：

- 終止 EC2 執行個體並按照相同的步驟啟動新的執行個體。請確定已連接 EFA。
- 將 EFA 連接至現有的執行個體。

1. 在 EC2 主控台中，移至 [Network Interfaces (網路界面)]。
2. 按一下 [Create a Network Interface (建立網路界面)]。
3. 選取您的執行個體所在的相同子網路。
4. 確保啟用「彈性織物適配器」，然後單擊創建。
5. 返回 [EC2 Instances (EC2 執行個體)] 索引標籤並選取您的執行個體。
6. 移至「動作：執行個體狀態」，並在連接 EFA 之前停止執行個體。
7. 從 [Actions (動作)] 中，選取 [Networking: Attach Network Interface (聯網：連接網路界面)]。
8. 選擇您剛建立的界面，然後按一下連接。
9. 重新啟動您的執行個體。

從執行個體

DLAMI 上已經存在以下測試腳本。執行它以確保核心模組已正確載入。

```
$ fi_info -p efa
```

您的輸出應該類似以下內容：

```
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
```

確認安全群組組態

DLAMI 上已經存在以下測試腳本。執行它以確保您建立的安全群組已正確設定。

```
$ cd /opt/amazon/efa/test/
$ ./efa_test.sh
```

您的輸出應該類似以下內容：

```
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
```

如果它停止回應或未完成，請確定您的安全性群組具有正確的入站/輸出規則。

使用全民福利局於全面 DLAMI

下節說明如何使用 EFA 在上執行多節點應用程式。 AWS Deep Learning AMI

使用 EFA 執行多節點應用程式

要跨節點集群運行應用程序，需要以下配置

主題

- 啟用無密碼 SSH

- 建立主機檔案
- NCCL 測試

啟用無密碼 SSH

在叢集中選取一個節點做為領導節點。其餘的節點稱為成員節點。

1. 在領導節點上，產生 RSA 金鑰對。

```
ssh-keygen -t rsa -N "" -f ~/.ssh/id_rsa
```

2. 變更領導節點上私有金鑰的許可。

```
chmod 600 ~/.ssh/id_rsa
```

3. 將公開金鑰複製~/.ssh/id_rsa.pub到叢集中~/.ssh/authorized_keys的成員節點，並將其附加至叢集中的成員節點。
4. 您現在應該可以使用私有 IP 直接從領導節點登入到成員節點。

```
ssh <member private ip>
```

5. 透過將下列項目新增至引線節點上的 ~/.ssh/config 檔案，以停用 strictHostKey檢查並啟用前導節點上的代理程式轉送：

```
Host *
    ForwardAgent yes
Host *
    StrictHostKeyChecking no
```

6. 在 Amazon Linux 2 執行個體上，在領導節點上執行下列命令，為設定檔提供正確的許可：

```
chmod 600 ~/.ssh/config
```

建立主機檔案

在領導節點上，建立主機檔案以識別叢集中的節點。主機檔案對於叢集中每個節點都必須有項目。建立一個檔案 ~/hosts，並使用私有 IP 新增每個節點，如下所示：

```
localhost slots=8
```

```
<private ip of node 1> slots=8
<private ip of node 2> slots=8
```

NCCL 測試

> **Note**
>
> 這些測試已使用 EFA 版本 1.30.0 和 OFI NCCL 外掛程式 1.7.4 執行。

下面列出了 Nvidia 提供的 NCCL 測試子集，用於在多個計算節點上測試功能和性能

支援的執行個體：P3dn、P4、P5

功能測試

NCCL 訊息傳輸多節點測試

nccl_message_transfer 是一項簡單的測試，可確保 NCCL OFI 外掛程式如預期般運作。該測試驗證了 NCCL 的連接建立和資料傳輸 API 的功能。使用 EFA 執行 NCCL 應用程式時，請確定您使用完整的執行路徑，如範例所示。根據叢集中的執行個體和 GPU 的數目來變更參數 np 和 N。如需詳細資訊，請參閱 AWS OFI NCC L 文件。

下列 nccl_ 訊息傳輸測試適用於通用的 CUDA xx.x 版本。您可以取代指令碼中的 CUDA 版本，在 Amazon EC2 執行個體中針對任何可用的 CUDA 版本執行命令。

```
$/opt/amazon/openmpi/bin/mpirun -n 2 -N 1 --hostfile hosts \
-x LD_LIBRARY_PATH=/usr/local/cuda-xx.x/efa/lib:/usr/local/cuda-xx.x/lib:/usr/
local/cuda-xx.x/lib64:/usr/local/cuda-xx.x:$LD_LIBRARY_PATH \
--mca btl tcp,self --mca btl_tcp_if_exclude lo,docker0 --bind-to none \
opt/aws-ofi-nccl/tests/nccl_message_transfer
```

您的輸出看起來應該如下所示。您可以檢查輸出，看看 EFA 正在用作 OFI 提供者。

```
INFO: Function: nccl_net_ofi_init Line: 1069: NET/OFI Selected Provider is efa (found 4
 nics)
INFO: Function: nccl_net_ofi_init Line: 1160: NET/OFI Using transport protocol SENDRECV
INFO: Function: configure_ep_inorder Line: 261: NET/OFI Setting
 FI_OPT_EFA_SENDRECV_IN_ORDER_ALIGNED_128_BYTES not supported.
INFO: Function: configure_nccl_proto Line: 227: NET/OFI Setting NCCL_PROTO to "simple"
INFO: Function: main Line: 86: NET/OFI Process rank 1 started. NCCLNet device used on
 ip-172-31-13-179 is AWS Libfabric.
```

```
INFO: Function: main Line: 91: NET/OFI Received 4 network devices
INFO: Function: main Line: 111: NET/OFI Network supports communication using CUDA
 buffers. Dev: 3
INFO: Function: main Line: 118: NET/OFI Server: Listening on dev 3
INFO: Function: main Line: 131: NET/OFI Send connection request to rank 1
INFO: Function: main Line: 173: NET/OFI Send connection request to rank 0
INFO: Function: main Line: 137: NET/OFI Server: Start accepting requests
INFO: Function: main Line: 141: NET/OFI Successfully accepted connection from rank 1
INFO: Function: main Line: 145: NET/OFI Send 8 requests to rank 1
INFO: Function: main Line: 179: NET/OFI Server: Start accepting requests
INFO: Function: main Line: 183: NET/OFI Successfully accepted connection from rank 0
INFO: Function: main Line: 187: NET/OFI Rank 1 posting 8 receive buffers
INFO: Function: main Line: 161: NET/OFI Successfully sent 8 requests to rank 1
INFO: Function: main Line: 251: NET/OFI Got completions for 8 requests for rank 0
INFO: Function: main Line: 251: NET/OFI Got completions for 8 requests for rank 1
```

性能測試

大型多節點非 CCL 效能測試

要使用 EFA 檢查 NCCL 性能，請運行官方 NCCL 測試存儲庫上提供的標準 NCCL 性能測試。DLAMI 隨附這個已經為 CUDA XX.X 建立的測試，您也可以使用 EFA 來執行自己的指令碼。

建構您自己的指令碼時，請參閱下列指引：

- 使用 EFA 執行 NCCL 應用程式時，請使用範例所示的完整路徑來執行完整的執行路徑。
- 根據叢集中的執行個體和 GPU 的數目來變更參數 np 和 N。
- 新增 NCCL_DEBUG = 資訊旗標，並確定記錄檔會將 EFA 用法指示為「選取的提供者為 EFA」。
- 設定要剖析的訓練記錄位置以進行驗證

```
TRAINING_LOG="testEFA_$(date +"%N").log"
```

在任何成員節點上使用命令 `watch nvidia-smi` 來監視 GPU 使用量。下列`watch nvidia-smi`指令適用於一般 CUDA xx.x 版本，且視執行個體的作業系統而定。您可以取代指令碼中的 CUDA 版本，在 Amazon EC2 執行個體中針對任何可用的 CUDA 版本執行命令。

- Amazon Linux 2：

```
 $ /opt/amazon/openmpi/bin/mpirun -n 16 -N 8 \
-x NCCL_DEBUG=INFO -x --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 -x NCCL_PROTO=simple -b 8 -e
 1G -f 2 -g 1 -c 1 -n 100 | tee ${TRAINING_LOG}
```

- UBUNTU

```
$ /opt/amazon/openmpi/bin/mpirun -n 16 -N 8 \
-x NCCL_DEBUG=INFO -x --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 -x NCCL_PROTO=simple-b 8 -e
 1G -f 2 -g 1 -c 1 -n 100 | tee ${TRAINING_LOG}
```

您的輸出看起來應如以下所示：

```
# 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   9591 on ip-172-31-4-37 device  0 [0x10] NVIDIA A100-SXM4-40GB
#  Rank  1 Group  0 Pid   9592 on ip-172-31-4-37 device  1 [0x10] NVIDIA A100-SXM4-40GB
#  Rank  2 Group  0 Pid   9593 on ip-172-31-4-37 device  2 [0x20] NVIDIA A100-SXM4-40GB
#  Rank  3 Group  0 Pid   9594 on ip-172-31-4-37 device  3 [0x20] NVIDIA A100-SXM4-40GB
#  Rank  4 Group  0 Pid   9595 on ip-172-31-4-37 device  4 [0x90] NVIDIA A100-SXM4-40GB
#  Rank  5 Group  0 Pid   9596 on ip-172-31-4-37 device  5 [0x90] NVIDIA A100-SXM4-40GB
#  Rank  6 Group  0 Pid   9597 on ip-172-31-4-37 device  6 [0xa0] NVIDIA A100-SXM4-40GB
#  Rank  7 Group  0 Pid   9598 on ip-172-31-4-37 device  7 [0xa0] NVIDIA A100-SXM4-40GB
#  Rank  8 Group  0 Pid  10216 on ip-172-31-13-179 device  0 [0x10] NVIDIA A100-
SXM4-40GB
#  Rank  9 Group  0 Pid  10217 on ip-172-31-13-179 device  1 [0x10] NVIDIA A100-
SXM4-40GB
#  Rank 10 Group  0 Pid  10218 on ip-172-31-13-179 device  2 [0x20] NVIDIA A100-
SXM4-40GB
#  Rank 11 Group  0 Pid  10219 on ip-172-31-13-179 device  3 [0x20] NVIDIA A100-
SXM4-40GB
```

```
#  Rank 12 Group  0 Pid  10220 on ip-172-31-13-179 device  4 [0x90] NVIDIA A100-
SXM4-40GB
#  Rank 13 Group  0 Pid  10221 on ip-172-31-13-179 device  5 [0x90] NVIDIA A100-
SXM4-40GB
#  Rank 14 Group  0 Pid  10222 on ip-172-31-13-179 device  6 [0xa0] NVIDIA A100-
SXM4-40GB
#  Rank 15 Group  0 Pid  10223 on ip-172-31-13-179 device  7 [0xa0] NVIDIA A100-
SXM4-40GB
ip-172-31-4-37:9591:9591 [0] NCCL INFO Bootstrap : Using ens32:172.31.4.37
ip-172-31-4-37:9591:9591 [0] NCCL INFO NET/Plugin: Failed to find ncclCollNetPlugin_v6
 symbol.
ip-172-31-4-37:9591:9591 [0] NCCL INFO NET/Plugin: Failed to find ncclCollNetPlugin
 symbol (v4 or v5).
ip-172-31-4-37:9591:9591 [0] NCCL INFO cudaDriverVersion 12020
NCCL version 2.18.5+cuda12.2
...
ip-172-31-4-37:9024:9062 [6] NCCL INFO NET/OFI Initializing aws-ofi-nccl 1.7.4-aws
ip-172-31-4-37:9020:9063 [2] NCCL INFO NET/OFI Using CUDA runtime version 11070
ip-172-31-4-37:9020:9063 [2] NCCL INFO NET/OFI Configuring AWS-specific options
ip-172-31-4-37:9024:9062 [6] NCCL INFO NET/OFI Using CUDA runtime version 11070
ip-172-31-4-37:9024:9062 [6] NCCL INFO NET/OFI Configuring AWS-specific options
ip-172-31-4-37:9024:9062 [6] NCCL INFO NET/OFI Setting provider_filter to efa
ip-172-31-4-37:9024:9062 [6] NCCL INFO NET/OFI Setting FI_EFA_FORK_SAFE environment
 variable to 1
ip-172-31-4-37:9024:9062 [6] NCCL INFO NET/OFI Disabling NVLS support due to NCCL
 version 21602
ip-172-31-4-37:9020:9063 [2] NCCL INFO NET/OFI Setting provider_filter to efa
ip-172-31-4-37:9020:9063 [2] NCCL INFO NET/OFI Setting FI_EFA_FORK_SAFE environment
 variable to 1
ip-172-31-4-37:9020:9063 [2] NCCL INFO NET/OFI Disabling NVLS support due to NCCL
 version 21602
ip-172-31-4-37:9020:9063 [2] NCCL INFO NET/OFI Running on p4d.24xlarge platform,
 Setting NCCL_TOPO_FILE environment variable to /opt/aws-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)
           0             0     float     sum      -1    11.02    0.00    0.00      0
 11.04    0.00    0.00      0
```

```
           0             0     float     sum      -1    11.01    0.00    0.00       0
11.00    0.00    0.00       0
           0             0     float     sum      -1    11.02    0.00    0.00       0
11.02    0.00    0.00       0
           0             0     float     sum      -1    11.01    0.00    0.00       0
11.00    0.00    0.00       0
           0             0     float     sum      -1    11.02    0.00    0.00       0
11.02    0.00    0.00       0
         256             4     float     sum      -1    632.7    0.00    0.00       0
628.2    0.00    0.00       0
         512             8     float     sum      -1    627.4    0.00    0.00       0
629.6    0.00    0.00       0
        1024            16     float     sum      -1    632.2    0.00    0.00       0
631.7    0.00    0.00       0
        2048            32     float     sum      -1    631.0    0.00    0.00       0
634.2    0.00    0.00       0
        4096            64     float     sum      -1    623.3    0.01    0.01       0
633.6    0.01    0.01       0
        8192           128     float     sum      -1    635.1    0.01    0.01       0
633.5    0.01    0.01       0
       16384           256     float     sum      -1    634.8    0.03    0.02       0
637.0    0.03    0.02       0
       32768           512     float     sum      -1    647.9    0.05    0.05       0
636.8    0.05    0.05       0
       65536          1024     float     sum      -1    658.9    0.10    0.09       0
667.0    0.10    0.09       0
      131072          2048     float     sum      -1    671.9    0.20    0.18       0
662.9    0.20    0.19       0
      262144          4096     float     sum      -1    692.1    0.38    0.36       0
685.1    0.38    0.36       0
      524288          8192     float     sum      -1    715.3    0.73    0.69       0
696.6    0.75    0.71       0
     1048576         16384     float     sum      -1    734.6    1.43    1.34       0
729.2    1.44    1.35       0
     2097152         32768     float     sum      -1    785.9    2.67    2.50       0
794.5    2.64    2.47       0
     4194304         65536     float     sum      -1    837.2    5.01    4.70       0
837.6    5.01    4.69       0
     8388608        131072     float     sum      -1    929.2    9.03    8.46       0
931.4    9.01    8.44       0
    16777216        262144     float     sum      -1   1773.6    9.46    8.87       0
1772.8    9.46    8.87       0
    33554432        524288     float     sum      -1   2110.2   15.90   14.91       0
2116.1   15.86   14.87       0
```

```
    67108864       1048576     float     sum      -1   2650.9   25.32   23.73      0
 2658.1   25.25   23.67      0
   134217728       2097152     float     sum      -1   3943.1   34.04   31.91      0
 3945.9   34.01   31.89      0
   268435456       4194304     float     sum      -1   7216.5   37.20   34.87      0
 7178.6   37.39   35.06      0
   536870912       8388608     float     sum      -1    13680   39.24   36.79      0
 13676   39.26   36.80      0
[  1073741824      16777216     float     sum      -1    25645   41.87   39.25      0
 25497   42.11   39.48      0 ] <- Used For Benchmark
...
# Out of bounds values : 0 OK
# Avg bus bandwidth    : 7.46044
```

驗證測試

若要驗證 EFA 測試傳回有效的結果，請使用下列測試來確認：

- 使用 EC2 執行個體中繼資料取得執行個體類型

```
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)
```

- 執行 性能測試
- 設定下列參數

```
CUDA_VERSION
CUDA_RUNTIME_VERSION
NCCL_VERSION
```

- 驗證結果，如下所示：

```
RETURN_VAL=`echo $?`
if [ ${RETURN_VAL} -eq 0 ]; then

    # Information on how the version come from logs
    #
    # ip-172-31-27-205:6427:6427 [0] NCCL INFO cudaDriverVersion 12020
    # NCCL version 2.16.2+cuda11.8
    # ip-172-31-27-205:6427:6820 [0] NCCL INFO NET/OFI Initializing aws-ofi-nccl
 1.7.1-aws
```

```
    # ip-172-31-27-205:6427:6820 [0] NCCL INFO NET/OFI Using CUDA runtime version
 11060

    # cudaDriverVersion 12020  --> This is max supported cuda version by nvidia
 driver
    # NCCL version 2.16.2+cuda11.8 --> This is NCCL version compiled with cuda
 version
    # Using CUDA runtime version 11060 --> This is selected cuda version

    # Validation of logs
    grep "NET/OFI Using CUDA runtime version ${CUDA_RUNTIME_VERSION}" ${TRAINING_LOG}
 || { echo "Runtime cuda text not found"; exit 1; }
    grep "NET/OFI Initializing aws-ofi-nccl" ${TRAINING_LOG} || { echo "aws-ofi-nccl
 is not working, please check if it is installed correctly"; exit 1; }
    grep "NET/OFI Configuring AWS-specific options" ${TRAINING_LOG} || { echo "AWS-
specific options text not found"; exit 1; }
    grep "Using network AWS Libfabric" ${TRAINING_LOG} || { echo "AWS Libfabric 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/AWS Libfabric/0/GDRDMA" ${TRAINING_LOG} || { echo "Text not found:
 NET/AWS 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; }
        grep "aws-ofi-nccl/xml/p4d-24xl-topo.xml" ${TRAINING_LOG} || { echo "Topology
 file not found"; exit 1; }
    elif [[ ${INSTANCE_TYPE} == "p4de.24xlarge" ]]; then
        grep "NET/AWS 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; }
        grep "aws-ofi-nccl/xml/p4de-24xl-topo.xml" ${TRAINING_LOG} || { echo
 "Topology file not found"; exit 1; }
    elif [[ ${INSTANCE_TYPE} == "p5.48xlarge" ]]; then
        grep "NET/AWS 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; }
```

```
        grep "aws-ofi-nccl/xml/p5.48xl-topo.xml" ${TRAINING_LOG} || { echo "Topology
 file 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
```

- 要訪問基準數據，我們可以解析多節點 all_reduce 測試中表輸出的最後一行：

```
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}"
```

GPU 監控和最佳化

下一節將引導您完成 GPU 最佳化和監控選項。本節的編排像一般的工作流程，包括監控、監督、預先處理和培訓。

- 監控
  - 使用以下方式監控 GPU CloudWatch
- 最佳化
  - 預處理
  - 培訓

監控

您的 DLAMI 預先安裝了幾個 GPU 監視工具。本指南還提及可供下載和安裝的工具。

- 使用以下方式監控 GPU CloudWatch-預先安裝的公用程式，可向 Amazon CloudWatch 報告 GPU 使用量統計資料。
- nvidia-smi CLI - 用於監控整體 GPU 運算和記憶體使用率的公用程式。這已預先安裝在您的 AWS Deep Learning AMI （DLAMI）上。
- NVML C 程式庫 – 以 C 為基礎的 API，可直接存取 GPU 監控和管理功能。這是由 nvidia-smi CLI 在幕後使用，並預先安裝在 DLAMI 上。它還有 Python 和 Perl 繫結，有助於以這些語言來開發。預先安裝在 DLAMI 的 gpumon.py 公用程式使用 nvidia-ml-py 中的 pynvml 套件。
- NVIDIA DCGM - 叢集管理工具。造訪開發人員頁面，了解如何安裝和設定這個工具。

> **Tip**
>
> 查看 NVIDIA 的開發人員部落格，瞭解如何使用安裝 DLAMI 的 CUDA 工具的最新資訊：
>
> - 使 TensorCore 用 Nsight IDE 和 Nvprof 監控使用率。

使用以下方式監控 GPU CloudWatch

當您使用 DLAMI 搭配 GPU 時，您可能會發現您在培訓或推論期間設法追蹤其使用狀況。這在最佳化資料管道和調校深度學習網路時可能有很用。

設定 GPU 指標的方式有兩種 CloudWatch：

- 使用 AWS CloudWatch 代理程式設定度量 (建議選項)
- 使用預先安裝gpumon.py的指令碼設定度量

使用 AWS CloudWatch 代理程式設定度量 (建議選項)

將 DLAMI 與統一 CloudWatch 代理程式整合，以設定 GPU 指標，並監控 Amazon EC2 加速執行個體中 GPU 協同處理程序的使用率。

使用 DLAMI 設定 GPU 指標的方式有四種：

- 設定最低 GPU 指標
- 設定部分 GPU 指標
- 設定所有可用的 GPU 指標
- 設定自訂 GPU 指標

如需更新和安全性修補程式的資訊，請參閱 AWS CloudWatch 代理程式的安全性修補

必要條件

若要開始使用，您必須設定允許執行個體推送指標的 Amazon EC2 執行個體 IAM 許可 CloudWatch。如需詳細步驟，請參閱建立 IAM 角色和使用者以搭配 CloudWatch 代理程式使用。

設定最低 GPU 指標

使用dlami-cloudwatch-agent@minimalsystemd服務設定最低 GPU 指標。此服務會設定下列測量結果：

- utilization_gpu
- utilization_memory

您可以在下列位置找到最低預先設定 GPU 指標的systemd服務：

```
/opt/aws/amazon-cloudwatch-agent/etc/dlami-amazon-cloudwatch-agent-minimal.json
```

使用以下命令啟用並啟動systemd服務：

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

設定部分 GPU 指標

使用dlami-cloudwatch-agent@partialsystemd服務設定部分 GPU 指標。此服務會設定下列測量結果：

- utilization_gpu
- utilization_memory
- memory_total
- memory_used
- memory_free

您可以在下列位置找到部分預先設定 GPU 指標的systemd服務：

```
/opt/aws/amazon-cloudwatch-agent/etc/dlami-amazon-cloudwatch-agent-partial.json
```

使用以下命令啟用並啟動systemd服務：

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

設定所有可用的 GPU 指標

使用dlami-cloudwatch-agent@allsystemd服務設定所有可用的 GPU 指標。此服務會設定下列測量結果：

- 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

您可以在下列位置找到所有可用預先設定 GPU 指標的systemd服務：

```
/opt/aws/amazon-cloudwatch-agent/etc/dlami-amazon-cloudwatch-agent-all.json
```

使用以下命令啟用並啟動systemd服務：

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

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

設定自訂 GPU 指標

如果預先設定的測量結果不符合您的需求，您可以建立自訂 CloudWatch 代理程式組態檔。

建立自訂規劃檔

若要建立自訂組態檔，請參閱手動建立或編輯 CloudWatch 代理程式組態檔中的詳細步驟。

在此範例中，假設結構定義位於/opt/aws/amazon-cloudwatch-agent/etc/amazon-cloudwatch-agent.json。

使用自訂檔案設定指標

執行下列命令，根據您的自訂檔案設定 CloudWatch 代理程式：

```
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
```

AWS CloudWatch 代理程式的安全性修補

新發行的 DLAMI 已設定為最新可用的 AWS CloudWatch 代理程式安全性修補程式。請參閱以下各節，根據您選擇的作業系統，使用最新的安全性修補程式來更新您目前的 DLAMI。

Amazon Linux 2

用於取yum得適用於 Amazon Linux 2 DLAMI 的最新 AWS CloudWatch 代理程式安全修補程式。

```
 sudo yum update
```

Ubuntu

若要透過 Ubuntu 取得 DLAMI 的最新 AWS CloudWatch 安全性修補程式，您必須使用 Amazon S3 下載連結重新安裝 AWS CloudWatch 代理程式。

```
wget https://s3.region.amazonaws.com/amazoncloudwatch-agent-region/ubuntu/arm64/latest/
amazon-cloudwatch-agent.deb
```

如需使用 Amazon S3 下載連結安裝 AWS CloudWatch 代理程式的詳細資訊，請參閱在伺服器上安裝和執行 CloudWatch 代理程式。

使用預先安裝**gpumon.py**的指令碼設定度量

稱為 gpumon.py 的公用程式已預先安裝在 DLAMI 上。它整合 CloudWatch 並支援監控每個 GPU 的使用情況：GPU 記憶體、GPU 溫度和 GPU 電源。指令碼會定期將受監視的資料傳送至 CloudWatch。您可以透 CloudWatch 過變更指令碼中的一些設定來設定要傳送至的資料粒度層級。但是，在啟動指令碼之前，您需要先設定 CloudWatch 才能接收指標。

如何設置和運行 GPU 監控 CloudWatch

1. 建立 IAM 使用者，或修改現有的使用者，以取得將指標發佈到的政策 CloudWatch。如果您建立新的使用者，請記下登入資料，因為您在下一步驟中需要用到。

   要搜尋的 IAM 政策為「雲觀察：PutMetric資料」。新增的政策如下所示：

   ```
   {
      "Version": "2012-10-17",
      "Statement": [
           {
               "Action": [
                   "cloudwatch:PutMetricData"
                ],
                "Effect": "Allow",
                "Resource": "*"
           }
      ]
   }
   ```

   > **Tip**
   >
   > 如需有關建立 IAM 使用者和新增政策的詳細資訊 CloudWatch，請參閱 CloudWatch 文件。

2. 在 DLAMI 上，執行AWS 設定並指定 IAM 使用者登入資料。

   ```
   $ aws configure
   ```

3. 執行 gpumon 公用程式之前，您可能需要對它進行一些修改。您可以在下列程式碼區塊中定義的位置找到 gpumon 公用程式和 README。如需gpumon.py指令碼的詳細資訊，請參閱指令碼的 Amazon S3 位置。

   ```
   Folder: ~/tools/GPUCloudWatchMonitor
   ```

```
Files:  ~/tools/GPUCloudWatchMonitor/gpumon.py
       ~/tools/GPUCloudWatchMonitor/README
```

選項：

- 如果您的執行個體「不在」us-east-1 中，請在 gpumon.py 中變更區域。
- 使用變更其他參數，例如 CloudWatch`namespace`或報表期間`store_reso`。

4. 此指令碼目前僅支援 Python 3。激活您首選框架的 Python 3 環境或激活 DLAMI 通用 Python 3 環境。

```
$ source activate python3
```

5. 在背景執行 gpumon 公用程式。

```
(python3)$ python gpumon.py &
```

6. 打開瀏覽器到 https://console.aws.amazon.com/cloudwatch/，然後選擇指標。它將有一個命名空間「DeepLearning火車」。

> **Tip**
>
> 您可以修改 gpumon.py 來變更命名空間。您也可以調整 `store_reso` 來修改報告間隔。

以下是針對執行 gpumon.py 監視 p2.8xlarge 執行個體上訓練工作的報告範例 CloudWatch 圖表。

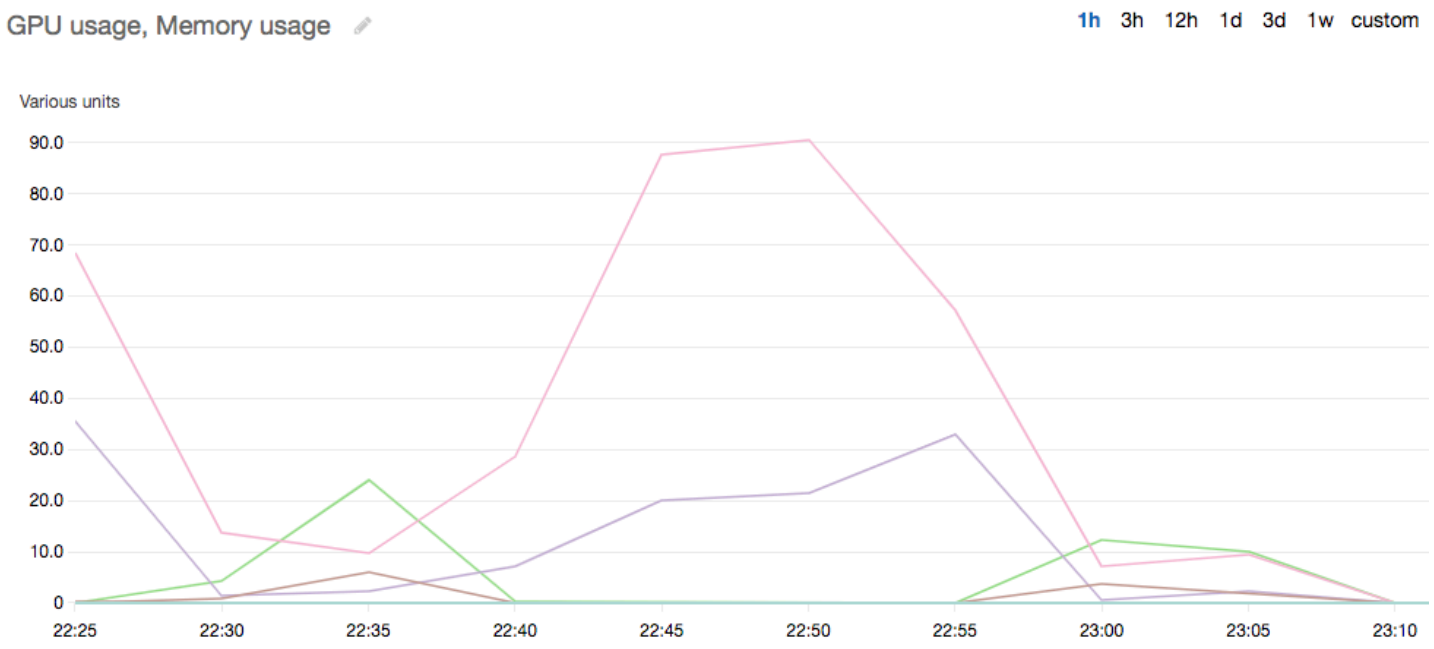

對於 GPU 監控和最佳化，您可能有興趣看其他這些主題：

- 監控
  - 使用以下方式監控 GPU CloudWatch
- 最佳化
  - 預處理
  - 培訓

最佳化

為了充分利用您的 GPU，您可以最佳化資料管道及調整深度學習網路。如下圖所述，神經網路的單純或基本實作使用 GPU 的方式可能不一致，而未完全發揮其潛能。當您最佳化您的前處理和資料載入時，您可以降低從 CPU 到 GPU 的瓶頸。您可以使用雜合 (當架構支援時)、調整批次大小和同步化呼叫，以調整神經網路本身。您在大多數架構中也可以使用多精確度 (float16 或 int8) 培訓，這可以大幅影響提高輸送量。

下列圖表顯示套用不同的最佳化時累積的效能提升。您的結果將取決於您處理的資料和您最佳化的網路。

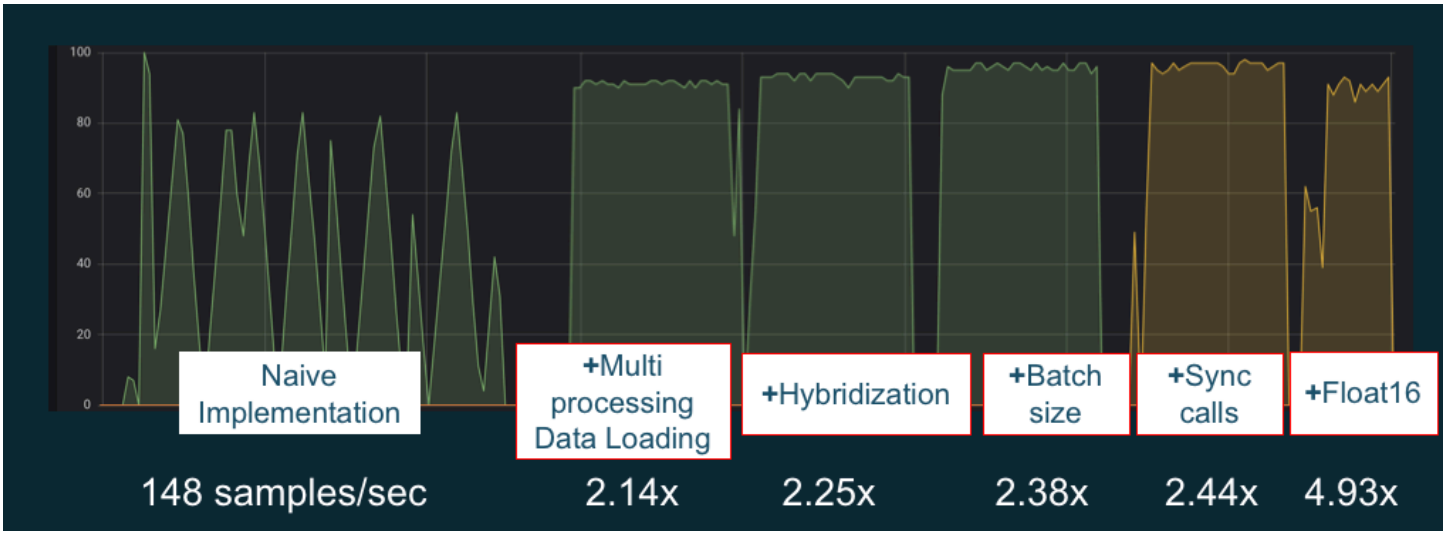

範例 GPU 效能最佳化。圖表來源：使用 MXNet Gluon 的效能技巧

以下指南介紹了可與 DLAMI 配合使用的選項，並幫助您提高 GPU 性能。

主題

- 預處理
- 培訓

預處理

透過轉換或擴增的資料預先處理通常是 CPU 密集型程序，這可能成為整個管道中的瓶頸。架構有用於影像處理的內建運算子，但 DALI (Data Augmentation Library) 展現比架構的內建選項更好的效能。

- NVIDIA Data Augmentation Library (DALI)：DALI 將資料擴增卸載到 GPU。DLAMI 並未預先安裝，但您可以透過在 DLAMI 或其他 Amazon 彈性運算雲端執行個體上安裝或載入受支援的架構容器來存取它。如需詳細資訊，請參閱 NVIDIA 網站上的 DALI 專案頁面。如需範例使用案例和下載程式碼範例，請參閱 SageMaker 預先處理訓練效能範例。
- nvJPEG：適用於 C 程式設計人員的 GPU 加速 JPEG 解碼器程式庫。它支援解碼單一映像或批次，以及深度學習中常見的後續轉換操作。nvJPEG 內建於 DALI，或者，您可以另外從 NVIDIA 網站的 nvjpeg 頁面下載來使用。

對於 GPU 監控和最佳化，您可能有興趣看其他這些主題：

- 監控
  - 使用以下方式監控 GPU CloudWatch

- 最佳化
  - 預處理
  - 培訓

培訓

透過混合精度培訓，您可以使用相同的記憶體數量來部署更大的網路，或相較於單一或雙精度網路而言，降低記憶體使用量，您將會看到運算效能提高。您也可享有較小和更快資料傳輸的好處，這是多節點分散式培訓的重要因素。若要利用混合精度培訓，您需要調整資料轉換和損耗縮放。以下指南說明如何對支援混合精度的架構這樣做。

- NVIDIA 深度學習開發套件-NVIDIA 網站上的文件，說明適用於 MXNet 的混合精確度實作，PyTorch以及. TensorFlow

> **Tip**
>
> 請務必到網站上查看您選擇的架構，並搜尋「混合精度」或 "fp16" 以取得最新的最佳化技術。以下是您可能覺得很有用的一些混合精度指南：
>
> - 與 TensorFlow （視頻）混合精度培訓-在 NVIDIA 博客網站。
> - 使用 float16 搭配 MXNet 進行混合精度培訓 - MXNet 網站上的常見問答集文章。
> - NVIDIA 的頂點：輕鬆混合精度培訓的工具 PyTorch-NVIDIA 網站上的博客文章。

對於 GPU 監控和最佳化，您可能有興趣看其他這些主題：

- 監控
  - 使用以下方式監控 GPU CloudWatch
- 最佳化
  - 預處理
  - 培訓

具有 DL AWS AMI 的推論芯片

AWS Inferentia 是一種定制的機器學習芯片，其設計 AWS 可用於高性能推論預測。 若要使用該晶片，請設定 Amazon 彈性運算雲端執行個體，並使用 AWS Neuron 軟體開發套件 (SDK) 呼叫推論晶片。為了為客戶提供最佳的推論體驗，神經元已內置於 AWS Deep Learning AMI （DLAMI）中。

下列主題說明如何開始使用 DLAMI 的推論。

目錄

啟動含有神經元的 DLAMI 執行個體 AWS

最新的 DLAMI 已準備好與 AWS 推論一起使用，並附帶神經元 API 包。 AWS 若要啟動 DLAMI 執行個體，請參閱啟動和設定 DLAMI。取得 DLAMI 之後，請使用此處的步驟來確保您的 AWS 推論晶片和 AWS 神經元資源處於作用中狀態。

目錄

驗證您的執行個體

在使用您的執行個體之前，請確認執行個體是否已正確設定並設定 Neuron。

識別 AWS 推論裝置

若要識別執行個體上的 Inferentia 裝置數量，請使用下列指令：

```
neuron-ls
```

如果您的執行個體已連接 Inferentia 裝置，您的輸出會類似下列內容：

```
+--------+--------+--------+-----------+--------------+
| 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 |
+--------+--------+--------+-----------+--------------+
```

提供的輸出取自 Inf1.6xLarge 執行個體，並包含下列資料欄：

- 神經元裝置：指派給. NeuronDevice 配置多個運行時使用此 ID 以使用不同 NeuronDevices的運行時。
- 神經元核心:目 NeuronCores 前在 NeuronDevice.
- 神經元記憶體:DRAM 記憶體的 NeuronDevice量.
- 已連接的設備：其他 NeuronDevices 已連接到 NeuronDevice.
- PCI BDF：. 的 PCI 匯流排裝置功能 (BDF) 識別碼。 NeuronDevice

檢視資源使用量

使用指`neuron-top`令檢視 vCPU 使用率、記憶體使用率、載入的模型和 Neuron 應用程式的有用資訊。 NeuronCore 不`neuron-top`帶引數的啟動將顯示所有使用的機器學習應用程序的數據 NeuronCores。

```
neuron-top
```

當應用程式使用 4 時 NeuronCores，輸出應類似下列影像：

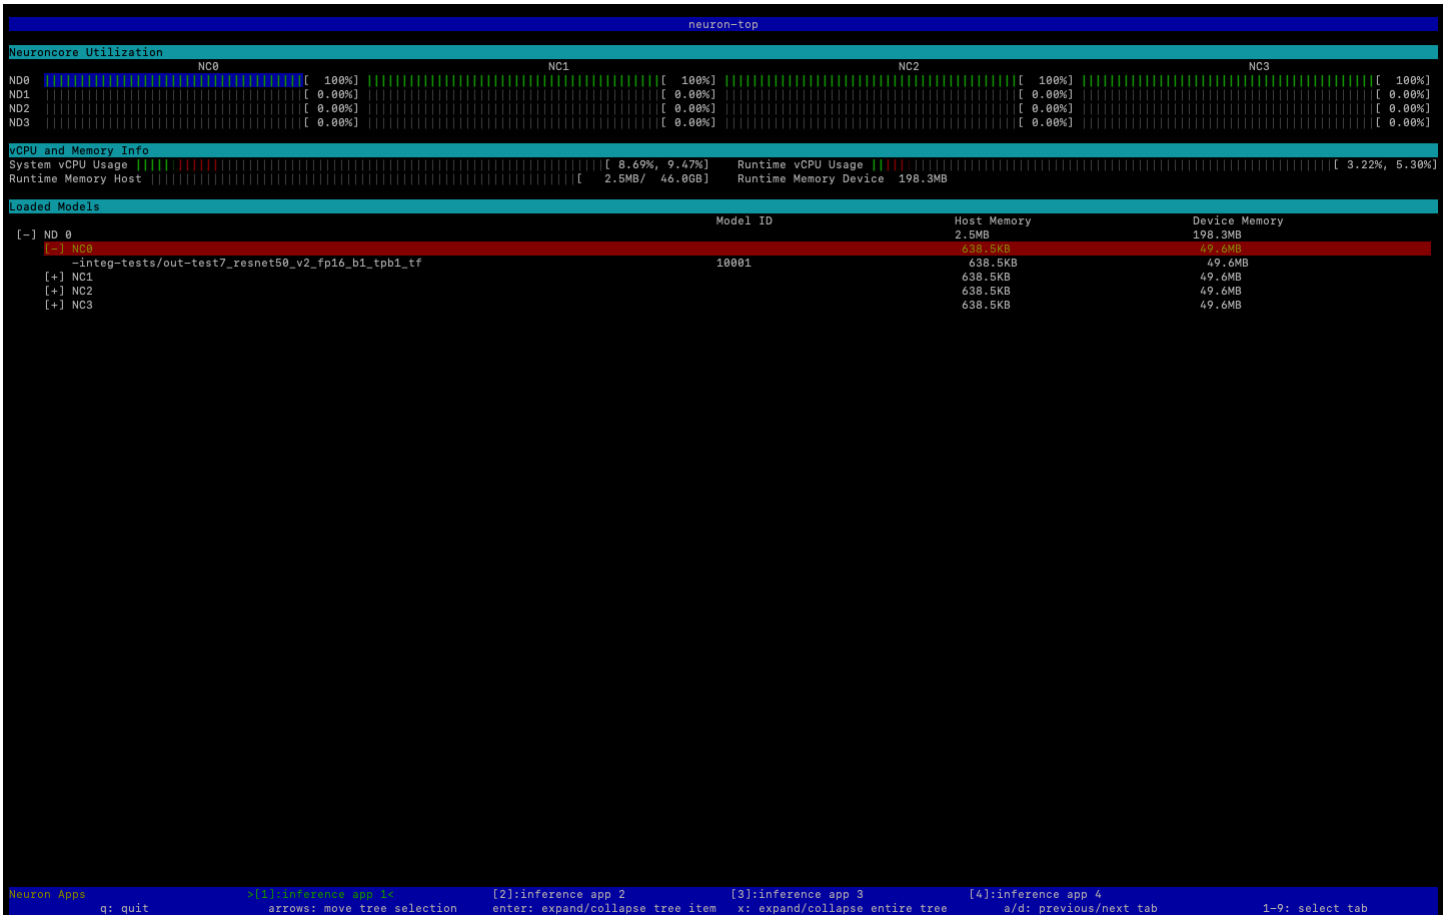

如需監控和最佳化神經元推論應用程式的資源的詳細資訊，請參閱神經元工具。

使用神經元監視器 (神經元監視器)

神經元監視器從系統上運行的神經元運行時收集指標，並以 JSON 格式將收集的數據流式傳輸到 stdout。這些測量結果會組織成您透過提供組態檔來設定的測量結果群組。有關神經元監視器的更多信息，請參閱神經元監視器用戶指南。

升級神經元軟件

有關如何在 DLAMI 中更新神經元 SDK 軟件的信息，請參閱《 AWS 神經元設置指南》。

後續步驟

使用 DLAMI 與神經元 AWS

使用 DLAMI 與神經元 AWS

AWS Neuron SDK 的典型工作流程是在編譯伺服器上編譯先前訓練過的機器學習模型。在此之後，將成品分配到 Inf1 執行個體以便執行。 AWS Deep Learning AMI (DLAMI) 已預先安裝在使用 Inferentia 的 InF1 執行個體中編譯和執行推論所需的一切。

以下各節說明如何使用 DLAMI 與推論。

目錄

使用 TensorFlow-神經元和神經元編譯器 AWS

本教學課程說明如何使用 AWS 神經元編譯器來編譯 Keras ResNet -50 模型，並以格式匯出為已儲存的模型。 SavedModel 此格式是典 TensorFlow 型的模型可互換格式。您也會學習如何使用範例輸入在 Inf1 執行個體上執行推論。

有關神經元 SDK 的更多信息，請參閱AWS 神經元 SDK 文檔。

目錄

必要條件

在使用本教學課程之前，您應該已完成 啟動含有神經元的 DLAMI 執行個體 AWS 中的設置步驟。您還應該熟悉深度學習和 DLAMI 的使用。

啟動 Conda 環境

使用下列指令啟動 TensorFlow-神經元控制環境：

```
source activate aws_neuron_tensorflow_p36
```

若要結束目前的 conda 環境，請執行下列命令：

```
source deactivate
```

Resnet50 編譯

建立一個叫做 **tensorflow_compile_resnet50.py** 的 Python 指令碼，具有以下內容。這個 Python 腳本編譯凱拉斯 ResNet 50 模型，並將其導出為保存的模型。

```
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')
```

使用下列命令編譯模型：

```
python tensorflow_compile_resnet50.py
```

編譯程序需要幾分鐘的時間。完成時，您的輸出應如以下所示：

```
...
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
...
```

編譯之後，儲存的模型會在 **ws_resnet50/resnet50_neuron.zip** 被壓縮。使用下列命令將模型解壓縮，並下載推論範例影像：

```
unzip ws_resnet50/resnet50_neuron.zip -d .
curl -O https://raw.githubusercontent.com/awslabs/mxnet-model-server/master/docs/
images/kitten_small.jpg
```

ResNet五十推論

建立一個叫做 **tensorflow_infer_resnet50.py** 的 Python 指令碼，具有以下內容。此指令碼使用先前編譯的推論模型，針對下載的模型執行推論。

```
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])
```

使用下列命令在模型上執行推論：

```
python tensorflow_infer_resnet50.py
```

您的輸出看起來應如以下所示：

```
...
[('n02123045', 'tabby', 0.6918919), ('n02127052', 'lynx', 0.12770271), ('n02123159',
 'tiger_cat', 0.08277027), ('n02124075', 'Egyptian_cat', 0.06418919), ('n02128757',
 'snow_leopard', 0.009290541)]
```

後續步驟

使用 AWS 神經元服務 TensorFlow

使用 AWS 神經元服務 TensorFlow

本教學課程說明如何在匯出儲存的模型以與 Service 搭配 TensorFlow 使用之前，建構圖形並新增 AWS Neuron 編譯步驟。 TensorFlow 服務是一種服務系統，可讓您跨網路擴展推論。神經元 TensorFlow 服務使用與正常服 TensorFlow 務相同的 API。唯一的區別是，必須針對 AWS Inferentia

編譯已儲存的模型，而入口點是名為的不同二進位檔案。tensorflow_model_server_neuron二進位檔可在 DLAMI 中找到/usr/local/bin/tensorflow_model_server_neuron並已預先安裝。

有關神經元 SDK 的更多信息，請參閱AWS 神經元 SDK 文檔。

目錄

必要條件

在使用本教學課程之前，您應該已完成 啟動含有神經元的 DLAMI 執行個體 AWS 中的設置步驟。您還應該熟悉深度學習和 DLAMI 的使用。

啟動 Conda 環境

使用下列指令啟動 TensorFlow-神經元控制環境：

```
source activate aws_neuron_tensorflow_p36
```

如果您需要退出目前的 conda 環境，請執行：

```
source deactivate
```

編譯和匯出儲存的模型

創建一個使用以下內容調tensorflow-model-server-compile.py用的 Python 腳本。 這個腳本構造一個圖形，並使用神經元編譯它。然後將編譯後的圖形匯出為儲存的模型。

```
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)
```

使用下列命令編譯模型：

```
python tensorflow-model-server-compile.py
```

您的輸出看起來應如以下所示：

```
...
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
```

為儲存的模型提供服務

一旦模型已編譯過，您可以使用以下命令，以 tensorflow_model_server_neuron 二進位檔案為儲存的模型提供服務：

```
tensorflow_model_server_neuron --model_name=resnet50_inf1 \
    --model_base_path=$HOME/resnet50_inf1/ --port=8500 &
```

您的輸出看起來應該如下所示。伺服器會在推論裝置的 DRAM 中暫存編譯的模型，以準備進行推論。

```
...
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 ...
```

向模型伺服器產生推論請求

建立一個叫做 `tensorflow-model-server-infer.py` 的 Python 指令碼，具有以下內容。此指令碼透過 gRPC (為一服務框架) 執行推斷。

```
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))
```

使用 gRPC，以下列命令在模型上執行推論：

```
python tensorflow-model-server-infer.py
```

您的輸出看起來應如以下所示：

```
[[('n02123045', 'tabby', 0.6918919), ('n02127052', 'lynx', 0.12770271), ('n02123159',
 'tiger_cat', 0.08277027), ('n02124075', 'Egyptian_cat', 0.06418919), ('n02128757',
 'snow_leopard', 0.009290541)]]
```

使用 MXNET 神經元和神經元編譯器 AWS

MXNET 神經元編譯 API 提供了一種方法來編譯可在推論裝置上執行的模型圖形。 AWS

在此範例中，您可以使用 API 編譯 ResNet -50 模型，並使用它來執行推論。

有關神經元 SDK 的更多信息，請參閱AWS 神經元 SDK 文檔。

目錄

必要條件

在使用本教學課程之前，您應該已完成 啟動含有神經元的 DLAMI 執行個體 AWS 中的設置步驟。您還應該熟悉深度學習和 DLAMI 的使用。

啟動 Conda 環境

使用以下命令啟動 MXNet-Neuron conda 環境：

```
source activate aws_neuron_mxnet_p36
```

若要退出目前的 conda 環境，請執行：

```
source deactivate
```

Resnet50 編譯

建立一個叫做 **mxnet_compile_resnet50.py** 的 Python 指令碼，具有以下內容。此指令碼使用 MXNET 神經元編譯 Python API 來編譯 -50 模型。 ResNet

```
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)
```

使用下列命令編譯模型：

```
python mxnet_compile_resnet50.py
```

編譯將需要幾分鐘的時間。 編譯完成後，下列檔案將位於您目前的目錄中：

```
resnet-50-0000.params
resnet-50-symbol.json
compiled_resnet50-0000.params
compiled_resnet50-symbol.json
```

ResNet五十推論

建立一個叫做 `mxnet_infer_resnet50.py` 的 Python 指令碼，具有以下內容。此指令碼會下載範例影像，並使用它來執行具有已編譯模型的推論。

```
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]))
```

使用以下命令，以編譯模型執行推斷：

```
python mxnet_infer_resnet50.py
```

您的輸出看起來應如以下所示：

```
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
```

後續步驟

使用 MXNet-Neuron 模型服務

使用 MXNet-Neuron 模型服務

在本教學課程中，您將學習如何使用預先培訓的 MXNet 模型來執行多模型伺服器 (MMS) 的即時影像分類。MMS 是一種靈活的 easy-to-use 工具，可提供使用任何機器學習或深度學習架構訓練的深度學習模型。本教學課程包含使用 AWS 神經元的編譯步驟，以及使用 MXNet 實作的 MMS。

有關神經元 SDK 的更多信息，請參閱AWS 神經元 SDK 文檔。

目錄

必要條件

在使用本教學課程之前，您應該已完成 啟動含有神經元的 DLAMI 執行個體 AWS 中的設置步驟。您還應該熟悉深度學習和 DLAMI 的使用。

啟動 Conda 環境

使用以下命令啟動 MXNet-Neuron conda 環境：

```
source activate aws_neuron_mxnet_p36
```

若要退出目前的 conda 環境，請執行：

```
source deactivate
```

下載範例程式碼

若要執行此範例，請使用下列命令下載範例程式碼：

```
git clone https://github.com/awslabs/multi-model-server
cd multi-model-server/examples/mxnet_vision
```

編譯模型

建立一個叫做 `multi-model-server-compile.py` 的 Python 指令碼，具有以下內容。該腳本將 ResNet 50 模型編譯為推論設備目標。

```
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)
```

若要編譯模型，請使用下列命令：

```
python multi-model-server-compile.py
```

您的輸出看起來應如以下所示：

```
...
[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!
```

建立一個叫做 `signature.json` 的檔案，具有以下內容，以設定輸入名稱和形狀：

```
{
  "inputs": [
    {
      "data_name": "data",
      "data_shape": [
        1,
        3,
        224,
        224
      ]
    }
  ]
}
```

您可以使用下列命令來下載 `synset.txt` 檔案。此檔案是 ImageNet 預測類別的名稱清單。

```
curl -O https://s3.amazonaws.com/model-server/model_archive_1.0/examples/
squeezenet_v1.1/synset.txt
```

按照 model_server_template 資料夾中的範本建立自訂服務類別。使用下列命令將範本複製到目前的工作目錄：

```
cp -r ../model_service_template/* .
```

編輯 mxnet_model_service.py 模組，將 mx.cpu() 內容取代為 mx.neuron() 內容，如下所示。您還需要將 model_input 所使用、不必要的資料副本註釋掉，因為 MXNet-Neuron 不支援 NDArray 和 Gluon API。

```
...
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]
```

使用下列指令，以模型歸檔程式封裝模型：

```
cd ~/multi-model-server/examples
model-archiver --force --model-name resnet-50_compiled --model-path mxnet_vision --
handler mxnet_vision_service:handle
```

執行推論

啟動多模型伺服器，並使用下列命令載入使用 RESTful API 的模型。請確認 neuron-rtd 是以預設設定執行。

```
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
```

以下列命令使用範例影像執行推論：

```
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
```

您的輸出看起來應如以下所示：

```
[
  {
    "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"
  }
]
```

若要在測試之後進行清理，請透過 RESTful API 發出 delete 命令，並使用以下命令停止模型伺服器：

```
curl -X DELETE http://127.0.0.1:8081/models/resnet-50_compiled

multi-model-server --stop
```

您應該會看到下列輸出：

```
{
  "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
```

使用 PyTorch-神經元和神經元編譯器 AWS

PyTorch-Neuron 編譯 API 提供了一種方法來編譯您可以在 AWS 推論設備上運行的模型圖。

經過訓練的模型必須編譯至 Inferentia 目標，才能部署到 Inf1 執行個體上。以下教學課程編譯了 Torchvision ResNet 50 模型，並將其匯出為儲存的模組。 TorchScript 接著，即可使用此模型執行推論。

為了方便起見，本教學課程使用 Inf1 執行個體進行編譯和推論。實際上，您可以使用 c5 執行個體系列等其他執行個體類型來編譯模型。接著，您必須將已編譯的模型部署到 Inf1 推論伺服器。如需詳細資訊，請參閱AWS 神經元 PyTorch SDK 文件。

目錄

必要條件

在使用本教學課程之前，您應該已完成 啟動含有神經元的 DLAMI 執行個體 AWS 中的設置步驟。您還應該熟悉深度學習和 DLAMI 的使用。

啟動 Conda 環境

使用下列指令啟動 PyTorch-神經元控制環境：

```
source activate aws_neuron_pytorch_p36
```

若要退出目前的 conda 環境，請執行：

```
source deactivate
```

Resnet50 編譯

建立一個叫做 **pytorch_trace_resnet50.py** 的 Python 指令碼，具有以下內容。這個腳本使用 PyTorch-神經元編譯 Python API 來編譯一個 ResNet -50 模型。

> **Note**
>
> 在編譯火炬視覺模型時，您應該注意這些版本和火炬軟件包之間存在依賴關係。這些依賴規則可以通過 pip 進行管理。火炬視野 ==0.6.1 與火炬 ==1.5.1 版本相符，而火炬視野 ==0.8.2 與火炬 ==1.7.1 版本相符。

```
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")
```

執行編譯指令碼。

```
python pytorch_trace_resnet50.py
```

編譯將需要幾分鐘的時間。 編譯完成後，編譯後的模型將另存為`resnet50_neuron.pt`本地目錄中。

ResNet五十推論

建立一個叫做 **`pytorch_infer_resnet50.py`** 的 Python 指令碼，具有以下內容。此指令碼會下載範例影像，並使用它來執行具有已編譯模型的推論。

```
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) )
```

使用以下命令，以編譯模型執行推斷：

```
python pytorch_infer_resnet50.py
```

您的輸出看起來應如以下所示：

```
Top 5 labels:
 ['tiger', 'lynx', 'tiger_cat', 'Egyptian_cat', 'tabby']
```

《ARM64 DLAMI》

AWS ARM64 GPU DLAMI 的設計旨在為深度學習工作負載提供高效能和成本效益。具體而言，G5G 執行個體類型採用基於 ARM64 的 AWS Graviton2 處理器，該處理器是由基於建立 AWS 並針對客戶在雲端中執行工作負載的方式進行最佳化。 AWS ARM64 GPU DlamI 預先配置了碼頭工人，NVIDIA 碼頭，NVIDIA 驅動程序，CUDA，CuDNN，非 CCL，以及流行的機器學習框架，如和。 TensorFlow PyTorch

使用 G5G 執行個體類型，與具有 GPU 加速的 x86 型執行個體相比，您可以利用 Graviton2 的價格和效能優勢來部署 GPU 加速深度學習模型，成本大幅降低。

選擇一個 ARM64 DLAMI

使用您選擇的 ARM64 DLAMI 啟動 G5G 執行個體。

如需啟動 DLAMI 的 step-by-step 指示，請參閱啟動和設定 DLAMI。

如需最新的 ARM64 DLAMI 的清單，請參閱 DLAMI 的發行說明。

開始使用

下列主題向您展示如何開始使用 ARM64 DLAMI。

目錄

使用 ARM64 圖像處理器 PyTorch DLAMI

AWS Deep Learning AMI 已準備好與以 Am64 處理器為基礎的 GPU 搭配使用，並針對. PyTorch ARM64 GPU PyTorch DLAMI 包含一個預先設定PyTorch、TorchVision以及用TorchServe於深度學習訓練和推論使用案例的 Python 環境。

目錄

驗證 PyTorch Python 境

Connect 到您的 G5G 實例，並使用以下命令激活基本 Conda 環境：

```
source activate base
```

您的指令提示字元應指出您正在基礎 Conda 環境中工作，其中包含 PyTorch TorchVision、和其他程式庫。

```
(base) $
```

驗證 PyTorch 環境的預設刀具路徑：

```
(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)
```

運行訓練示例 PyTorch

執行 MNIST 訓練工作範例：

```
git clone https://github.com/pytorch/examples.git
cd examples/mnist
python main.py
```

您的輸出應該類似以下內容：

```
...
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%)
```

執行推論範例 PyTorch

使用下列指令來下載預先訓練的 densenet161 模型，並使用下列方式執行推論： 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
```

您的輸出應該類似以下內容：

```
{
  "tiger_cat": 0.4693363308906555,
  "tabby": 0.4633873701095581,
  "Egyptian_cat": 0.06456123292446136,
  "lynx": 0.0012828150065615773,
  "plastic_bag": 0.00023522898778133094
}
```

使用下列命令取消註冊 densenet161 模型並停止伺服器：

```
curl -X DELETE http://localhost:8081/models/densenet161/1.0
torchserve --stop
```

您的輸出應該類似以下內容：

```
{
  "status": "Model \"densenet161\" unregistered"
}
TorchServe has stopped.
```

Inference

本節提供如何使用 DLAMI 架構和工具執行推論的教學課程。

推論工具

- TensorFlow 服務

模型服務

以下是使用 Conda 在深度學習 AMI 上安裝的模型服務選項。按一下其中一個選項，了解如何使用它。

主題

- TensorFlow 服務
- TorchServe

TensorFlow 服務

TensorFlow Service 是適用於機器學習模型的彈性、高效能服務系統。

`tensorflow-serving-api`這是預先安裝了深度學習 AMI 與康達！您可以在 `~/examples/tensorflow-serving/` 找到訓練、匯出和提供 MNIST 模型服務的範例指令碼。

若要執行這些範例，請先使用 Conda 連線至您的深度學習 AMI，然後啟動 TensorFlow 環境。

```
$ source activate tensorflow2_p310
```

現在，將目錄變更到服務範例指令碼資料夾。

```
$ cd ~/examples/tensorflow-serving/
```

提供預先訓練的 Inception 模型

以下是您可以嘗試以提供像是 Inception 之不同模型的範例。作為一般規則，您需要一個可服務的模型和客戶端腳本已經下載到 DLAMI。

使用 Inception 模型提供及測試推論

1. 下載模型。

   ```
   $ curl -O https://s3-us-west-2.amazonaws.com/tf-test-models/INCEPTION.zip
   ```

2. Untar 模型。

   ```
   $ unzip INCEPTION.zip
   ```

3. 下載哈士奇的圖片。

```
$ curl -O https://upload.wikimedia.org/wikipedia/commons/b/b5/Siberian_Husky_bi-
eyed_Flickr.jpg
```

4. 啟動伺服器。請注意，若為 Amazon Linux，您必須將用於 model_base_path 的目錄從 /home/ubuntu 變更為 /home/ec2-user。

```
$ tensorflow_model_server --model_name=INCEPTION --model_base_path=/home/ubuntu/
examples/tensorflow-serving/INCEPTION/INCEPTION --port=9000
```

5. 當伺服器在前景執行時，您需要啟動另一個終端機工作階段才能繼續。打開一個新 TensorFlow 的終端並激活source activate tensorflow2_p310。然後，使用您慣用的文字編輯器來建立具有下列內容的指令碼。將其命名為 inception_client.py。此指令碼會以影像檔案名稱做為參數，並從預先訓練的模型取得預測結果。

```
from __future__ import print_function

import grpc
import tensorflow as tf
import argparse

from tensorflow_serving.apis import predict_pb2
from tensorflow_serving.apis import prediction_service_pb2_grpc

parser = argparse.ArgumentParser(
    description='TF Serving Test',
    formatter_class=argparse.ArgumentDefaultsHelpFormatter
)
parser.add_argument('--server_address', default='localhost:9000',
                    help='Tenforflow Model Server Address')
parser.add_argument('--image', default='Siberian_Husky_bi-eyed_Flickr.jpg',
                    help='Path to the image')
args = parser.parse_args()


def main():
  channel = grpc.insecure_channel(args.server_address)
  stub = prediction_service_pb2_grpc.PredictionServiceStub(channel)
  # Send request
  with open(args.image, 'rb') as f:
    # See prediction_service.proto for gRPC request/response details.
    request = predict_pb2.PredictRequest()
```

```
    request.model_spec.name = 'INCEPTION'
    request.model_spec.signature_name = 'predict_images'

    input_name = 'images'
    input_shape = [1]
    input_data = f.read()
    request.inputs[input_name].CopyFrom(
      tf.make_tensor_proto(input_data, shape=input_shape))

    result = stub.Predict(request, 10.0)  # 10 secs timeout
    print(result)

  print("Inception Client Passed")


if __name__ == '__main__':
  main()
```

6. 現在執行此指令碼，將伺服器位置和連接埠以及哈士奇相片的檔案名稱當做參數傳遞。

```
$ python3 inception_client.py --server=localhost:9000 --image Siberian_Husky_bi-
eyed_Flickr.jpg
```

訓練和提供 MNIST 模型

在本教學課程中，我們將匯出模型，然後在 tensorflow_model_server 應用程式中提供其服務。最後，您可以使用範例用戶端指令碼來測試模型伺服器。

執行指令碼，以便訓練和匯出 MNIST 模型。做為指令碼的唯一引數，您需要提供資料夾位置供其用來儲存模型。現在我們可以將它放在 mnist_model 中。指令碼會為您建立資料夾。

```
$ python mnist_saved_model.py /tmp/mnist_model
```

請耐心等待，因為指令碼可能需要一些時間才能提供輸出。當訓練完成且模型最後匯出時，您應該會看到下列項目：

```
Done training!
Exporting trained model to mnist_model/1
Done exporting!
```

下一個步驟是執行 tensorflow_model_server 以便提供匯出的模型做為服務。

```
$ tensorflow_model_server --port=9000 --model_name=mnist --model_base_path=/tmp/
mnist_model
```

提供用戶端指令碼給您測試伺服器。

若要測試，您需要開啟新的終端機視窗。

```
$ python mnist_client.py --num_tests=1000 --server=localhost:9000
```

更多功能和範例

如果您有興趣了解有關 TensorFlow 服務的更多信息，請查看TensorFlow 網站。

您也可以將 TensorFlow 服務與 Amazon Elastic Inference 一起使用。查看有關如何使用 Elastic Inference 與 TensorFlow 服務的指南以獲取更多信息。

TorchServe

TorchServe 是一種靈活的工具，可用於提供已從匯出的深度學習模型 PyTorch。 TorchServe 隨附與 Conda 的深度學習 AMI 一起預先安裝。

如需使用的詳細資訊 TorchServe，請參閱模型伺服器以取得 PyTorch文件。

主題

提供影像分類模型 TorchServe

本教學課程展示如何使用提供影像分類模型 TorchServe。它使用由 PyTorch提供的 DenseNet -161 模型。 伺服器執行後，會偵聽預測要求。當您上傳圖像（在這種情況下是小貓的圖像）時，服務器返回對模型進行培訓的類中的前 5 個匹配類的預測。

若要提供範例影像分類模型 TorchServe

1. 使用 Conda v34 或更新版本的深度學習 AMI Connect 到亞馬遜彈性運算雲端 (Amazon EC2) 執行個體。
2. 啟用`pytorch_p310`環境。

   ```
   source activate pytorch_p310
   ```
3. 克隆 TorchServe 存儲庫，然後創建一個目錄來存儲您的模型。

   ```
   git clone https://github.com/pytorch/serve.git
   ```

```
mkdir model_store
```

4. 使用模型歸檔器封存模型。extra-files參數使用TorchServe回購中的文件，因此如有必要，請更新路徑。 如需有關模型歸檔程式的詳細資訊，請參閱的火炬模型歸檔程式。 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. 執行 TorchServe 以啟動端點。添加> /dev/null安靜日誌輸出。

```
torchserve --start --ncs --model-store model_store --models densenet161.mar > /dev/
null
```

6. 下載小貓的圖像並將其發送到 TorchServe預測端點：

```
curl -O https://s3.amazonaws.com/model-server/inputs/kitten.jpg
curl http://127.0.0.1:8080/predictions/densenet161 -T kitten.jpg
```

預測端點返回 JSON 的預測類似於以下前五大預測，其中圖像的可能性為 47%，其中包含埃及貓的可能性為 46%，其次是 46% 的機會，它有一隻虎斑貓。

```
{
 "tiger_cat": 0.46933576464653015,
 "tabby": 0.463387668132782,
 "Egyptian_cat": 0.0645613968372345,
 "lynx": 0.0012828196631744504,
 "plastic_bag": 0.00023523058849200606
}
```

7. 完成測試後，停止服務器：

```
torchserve --stop
```

其他例子

TorchServe 有各種可以在 DLAMI 實例上運行的示例。您可以在 TorchServe專案儲存庫範例頁面上檢視它們。

更多信息

如需更多 TorchServe 文件，包括如何設 TorchServe定 Docker 和最新 TorchServe 功能，請參閱上 GitHub的 TorchServe 專案頁面。

升級您的 DLAMI

在這裡，您可以找到有關升級 DLAMI 的信息以及更新 DLAMI 軟件的提示。

主題

升級至新的 DLAMI 版本

DLAMI 的系統映像會定期更新，以利用新的深度學習架構版本、CUDA 和其他軟體更新，以及效能調整。如果您已經使用 DLAMI 一段時間，並且想要利用更新，則需要啟動新的執行個體。您也必須手動傳輸任何資料集、檢查點或其他寶貴的資料。相反地，您可以使用 Amazon EBS 保留您的資料，並將其附加到新的 DLAMI。利用這種方式，您可以經常升級，同時減少轉換資料所需的時間。

> **Note**
>
> 在 DLAMI 之間連接和移動 Amazon EBS 磁碟區時，您必須同時在相同的可用區域中同時擁有 DLAMI 和新磁碟區。

1. 使用 Amazon EC2 主控台建立新的 Amazon EBS 磁碟區。如需詳細指示，請參閱建立 Amazon EBS 磁碟區。
2. 將新建立的 Amazon EBS 磁碟區連接到現有的 DLAMI。如需詳細指示，請參閱附加 Amazon EBS 磁碟區。
3. 傳輸您的資料，例如資料集、檢查點和組態檔案。
4. 啟動一個 DLAMI。如需詳細指示，請參閱 啟動和設定 DLAMI。
5. 從舊的 DLAMI 中分離 Amazon EBS 卷。如需詳細指示，請參閱分離 Amazon EBS 磁碟區。
6. 將 Amazon EBS 磁碟區連接到您的新 DLAMI。依照步驟 2 的指示連接磁碟區。
7. 驗證新 DLAMI 上的數據可用後，請停止並終止舊的 DLAMI。如需詳細的清除說明，請參閱清除。

軟體更新的秘訣

有時，您可能需要手動更新 DLAMI 上的軟件。通常建議您使用 `pip` 來更新 Python 套件。您也應該使pip用在 Conda 的深度學習 AMI 上更新 Conda 環境中的套件。請參閱特定架構或軟體網站的升級和安裝說明。

> **Note**
>
> 我們無法保證套件更新會成功。嘗試在具有不相容相依性的環境中更新套件可能會導致失敗。在這種情況下，您應該聯繫庫維護者以查看是否可以更新軟件包依賴關係。或者，您可以嘗試以允許更新的方式修改環境。不過，這項修改可能意味著移除或更新現有套件，這表示我們無法再保證此環境的穩定性。

AWS Deep Learning AMI 隨附許多 Conda 環境以及許多預先安裝的套件。由於預先安裝的套件數量龐大，因此很難找到一組保證相容的套件。您可能會看到警告 「環境不一致，請仔細檢查包裝計劃」。DLAMI 可確保所有 DLAMI 提供的環境都正確無誤，但無法保證任何使用者安裝的套件都能正常運作。

接收有關新更新的通知

> **Note**
>
> AWS 深度學習 AMI 每週針對安全性修補程式提供發行節奏。雖然這些增量安全性修補程式可能未包含在官方版本說明中，系統仍會傳送發行通知。

每當發布新的 DLAMI 時，您都可以收到通知。通知將透過 Amazon SNS 並使用下列主題發布。

```
arn:aws:sns:us-west-2:767397762724:dlami-updates
```

發布新的 DLAMI 時，消息將在此處發布。AMI 的版本、中繼資料和地區 AMI ID 將包含在訊息中。

這些訊息可以使用幾種不同的方法來接收。我們建議您使用以下方法。

1. 開啟 Amazon SNS 主控台。
2. 如有必要，請在導覽列中將「 AWS 區域」變更為美國西部 (奧勒岡)。您必須選取您要訂閱之 SNS 通知的建立地區。

3. 在功能窗格中，選擇 [訂閱] > [建立訂閱]。
4. 針對 Create subscription (建立訂閱) 對話方塊，執行下列作業：
   a. 對於主題 ARN，請複製並粘貼以下 Amazon 資源名稱（ARN）：**arn:aws:sns:us-west-2:767397762724:dlami-updates**
   b. 對於協議，從中選擇一個 [Amazon SQS， AWS 密碼，電子郵件，電子郵件 JSON]
   c. 對於端點，請輸入您將用於接收通知的資源電子郵件地址或 Amazon 資源名稱 (ARN)。
   d. 選擇建立訂閱。
5. 您會收到一封包含主旨行AWS 通知-訂閱確認的確認電子郵件。開啟電子郵件並選擇 Confirm subscription (確認訂閱) 完成訂閱。

中的安全性 AWS Deep Learning AMI

雲安全 AWS 是最高的優先級。身為 AWS 客戶，您可以從資料中心和網路架構中獲益，該架構專為滿足對安全性最敏感的組織的需求而打造。

安全是 AWS 與您之間共同的責任。共同責任模型將其描述為雲端的安全性和雲端中的安全性：

- 雲端的安全性 — AWS 負責保護在 AWS 雲端中執行 AWS 服務的基礎架構。 AWS 還為您提供可以安全使用的服務。若要瞭解適用於 DLAMI 的法規遵循計劃，請參閱合規計劃AWS 服務範圍內的 AWS 服務範圍 (遵)。
- 雲端中的安全性 — 您的責任取決於您使用的 AWS 服務。您也必須對其他因素負責，包括資料的機密性、您公司的要求和適用法律和法規。

本文件可協助您瞭解如何在使用 DLAMI 時套用共同責任模型。下列主題說明如何設定 DLAMI 以符合安全性和合規性目標。您還將學習如何使用其他 AWS 服務來幫助您監控和保護 DLAMI 資源。

如需詳細資訊，請參閱 Amazon EC2 中的安全性。

主題

- 資料保護 AWS Deep Learning AMI
- 中的 Identity and Access Management AWS Deep Learning AMI
- 登錄和監控 AWS Deep Learning AMI
- 符合性驗證 AWS Deep Learning AMI
- 韌性在 AWS Deep Learning AMI
- 基礎架構安全 AWS Deep Learning AMI

資料保護 AWS Deep Learning AMI

AWS 共同責任模型適用於 AWS 深度學習 AMI 中的資料保護。如此模型中所述， AWS 負責保護執行所有 AWS 雲端. 您負責維護在此基礎設施上託管內容的控制權。您也同時負責所使用 AWS 服務 的安全組態和管理任務。如需資料隱私權的詳細資訊，請參閱資料隱私權常見問答集。如需有關歐洲資料保護的相關資訊，請參閱 AWS 安全性部落格上的 AWS 共同的責任模型和 GDPR 部落格文章。

基於資料保護目的，我們建議您使用 AWS IAM Identity Center 或 AWS Identity and Access Management (IAM) 保護 AWS 帳戶 登入資料並設定個別使用者。如此一來，每個使用者都只會獲得授與完成其任務所必須的許可。我們也建議您採用下列方式保護資料：

- 每個帳戶均要使用多重要素驗證 (MFA)。
- 使用 SSL/TLS 與 AWS 資源進行通訊。我們需要 TLS 1.2 並建議使用 TLS 1.3。
- 使用設定 API 和使用者活動記錄 AWS CloudTrail。
- 使用 AWS 加密解決方案以及其中的所有默認安全控制 AWS 服務。
- 使用進階的受管安全服務 (例如 Amazon Macie)，協助探索和保護儲存在 Amazon S3 的敏感資料。
- 如果您在透過命令列介面或 API 存取時需要經 AWS 過 FIPS 140-2 驗證的加密模組，請使用 FIPS 端點。如需有關 FIPS 和 FIPS 端點的更多相關資訊，請參閱聯邦資訊處理標準 (FIPS) 140-2 概觀。

我們強烈建議您絕對不要將客戶的電子郵件地址等機密或敏感資訊，放在標籤或自由格式的文字欄位中，例如名稱欄位。這包括當您使用控制台，API 或 SDK AWS 服務 使用 DLAMI 或 AWS 其他方式時。 AWS CLI您在標籤或自由格式文字欄位中輸入的任何資料都可能用於計費或診斷日誌。如果您提供外部伺服器的 URL，我們強烈建議請勿在驗證您對該伺服器請求的 URL 中包含憑證資訊。

中的 Identity and Access Management AWS Deep Learning AMI

AWS Identity and Access Management (IAM) 可協助管理員安全地控制 AWS 資源存取權。 AWS 服務 IAM 管理員控制哪些人可以驗證 (登入) 和授權 (具有權限) 以使用 DLAMI 資源。您可以使用 IAM AWS 服務 ，無需額外付費。

如需 Identity and Access Management 的詳細資訊，請參閱 Amazon EC2 中的 Identity and Access Management。

主題

- 使用身分來驗證
- 使用政策管理存取權
- IAM 搭配 Amazon EMR

使用身分來驗證

驗證是您 AWS 使用身分認證登入的方式。您必須以 IAM 使用者身分或假設 IAM 角色進行驗證 (登入 AWS)。 AWS 帳戶根使用者

您可以使用透過 AWS 身分識別來源提供的認證，以聯合身分識別身分登入。 AWS IAM Identity Center (IAM 身分中心) 使用者、貴公司的單一登入身分驗證，以及您的 Google 或 Facebook 登入資料都是聯合身分識別的範例。您以聯合身分登入時，您的管理員先前已設定使用 IAM 角色的聯合身分。當您使 AWS 用同盟存取時，您會間接擔任角色。

根據您的使用者類型，您可以登入 AWS Management Console 或 AWS 存取入口網站。如需有關登入的詳細資訊 AWS，請參閱《AWS 登入 使用指南》 AWS 帳戶中的如何登入您的。

如果您 AWS 以程式設計方式存取，請 AWS 提供軟體開發套件 (SDK) 和命令列介面 (CLI)，以使用您的認證以加密方式簽署要求。如果您不使用 AWS 工具，則必須自行簽署要求。如需使用建議的方法自行簽署請求的詳細資訊，請參閱 IAM 使用者指南中的簽署 AWS API 請求。

無論您使用何種身分驗證方法，您可能都需要提供額外的安全性資訊。例如， AWS 建議您使用多重要素驗證 (MFA) 來增加帳戶的安全性。如需更多資訊，請參閱 AWS IAM Identity Center 使用者指南中的多重要素驗證和 IAM 使用者指南中的在 AWS中使用多重要素驗證 (MFA)。

AWS 帳戶 根使用者

當您建立時 AWS 帳戶，您會從一個登入身分開始，該身分可完整存取該帳戶中的所有資源 AWS 服務和資源。此身分稱為 AWS 帳戶 root 使用者，可透過使用您用來建立帳戶的電子郵件地址和密碼登入來存取。強烈建議您不要以根使用者處理日常任務。保護您的根使用者憑證，並將其用來執行只能由根使用者執行的任務。如需這些任務的完整清單，了解需以根使用者登入的任務，請參閱《IAM 使用者指南》中的需要根使用者憑證的任務。

IAM 使用者和群組

IAM 使用者是您內部的身分，具 AWS 帳戶 有單一人員或應用程式的特定許可。建議您盡可能依賴暫時憑證，而不是擁有建立長期憑證 (例如密碼和存取金鑰) 的 IAM 使用者。但是如果特定使用案例需要擁有長期憑證的 IAM 使用者，建議您輪換存取金鑰。如需更多資訊，請參閱 IAM 使用者指南中的為需要長期憑證的使用案例定期輪換存取金鑰。

IAM 群組是一種指定 IAM 使用者集合的身分。您無法以群組身分簽署。您可以使用群組來一次為多名使用者指定許可。群組可讓管理大量使用者許可的程序變得更為容易。例如，您可以擁有一個名為 IAMAdmins 的群組，並給予該群組管理 IAM 資源的許可。

使用者與角色不同。使用者只會與單一人員或應用程式建立關聯，但角色的目的是在由任何需要它的人員取得。使用者擁有永久的長期憑證，但角色僅提供暫時憑證。如需進一步了解，請參閱IAM 使用者指南中的建立 IAM 使用者 (而非角色) 的時機。

IAM 角色

IAM 角色是您 AWS 帳戶 內部具有特定許可的身分。它類似 IAM 使用者，但不與特定的人員相關聯。您可以切換角色，在中暫時擔任 IAM 角色。 AWS Management Console 您可以透過呼叫 AWS CLI 或 AWS API 作業或使用自訂 URL 來擔任角色。如需使用角色的方法詳細資訊，請參閱 IAM 使用者指南中的使用 IAM 角色。

使用暫時憑證的 IAM 角色在下列情況中非常有用：

- 聯合身分使用者存取 — 如需向聯合身分指派許可，請建立角色，並為角色定義許可。當聯合身分進行身分驗證時，該身分會與角色建立關聯，並獲授予由角色定義的許可。如需有關聯合角色的相關資訊，請參閱 IAM 使用者指南中的為第三方身分提供者建立角色。如果您使用 IAM Identity Center，則需要設定許可集。為控制身分驗證後可以存取的內容，IAM Identity Center 將許可集與 IAM 中的角色相關聯。如需有關許可集的資訊，請參閱 AWS IAM Identity Center 使用者指南中的許可集。
- 暫時 IAM 使用者許可 – IAM 使用者或角色可以擔任 IAM 角色來暫時針對特定任務採用不同的許可。
- 跨帳戶存取權：您可以使用 IAM 角色，允許不同帳戶中的某人 (信任的主體) 存取您帳戶的資源。角色是授予跨帳戶存取權的主要方式。但是，對於某些策略 AWS 服務，您可以將策略直接附加到資源（而不是使用角色作為代理）。若要了解跨帳戶存取角色和以資源為基礎的政策之間的差異，請參閱 IAM 使用者指南中的 IAM 中的跨帳戶資源存取。
- 跨服務訪問 — 有些 AWS 服務 使用其他 AWS 服務功能。例如，當您在服務中進行呼叫時，該服務通常會在 Amazon EC2 中執行應用程式或將物件儲存在 Amazon Simple Storage Service (Amazon S3) 中。服務可能會使用呼叫主體的許可、使用服務角色或使用服務連結角色來執行此作業。
  - 轉寄存取工作階段 (FAS) — 當您使用 IAM 使用者或角色在中執行動作時 AWS，您會被視為主體。使用某些服務時，您可能會執行某個動作，進而在不同服務中啟動另一個動作。FAS 會使用主體呼叫的權限 AWS 服務，並結合要求 AWS 服務 向下游服務發出要求。只有當服務收到需要與其 AWS 服務 他資源互動才能完成的請求時，才會發出 FAS 請求。在此情況下，您必須具有執行這兩個動作的許可。如需提出 FAS 請求時的政策詳細資訊，請參閱《轉發存取工作階段》。
  - 服務角色 – 服務角色是服務擔任的 IAM 角色，可代表您執行動作。IAM 管理員可以從 IAM 內建立、修改和刪除服務角色。如需詳細資訊，請參閱 IAM 使用者指南中的建立角色以委派許可給 AWS 服務服務。
  - 服務連結角色 — 服務連結角色是連結至. AWS 服務服務可以擔任代表您執行動作的角色。服務連結角色會顯示在您的中， AWS 帳戶 且屬於服務所有。IAM 管理員可以檢視，但不能編輯服務連結角色的許可。
- 在 Amazon EC2 上執行的應用程式 — 您可以使用 IAM 角色來管理在 EC2 執行個體上執行的應用程式以及發出 AWS CLI 或 AWS API 請求的臨時登入資料。這是在 EC2 執行個體內儲存存取金鑰的較好方式。若要將 AWS 角色指派給 EC2 執行個體並提供給其所有應用程式，請建立連接至執行個體的執行個體設定檔。執行個體設定檔包含該角色，並且可讓 EC2 執行個體上執行的程式取得暫時憑證。如需詳細資訊，請參閱 IAM 使用者指南中的利用 IAM 角色來授予許可給 Amazon EC2 執行個體上執行的應用程式。

如需了解是否要使用 IAM 角色或 IAM 使用者，請參閱 IAM 使用者指南中的建立 IAM 角色 (而非使用者) 的時機。

使用政策管理存取權

您可以透 AWS 過建立原則並將其附加至 AWS 身分識別或資源來控制中的存取。原則是一個物件 AWS ，當與身分識別或資源相關聯時，會定義其權限。 AWS 當主參與者 (使用者、root 使用者或角色工作階段) 提出要求時，評估這些原則。政策中的許可決定是否允許或拒絕請求。大多數原則會 AWS 以 JSON 文件的形式儲存在中。如需 JSON 政策文件結構和內容的詳細資訊，請參閱 IAM 使用者指南中的 JSON 政策概觀。

管理員可以使用 AWS JSON 政策來指定誰可以存取哪些內容。也就是說，哪個主體在什麼條件下可以對什麼資源執行哪些動作。

預設情況下，使用者和角色沒有許可。若要授予使用者對其所需資源執行動作的許可，IAM 管理員可以建立 IAM 政策。然後，管理員可以將 IAM 政策新增至角色，使用者便能擔任這些角色。

IAM 政策定義該動作的許可，無論您使用何種方法來執行操作。例如，假設您有一個允許 `iam:GetRole` 動作的政策。具有該原則的使用者可以從 AWS Management Console AWS CLI、或 AWS API 取得角色資訊。

身分型政策

身分型政策是可以附加到身分 (例如 IAM 使用者、使用者群組或角色) 的 JSON 許可政策文件。這些政策可控制身分在何種條件下能對哪些資源執行哪些動作。若要了解如何建立身分類型政策，請參閱 IAM 使用者指南中的建立 IAM 政策。

身分型政策可進一步分類成內嵌政策或受管政策。內嵌政策會直接內嵌到單一使用者、群組或角色。受管理的策略是獨立策略，您可以將其附加到您的 AWS 帳戶. 受管政策包括 AWS 受管政策和客戶管理的策略。如需了解如何在受管政策及內嵌政策間選擇，請參閱 IAM 使用者指南中的在受管政策和內嵌政策間選擇。

資源型政策

資源型政策是連接到資源的 JSON 政策文件。資源型政策的最常見範例是 IAM 角色信任政策和 Amazon S3 儲存貯體政策。在支援資源型政策的服務中，服務管理員可以使用它們來控制對特定資源的存取權限。對於附加政策的資源，政策會定義指定的主體可以對該資源執行的動作以及在何種條件下執行的動作。您必須在資源型政策中指定主體。主參與者可以包括帳戶、使用者、角色、同盟使用者或。 AWS 服務

資源型政策是位於該服務中的內嵌政策。您無法在以資源為基礎的政策中使用 IAM 的 AWS 受管政策。

存取控制清單 (ACL)

存取控制清單 (ACL) 可控制哪些主體 (帳戶成員、使用者或角色) 擁有存取某資源的許可。ACL 類似於資源型政策，但它們不使用 JSON 政策文件格式。

Amazon S3 和 Amazon VPC 是支援 ACL 的服務範例。 AWS WAF如需進一步了解 ACL，請參閱 Amazon Simple Storage Service 開發人員指南中的存取控制清單 (ACL) 概觀。

其他政策類型

AWS 支援其他較不常見的原則類型。這些政策類型可設定較常見政策類型授予您的最大許可。

- 許可界限 – 許可範圍是一種進階功能，可供您設定身分型政策能授予 IAM 實體 (IAM 使用者或角色) 的最大許可。您可以為實體設定許可界限。所產生的許可會是實體的身分型政策和其許可界限的交集。會在 `Principal` 欄位中指定使用者或角色的資源型政策則不會受到許可界限限制。所有這類政策中的明確拒絕都會覆寫該允許。如需許可界限的詳細資訊，請參閱 IAM 使用者指南中的 IAM 實體許可界限。
- 服務控制策略（SCP）— SCP 是 JSON 策略，用於指定中組織或組織單位（OU）的最大權限。AWS Organizations AWS Organizations 是一種用於分組和集中管理您企業擁 AWS 帳戶 有的多個服務。若您啟用組織中的所有功能，您可以將服務控制政策 (SCP) 套用到任何或所有帳戶。SCP 限制成員帳戶中實體的權限，包括每個 AWS 帳戶根使用者帳戶。如需 Organizations 和 SCP 的詳細資訊，請參閱 AWS Organizations 使用者指南中的 SCP 運作方式。
- 工作階段政策 – 工作階段政策是一種進階政策，您可以在透過編寫程式的方式建立角色或聯合使用者的暫時工作階段時，作為參數傳遞。所產生工作階段的許可會是使用者或角色的身分型政策和工作階段政策的交集。許可也可以來自資源型政策。所有這類政策中的明確拒絕都會覆寫該允許。如需詳細資訊，請參閱 IAM 使用者指南中的工作階段政策。

多種政策類型

將多種政策類型套用到請求時，其結果形成的許可會更為複雜、更加難以理解。要了解如何在涉及多個政策類型時 AWS 確定是否允許請求，請參閱《IAM 使用者指南》中的政策評估邏輯。

IAM 搭配 Amazon EMR

您可以 AWS Identity and Access Management 搭配 Amazon EMR 來定義使用者、 AWS 資源、群組、角色和政策。您也可以控制這些使用者和角色可存取的 AWS 服務。

如需將 IAM 與 Amazon EMR 搭配使用的詳細資訊，請參閱 Amazon EMR 的 AWS Identity and Access Management。

登錄和監控 AWS Deep Learning AMI

您的 AWS Deep Learning AMI 執行個體隨附數個 GPU 監控工具，其中包括向 Amazon 報告 GPU 使用率統計資料的公用程式 CloudWatch。如需詳細資訊，請參閱 GPU 監控和最佳化及監控 Amazon EC2。

使用量追蹤

下列 AWS Deep Learning AMI 作業系統發行版包含可 AWS 收集執行個體類型、執行個體 ID、DLAMI 類型和作業系統資訊的程式碼。不會收集或保留 DLAMI 中使用的指令的相關資訊。不會收集或保留任何其他有關「DLAMI 宅重組」的資料。

- Ubuntu 16.04
- Ubuntu 18.04
- Ubuntu 20.04
- Amazon Linux 2

若要選擇退出 DLAMI 的使用狀況追蹤，請在啟動期間向 Amazon EC2 執行個體新增標籤。標籤應該使用關聯值設定為的鍵`OPT_OUT_TRACKING``true`。如需詳細資訊，請參閱標記您的 Amazon EC2 資源。

符合性驗證 AWS Deep Learning AMI

協力廠商稽核人員會評估其安全性與合規性， AWS Deep Learning AMI 做為多個 AWS 合規計畫的一部分。如需支援的合規計畫相關資訊，請參閱 Amazon EC2 的合規驗證。

如需特定規範計劃範圍內的 AWS 服務清單，請參閱合規計劃AWS 服務範圍方案)。如需一般資訊，請參閱AWS 規範計劃AWS。

您可以使用下載第三方稽核報告 AWS Artifact。如需詳細資訊，請參閱下載 AWS 人工因素下載人工因 Ar AWS 。

您在使用 DLAMI 時的合規責任取決於您資料的敏感性、公司的合規目標以及適用的法律和法規。AWS 提供下列資源以協助遵循法規：

- 安全與合規快速入門指南：這些部署指南討論架構考量，並提供在 AWS上部署以安全及合規為重心之基準環境的步驟。
- AWS 合規資源AWS — 此工作簿和指南集合可能適用於您的產業和所在地。

- 使用AWS Config 開發人員指南中的規則評估資源 — 此 AWS Config 服務會評估您的資源組態符合內部實務、產業準則和法規的程度。
- AWS Security Hub— 此 AWS 服務提供安全狀態的全面檢視，協助您檢查您 AWS 是否符合安全性產業標準和最佳做法。

韌性在 AWS Deep Learning AMI

AWS 全球基礎架構是圍繞區 AWS 域和可用區域建立的。 AWS 區域提供多個實體分離和隔離的可用區域，這些區域透過低延遲、高輸送量和高度備援的網路連線。透過可用區域，您可以設計與操作的應用程式和資料庫，在可用區域之間自動容錯移轉而不會發生中斷。可用區域的可用性、容錯能力和擴展能力，均較單一或多個資料中心的傳統基礎設施還高。

如需區域和可用區域的相關 AWS 資訊，請參閱AWS 全域基礎結構。

如需協助支援資料備援和備份需求相關功能的詳細資訊，請參閱 Amazon EC2 中的備援。

基礎架構安全 AWS Deep Learning AMI

的基礎設施安全性 AWS Deep Learning AMI 由 Amazon EC2 提供支援。如需詳細資訊，請參閱 Amazon EC2 中的基礎設施安全。

DLAMI 的重要變化

常見問答集

有什麼變化？

在二零二三年十一月十五日 AWS Deep Learning AMI （中文版）將會分為兩個不同的組別：

- 使用 Nvidia 專有驅動程序的 DLAM（支持 P3，P3DN，G3）。
- 使用 Nvidia 操作系統驅動程序的 DLAM（支持 G4DN，G5，P4，P5）。

因此，將為兩個類別中的每個類別建立新的 DLAMI，其中包含新名稱和新 AMI ID。這些 DLAMI 無法互換-即來自一個群組的 DLAMI 將不支援另一個群組支援的執行個體，例如支援 p5 的 DLAMI 將不支援 g3，反之亦然。

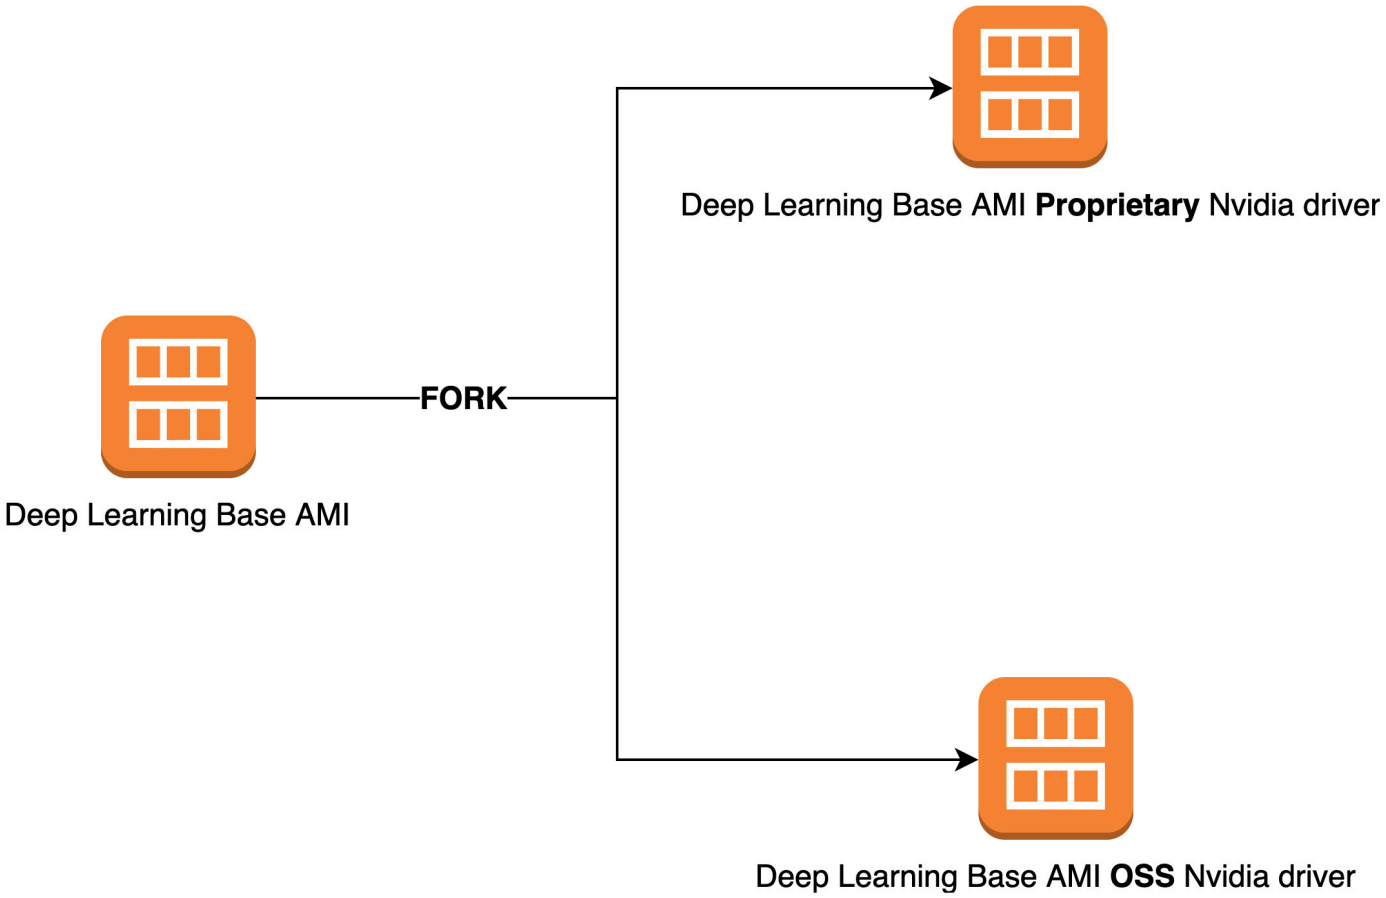

為什麼需要進行此更改？

目前用於 NVIDIA GPU 的 DLAMI 包括來自 NVIDIA 的專有內核驅動程序。不過，最近上游的 Linux 核心社群接受了一項變更，該變更會將專有核心驅動程式 (例如 NVIDIA GPU 驅動程式) 與其他核心驅動程式通訊隔離開來。這項變更會停用 P4/P5 系列執行個體上的 GPUDirect RDMA，這項機制可讓 GPU 有效地使用 EFA 進行分散式訓練。因此，DLAMI 將使用 OpenRM 驅動程序（NVIDIA 開源驅動程序），與開源的 EFA 驅動程序鏈接到支持 G4DN，G5，P4 和 P5。不過，這個 OpenRM 驅動程式不支援較舊的執行個體 (P3、G3 等) 因此，為了確保我們持續提供目前、高效能和安全的 DLAMI 支援這兩種類型的執行個體，我們會將 DLAMI 分成兩個群組-一個使用 OpenRM 驅動程式 (支援 G4dn、G5、P4 和 P5)，另一個使用較舊的專有驅動程式 (支援較舊的執行個體 P3、P3DN、G3)。

哪些 DLAM 會受到此變更的影響？

所有 DLAMI 都會受到此變更的影響。

這對你意味著什麼？

新的 DLAMI 將繼續提供目前 DLAMI 的功能、效能和安全性，只要它們是在相容的執行個體類型上執行。如果您使用 DLAMI，則需要確保在每個 DLAMI 的發行說明中提到的其中一個兼容實例上啟動 DLAMI（請參閱此處）。例如：您需要適應此變更，才能：

- 使用正確的 CLI 查詢呼叫 DLAMI (請參閱下文)
- 從主控台和 CLI 在相容的執行個體類型上啟動 DLAMI

如果您是從 EC2 主控台快速入門啟動 DLAMI：每個 DLAMI 說明都會列出 EC2 主控台支援的執行個體類型。您應該在相容的執行個體上啟動 DLAMI。

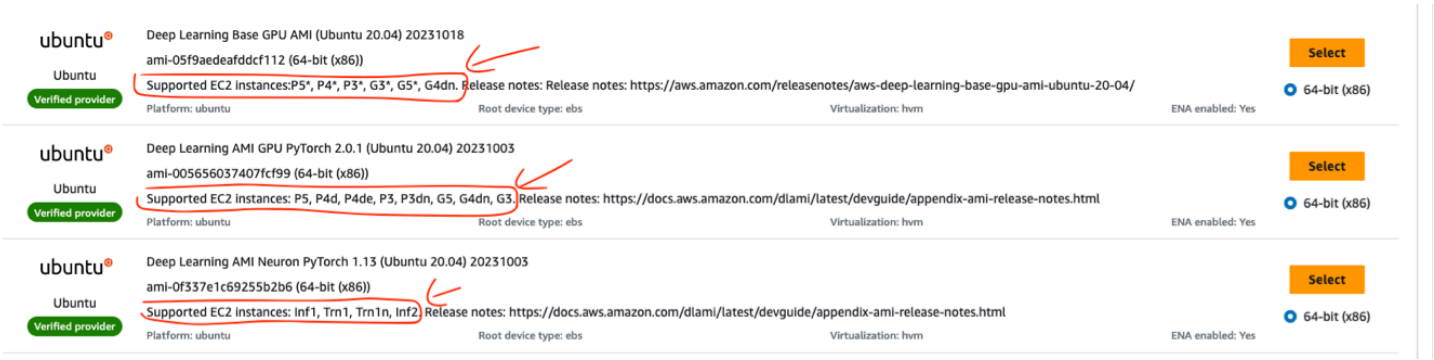

如果您使用 CLI 啟動 DLAMI，則必須修改您的查詢。例如：

目前，下列 CLI 查詢用於支援所有執行個體 [P3、P3dn、G3、G4 DN、G5、P4、P5] 的基礎 DLAMI：

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

新的 CLI 查詢將是：

對於支援 P3、P3dn 和 G3 的 DLAMI 本數位數據：

```
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
```

對於支援 G4 DN、G5、P4 和 P5 的基本數據：

```
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
```

請在這裡參閱新 AMI 的更新版本說明。如需如何在 EC2 執行個體上啟動 AMI，請參閱這裡的指示。

你應該什麼時候開始使用新的 DLAMI？

您應該儘快針對最新的架構、相依性、修補程式和功能開始使用新的 DLAMI。或者，如果您使用的是 2023 年 11 月 8 日之前發布的 Amazon Linux 2 DLAMI，那麼您可以選擇繼續實時修補他們的 DLAMI（請參閱此處的說明），直到 2023 年 11 月 30 日為止。

新的 DLAMI 會否有任何功能損失？

否，新的 DLAMI 不會損失任何功能。拆分後的新 DLAMI 將繼續提供舊 DLAMI 的所有功能，性能和安全性，只要它們是在兼容的實例上運行。我們將 DLAMI 分成兩個群組，以便繼續提供最新、高效能且安全的 DLAMI，供您在廣泛的執行個體上使用。

關於可攜式資料中心呢？

DLC 不包含 NVIDIA 驅動程式，因此它們不會受到此變更的影響。但是您應該確定 DLC 是在與基礎執行個體相容的 AMI 上執行。

相關資訊

主題

- 論壇
- 相關 部落格文章
- 常見問答集

論壇

- 論壇：AWS深度學習 AMI

相關 部落格文章

- 更新了與深度學習 AMI 相關的文章列表
- 啟動一個AWS Deep Learning AMI（在 10 分鐘內）
- 在 Amazon EC2 C5 和 P3 執行個體上使用最佳化 TensorFlow 1.6，加快訓練速度
- 適用於 Machine Learning 從業人員的新AWS深度學習 AMI
- 新推出的訓練課程：Machine Learning 與深度學習簡介AWS
- 深度學習之旅AWS

常見問答集

- 問：如何追蹤與 DLAMI 相關的產品公告？

  以下是兩個建議：

  - 將此部落格類別加入書籤，可在此找到「AWS深度學習 AMI」：更新深度學習 AMI 相關文章清單。
  - 「觀看」論壇：AWS深度學習 AMI
- 問：是否已安裝 NVIDIA 驅動程式和 CUDA？

  是。一些 DLAMI 有不同的版本。具使用康達的深度學習 AMI有任何 DLAMI 的最新版本。CUDA 安裝和架構連結中提供更多詳細資訊。您也可以參考特定 AMI 的版本說明，以確認已安裝的內容。

- 問：是否已安裝 CUDNN？

  是。

- 問：如何查看已偵測到 GPU 及其目前狀態？

  執行 `nvidia-smi`。這會顯示一個或多個 GPU (取決於執行個體類型) 及其目前的記憶體耗用量。

- 問：是否已為我設定虛擬環境？

  是，但僅限 使用康達的深度學習 AMI。

- 問：安裝的是什麼版本的 Python？

  每個 DLAMI 都有蟒蛇 2 和 3。使用康達的深度學習 AMI 對於每個架構版本都已具備環境。

- 問：是否已安裝 Keras？

  取決於 AMI。使用康達的深度學習 AMI 在每個架構的前端提供 Keras。Keras 版本取決於架構的支援。

- 問：它是免費的嗎？

  所有的 DLAMI 都是免費的。不過，取決於您選擇的執行個體類型，執行個體可能不是免費的。如需更多詳細資訊，請參閱特殊護理 DLAMI 價。

- 問：我收到架構中的 CUDA 錯誤或 GPU 相關訊息。怎麼回事？

  檢查您使用哪一種執行個體類型。它需有 GPU，許多範例和教學課程才能運作。如果執行中沒有`nvidia-smi`顯示 GPU，則您需要使用具有一或多個 GPU 的執行個體啟動另一個 DLAMI。如需更多詳細資訊，請參閱選取 DLAMI 的例證類型。

- 問：我可以使用泊塢視窗嗎？

  自從使用 Conda 的深度學習 AMI 版本 14 以來，Docker 就已預先安裝。請注意，您需要在 GPU 執行個體上使用 nvidia-docker 來使用 GPU。

- 問：Linux 區域有哪些區域可供使用？

區域	代碼
美國東部 (俄亥俄)	us-east-2
美國東部 (維吉尼亞北部)	us-east-1
GovCloud	us-gov-west-1

區域	代碼
美國西部 (加利佛尼亞北部)	us-west-1
美國西部 (奧勒岡)	us-west-2
北京 (中國)	cn-north-1
寧夏 (中國)	cn-northwest-1
亞太區域 (孟買)	ap-south-1
亞太區域 (首爾)	ap-northeast-2
亞太區域 (新加坡)	ap-southeast-1
亞太區域 (雪梨)	ap-southeast-2
亞太區域 (東京)	ap-northeast-1
加拿大 (中部)	ca-central-1
歐洲 (法蘭克福)	eu-central-1
歐洲 (愛爾蘭)	eu-west-1
歐洲 (倫敦)	eu-west-2
歐洲 (巴黎)	eu-west-3
南洲 (聖保羅)	sa-east-1

- 問：視窗 DLAM 在哪些區域可供使用？

區域	代碼
美國東部 (俄亥俄)	us-east-2
美國東部 (維吉尼亞北部)	us-east-1

區域	代碼
GovCloud	us-gov-west-1
美國西部 (加利佛尼亞北部)	us-west-1
美國西部 (奧勒岡)	us-west-2
北京 (中國)	cn-north-1
亞太區域 (孟買)	ap-south-1
亞太區域 (首爾)	ap-northeast-2
亞太區域 (新加坡)	ap-southeast-1
亞太區域 (雪梨)	ap-southeast-2
亞太區域 (東京)	ap-northeast-1
加拿大 (中部)	ca-central-1
歐洲 (法蘭克福)	eu-central-1
歐洲 (愛爾蘭)	eu-west-1
歐洲 (倫敦)	eu-west-2
歐洲 (巴黎)	eu-west-3
南洲 (聖保羅)	sa-east-1

特拉米的發行公告

> **Note**
>
> AWS Deep Learning AMI每晚有安全性修補程式的發行節奏。這些增量安全性修補程式不包含在官方發行說明中。

請參考 DLAMI Support 原則頁面，瞭解任何不受支援的架構版本說明。

基地 DLAMI

GPU

- X86
  - AWS 深度學習基礎 AMI (Amazon Linux 2)
  - AWS 深度學習基礎 AMI
  - AWS 深度學習基礎 AMI
- ARM64
  - AWS 深度學習基礎系統 ARM64 AMI
  - AWS 深度學習基礎 ARM64 AMI (Amazon 亞馬遜 2)

AWS 神经元

- X86
  - AWS 深度學習基礎 AMI 神經元 (Amazon Linux 2)
  - AWS 深度學習基礎 AMI 經元

高通公司

- X86
  - AWS 深度學習基礎高通 AMI（Amazon Linux 2）

單框架 DLAMI

PyTorch特定 AMI

GPU

- X86
  - AWS 深度學習網路 GPU PyTorch 2.3
  - AWS 深度學習 AMI GPU PyTorch 2.3 (Amazon Linux 2)
  - AWS 深度學習網路 GPU PyTorch 2.2
  - AWS 深度學習 AMI GPU PyTorch 2.2 (Amazon Linux 2)
  - AWS 深度學習 AMI GPU PyTorch 1.13 (Amazon Linux 2)
  - AWS 深度學習 AMI GPU PyTorch
- ARM64
  - AWS 深度學習 ARM64 網路 GPU 介面卡 PyTorch 2.3
  - AWS 深度學習 ARM64 網路 GPU 介面卡 PyTorch 2.2

AWS 神经元

- X86
  - AWS 深度學習 AMI 神經元 PyTorch 1.13 (Amazon Linux 2)
  - AWS 深度學習 AMI 神經元 PyTorch

TensorFlow特定 AMI

GPU

- X86
  - AWS 深度學習 AMI GPU TensorFlow 2.16 (Amazon Linux 2)
  - AWS 深度學習網路 GPU TensorFlow 2.16
  - AWS 深度學習 AMI GPU TensorFlow 2.15 (Amazon Linux 2)
  - AWS 深度學習 AMI GPU TensorFlow
  - AWS 深度學習 AMI GPU TensorFlow 2.13 (Amazon Linux 2)
  - AWS 深度學習 AMI GPU TensorFlow

AWS 神经元

- X86
  - AWS 深度學習 AMI 神經元 TensorFlow 2.10 (Amazon Linux 2)
  - AWS 深度學習 AMI 神經元 TensorFlow

多框架

> **Note**
>
> 如果您只使用一個機器學習架構，我們建議您使用 單框架 DLAMI

GPU

- X86
  - AWS 深度學習 AMI (Amazon 2)

AWS 神经元

- X86
  - AWS 深度學習 AMI 經元

DLAMI 的通知

下表列出 AWS Deep Learning AMI 中已取代的功能的相關資訊。

已取代的功能	取代日期	取代通知
Ubuntu 16.04	10/07/2021	Ubuntu Linux 16.04 LTS 於 2021 年 4 月 30 日達到了其五年 LTS 窗口的結束，並且不再受其供應商的支持。截至 2021 年 10 月，新版本中已不再對深度學習基礎 AMI (Ubuntu 16.04) 進行更新。以前的版本將繼續可用。
Amazon Linux	10/07/2021	亞馬遜 Linux 是end-of-life截至 2020 年十二月的資料。截至 2021 年 10 月，新版本中不再有深度學習 AMI（亞馬遜 Linux）的更新。舊版本的 AMI (Amazon Linux) 將繼續用的舊版本。
Chainer	2020/7/1	Chainer 已宣布自 2019 年 12 月起終止主要版本。因此，從 2020 年 7 月開始，我們將不再在 DLAMI 上包含 Chainer Conda 環境。包含這些環境的舊版 DLAMI 將繼續提供。只有在有由開放原始碼社群針對這些架構發佈的安全性修正時，我們才會提供這些環境的更新。
Python 3.6	2020/6/15	由於客戶請求，針對新的 TF/MX/PT 版本，我們即將移轉至 Python 3.7。

已取代的功能	取代日期	取代通知
Python 2	2020/1/1	Python 開放原始碼社群已正式終止支援 Python 2。 TensorFlow PyTorch, 和 MXNet 社群也宣布，TensorFlow 1.15、TensorFlow 2.1、 PyTorch 1.4 和 MXNet 1.6.0 版本將是最後一個支援 Python 2 的版本。

AWS Deep Learning AMI 開發人員指南的文件歷史

變更	描述	日期
ARM64 DLAMI	AWS Deep Learning AMI 現在支援以 Am64 處理器為基礎的 GPU 上的影像。	2021 年 11 月 29 日
TensorFlow 2	與康達的深度學習 AMI 現在隨附 TensorFlow 2 與 CUDA 10。	2019 年 12 月 3 日
AWS 推論	深度學習 AMI 現在支援 AWS 推論硬體和 AWS 神經元 SDK。	2019 年 12 月 3 日
搭配成立模型使用 TensorFlow 服務	針對「Elastic Inference」和「彈性推論」的「 TensorFlow 服務」新增了一個將推論與 Inception 模型搭配使用的範例。	2018 年 11 月 28 日
Elastic Inference	已在安裝指南中加入彈性的推論事前準備和相關資訊。	2018 年 11 月 28 日
PyTorch 從夜間構建安裝	已新增教學課程，內容涵蓋如何解除安裝 PyTorch，然後使用 Conda 在深度學習 AMI PyTorch 上安裝夜間組建。	2018 年 9 月 25 日
泊塢窗現在已預先安裝在您的 DLAMI 上	自從 14 版的深度學習 AMI 與孔達，碼頭工人和 NVIDIA 的 GPU 泊塢窗版本已預先安裝。	2018 年 9 月 25 日
康達教程	範例 MOTD 已更新，以反映較新版本。	2018 年 7 月 23 日

舊版更新：

下表說明 2018 年 7 月 AWS Deep Learning AMI 之前每個發行版本中的重要變更。

變更	描述	日期
TensorFlow 與霍洛沃德	新增了與霍洛沃德一 ImageNet 起 TensorFlow 訓練的教學課程。	2018 年 6 月 6 日
升級指南	新增升級指南。	2018 年 5 月 15 日
新的區域和新的 10 分鐘教學課程	新增新的區域：美國西部 (加州北部)、南美洲、加拿大 (中部)、歐洲 (倫敦) 和歐洲 (巴黎)。此外，10 分鐘教學課程的第一個版本標題為：「深度學習 AMI 入門」。	2018 年 4 月 26 日
Chainer 教學課程	新增在多重 GPU、單一 GPU 和 CPU 模式中使用 Chainer 的教學課程。CUDA 整合已從 CUDA 8 升級到 CUDA 9，適用於數個架構。	2018 年 2 月 28 日
Linux AMI 版本 3.0 版，以及 MXNet 模型伺服器、TensorFlow 服務和 TensorBoard	針對 Conda AMI 新增教學課程，其中包含使用 MXNet 模型伺服器 v0.1.5、服務 v1.4.0 和 v0.4.0 的新模型和視覺化服 TensorFlow 務功能。 TensorBoard Conda 和 CUDA 概觀中描述 AMI 和架構 CUDA 功能。最新版本備註移到 https://aws.amazon.com/releasenotes/	2018 年 1 月 25 日
Linux AMI v2.0	基礎、來源和 Conda AMI 更新為使用 NCCL 2.1。來源和康達 AMI 更新為 MXNet 1.0	2017 年 12 月 11 日

變更	描述	日期
	版、 PyTorch 0.3.0 和克拉斯 2.0.9。	
新增兩個 Windows AMI 選項	發佈Windows 2012 R2 和 2016 AMI：新增到 AMI 選購指南並新增到版本備註。	2017 年 11 月 30 日
初始文件版本	詳細描述變更，並提供已變更主題/章節的連結。	2017 年 11 月 15 日

AWS 詞彙表

如需最新的 AWS 術語，請參閱《AWS 詞彙表 參考》中的 AWS 詞彙表。

本文為英文版的機器翻譯版本，如內容有任何歧義或不一致之處，概以英文版為準。