



NetApp AIPod Mini for ERAG - 部署步驟

NetApp artificial intelligence solutions

NetApp
February 12, 2026

目錄

NetApp AIPOD Mini for ERAG - 部署步驟	1
假設：	1
先決條件	1
ERAG 2.0/2.0.1 部署步驟	1
1.從 GitHub 拉取 Enterprise RAG 2.0 版本	1
2.安裝必備組件	2
3.建立 inventory 檔案	2
4.為每個節點設定免密碼 SSH	3
5.驗證連線能力	3
6.編輯 config.yaml 檔案	4
7.部署 K8s 叢集（使用 Trident）	4
8.變更 iwatch 開啟描述元的數量	5
9.安裝 kubectl	5
10.在 Kubernetes 叢集中安裝 MetalLB	5
11.設定 MetalLB	5
12.使用 FQDN、磁碟區存取模式、入口和 S3 詳細資料更新 config.yaml。	6
13.設定排程同步設定	7
14.部署 Enterprise RAG 2.0/2.0.1	8
15.建立 DNS 項目	8
16.存取 Enterprise RAG UI	9
故障排除指南	9
1.問題：Keycloak Helm 安裝衝突	9
2.問題：找不到 Trident Operator Helm Chart 版本	9

NetApp AIPod Mini for ERAG - 部署步驟

本文提供了一份全面的逐步指南，指導您如何部署 NetApp AIPod Mini for Enterprise RAG (ERAG) 2.0。它涵蓋了所有核心元件的端對端安裝和配置，包括 Kubernetes 平台、NetApp Trident 用於儲存編排，以及使用 ansible playbooks 建立的 ERAG 2.0 堆疊。除了部署工作流程之外，本文檔還包含一份專門的故障排除指南，其中記錄了安裝過程中遇到的常見問題、其根本原因以及建議的解決方案，以確保流暢可靠的部署體驗。



Sathish Thyagarajan、Michael Oglesby、Arpita Mahajan NetApp

假設：

- 部署使用者擁有足夠的權限來建立命名空間和安裝 Helm 圖表。
- Xeon 伺服器執行 Ubuntu 22.04。
- 所有 Xeon 伺服器都設定了相同的使用者名稱。
- DNS 管理存取權限可用。
- ONTAP 9.16 已部署，並配置了用於 S3 存取的 SVM。
- S3 儲存桶已建立並配置完成。

先決條件

安裝 Git、Python3.11 和 pip for Python3.11

在 Ubuntu 22.04 上：

```
add-apt-repository ppa:deadsnakes/ppa
apt update
apt upgrade
apt install python3.11
python3.11 --version
apt install python3.11-pip
python3.11 -m pip --version
```

ERAG 2.0/2.0.1 部署步驟

1.從 GitHub 拉取 Enterprise RAG 2.0 版本

```
git clone https://github.com/oapea-project/Enterprise-RAG.git
cd Enterprise-RAG/
git checkout tags/release-2.0.0
```

對於 ERAG 2.0.1 、請使用下列命令

```
git checkout tags/release-2.0.1
```

2.安裝必備組件

```
cd deployment/
sudo apt-get install python3.11-venv
python3 -m venv erag-venv
source erag-venv/bin/activate
pip install --upgrade pip
pip install -r requirements.txt
ansible-galaxy collection install -r requirements.yaml --upgrade
```

3.建立 inventory 檔案

```

cp -a inventory/sample inventory/<cluster-name>
vi inventory/<cluster-name>/inventory.ini
# Control plane nodes
kube-3 ansible_host=<control_node_ip_address>

# Worker nodes
kube-1 ansible_host=<worker_node1_ip_address>
kube-2 ansible_host=<worker_node2_ip_address>

# Define node groups
[kube_control_plane]
kube-1
kube-2
kube-3

[kube_node]
kube-1
kube-2

[etcd:children]
kube_control_plane

[k8s_cluster:children]
kube_control_plane
kube_node

# Vars
[k8s_cluster:vars]
ansible_become=true
ansible_user=<ssh_username>
ansible_connection=ssh

```

4.為每個節點設定免密碼 SSH

```
ssh-copy-id REMOTE_USER@MACHINE_IP
```

注意：如果使用部署節點部署 ERAG，請確保在部署節點上也配置了無密碼 SSH。

5.驗證連線能力

```
ansible all -i inventory/<cluster-name>/inventory.ini -m ping
```

注意：如果您的節點上未配置免密碼 sudo，則需要在此命令中新增 --ask-become-pass。使用 --ask-become

-pass 時，請務必確保每個節點上的 ssh 使用者密碼相同。

6.編輯 config.yaml 檔案

編輯 inventory/<cluster-name>/config.yaml 以反映您的環境具體情況，準備部署。

```
vi inventory/<cluster-name>/config.yaml
```

範例片段：

```
...
deploy_k8s: true
...
install_csi: "netapp-trident"
...
local_registry: false
...
trident_operator_version: "2510.0"      # Trident operator version (becomes
100.2506.0 in Helm chart)
trident_namespace: "trident"            # Kubernetes namespace for Trident
trident_storage_class: "netapp-trident" # StorageClass name for Trident
trident_backend_name: "ontap-nas"       # Backend configuration name
...
ontap_management_lif: "<ontap_mgmt_lif>"      # ONTAP management
LIF IP address
ontap_data_lif: "<ontap_nfs_data_lif>"        # ONTAP data LIF
IP address
ontap_svm: "<ontap_svm>"                      # Storage Virtual Machine
(SVM) name
ontap_username: "<ontap_username>"           # ONTAP username
with admin privileges
ontap_password: "<redacted>"                  # ONTAP password
ontap_aggregate: "<ontap_aggr>"              # ONTAP aggregate name
for volume creation
...
kubeconfig: "<repository path>/deployment/inventory/<cluster-
name>/artifacts/admin.conf"
...
```

7.部署 K8s 叢集（使用 Trident）

使用 configure 和 install 標籤執行 ansible-playbook playbooks/infrastructure.yaml 來部署叢集和 Trident CSI。

```
ansible-playbook playbooks/infrastructure.yaml --tags configure,install -i
inventory/<cluster-name>/inventory.ini -e @inventory/<cluster-
name>/config.yaml
```

注意：- 如果您的節點上未設定免密碼 `sudo`，則需要將 `--ask-become-pass` 新增至此命令。使用 `--ask-become-pass` 時，請務必確保每個節點上的 `ssh` 使用者密碼相同。- 有關詳細資訊，請參閱 ["NetApp Trident CSI 整合，適用於企業 RAG"](#)。有關更多詳細資訊，請參閱 ["Trident 安裝文檔"](#)。

8. 變更 `iwatch` 開啟描述元的數量

詳情請參閱 ["iwatch 開放式描述符"](#)。

9. 安裝 `kubectl`

如果尚未安裝，請參閱 ["安裝 Kubectl"](#)。從 `<repository path>/deployment/inventory/<cluster-name>/artifacts/admin.conf` 擷取 `kubeconfig` 檔案。

10. 在 Kubernetes 叢集中安裝 MetalLB

在 Kubernetes 叢集上使用 Helm 安裝 MetalLB。

```
helm repo add metallb https://metallb.github.io/metallb
helm -n metallb-system install metallb metallb/metallb --create-namespace
```

詳情請參閱 ["MetalLB 安裝"](#)。

11. 設定 MetalLB

MetalLB 已設定為第 2 層模式，並根據文件化的組態準則建立了所需的 `IPAddressPool` 和 `L2Advertisement` 資源。

```
vi metallb-ipaddrpool-l2adv.yaml
kubectl apply -f metallb-ipaddrpool-l2adv.yaml
```

範例片段：

```

vi metallb-ipaddrpool-l2adv.yaml
---
apiVersion: metallb.io/v1beta1
kind: IPAddressPool
metadata:
  name: erag
  namespace: metallb-system
spec:
  addresses:
  - <IPAddressPool>
---
apiVersion: metallb.io/v1beta1
kind: L2Advertisement
metadata:
  name: metallb-l2adv
  namespace: metallb-system

```

注意：- 使用 metallb-system 作為 MetallB IPAddressPool 和 L2Advertisement 的命名空間。- IP 位址池可以包含與 Kubernetes 節點位於相同子網路內的任何未使用的 IP 位址。ERAG 只需要一個 IP 位址。- 詳情請參閱 ["MetalLB Layer2 配置"](#)。

12. 使用 FQDN、磁碟區存取模式、入口和 S3 詳細資料更新 config.yaml。

修改位於 inventory/<cluster-name>/config.yaml 的 config.yaml 檔案，以定義部署 FQDN、設定磁碟區存取模式、設定 ingress 曝光並整合 ONTAP S3。

編輯 config.yaml 並套用以下配置變更：

- FQDN：指定用於存取部署的完整網域名稱。
- 磁碟區存取模式：在 gmc.pvc 部分下，設定 accessMode: ReadWriteMany 以支援跨多個 pod 對模型磁碟區的並行存取。
- Ingress 設定：將 ingress service_type 設定為 LoadBalancer 以允許外部存取應用程式。
- S3 儲存詳情：設定 storageType 為 s3compatible 並配置 ONTAP S3 參數，包括區域、存取憑證、內部和外部端點。
- SSL 憑證驗證：僅當 ONTAP S3 配置為使用自簽名憑證時，才將 edpInternalCertVerify 和 edpExternalCertVerify 設為 false。如果憑證由受公共信任的 CA 頒發，則應保持啟用這些參數。

範例片段：

```

vi inventory/<cluster-name>/config.yaml
...
FQDN: "<FQDN>" # Provide the FQDN for the deployment
...
gmc:
  enabled: true
  pvc:
    accessMode: ReadWriteMany # AccessMode
  models:
    modelLlm:
      name: model-volume-llm
      storage: 100Gi
    modelEmbedding:
      name: model-volume-embedding
      storage: 20Gi
    modelReranker:
      name: model-volume-reranker
      storage: 10Gi
...
ingress:
  ...
  service_type: LoadBalancer
  ...
edp:
  ...
  storageType: s3compatible
  ...
  s3compatible:
    region: "us-east-1"
    accessKeyId: "<your_access_key>"
    secretAccessKey: "<your_secret_key>"
    internalUrl: "https://<IP-address>"
    externalUrl: "https://<IP-address>"
    bucketNameRegexFilter: ".*"
    edpExternalCertVerify: false
    edpInternalCertVerify: false
  ...

```

注意：- 預設情況下，Intel® AI for Enterprise RAG 應用程式會從 SVM 中的所有現有儲存桶中擷取資料。如果您的 SVM 中有多個儲存桶，您可以修改 `bucketNameRegexFilter` 欄位，以便僅從特定儲存桶中提取資料。- 有關詳細資訊，請參閱 ["Intel® AI for Enterprise RAG 部署"](#) 文件。

13. 設定排程同步設定

安裝適用於 Intel® AI for Enterprise RAG 的 OPEA 應用程式時，請啟用 `scheduledSync`，以便應用程式自動從您的 S3 儲存桶中擷取新的或更新的檔案。

什麼時候 `scheduledSync` 啟用後，應用程式會自動檢查來源 S3 儲存桶中是否有新檔案或更新的檔案。在此同步過程中發現的任何新檔案或更新檔案都會自動提取並新增至 RAG 知識庫。應用程式根據預設的時間間隔檢查您的來源儲存桶。預設時間間隔為 60 秒，這表示應用程式每 60 秒檢查一次變更。您可能希望更改此間隔以滿足您的特定需求。

若要啟用 `scheduledSync` 並設定同步間隔，請在 `deployment/components/edp/values.yaml` 中設定以下值：

```
vi components/edp/values.yaml
...
presignedUrlCredentialsSystemFallback: "true"
...
celery:
  ...
  config:
    ...
    scheduledSync:
      enabled: true
      syncPeriodSeconds: "60"
  ...
```

14. 部署 Enterprise RAG 2.0/2.0.1

安裝前，請依照 ["Intel® AI 企業級 RAG 應用程式部署指南"](#) 中概述的步驟驗證基礎架構是否已準備好。此步驟可確保底層基礎架構配置正確，並滿足 Enterprise RAG Application 成功安裝所需的所有先決條件。

使用以下命令執行安裝：

```
ansible-playbook -u $USER playbooks/application.yaml --tags
configure,install -e @inventory/<cluster-name>/config.yaml
```

注意：如果您的部署節點（執行 ansible-playbook 指令的筆記型電腦或跳板機）上未設定免密碼 sudo，則需要將 `--ask-become-pass` 新增至此指令。使用 `--ask-become-pass` 時，請務必確保每個節點上的 ssh 使用者密碼相同。

15. 建立 DNS 項目

在您的 DNS 伺服器中為 Enterprise RAG Web 控制面板建立 DNS 項目。若要繼續，請擷取指派給 Enterprise RAG 入口 LoadBalancer 的外部 IP 位址：

```
kubectl -n ingress-nginx get svc ingress-nginx-controller
```

為步驟 12 中使用的 FQDN 建立指向此 IP 位址的 DNS 項目。

注意：- DNS 項目使用的 FQDN 必須與組態檔中的 FQDN 相符。

16.存取 Enterprise RAG UI

透過在瀏覽器中導覽至該 FQDN 來存取 Enterprise RAG UI。注意：您可以從 `cat ansible-logs/default_credentials.txt` 擷取預設 UI 憑證

故障排除指南

1.問題：Keycloak Helm 安裝衝突

場景：部署 ERAG 時，Keycloak 安裝可能會失敗，並出現以下錯誤：

```
FAILED - RETRYING: [localhost]: Install Keycloak Helm chart (5 retries left).  
Failure when executing Helm command. Exited 1.  
  stdout:  
  stderr: Error: UPGRADE FAILED: another operation  
(install/upgrade/rollback) is in progress
```

操作：如果重試後仍然失敗 - 卸載 ERAG 部署，使用以下命令刪除現有的 auth 命名空間，然後重新執行部署。

```
ansible-playbook playbooks/application.yaml --tags uninstall -e  
@inventory/<cluster-name>/config.yaml  
  
helm -n auth uninstall keycloak  
kubectl -n auth get pvc # confirm all PVCs are gone; if any are left,  
delete them  
kubectl delete ns auth
```

注意：過時的 Helm 版本狀態可能會阻止後續的安裝或升級作業。

2.問題：找不到 Trident Operator Helm Chart 版本

場景：在 ERAG 部署過程中，由於 Helm Chart 版本不匹配，Trident Operator 安裝可能會失敗。可能會出現以下錯誤：

```
TASK [netapp_trident_csi_setup : Install Trident operator via Helm]
fatal: [localhost]: FAILED! => changed=false
  command: /usr/local/bin/helm --version=100.2510.0 show chart 'netapp-
trident/trident-operator'
  msg: |-
    Failure when executing Helm command. Exited 1.
  stdout:
  stderr: Error: chart "trident-operator" matching 100.2510.0 not found
in netapp-trident index.
      (try 'helm repo update'): no chart version found for trident-
operator-100.2510.0
```

操作：如果發生此錯誤，請更新 Helm 儲存庫索引並重新執行部署 playbook。

```
helm repo update
ansible-playbook playbooks/application.yaml -e @inventory/<cluster-
name>/config.yaml
```

注意：這是 ERAG 2.0 版本中的已知問題。修復程式已提交，並將包含在未來版本中。

版權資訊

Copyright © 2026 NetApp, Inc. 版權所有。台灣印製。非經版權所有人事先書面同意，不得將本受版權保護文件的任何部分以任何形式或任何方法（圖形、電子或機械）重製，包括影印、錄影、錄音或儲存至電子檢索系統中。

由 NetApp 版權資料衍伸之軟體必須遵守下列授權和免責聲明：

此軟體以 NETAPP「原樣」提供，不含任何明示或暗示的擔保，包括但不限於有關適售性或特定目的適用性之擔保，特此聲明。於任何情況下，就任何已造成或基於任何理論上責任之直接性、間接性、附隨性、特殊性、懲罰性或衍生性損害（包括但不限於替代商品或服務之採購；使用、資料或利潤上的損失；或企業營運中斷），無論是在使用此軟體時以任何方式所產生的契約、嚴格責任或侵權行為（包括疏忽或其他）等方面，NetApp 概不負責，即使已被告知有前述損害存在之可能性亦然。

NetApp 保留隨時變本文所述之任何產品的權利，恕不另行通知。NetApp 不承擔因使用本文所述之產品而產生的責任或義務，除非明確經過 NetApp 書面同意。使用或購買此產品並不會在依據任何專利權、商標權或任何其他 NetApp 智慧財產權的情況下轉讓授權。

本手冊所述之產品受到一項（含）以上的美國專利、國外專利或申請中專利所保障。

有限權利說明：政府機關的使用、複製或公開揭露須受 DFARS 252.227-7013（2014 年 2 月）和 FAR 52.227-19（2007 年 12 月）中的「技術資料權利 - 非商業項目」條款 (b)(3) 小段所述之限制。

此處所含屬於商業產品和 / 或商業服務（如 FAR 2.101 所定義）的資料均為 NetApp, Inc. 所有。根據本協議提供的所有 NetApp 技術資料和電腦軟體皆屬於商業性質，並且完全由私人出資開發。美國政府對於該資料具有非專屬、非轉讓、非轉授權、全球性、有限且不可撤銷的使用權限，僅限於美國政府為傳輸此資料所訂合約所允許之範圍，並基於履行該合約之目的方可使用。除非本文另有規定，否則未經 NetApp Inc. 事前書面許可，不得逕行使用、揭露、重製、修改、履行或展示該資料。美國政府授予國防部之許可權利，僅適用於 DFARS 條款 252.227-7015(b)（2014 年 2 月）所述權利。

商標資訊

NETAPP、NETAPP 標誌及 <http://www.netapp.com/TM> 所列之標章均為 NetApp, Inc. 的商標。文中所涉及的所有其他公司或產品名稱，均為其各自所有者的商標，不得侵犯。