



## Apache Spark 任務效能調校 AWS Glue 的最佳實務



# : Apache Spark 任務效能調校 AWS Glue 的最佳實務

# Table of Contents

簡介 .....	1
關鍵主題 .....	2
架構 .....	2
彈性分散式資料集 .....	3
延遲評估 .....	4
Spark 應用程式術語 .....	5
平行處理 .....	6
Catalyst 最佳化工具 .....	7
調查效能問題 .....	9
使用 Spark UI 識別瓶頸 .....	9
調校效能的策略 .....	11
效能調校的基線策略 .....	11
Spark 任務效能的調校實務 .....	11
擴展叢集容量 .....	12
CloudWatch 指標 .....	12
Spark 使用者介面 .....	13
使用最新版本 .....	14
減少資料掃描量 .....	15
CloudWatch 指標 .....	15
Spark 使用者介面 .....	16
平行處理任務 .....	24
CloudWatch 指標 .....	24
Spark 使用者介面 .....	25
最佳化隨機播放 .....	29
CloudWatch 指標 .....	30
Spark 使用者介面 .....	30
將規劃開銷降至最低 .....	37
CloudWatch 指標 .....	38
Spark 使用者介面 .....	38
最佳化使用者定義的函數 .....	39
標準 Python UDF .....	40
向量化 UDF .....	41
Spark SQL .....	42
將 panda 用於大數據 .....	42

---

資源 .....	43
文件歷史紀錄 .....	44
詞彙表 .....	45
# .....	45
A .....	45
B .....	48
C .....	49
D .....	52
E .....	55
F .....	57
G .....	58
H .....	59
I .....	60
L .....	62
M .....	63
O .....	67
P .....	69
Q .....	71
R .....	71
S .....	74
T .....	77
U .....	78
V .....	78
W .....	79
Z .....	80
.....	lxxxi

# Apache Spark 任務效能調校 AWS Glue 的最佳實務

Roman Myers、Takashi Onikura 和 Noritaka Sekiyama , Amazon Web Services (AWS)

2023 年 12 月 ([文件歷史記錄](#))

AWS Glue 提供不同的調校效能選項。本指南定義了 Apache Spark AWS Glue 調校的關鍵主題。然後，它提供基準策略，供您 AWS Glue 在調校 Apache Spark 任務時遵循這些策略。使用本指南了解如何透過解譯 中可用的指標來識別效能問題 AWS Glue。然後整合策略來解決這些問題、將效能最大化並將成本降至最低。

本指南涵蓋下列調校實務：

- [擴展叢集容量](#)
- [使用 AWS Glue 最新版本](#)
- [減少資料掃描量](#)
- [平行處理任務](#)
- [將規劃開銷降至最低](#)
- [最佳化隨機播放](#)
- [最佳化使用者定義的函數](#)

# Apache Spark 中的關鍵主題

本節說明用於調校 Apache Spark 效能 AWS Glue 的 Apache Spark 基本概念和關鍵主題。在討論真實世界調校策略之前，請務必了解這些概念和主題。

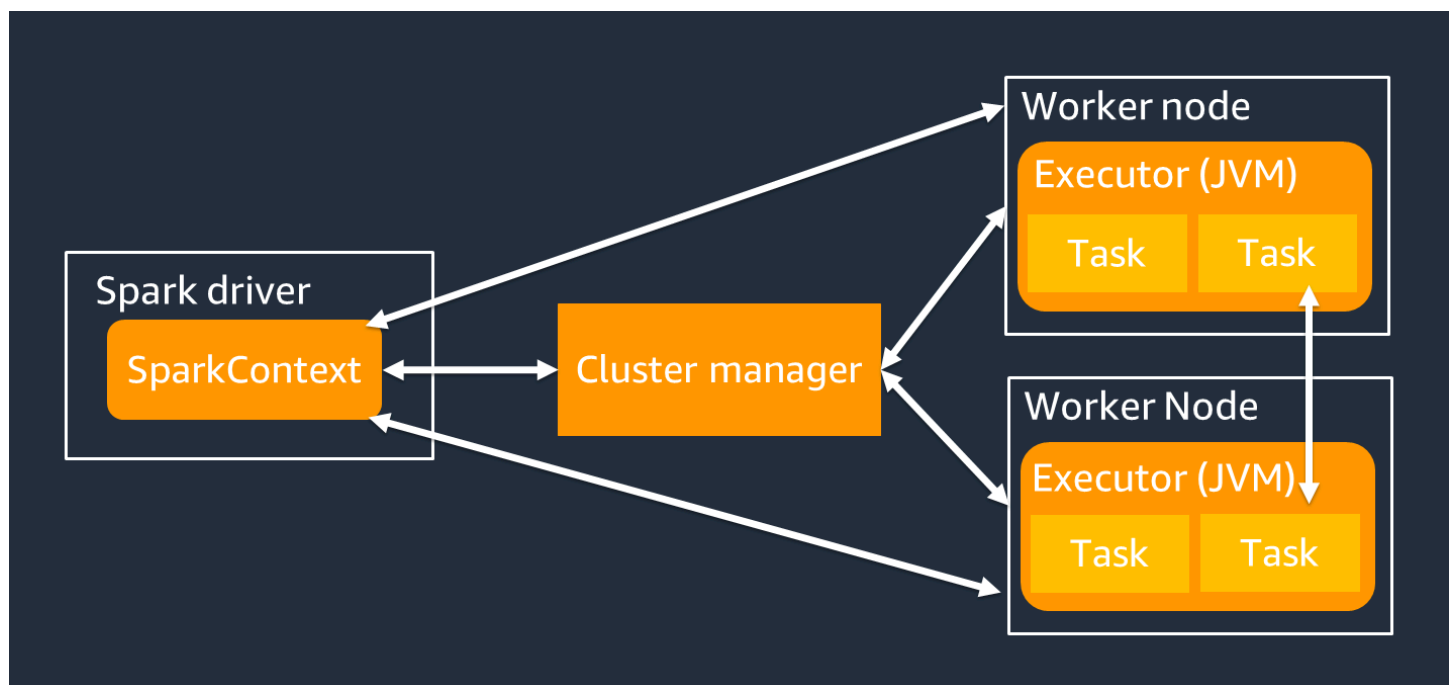
## 架構

Spark 驅動程式主要負責將您的 Spark 應用程式分割為可在個別工作者上完成的任務。Spark 驅動程式有下列責任：

- 在程式碼 `main()` 中執行
- 產生執行計畫
- 搭配叢集管理員佈建 Spark 執行器，以管理叢集上的資源
- 排程任務並請求 Spark 執行器的任務
- 管理任務進度和復原

您可以使用 `SparkContext` 物件來與 Spark 驅動程式互動，以進行任務執行。

Spark 執行器是一種工作者，用於保存從 Spark 驅動程式傳遞的資料和執行中的任務。Spark 執行器的數量會隨著叢集的大小而增加和減少。




**Note**

Spark 執行器具有多個槽，以便平行處理多個任務。根據預設，Spark 支援每個虛擬 CPU (vCPU) 核心一個任務。例如，如果執行器有四個 CPU 核心，則可以執行四個並行任務。

## 彈性分散式資料集

Spark 會執行複雜任務，以跨 Spark 執行器存放和追蹤大型資料集。當您編寫 Spark 任務的程式碼時，您不需要考慮儲存體的詳細資訊。Spark 提供彈性分散式資料集 (RDD) 抽象，這是可以平行操作的元素集合，並可分割叢集的 Spark 執行器。

下圖顯示 Python 指令碼在一般環境中執行時，以及在 Spark 架構 (PySpark) 中執行時，如何在記憶體中存放資料的差異。



- Python – 在 Python 指令碼 `val = [1,2,3...N]` 中寫入 會將資料保留在執行程式碼的單一電腦上的記憶體中。
- PySpark – Spark 提供 RDD 資料結構，以載入和處理分散在多個 Spark 執行器上的記憶體的資料。您可以使用 等程式碼產生 `RDD rdd = sc.parallelize[1,2,3...N]`，Spark 可以在多個 Spark 執行器之間自動分配和保留記憶體中的資料。

在許多 AWS Glue 任務中，您可以透過 DynamicFrames 和 Spark DataFrames 使用 RDDs AWS Glue。這些摘要可讓您定義 RDD 中的資料結構描述，並使用該額外資訊執行更高階的任務。由於它們在內部使用 RDDs，因此資料會以透明的方式分佈並載入到下列程式碼中的多個節點：

- DynamicFrame

```
dyf= glueContext.create_dynamic_frame.from_options(
    's3', {"paths": [ "s3://<YourBucket>/<Prefix>/" ]},
    format="parquet",
    transformation_ctx="dyf"
)
```

- DataFrame

```
df = spark.read.format("parquet")
    .load("s3://<YourBucket>/<Prefix>")
```

RDD 具有下列功能：

- RDDs由分成多個部分的資料組成，稱為分割區。每個 Spark 執行器都會在記憶體中存放一或多個分割區，而資料會分散到多個執行器。
- RDDs 是不可變的，這表示它們在建立之後無法變更。若要變更 DataFrame，您可以使用轉換，如下節所定義。
- RDDs會跨可用節點複寫資料，以便從節點故障中自動復原。

## 延遲評估

RDDs支援兩種類型的操作：從現有資料集建立新資料集的轉換，以及在資料集上執行運算後將值傳回驅動程式的動作。

- 轉換 – 由於 RDDs 不可變，因此您只能使用轉換來變更它們。

例如，map 是一種轉換，透過 函數傳遞每個資料集元素，並傳回代表結果的新 RDD。請注意，map方法不會傳回輸出。Spark 會存放未來的抽象轉換，而不是讓您與結果互動。在您呼叫動作之前，Spark 不會對轉換採取行動。

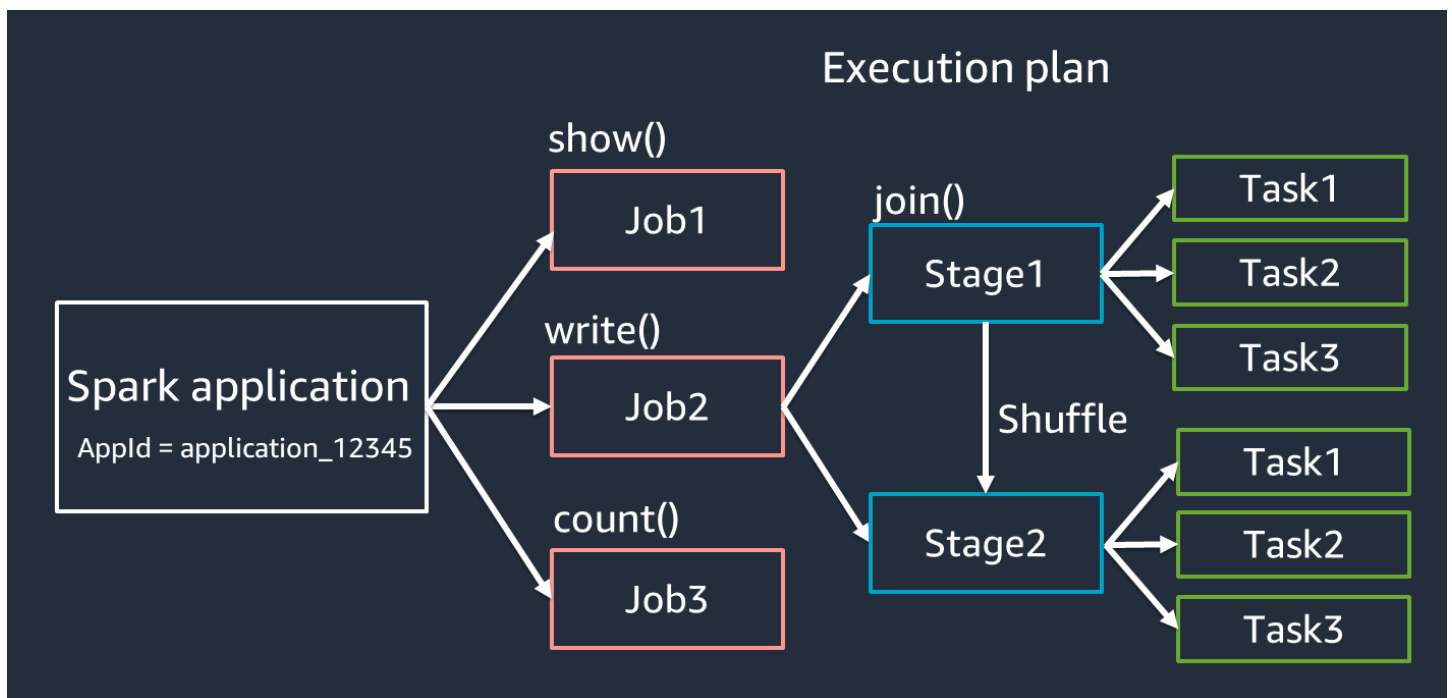
- 動作 – 使用轉換，您可以建立邏輯轉換計畫。若要啟動運算，請執行動作，例如 write、show、count 或 collect。

Spark 中的所有轉換都是延遲的，因為它們不會立即運算其結果。反之，Spark 會記住套用至某些基本資料集的一系列轉換，例如 Amazon Simple Storage Service (Amazon S3) 物件。只有在動作需要將結果傳回給驅動程式時，才會計算轉換。此設計可讓 Spark 更有效率地執行。例如，假設透過 map 轉換建立的資料集僅由大幅減少資料列數量的轉換耗用，例如 reduce。然後，您可以將經過兩個轉換的較小資料集傳遞給驅動程式，而不是傳遞較大的映射資料集。

## Spark 應用程式術語

本節涵蓋 Spark 應用程式術語。Spark 驅動程式會建立執行計畫，並以數個抽象概念控制應用程式的行為。下列術語對於使用 Spark UI 進行開發、偵錯和效能調校非常重要。

- 應用程式 – 根據 Spark 工作階段 (Spark 內容)。由唯一 ID 識別，例如 <application\_XXX>。
- 任務 – 根據為 RDD 建立的動作。任務包含一或多個階段。
- 階段 – 根據為 RDD 建立的隨機播放。階段包含一或多個任務。隨機播放是 Spark 重新分配資料的機制，因此會在 RDD 分割區之間以不同的方式分組。某些轉換，例如 join()，需要隨機播放。最佳化隨機播放調校實務中[會更詳細地討論隨機播放](#)。
- 任務 – 任務是 Spark 排定的最小處理單位。系統會為每個 RDD 分割區建立任務，而任務數量是階段中同時執行的最大數量。



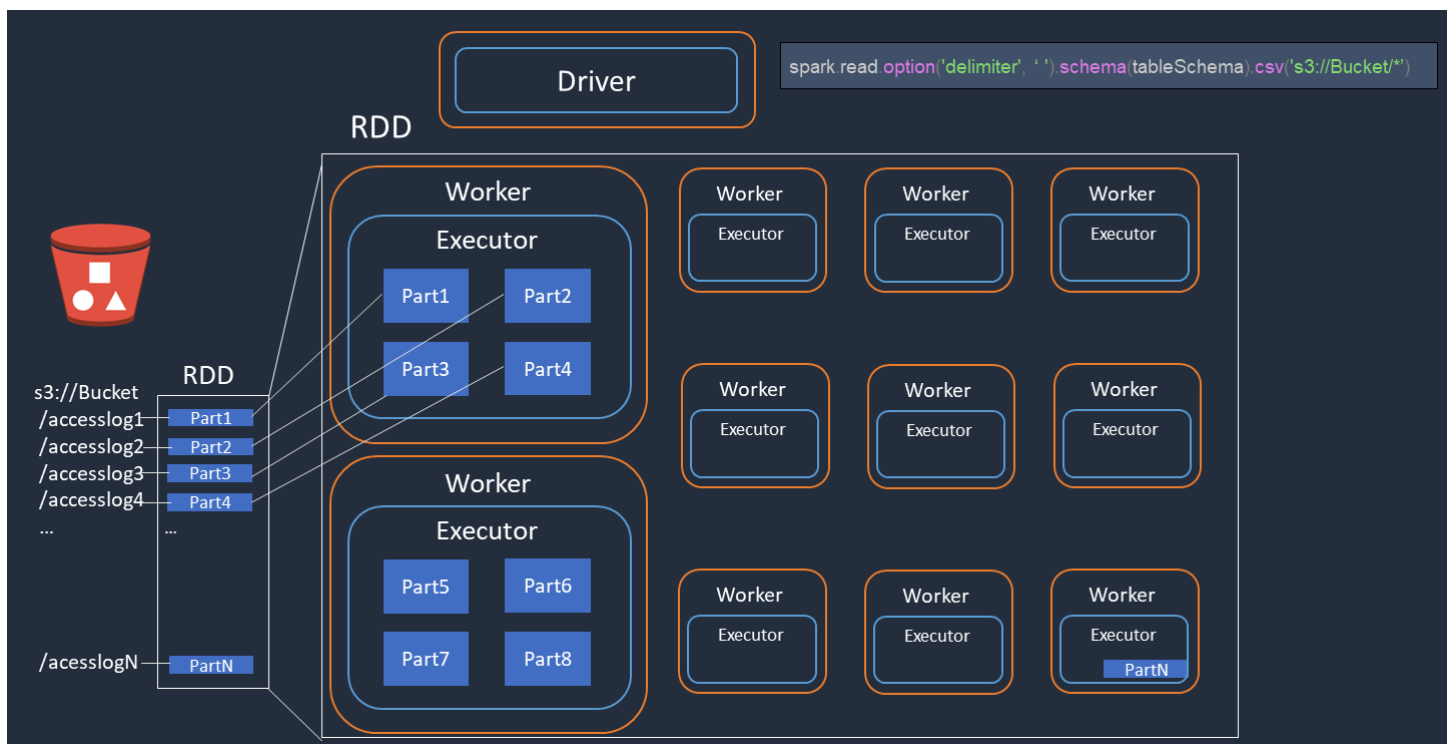
**Note**

最佳化平行處理時，任務是最重要的考量事項。任務數量隨 RDD 數量而擴展

## 平行處理

Spark 會平行處理載入和轉換資料的任務。

請考慮您在 Amazon S3 上執行存取日誌檔案 ( 名為 accesslog1 ... accesslogN ) 分散式處理的範例。下圖顯示分散式處理流程。

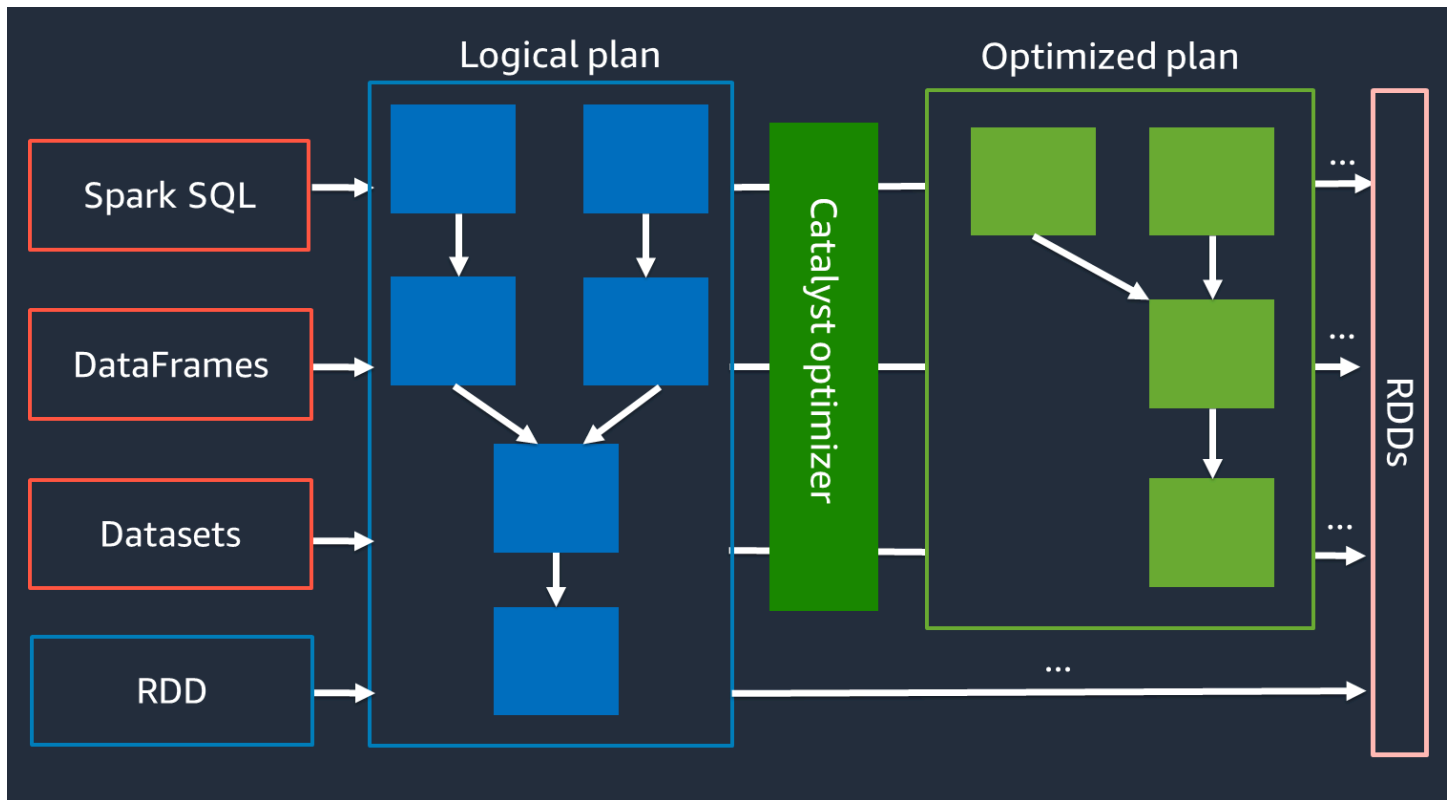


1. Spark 驅動程式會建立執行計畫，以便在多個 Spark 執行器之間進行分散式處理。
2. Spark 驅動程式會根據執行計畫指派每個執行器的任務。根據預設，Spark 驅動程式會為每個 S3 物件 ( ) 建立 RDD 分割區 ( 每個分割區對應於 Spark 任務 ) Part1 ... N。然後，Spark 驅動程式會將任務指派給每個執行器。
3. 每個 Spark 任務都會下載其指派的 S3 物件，並將其存放在 RDD 分割區的記憶體中。如此一來，多個 Spark 執行器會平行下載和處理其指派的任務。

如需分割區初始數量和最佳化的詳細資訊，請參閱[平行處理任務](#)一節。

## Catalyst 最佳化工具

在內部，Spark 使用稱為 [Catalyst 最佳化工具](#) 的引擎來最佳化執行計畫。Catalyst 具有查詢最佳化工具，您可以在執行高階 Spark APIs 時使用，例如 [Spark SQL](#)、[DataFrame](#) 和 [資料集](#)，如下圖所述。



由於 Catalyst 最佳化工具無法直接與 RDD API 搭配使用，因此高階 APIs 通常比低階 RDD API 更快。對於複雜的聯結，Catalyst 最佳化工具可以透過最佳化任務執行計畫來大幅改善效能。您可以在 Spark UI 的 SQL 索引標籤上查看 Spark 任務的最佳化計畫。

### 自適應查詢執行

Catalyst 最佳化工具會透過稱為自適應查詢執行的程序來執行執行期最佳化。自適應查詢執行會使用執行時間統計資料，在任務執行時重新最佳化查詢的執行計畫。自適應查詢執行提供數種效能挑戰的解決方案，包括合併隨機播放後分割區、將排序合併聯結轉換為廣播聯結，以及扭曲聯結最佳化，如下列各節所述。

自適應查詢執行可在 AWS Glue 3.0 和更新版本中使用，且預設會在 AWS Glue 4.0 (Spark 3.3.0) 和更新版本中啟用。您可以在程式碼 `spark.conf.set("spark.sql.adaptive.enabled", "true")` 中使用 來開啟和關閉自適應查詢執行。

### Coalescing 隨機播放後分割區

此功能會根據map輸出統計資料，減少每次隨機播放後的 RDD 分割區（餘音）。其可簡化執行查詢時隨機播放分割區編號的調校。您不需要設定隨機分割號碼以符合您的資料集。在您擁有足夠多的隨機播放分割區初始數量之後，Spark 可以在執行時間選擇適當的隨機播放分割區編號。

當 `spark.sql.adaptive.enabled` 和 `spark.sql.adaptive.coalescePartitions.enabled` 都設為 `true`

時 `spark.sql.adaptive.coalescePartitions.enabled`，會啟用並行隨機播放後分割區。如需詳細資訊，請參閱 [Apache Spark 文件](#)。

### 將排序合併聯結轉換為廣播聯結

此功能會辨識您何時聯結兩個大小大致不同的資料集，並根據該資訊採用更有效率的聯結演算法。如需詳細資訊，請參閱 [Apache Spark 文件](#)。[最佳化隨機播放](#) 區段會討論聯結策略。

### 扭曲聯結最佳化

資料扭曲是 Spark 任務最常見的瓶頸之一。它描述了資料偏向特定 RDD 分割區（因此是特定任務）的情況，這會延遲應用程式的整體處理時間。這通常會降低聯結操作的效能。扭曲聯結最佳化功能會動態處理排序合併聯結中的扭曲，方法是將扭曲的任務分割（並視需要複寫）為大致均勻大小的任務。

當設為 `true` 時 `spark.sql.adaptive.skewJoin.enabled`，會啟用此功能。如需詳細資訊，請參閱 [Apache Spark 文件](#)。[最佳化隨機播放](#) 區段會進一步討論資料扭曲。

## 使用 Spark UI 調查效能問題

在您套用任何最佳實務來調整 AWS Glue 任務的效能之前，強烈建議您分析效能並找出瓶頸。這可協助您專注於正確的事。

為了快速分析，[Amazon CloudWatch 指標](#) 提供任務指標的基本檢視。[Spark UI](#) 提供更深入的效能調校檢視。若要搭配 Spark UI 使用 AWS Glue，您必須為 [AWS Glue 任務啟用 Spark UI](#)。熟悉 Spark UI 後，請遵循 [調校 Spark 任務效能的策略](#)，以根據您的調查結果識別並減少瓶頸的影響。

## 使用 Spark UI 識別瓶頸

當您開啟 Spark UI 時，Spark 應用程式會列在資料表中。根據預設，AWS Glue 任務的應用程式名稱為 nativespark-<Job Name>-<Job Run ID>。根據任務執行 ID 選擇目標 Spark 應用程式，以開啟任務索引標籤。未完成的任務執行，例如串流任務執行，會列在顯示未完成的應用程式中。

任務索引標籤會顯示 Spark 應用程式中所有任務的摘要。若要判斷任何階段或任務失敗，請檢查任務總數。若要尋找瓶頸，請選擇持續時間來排序。選擇描述欄中顯示的連結，深入了解長時間執行任務的詳細資訊。

**Spark Jobs (?)**  
 User: spark  
 Total Uptime: 7.7 min  
 Scheduling Mode: FIFO  
 Completed Jobs: 7

▶ Event Timeline  
 ▼ Completed Jobs (7)

Page: 1 1 Pages. Jump to 1 . Show 100 items in a page. Go

Job Id	Description	Submitted	Duration	Stages: Succeeded/Total	Tasks (for all stages): Succeeded/Total
3	parquet at NativeMethodAccessorImpl.java:0 parquet at NativeMethodAccessorImpl.java:0	2023/03/30 06:49:02	6.5 min	1/1 (1 skipped)	5/5 (799 skipped)
0	showString at NativeMethodAccessorImpl.java:0 showString at NativeMethodAccessorImpl.java:0	2023/03/30 06:48:15	29 s	1/1	799/799
2	parquet at NativeMethodAccessorImpl.java:0 parquet at NativeMethodAccessorImpl.java:0	2023/03/30 06:48:48	14 s	1/1	799/799

任務的詳細資訊頁面會列出階段。在此頁面上，您可以看到整體洞見，例如持續時間、成功任務的數量及總任務數、輸入和輸出的數量，以及隨機讀取和隨機寫入的數量。

**Details for Job 3**  
 Status: SUCCEEDED  
 Submitted: 2023/03/30 06:49:02  
 Duration: 6.5 min  
 Associated SQL Query: 2  
 Completed Stages: 1  
 Skipped Stages: 1

▶ Event Timeline  
 ▶ DAG Visualization  
 ▼ Completed Stages (1)

Page: 1 1 Pages. Jump to 1 . Show 100 items in a page. Go

Stage Id	Description	Submitted	Duration	Tasks: Succeeded/Total	Input	Output	Shuffle Read	Shuffle Write
5	parquet at NativeMethodAccessorImpl.java:0	+details 2023/03/30 06:49:02	6.5 min	5/5		10.2 GiB	11.9 GiB	

執行器索引標籤會詳細說明 Spark 叢集容量。您可以檢查核心的總數。下列螢幕擷取畫面中顯示的叢集總共包含 316 個作用中核心和 512 個核心。根據預設，每個核心可以同時處理一個 Spark 任務。

Executors								
<a href="#">Show Additional Metrics</a>								
Summary								
	RDD Blocks	Storage Memory	Disk Used	Cores	Active Tasks	Failed Tasks	Complete Tasks	Total Tasks
<b>Active(80)</b>	0	0.0 B / 465.9 GiB	0.0 B	316	10	0	2399	2399
<b>Dead(49)</b>	0	0.0 B / 285.4 GiB	0.0 B	196	10	0	3	3
<b>Total(129)</b>	0	0.0 B / 751.3 GiB	0.0 B	512	10	0	2402	2402

根據工作詳細資訊頁面上 5/5 顯示的值，階段 5 是最長的階段，但只使用 512 個核心中的 5 個核心。由於此階段的平行處理非常低，但需要大量時間，因此您可以將其識別為瓶頸。為了改善效能，您想要了解原因。若要進一步了解如何辨識並減少常見效能瓶頸的影響，請參閱 [調校 Spark 任務效能的策略](#)。

# 調校 Spark 任務效能的策略

準備調校參數時，請使用以下最佳實務：

- 在開始識別問題之前，先決定您的效能目標。
- 嘗試變更調校參數之前，先使用指標來識別問題。

為在調校任務時得到最一致的結果，應制定調校工作的基線策略。

## 效能調校的基線策略

一般而言，效能調校依照以下工作流程進行：

1. 決定效能目標。
2. 量測指標。
3. 識別瓶頸。
4. 降低瓶頸的影響。
5. 重複步驟 2-4，直到達到預期的目標。

首先，確定您的效能目標。例如，您的其中一個目標是在 AWS Glue 3 小時內完成任務的執行。定義目標之後，請測量任務效能指標。識別指標和瓶頸的趨勢，以符合目標。尤其，識別瓶頸對於故障診斷、偵錯和效能調校最為重要。在執行 Spark 應用程式期間，Spark 會在 Spark 事件日誌中記錄每個任務的狀態和統計資料。

在中 AWS Glue，您可以透過 Spark 歷史記錄伺服器提供的 [Spark Web UI](#) 檢視 Spark 指標。AWS Glue 針對 Spark 任務，可以將 [Spark 事件日誌](#) 傳送至您在 Amazon S3 中指定的位置。AWS Glue 也提供範例 [AWS CloudFormation 範本](#) 和 [Dockerfile](#)，以在 Amazon EC2 執行個體或本機電腦上啟動 Spark 歷史記錄伺服器，因此您可以使用 Spark UI 搭配事件日誌。

在您確定績效目標並識別指標來評估這些目標之後，您可以開始使用以下章節中的策略來識別和修復瓶頸。

## Spark 任務效能的調校實務

您可以使用下列策略來調校 Spark AWS Glue 任務的效能：

- AWS Glue 資源：
  - [擴展叢集容量](#)
  - [使用 AWS Glue 最新版本](#)
- Spark 應用程式：
  - [減少資料掃描量](#)
  - [平行處理任務](#)
  - [最佳化隨機播放](#)
  - [將規劃開銷降至最低](#)
  - [最佳化使用者定義的函數](#)

使用這些策略之前，您必須能夠存取 Spark 任務的指標和組態。您可以在 [AWS Glue 文件](#) 中找到此資訊。

從 AWS Glue 資源的角度來看，您可以透過新增 AWS Glue 工作者並使用 AWS Glue 最新版本來實現效能改善。

從 Apache Spark 應用程式的觀點來看，您可以存取數個可改善效能的策略。如果將不必要的資料載入 Spark 叢集，您可以將其移除，以減少載入的資料量。如果您已使用不足的 Spark 叢集資源且資料 I/O 很低，您可以識別要平行化的任務。您可能也想要最佳化繁重的資料傳輸操作，例如需要大量時間的聯結。您也可以最佳化任務查詢計畫，或降低個別 Spark 任務的運算複雜性。

若要有效率地套用這些策略，您必須諮詢您的指標來識別何時適用這些策略。如需詳細資訊，請參閱下列各節。這些技術不僅適用於效能調校，也適用於解決out-of-memory(OOM) 錯誤等典型問題。


## 擴展叢集容量

如果您的任務花費太多時間，但執行器耗用足夠的資源，且 Spark 正在建立相對於可用核心的大量任務，請考慮擴展叢集容量。若要評估這是否適當，請使用下列指標。

### CloudWatch 指標

- 檢查 CPU 負載和記憶體使用率，以判斷執行器是否耗用足夠的資源。
- 檢查任務執行的時間長度，以評估處理時間是否太長而無法滿足您的效能目標。

在下列範例中，四個執行器以超過 97% 的 CPU 負載執行，但在大約三個小時後仍未完成處理。



**Note**

如果 CPU 負載低，您可能不會受益於擴展叢集容量。

## Spark 使用者介面

在任務索引標籤或階段索引標籤上，您可以查看每個任務或階段的任務數量。在下列範例中，Spark 已建立 58100 任務。

**Stages for All Jobs**

Completed Stages: 1

~ Completed Stages (1)

Stage Id	Description	Submitted	Duration	Tasks: Succeeded/Total	Input
0	count at DynamicFrame.scala:1414	2023/04/18 10:59:10	4.8 h	58100/58100	28.4 GB

在執行器索引標籤上，您可以看到執行器和任務的總數。在下列螢幕擷取畫面中，每個 Spark 執行器都有四個核心，可以同時執行四個任務。

**Executors**

Show 20 entries

Executor ID	Address	Status	RDD Blocks	Storage Memory	Disk Used	Cores
driver	172.35.229.149:37603	Active	0	0.0 B / 6.3 GB	0.0 B	0
1	172.34.249.100:34733	Active	0	0.0 B / 6.3 GB	0.0 B	4
2	172.35.72.25:38929	Active	0	0.0 B / 6.3 GB	0.0 B	4
3	172.34.49.138:39961	Active	0	0.0 B / 6.3 GB	0.0 B	4
4	172.36.70.76:39323	Active	0	0.0 B / 6.3 GB	0.0 B	4

在此範例中，Spark 任務的數量 (58100) 遠大於執行器可同時處理的 16 個任務 (4 個執行器 × 4 個核心)。

如果您觀察到這些症狀，請考慮擴展叢集。您可以使用下列選項來擴展叢集容量：

- Enable AWS Glue Auto Scaling – [Auto Scaling](#) 適用於 3.0 AWS Glue 版或更新版本中的 AWS Glue 擷取、轉換和載入 (ETL) 和串流任務。會根據每個階段的分割區數量或任務執行時產生微批次的速率 AWS Glue，自動從叢集新增和移除工作者。

如果您觀察到即使 Auto Scaling 已啟用，工作者數量也不會增加的情況，請考慮手動新增工作者。不過，請注意，手動擴展一個階段可能會導致許多工作者在稍後階段處於閒置狀態，因此成本更高，因此效能不會增加。

啟用 Auto Scaling 之後，您可以在 CloudWatch 執行器指標中查看執行器的數量。使用下列指標來監控 Spark 應用程式中執行器的需求：

- `glue.driver.ExecutorAllocationManager.executors.numberAllExecutors`
- `glue.driver.ExecutorAllocationManager.executors.numberMaxNeededExecutors`

如需指標的詳細資訊，請參閱[AWS Glue 使用 Amazon CloudWatch 指標進行監控](#)。

- 向外擴展：增加工作者數量 AWS Glue – 您可以手動增加工作者數量 AWS Glue。只有在您觀察到閒置的工作者時，才新增工作者。此時，新增更多工作者將增加成本，而不會改善結果。如需詳細資訊，請參閱[平行處理任務](#)。
- 擴展：使用較大的工作者類型 – 您可以手動變更 AWS Glue 工作者的執行個體類型，以使用具有更多核心、記憶體和儲存體的工作者。較大的工作者類型可讓您垂直擴展和執行密集資料整合任務，例如記憶體密集型資料轉換、偏斜彙總，以及涉及 PB 資料的實體偵測檢查。

向上擴展也有助於 Spark 驅動程式需要更大容量的情況，例如，因為任務查詢計畫相當大。如需工作者類型和效能的詳細資訊，請參閱 AWS 大數據部落格文章[使用新的大型工作者類型 G.4X 和 G.8X 擴展 AWS Glue Apache Spark 任務](#)。

使用較大的工作者也可以減少所需的工作者總數，透過減少加入等密集操作中的隨機播放來提高效率。

## 使用 AWS Glue 最新版本

建議使用 AWS Glue 最新版本。每個版本內建了數個最佳化和升級，可能會自動改善任務效能。例如，AWS Glue 4.0 提供下列新功能：

- 新的最佳化 Apache Spark 3.3.0 執行期 – AWS Glue 4.0 以 Apache Spark 3.3.0 執行期為基礎，為開放原始碼 Spark 帶來相當的效能改善。Spark 3.3.0 執行期以 Spark 2.x 的許多創新為基礎。
- 增強型 Amazon Redshift 連接器 – AWS Glue 4.0 和更新版本為 Apache Spark 提供 Amazon Redshift 整合。整合以現有的開放原始碼連接器為基礎，並增強其效能和安全性。整合可協助應用程式以高達 10 倍的速度執行。如需詳細資訊，請參閱有關 [Amazon Redshift 與 Apache Spark 整合](#) 的部落格文章。
- 使用 CSV 和 JSON 資料 – 3.0 版及更新版本進行向量化讀取的 SIMD 型執行新增了最佳化讀取器，相較於資料列型讀取器，可大幅加快整體任務效能。AWS Glue 如需 CSV 資料的詳細資訊，請參閱 [使用向量化 SIMD CSV 讀取器最佳化讀取效能](#)。如需 JSON 資料的詳細資訊，請參閱 [搭配 Apache Arrow 單欄式格式使用向量化 SIMD JSON 讀取器](#)。

每個 AWS Glue 版本都會包含此類型的升級，包括連接器、驅動程式和程式庫更新。如需詳細資訊，請參閱 [AWS Glue 版本](#) 和 [將 AWS Glue 任務遷移至 AWS Glue 4.0 版](#)。

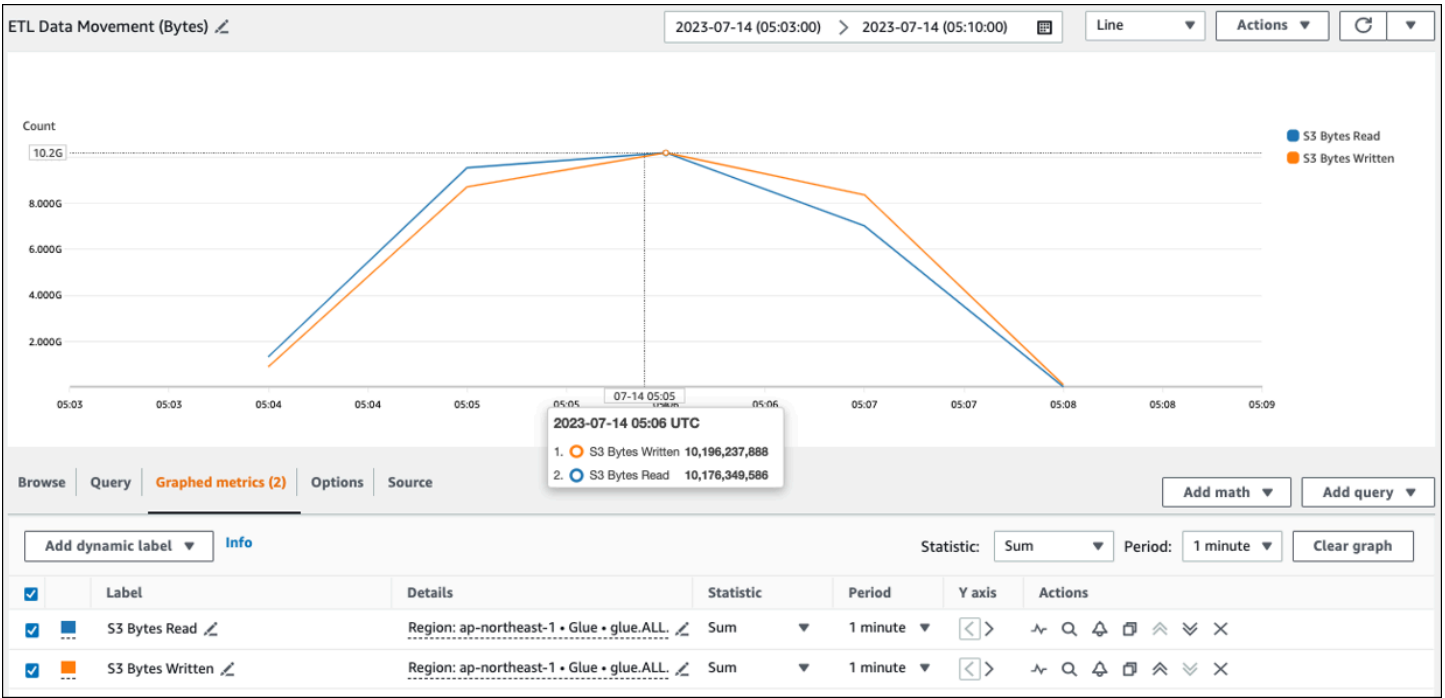
## 減少資料掃描量

若要開始，請考慮僅載入您需要的資料。您只需減少每個資料來源載入 Spark 叢集的資料量，即可改善效能。若要評估此方法是否適當，請使用下列指標。

您可以在 [CloudWatch 指標](#) 中檢查來自 Amazon S3 的讀取位元組，以及在 Spark UI 中檢查更多詳細資訊，如 [Spark UI](#) 一節所述。

### CloudWatch 指標

您可以在 [ETL 資料移動 \(位元組\)](#) 中查看 Amazon S3 的大約讀取大小。此指標顯示自上次報告以來，所有執行器從 Amazon S3 讀取的位元組數。您可以使用它來監控來自 Amazon S3 的 ETL 資料移動，而且您可以將讀取與來自外部資料來源的擷取速率進行比較。



如果您觀察到比預期更大的 S3 位元組讀取資料點，請考慮下列解決方案。

## Spark 使用者介面

在 AWS Glue 適用於 Spark UI 的階段索引標籤上，您可以看到輸入和輸出大小。在下列範例中，階段 2 讀取 47.4 GiB 輸入和 47.7 GiB 輸出，而階段 5 讀取 61.2 MiB 輸入和 56.6 MiB 輸出。

**Stages for All Jobs**

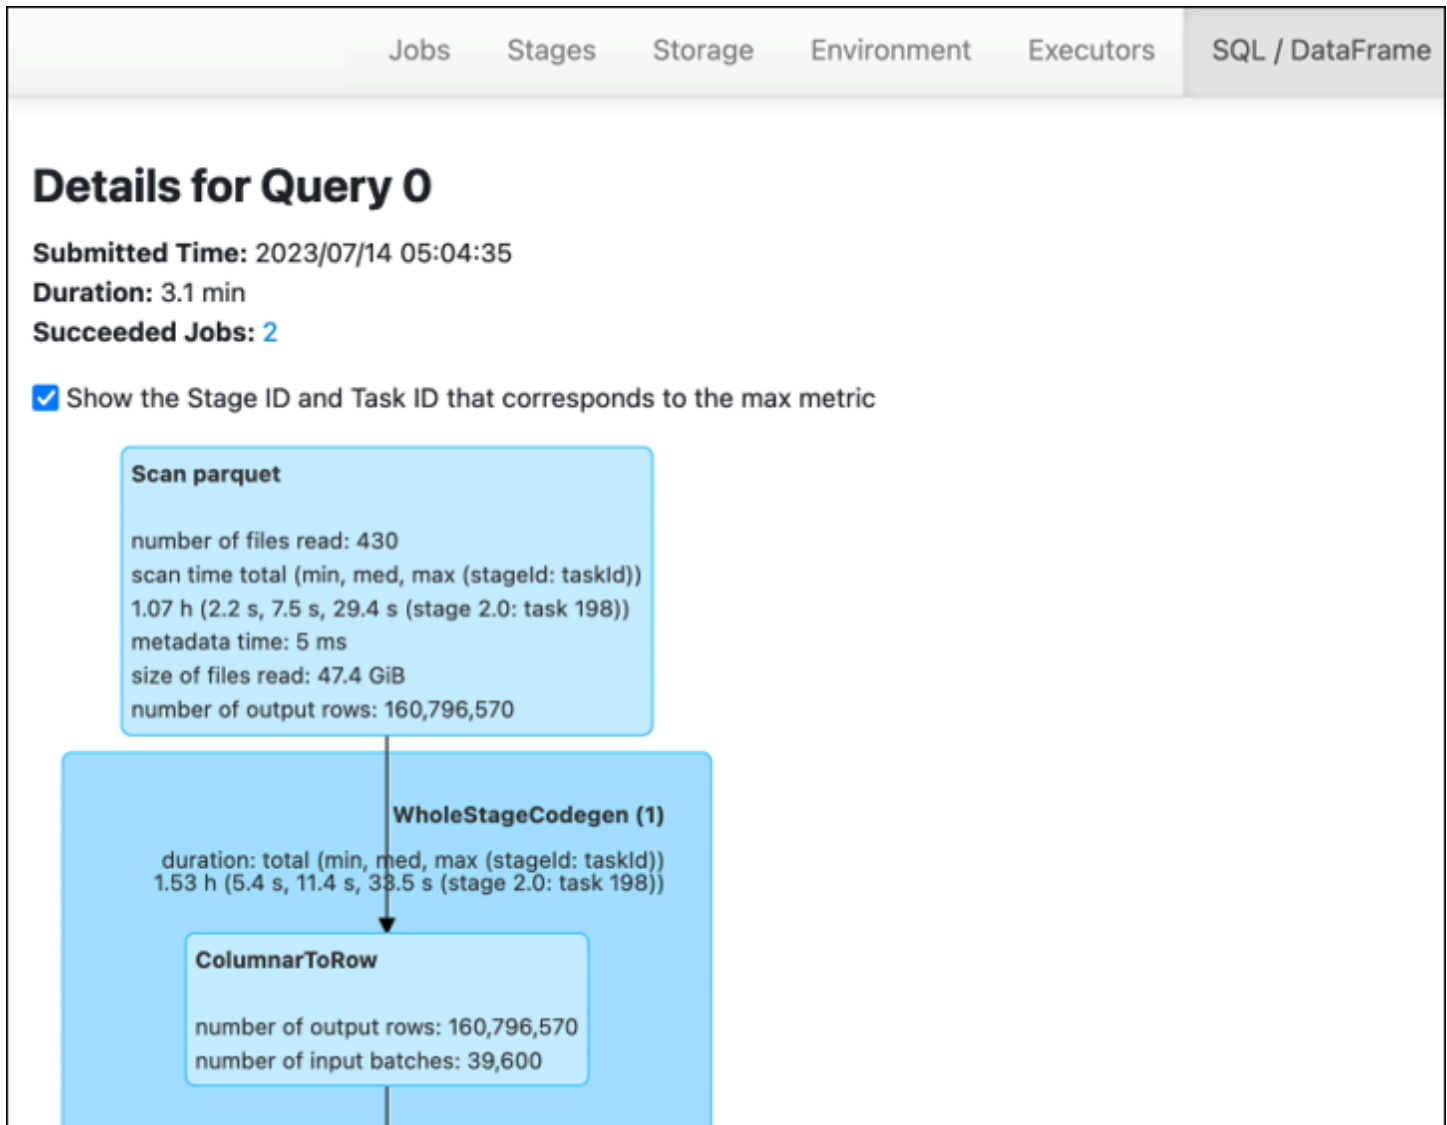
Completed Stages: 6

Completed Stages (6)

Page: 1 1 Pages. Jump to 1 . Sho

Stage Id	Description	Submitted	Duration	Tasks: Succeeded/Total	Input	Output
5	parquet at NativeMethodAccessorImpl.java:0	2023/07/14 05:09:49	15 s	414/414	61.2 MiB	56.6 MiB
4	load at NativeMethodAccessorImpl.java:0	2023/07/14 05:09:47	0.6 s	1/1		
3	Listing leaf files and directories for 43 paths: s3://amazon-reviews-pds/parquet/product_category=Apparel, ... load at NativeMethodAccessorImpl.java:0	2023/07/14 05:09:46	1 s	43/43		
2	parquet at NativeMethodAccessorImpl.java:0	2023/07/14 05:04:36	3.1 min	414/414	47.4 GiB	47.7 GiB
1	load at NativeMethodAccessorImpl.java:0	2023/07/14 05:04:31	2 s	1/1		
0	Listing leaf files and directories for 43 paths: s3://amazon-reviews-pds/parquet/product_category=Apparel, ... load at NativeMethodAccessorImpl.java:0	2023/07/14 05:04:13	6 s	43/43		

當您在 AWS Glue 任務中使用 Spark SQL 或 DataFrame 方法時，SQL / DataFrame 索引標籤會顯示這些階段的更多統計資料。在此情況下，階段 2 會顯示檔案讀取數量：430，檔案讀取大小：47.4 GiB，輸出資料列數量：160,796,570。



如果您發現您正在讀取的資料與您正在使用的資料之間存在很大的差異，請嘗試以下解決方案。

## Amazon S3

若要減少從 Amazon S3 讀取時載入任務的資料量，請考慮資料集的檔案大小、壓縮、檔案格式和檔案配置（分割區）。AWS Glue 對於 Spark 任務通常用於原始資料的 ETL，但為了有效率的分散式處理，您需要檢查資料來源格式的功能。

- 檔案大小 – 我們建議將輸入和輸出的檔案大小保持在中等範圍內（例如 128 MB）。太小的檔案和太大的檔案可能會導致問題。

大量小型檔案會導致下列問題：

- Amazon S3 上的大量網路 I/O 負載，因為對許多物件（相較於存放相同資料數量的幾個物件 Head）提出請求（例如 ListGet、或）所需的額外負荷。
- Spark 驅動程式上的大量 I/O 和處理負載，這會產生許多分割區和任務，並導致過度平行處理。


另一方面，如果您的檔案類型無法分割（例如 gzip）且檔案太大，Spark 應用程式必須等到單一任務完成讀取整個檔案。

若要減少為每個小型檔案建立 Apache Spark 任務時產生的過度平行處理，請使用 [DynamicFrames 的檔案分組](#)。此方法可降低 Spark 驅動程式發生 OOM 例外狀況的機率。若要設定檔案分組，請設定 `groupFiles` 和 `groupSize` 參數。下列程式碼範例使用 ETL 指令碼中的 AWS Glue `DynamicFrame` API 搭配這些參數。

```
dyf = glueContext.create_dynamic_frame_from_options("s3",
  {'paths': ["s3://input-s3-path/"],
  'recurse': True,
  'groupFiles': 'inPartition',
  'groupSize': '1048576'},
  format="json")
```

- 壓縮 – 如果您的 S3 物件位於數百 MB 中，請考慮壓縮它們。有各種壓縮格式，可廣泛分類為兩種類型：
  - gzip 等無法分割的壓縮格式需要一個工作者解壓縮整個檔案。
  - 可分割壓縮格式，例如 bzip2 或 LZO（索引），允許檔案的部分解壓縮，可平行處理。

對於 Spark（和其他常見的分散式處理引擎），您可以將來源資料檔案分割為引擎可以平行處理的區塊。這些單位通常稱為分割。資料為可分割格式之後，最佳化的 AWS Glue 讀取器可以透過提供 `GetObject` API `Range` 選項，僅擷取特定區塊，從 S3 物件擷取分割。請考慮下圖，了解這在實務上如何運作。



只要檔案為最佳大小或檔案可分割，壓縮的資料就能大幅加速您的應用程式。較小的資料大小可減少從 Amazon S3 掃描的資料，以及從 Amazon S3 到 Spark 叢集的網路流量。另一方面，壓縮和解壓縮資料需要更多 CPU。所需的運算量會隨著壓縮演算法的壓縮比率而擴展。選擇可分割壓縮格式時，請考慮此取捨。

### Note

雖然 gzip 檔案通常無法分割，但您可以使用 gzip 壓縮個別 parquet 區塊，而且這些區塊可以平行化。

- 檔案格式 – 使用單欄格式。[Apache Parquet](#) 和 [Apache ORC](#) 是熱門的單欄式資料格式。Parquet 和 ORC 會根據資料類型採用資料欄型壓縮、編碼和壓縮每個資料欄，以有效率地存放資料。如需 Parquet 編碼的詳細資訊，請參閱 [Parquet 編碼定義](#)。Parquet 檔案也可以分割。

單欄格式依資料欄分組值，並將其存放在區塊中。使用單欄式格式時，您可以略過對應於您不打算使用之資料欄的資料區塊。Spark 應用程式只能擷取您需要的資料欄。一般而言，更好的壓縮率或略過資料區塊意味著從 Amazon S3 讀取較少的位元組，進而獲得更好的效能。這兩種格式也支援下列下推方法來減少 I/O：

- 投影下推 – 投影下推是一種僅擷取應用程式中指定資料欄的技術。您可以在 Spark 應用程式中指定資料欄，如下列範例所示：
  - DataFrame 範例：`df.select("star_rating")`

- Spark SQL 範例：`spark.sql("select start_rating from <table>")`
- 述詞下推 – 述詞下推是一種有效處理 WHERE 和 GROUP BY子句的技術。這兩種格式都有代表資料欄值的資料區塊。每個區塊都會保留區塊的統計資料，例如最大值和最小值。Spark 可以使用這些統計資料，根據應用程式中使用的篩選條件值來判斷是否應讀取或略過區塊。若要使用此功能，請在條件中新增更多篩選條件，如下列範例所示：
  - DataFrame 範例：`df.select("star_rating").filter("star_rating < 2")`
  - Spark SQL 範例：`spark.sql("select * from <table> where star_rating < 2")`
- 檔案配置 – 根據資料的使用方式，將 S3 資料儲存到不同路徑中的物件，您可以有效率地擷取相關資料。如需詳細資訊，請參閱《Amazon S3 文件》中的[使用字首整理物件](#)。AWS Glue 支援以格式將金鑰和值儲存到 Amazon S3 字首key=value，並依 Amazon S3 路徑分割您的資料。透過分割資料，您可以限制每個下游分析應用程式掃描的資料量，從而改善效能並降低成本。如需詳細資訊，請參閱[管理 中 ETL 輸出的分割區 AWS Glue](#)。

分割會將資料表分成不同的部分，並根據年、月和日等資料欄值，將相關資料保留在分組檔案中，如下列範例所示。

```
# Partitioning by /YYYY/MM/DD
s3://<YourBucket>/year=2023/month=03/day=31/0000.gz
s3://<YourBucket>/year=2023/month=03/day=01/0000.gz
s3://<YourBucket>/year=2023/month=03/day=02/0000.gz
s3://<YourBucket>/year=2023/month=03/day=03/0000.gz
...
```

您可以使用 中的資料表來建立資料集模型，藉此定義資料集的分割區 AWS Glue Data Catalog。然後，您可以使用分割區剔除來限制資料掃描的數量，如下所示：

- For AWS Glue DynamicFrame，設定 `push_down_predicate` ( 或 `catalogPartitionPredicate`)。

```
dyf = Glue_context.create_dynamic_frame.from_catalog(
    database=src_database_name,
    table_name=src_table_name,
    push_down_predicate = "year='2023' and month ='03'",
)
```

- 針對 Spark DataFrame，設定固定路徑以刪除分割區。

```
df = spark.read.format("json").load("s3://<YourBucket>/year=2023/month=03/*/*.gz")
```

- 對於 Spark SQL，您可以設定 where 子句從 Data Catalog 刪除分割區。

```
df = spark.sql("SELECT * FROM <Table> WHERE year= '2023' and month = '03'")
```

- 若要在使用 寫入資料時依日期分割 AWS Glue，請在 DataFrame 中的 DynamicFrame 或 [partitionBy\(\)](#) 中設定 [partitionKeys](#)，資料欄中的日期資訊如下所示。

- DynamicFrame

```
glue_context.write_dynamic_frame_from_options(
    frame= dyf, connection_type='s3',format='parquet'
    connection_options= {
        'partitionKeys': ["year", "month", "day"],
        'path': 's3://<YourBucket>/<Prefix>/'
    }
)
```

- DataFrame

```
df.write.mode('append')\
    .partitionBy('year','month','day')\
    .parquet('s3://<YourBucket>/<Prefix>/')
```

這可以改善輸出資料消費者的效能。

如果您無法存取 來修改建立輸入資料集的管道，則分割不是一個選項。反之，您可以使用 glob 模式來排除不需要的 S3 路徑。在 DynamicFrame 中讀取時設定[排除](#)。例如，下列程式碼排除 2023 年的第 01 到 09 個月天數。

```
dyf = glueContext.create_dynamic_frame.from_catalog(
    database=db,
    table_name=table,
    additional_options = { "exclusions":["\\\"**year=2023/month=0[1-9]**\\\""] },
    transformation_ctx='dyf'
)
```

您也可以 Data Catalog 的資料表屬性中設定排除：

- 索引鍵：exclusions

- 值：["\*\*year=2023/month=0[1-9]\*\*"]
- 太多 Amazon S3 分割區 – 避免在包含各種值的資料欄上分割 Amazon S3 資料，例如具有數千個值的 ID 資料欄。這可以大幅增加儲存貯體中的分割區數量，因為可能的分割區數量是您已分割的所有欄位的乘積。太多分割區可能會導致下列情況：
  - 從 Data Catalog 擷取分割區中繼資料的延遲增加
  - 需要更多 Amazon S3 API 請求的小型檔案數量增加 (List、Get 和 Head)

例如，當您在 `partitionBy` 或 `中` 設定日期類型時 `partitionKeys`，等日期層級分割 `yyyy/mm/dd` 適用於許多使用案例。不過，`yyyy/mm/dd/<ID>` 可能會產生太多分割區，進而對整體效能產生負面影響。

另一方面，一些使用案例，例如即時處理應用程式，需要許多分割區，例如 `yyyy/mm/dd/hh`。如果您的使用案例需要大量分割區，請考慮使用 [AWS Glue 分割區索引](#) 來減少從 Data Catalog 擷取分割區中繼資料的延遲。

## 資料庫和 JDBC

若要在從資料庫擷取資訊時減少資料掃描，您可以在 SQL 查詢中指定 `where` 述詞（或子句）。不提供 SQL 界面的資料庫將提供自己的查詢或篩選機制。

使用 Java Database Connectivity (JDBC) 連線時，請使用 `where` 子句為下列參數提供選取查詢：

- 對於 `DynamicFrame`，請使用 [sampleQuery](#) 選項。使用 `create_dynamic_frame.from_catalog` 時，請設定 `additional_options` 數，如下所示。

```
query = "SELECT * FROM <TableName> where id = 'XX' AND"
datasource0 = glueContext.create_dynamic_frame.from_catalog(
    database = db,
    table_name = table,
    additional_options={
        "sampleQuery": query,
        "hashexpression": key,
        "hashpartitions": 10,
        "enablePartitioningForSampleQuery": True
    },
    transformation_ctx = "datasource0"
)
```

當時 using `create_dynamic_frame.from_options`，設定引 `connection_options` 數，如下所示。

```
query = "SELECT * FROM <TableName> where id = 'XX' AND"
datasource0 = glueContext.create_dynamic_frame.from_options(
    connection_type = connection,
    connection_options={
        "url": url,
        "user": user,
        "password": password,
        "dbtable": table,
        "sampleQuery": query,
        "hashexpression": key,
        "hashpartitions": 10,
        "enablePartitioningForSampleQuery": True
    }
)
```

- 對於 DataFrame，請使用 [查詢](#) 選項。

```
query = "SELECT * FROM <TableName> where id = 'XX'"
jdbcDF = spark.read \
    .format('jdbc') \
    .option('url', url) \
    .option('user', user) \
    .option('password', pwd) \
    .option('query', query) \
    .load()
```

- 對於 Amazon Redshift，請使用 AWS Glue 4.0 或更新版本來利用 [Amazon Redshift Spark 連接器](#) 中的下推支援。

```
dyf = glueContext.create_dynamic_frame.from_catalog(
    database = "redshift-dc-database-name",
    table_name = "redshift-table-name",
    redshift_tmp_dir = args["temp-s3-dir"],
    additional_options = {"aws_iam_role": "arn:aws:iam::role-account-id:role/rs-role-name"}
)
```

- 如需其他資料庫，請參閱該資料庫的文件。

## AWS Glue 選項

- 若要避免對所有連續任務執行進行完整掃描，並僅處理上次任務執行期間不存在的資料，請啟用[任務書籤](#)。
- 若要限制要處理的輸入資料數量，請使用任務書籤啟用[週框執行](#)。這有助於減少每個任務執行的掃描資料量。


## 平行處理任務

若要最佳化效能，請務必平行處理資料載入和轉換的任務。正如我們在 [Apache Spark 中討論的關鍵主題](#) 所述，彈性分散式資料集 (RDD) 分割區的數量很重要，因為它決定平行處理的程度。Spark 建立的每個任務都會以 1 : 1 為基礎對應至 RDD 分割區。若要獲得最佳效能，您需要了解如何決定 RDD 分割區的數量，以及如何最佳化該數量。

如果您沒有足夠的平行處理，下列症狀將記錄在 [CloudWatch 指標](#) 和 Spark UI 中。

## CloudWatch 指標

檢查 CPU 負載和記憶體使用率。如果某些執行器未在任務的某個階段期間處理，則適合改善平行處理。在此情況下，在視覺化時間範圍內，執行器 1 正在執行任務，但剩餘的執行器 (2、3 和 4) 並未執行。您可以推斷 Spark 驅動程式未指派這些執行器的任務。




## Spark 使用者介面

在 Spark UI 的階段索引標籤上，您可以查看階段中的任務數量。在此情況下，Spark 只執行一個任務。

- Tasks (1)														
Index	ID	Attempt	Status	Locality Level	Executor ID	Host	Launch Time	Duration	Task Deserialization Time	GC Time	Result Serialization Time	Input Size / Records	Write Time	Shuffle Write Size / Records
0	1	0	SUCCESS	ANY	1	172.34.235.123	2023/04/19 10:20:02	1.3 min	0.3 s	0.4 s	1 ms	2.0 GB / 7135819	12 ms	59.0 B / 1

此外，事件時間軸會顯示執行器 1 處理一個任務。這表示此階段中的工作完全在某個執行器上執行，而其他執行器則處於閒置狀態。



如果您觀察到這些症狀，請嘗試每個資料來源的下列解決方案。

### 從 Amazon S3 平行載入資料

若要平行處理來自 Amazon S3 的資料載入，請先檢查預設的分割區數量。然後，您可以手動判斷分割區的目標數量，但請務必避免擁有太多分割區。

#### 決定預設的分割區數量

對於 Amazon S3，初始數量的 Spark RDD 分割區（每個分割區對應至 Spark 任務）取決於 Amazon S3 資料集的功能（例如，格式、壓縮和大小）。當您從存放在 Amazon S3 中的 CSV 物件建立 an AWS Glue DynamicFrame 或 Spark DataFrame 時，初始 RDD 分割區數量 (NumPartitions) 大約可以如下計算：

- 物件大小  $\leq 64$  MB :  $\text{NumPartitions} = \text{Number of Objects}$
- 物件大小  $> 64$  MB :  $\text{NumPartitions} = \text{Total Object Size} / 64 \text{ MB}$
- 不可分割 (gzip) :  $\text{NumPartitions} = \text{Number of Objects}$

如[減少資料掃描量](#)一節所述，Spark 會將大型 S3 物件分成可平行處理的分割。當物件大於分割大小時，Spark 會分割物件，並為每個分割建立 RDD 分割區（和任務）。Spark 的分割大小取決於您的資料格式和執行時間環境，但這是合理的開始近似值。有些物件是使用 gzip 等不可分割的壓縮格式進行壓縮，因此 Spark 無法分割它們。

NumPartitions 值可能會根據您的資料格式、壓縮、AWS Glue 版本、AWS Glue 工作者數量和 Spark 組態而有所不同。

例如，當您使用 Spark DataFrame 載入單一 10 GB csv.gz 物件時，Spark 驅動程式只會建立一個 RDD 分割區 (NumPartitions=1)，因為 gzip 是不可分割的。這會導致一個特定 Spark 執行器的繁重負載，並且不會將任何任務指派給剩餘的執行器，如下圖所述。

在 [Spark Web UI 階段索引標籤上檢查](#)階段的實際任務數量 (NumPartitions)，或在程式碼 `df.rdd.getNumPartitions()` 中執行以檢查平行處理。

遇到 10 GB gzip 檔案時，請檢查產生該檔案的系統是否可以以可分割格式產生該檔案。如果這不是選項，您可能需要[擴展叢集容量](#)來處理檔案。若要有有效對您載入的資料執行轉換，您需要使用重新分割來重新平衡叢集中整個工作者的 RDD。

### 手動判斷分割區的目標數量

視資料屬性和 Spark 實作特定功能而定，即使基礎工作仍可平行化，最終仍可能具有較低的 NumPartitions 值。如果 NumPartitions 太小，請執行 `df.repartition(N)` 以增加分割區數量，以便將處理分散到多個 Spark 執行器。

在這種情況下，執行 NumPartitions `df.repartition(100)` 會從 1 增加到 100，建立 100 個資料分割區，每個分割區都有可指派給其他執行器的任務。

操作會平均 `repartition(N)` 分割整個資料 (10 GB/100 個分割區 = 100 MB/分割區)，避免資料扭曲至特定分割區。

#### Note

join 執行等隨機播放操作時，分割區數量會根據 `spark.sql.shuffle.partitions` 或的 值動態增加或減少 `spark.default.parallelism`。這有助於在 Spark 執行器之間更有效率地交換資料。如需詳細資訊，請參閱 [Spark 文件](#)。

您在決定分割區的目標數量時，目標是最大化佈建 AWS Glue 工作者的使用量。AWS Glue 工作者數量和 Spark 任務數量與 vCPUs 數量相關。Spark 支援每個 vCPU 核心一個任務。在 3.0 AWS Glue 版或更新版本中，您可以使用下列公式計算分割區的目標數量。

```
# Calculate NumPartitions by WorkerType
numExecutors = (NumberOfWorkers - 1)
numSlotsPerExecutor =
  4 if WorkerType is G.1X
  8 if WorkerType is G.2X
```

```

16 if WorkerType is G.4X
32 if WorkerType is G.8X
NumPartitions = numSlotsPerExecutor * numExecutors

# Example: Glue 4.0 / G.1X / 10 Workers
numExecutors = ( 10 - 1 ) = 9 # 1 Worker reserved on Spark Driver
numSlotsPerExecutor = 4 # G.1X has 4 vCpu core ( Glue 3.0 or later )
NumPartitions = 9 * 4 = 36

```

在此範例中，每個 G.1X 工作者都會提供四個 vCPU 核心給 Spark 執行器 (`spark.executor.cores = 4`)。Spark 為每個 vCPU Core 支援一個任務，因此 G.1X Spark 執行器可以同時執行四個任務 (`numSlotPerExecutor`)。如果任務需要相同的時間量，則此分割區數量會充分利用叢集。不過，某些任務需要比其他任務更長的時間，才能建立閒置核心。如果發生這種情況，請考慮 `numPartitions` 將 2 或 3 相乘，以分解並有效率地排程瓶頸任務。

### 太多分割區

過多的分割區會建立過多的任務。這會導致 Spark 驅動程式負載過重，因為與分散式處理相關的額外負荷，例如管理任務和 Spark 執行器之間的資料交換。

如果您任務中的分割區數量遠大於您的分割區目標數量，請考慮減少分割區數量。您可以使用下列選項來減少分割區：

- 如果您的檔案大小很小，請使用 AWS Glue [groupFiles](#)。您可以減少啟動 Apache Spark 任務以處理每個檔案所產生的過度平行處理。
- 使用 `coalesce(N)` 將分割區合併在一起。這是一個低成本的程序。減少分割區數量時，`coalesce(N)` 優先於 `repartition(N)`，因為 `repartition(N)` 會執行隨機播放來平均分配每個分割區中的記錄數量。這會增加成本和管理開銷。
- 使用 Spark 3.x 自適應查詢執行。如 [Apache Spark 中關鍵主題一節中所述](#)，自適應查詢執行提供函數，可自動合併分割區數量。當您在執行執行之前不知道分割區數量時，可以使用此方法。

### 從 JDBC 平行載入資料

Spark RDD 分割區的數量取決於組態。請注意，根據預設，只會執行單一任務來透過 SELECT 查詢掃描整個來源資料集。

AWS Glue DynamicFrames 和 Spark DataFrames 都支援跨多個任務的平行 JDBC 資料載入。這可透過使用 `where` 述詞將一個 SELECT 查詢分割為多個查詢來完成。若要平行化 JDBC 的讀取，請設定下列選項：

- For AWS Glue DynamicFrame , 設定 hashfield ( 或 hashexpression) 和 hashpartition。若要進一步了解，請參閱[平行讀取 JDBC 資料表](#)。

```
connection_mysql8_options = {
  "url": "jdbc:mysql://XXXXXXXXXXXX.XXXXXXX.us-east-1.rds.amazonaws.com:3306/test",
  "dbtable": "medicare_tb",
  "user": "test",
  "password": "XXXXXXXXXX",
  "hashexpression": "id",
  "hashpartitions": "10"
}
datasource0 = glueContext.create_dynamic_frame.from_options(
  'mysql',
  connection_options=connection_mysql8_options,
  transformation_ctx= "datasource0"
)
```

- 針對 Spark DataFrame , 設定 numPartitions、lowerBound、partitionColumn 和 upperBound。若要進一步了解，請參閱[JDBC 至其他資料庫](#)。

```
df = spark.read \
  .format("jdbc") \
  .option("url", "jdbc:mysql://XXXXXXXXXXXX.XXXXXXX.us-east-1.rds.amazonaws.com:3306/
test") \
  .option("dbtable", "medicare_tb") \
  .option("user", "test") \
  .option("password", "XXXXXXXXXX") \
  .option("partitionColumn", "id") \
  .option("numPartitions", "10") \
  .option("lowerBound", "0") \
  .option("upperBound", "1141455") \
  .load()

df.write.format("json").save("s3://bucket_name/Tests/sparkjdbc/with_parallel/")
```

## 使用 ETL 連接器時，從 DynamoDB 平行載入資料

Spark RDD 分割區的數量由 dynamodb.splits 參數決定。若要平行處理 Amazon DynamoDB 的讀取，請設定下列選項：

- 增加 的值 dynamodb.splits。

- 依照 [for Spark 中 ETL 的連線類型和選項中說明 AWS Glue](#) 的公式來最佳化 參數。

## 從 Kinesis Data Streams 平行載入資料

Spark RDD 分割區的數量取決於來源 Amazon Kinesis Data Streams 資料串流中的碎片數量。如果您的資料串流中只有幾個碎片，則只會有幾個 Spark 任務。這可能會導致下游程序的平行處理率低。若要平行化 Kinesis Data Streams 的讀取，請設定下列選項：

- 從 Kinesis Data Streams 載入資料時，增加碎片數量以取得更多平行處理。
- 如果您在微型批次中的邏輯夠複雜，請考慮在捨棄不需要的資料欄後，在批次開始時重新分割資料。

如需詳細資訊，請參閱[最佳化 AWS Glue 串流 ETL 任務成本和效能的最佳實務](#)。

## 資料載入後平行處理任務

若要在資料載入後平行處理任務，請使用下列選項來增加 RDD 分割區的數量：

- 重新分割資料以產生更多分割區，特別是如果負載本身無法平行化，則在初始載入之後。

在 `DynamicFrame` 或 `DataFrame repartition()` 上呼叫，指定分割區的數量。良好的經驗法則是可用核心數目的兩倍或三倍。

不過，寫入分割的資料表時，這可能會導致檔案爆炸（每個分割區可能會在每個資料表分割區中產生檔案）。若要避免這種情況，您可以依資料欄重新分割 `DataFrame`。這會使用資料表分割區資料欄，以便在寫入之前整理資料。您可以指定更多分割區，而無需在資料表分割區上取得小型檔案。不過，請小心避免資料扭曲，其中某些分割區值最終會變成大部分的資料，並延遲任務的完成。

- 有隨機播放時，請增加 `spark.sql.shuffle.partitions` 值。這也有助於解決隨機播放時的任何記憶體問題。

當您有超過 2,001 個隨機分割區時，Spark 會使用壓縮的記憶體格式。如果您的數字接近此值，建議您設定超過該限制 `spark.sql.shuffle.partitions` 的值，以取得更有效率的表示法。

## 最佳化隨機播放

`join()` 和 等特定操作 `groupByKey()` 需要 Spark 來執行隨機播放。隨機播放是 Spark 重新分配資料的機制，因此會在 RDD 分割區之間以不同的方式分組。隨機播放有助於修復效能瓶頸。不過，由於隨機播放通常涉及在 Spark 執行器之間複製資料，因此隨機播放是複雜且昂貴的操作。例如，隨機播放會產生下列成本：


- 磁碟輸入/輸出：
  - 在磁碟上產生大量中繼檔案。
- 網路 I/O：
  - 需要許多網路連線（連線數目 = Mapper × Reducer）。
  - 由於記錄會彙總到可能託管在不同 Spark 執行器上的新 RDD 分割區，因此您資料集的很大一部分可能會在 Spark 執行器之間透過網路移動。
- CPU 和記憶體負載：
  - 排序值並合併資料集。這些操作計劃在執行器上，對執行器施加繁重負載。

隨機播放是 Spark 應用程式效能降低的最重要因素之一。儲存中繼資料時，可能會耗盡執行器本機磁碟上的空間，這會導致 Spark 任務失敗。

您可以在 CloudWatch 指標和 Spark UI 中評估隨機播放效能。

## CloudWatch 指標

如果隨機播放位元組寫入值高於隨機播放位元組讀取，則 Spark 任務可能會使用[隨機播放操作](#)，例如 `join()` 或 `groupByKey()`。



## Spark 使用者介面

在 Spark UI 的階段索引標籤上，您可以檢查隨機讀取大小/記錄值。您也可以在執行器索引標籤上看到它。

在下列螢幕擷取畫面中，每個執行器會與隨機播放程序交換約 18.6GB/4020000 記錄，隨機播放讀取大小總計約為 75 GB)。

隨機溢出 (磁碟) 欄顯示大量資料溢出記憶體到磁碟，這可能會導致磁碟完整或效能問題。

- Aggregated Metrics by Executor				
Executor ID ▲	Address	Shuffle Read Size / Records	Shuffle Spill (Memory)	Shuffle Spill (Disk)
1	172.35.205.23:46731	18.6 GB / 40210300	98.1 GB	16.8 GB
2	172.35.195.173:46185	18.7 GB / 40246767	117.2 GB	17.3 GB
3	172.36.135.106:35913	18.6 GB / 40253921	101.6 GB	16.6 GB
4	172.34.131.223:46879	18.6 GB / 40190741	99.5 GB	16.4 GB

如果您觀察到這些症狀，而且與效能目標相比，階段需要太長的時間，或者失敗並出現 Out Of Memory 或 No space left on device 錯誤，請考慮下列解決方案。

## 最佳化聯結

此 `join()` 操作會聯結資料表，是最常用的隨機播放操作，但通常是效能瓶頸。由於加入是一項昂貴的操作，我們建議您不要使用它，除非它對您的業務需求至關重要。詢問下列問題，再次確認您有效使用資料管道：

- 您是否正在重新計算也可以在您可以重複使用的其他任務中執行的聯結？
- 您是否加入，將外部索引鍵解析為輸出消費者未使用的值？

在您確認加入操作對於您的業務需求至關重要之後，請參閱下列選項，以符合您需求的方式最佳化您的加入。

在加入之前使用下推

在執行聯結之前，篩選掉 DataFrame 中不必要的資料列和資料欄。這具有下列優點：

- 減少隨機播放期間的資料傳輸量
- 減少 Spark 執行器中的處理量
- 減少資料掃描量

```
# Default
df_joined = df1.join(df2, ["product_id"])

# Use Pushdown
```

```
df1_select =
  df1.select("product_id","product_title","star_rating").filter(col("star_rating")>=4.0)
df2_select = df2.select("product_id","category_id")
df_joined = df1_select.join(df2_select, ["product_id"])
```

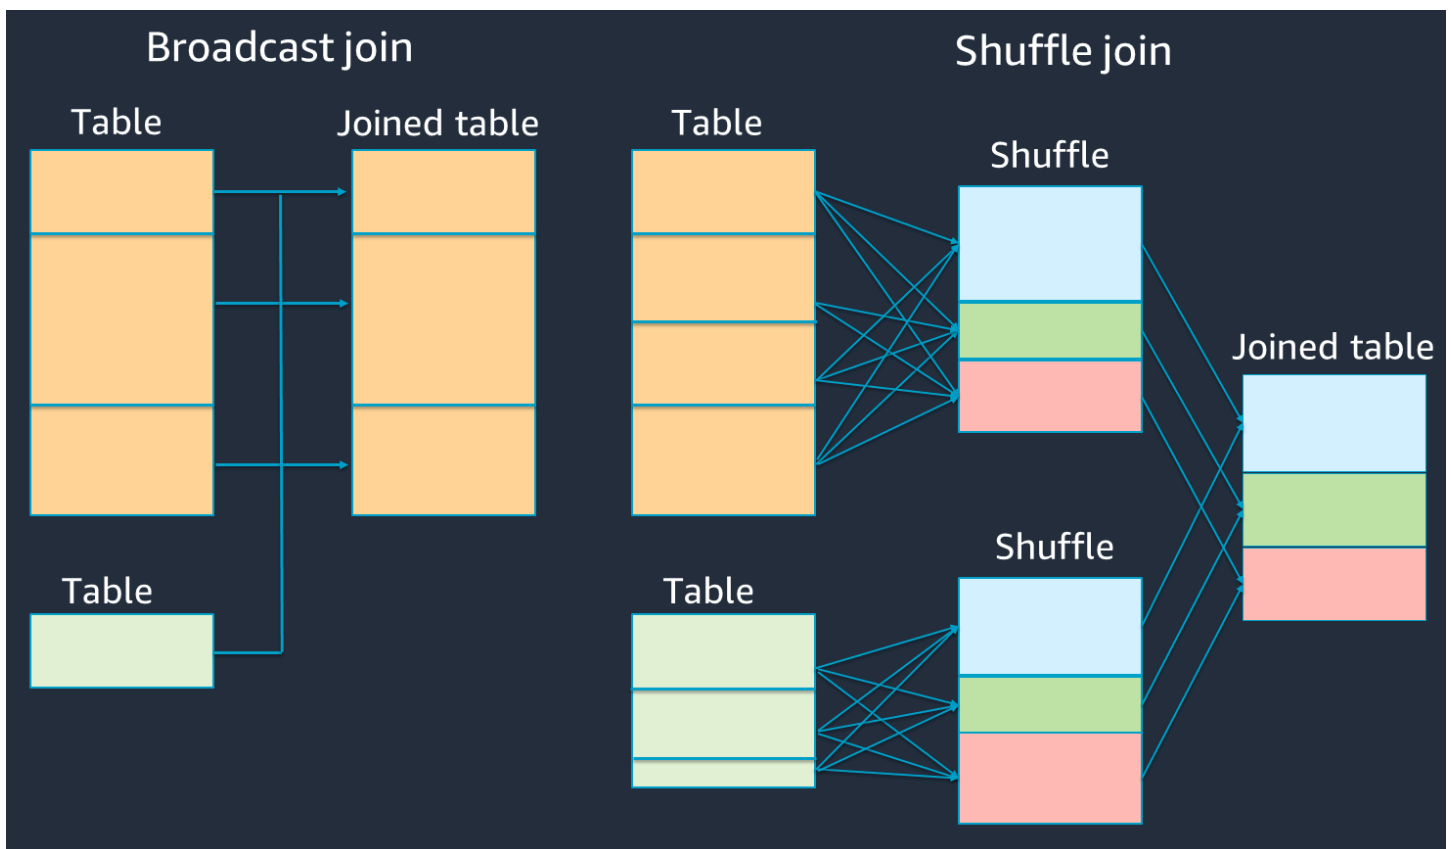
## 使用 DataFrame 聯結

嘗試使用 SparkSQL、DataFrame 和資料集等 Spark [高階 API](#)，而不是 RDD API 或 DynamicFrame 聯結。您可以使用 `df.toDF()` 方法呼叫，將 DynamicFrame 轉換為 DataFrame。如 [Apache Spark 中的關鍵主題章節所述](#)，這些聯結操作會在內部利用 Catalyst 最佳化工具的查詢最佳化。

## 隨機播放和廣播雜湊聯結和提示

Spark 支援兩種類型的聯結：隨機聯結和廣播雜湊聯結。廣播雜湊聯結不需要隨機播放，而且可能需比隨機播放聯結更少的處理。不過，它僅適用於將小型資料表加入大型資料表時。加入可放入單一 Spark 執行器記憶體中的資料表時，請考慮使用廣播雜湊聯結。

下圖顯示廣播雜湊聯結和隨機聯結的高階結構和步驟。



每個聯結的詳細資訊如下：

- 隨機聯結：
  - 隨機雜湊聯結會聯結兩個資料表，而不會排序和分配兩個資料表之間的聯結。它適用於可存放在 Spark 執行器記憶體中的小型資料表聯結。
  - 排序合併聯結會分配要依索引鍵聯結的兩個資料表，並在聯結之前對其進行排序。它適用於大型資料表的聯結。
- 廣播雜湊聯結：
  - 廣播雜湊聯結會將較小的 RDD 或資料表推送至每個工作者節點。然後，它會與較大 RDD 或資料表的每個分割區進行對應端組合。

當您的其中一個 RDDs 或資料表可以容納在記憶體中或可以容納在記憶體中時，它適用於聯結。盡可能進行廣播雜湊聯結是有益的，因為它不需要隨機播放。您可以使用聯結提示從 Spark 請求廣播聯結，如下所示。

```
# DataFrame
from pySpark.sql.functions import broadcast
df_joined= df_big.join(broadcast(df_small), right_df[key] == left_df[key],
    how='inner')

-- SparkSQL
SELECT /*+ BROADCAST(t1) / FROM t1 INNER JOIN t2 ON t1.key = t2.key;
```

如需聯結提示的詳細資訊，請參閱[聯結提示](#)。

在 AWS Glue 3.0 和更新版本中，您可以透過啟用[自適應查詢執行](#)和其他參數，自動利用廣播雜湊聯結。當任一聯結端的執行時間統計資料小於自適應廣播雜湊聯結閾值時，自適應查詢執行會將排序合併聯結轉換為廣播雜湊聯結。

在 AWS Glue 3.0 中，您可以透過設定 `spark.sql.adaptive.enabled=true` 來啟用自適應查詢執行。

`spark.sql.adaptive.enabled=true` 根據預設，AWS Glue 4.0 中會啟用自適應查詢執行。

您可以設定與隨機播放和廣播雜湊聯結相關的其他參數：

- `spark.sql.adaptive.localShuffleReader.enabled`
- `spark.sql.adaptive.autoBroadcastJoinThreshold`

如需相關參數的詳細資訊，請參閱[將排序合併聯結轉換為廣播聯結](#)。

在 AWS Glue 3.0 和更新版本中，您可以使用其他加入提示進行隨機播放來調整您的行為。

```

-- Join Hints for shuffle sort merge join
SELECT /*+ SHUFFLE_MERGE(t1) / FROM t1 INNER JOIN t2 ON t1.key = t2.key;
SELECT /*+ MERGEJOIN(t2) / FROM t1 INNER JOIN t2 ON t1.key = t2.key;
SELECT /*+ MERGE(t1) / FROM t1 INNER JOIN t2 ON t1.key = t2.key;

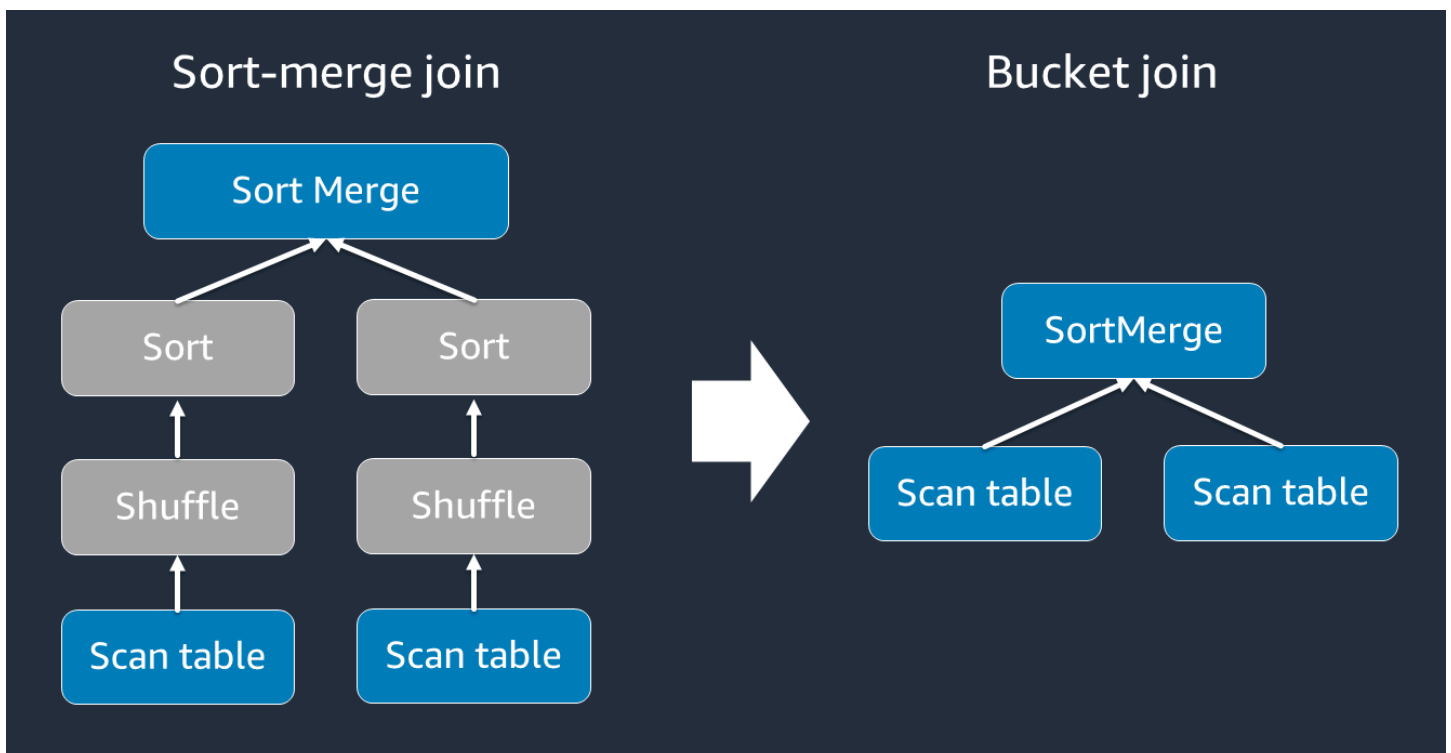
-- Join Hints for shuffle hash join
SELECT /*+ SHUFFLE_HASH(t1) / FROM t1 INNER JOIN t2 ON t1.key = t2.key;

-- Join Hints for shuffle-and-replicate nested loop join
SELECT /*+ SHUFFLE_REPLICATE_NL(t1) / FROM t1 INNER JOIN t2 ON t1.key = t2.key;

```

## 使用儲存貯體

排序合併聯結需要兩個階段：隨機排序和排序，然後合併。這兩個階段可能會使 Spark 執行器超載，並在某些執行器合併時導致 OOM 和效能問題，而其他執行器同時排序。在這種情況下，可以使用[儲存貯體](#)有效率地加入。儲存貯體會先隨機排序和預先排序您的輸入，然後將該排序資料寫入中介資料表。預先定義排序的中介資料表，可以降低合併大型資料表時的隨機排序和排序步驟成本。



儲存貯體資料表適用於下列項目：

- 經常透過相同索引鍵聯結的資料，例如 `account_id`
- 載入每日累積資料表，例如可在通用資料欄上儲存的基底和差異資料表

您可以使用下列程式碼建立儲存貯體資料表。

```
df.write.bucketBy(50, "account_id").sortBy("age").saveAsTable("bucketed_table")
```

在聯結前重新分割聯結金鑰上的 DataFrames

若要在聯結前重新分割聯結金鑰上的兩個 DataFrames，請使用下列陳述式。

```
df1_repartitioned = df1.repartition(N,"join_key")
df2_repartitioned = df2.repartition(N,"join_key")
df_joined = df1_repartitioned.join(df2_repartitioned,"product_id")
```


這會先在聯結金鑰上分割兩個（仍然分開）RDDs，再啟動聯結。如果兩個 RDDs 具有相同分割程式碼的相同金鑰上進行分割，則您計劃聯結的 RDD 記錄，在隨機切換聯結之前，會有很高的可能性共置在相同的工作者上。這可以透過減少聯結期間的網路活動和資料扭曲來改善效能。

## 克服資料扭曲

資料扭曲是 Spark 任務瓶頸的最常見原因之一。當資料未平均分散到 RDD 分割區時，就會發生這種情況。這會導致該分割區的任務花費比其他分割區長得多，因而延遲應用程式的整體處理時間。

若要識別資料扭曲，請在 Spark UI 中評估下列指標：

- 在 Spark UI 的階段索引標籤上，檢查事件時間軸頁面。您可以在下列螢幕擷取畫面中看到任務分佈不均勻。分佈不均勻或執行時間過長的任務可能表示資料扭曲。



- 另一個重要的頁面是摘要指標，顯示 Spark 任務的統計資料。下列螢幕擷取畫面顯示持續時間、GC 時間、溢出（記憶體）、溢出（磁碟）等具有百分位數的指標。

Metric	Min	25th percentile	Median	75th percentile	Max
Duration	9 s	10 s	11 s	13 s	6.4 min
GC Time	0.0 ms	0.2 s	0.3 s	0.4 s	1 s
Spill (memory)	0.0 B	0.0 B	0.0 B	0.0 B	16.7 GiB
Spill (disk)	0.0 B	0.0 B	0.0 B	0.0 B	10.2 GiB
Output Size / Records	8.3 MiB / 12651	9.4 MiB / 21462	36.1 MiB / 63860	92.9 MiB / 258057	10.1 GiB / 20370130
Shuffle Read Size / Records	9.8 MiB / 12651	11.7 MiB / 21462	43.4 MiB / 63860	122.6 MiB / 258057	11.8 GiB / 20370130

當任務平均分散時，您會在所有百分位數中看到類似的數字。當資料扭曲時，您會在每個百分位數中看到非常偏差的值。在此範例中，任務持續時間在最小值、第 25 個百分位數、中位數和第 75 個百分位數小於 13 秒。雖然 Max 任務處理的資料是第 75 個百分位數的 100 倍，但其 6.4 分鐘的持續時間約為 30 倍。這表示至少有一個任務（或最多 25% 的任務）花費比其餘任務長得多。

如果您看到資料扭曲，請嘗試下列動作：

- 如果您使用 AWS Glue 3.0，請設定 `spark.sql.adaptive.enabled=true` 來啟用自適應查詢執行。預設會在 AWS Glue 4.0 中啟用自適應查詢執行。

您也可以透過設定下列相關參數，將自適應查詢執行用於連結引入的資料扭曲：

- `spark.sql.adaptive.skewJoin.skewedPartitionFactor`
- `spark.sql.adaptive.skewJoin.skewedPartitionThresholdInBytes`
- `spark.sql.adaptive.advisoryPartitionSizeInBytes=128m` (128 mebibytes or larger should be good)
- `spark.sql.adaptive.coalescePartitions.enabled=true` (when you want to coalesce partitions)

如需詳細資訊，請參閱 [Apache Spark 文件](#)。

- 對連結索引鍵使用具有大量值的索引鍵。在隨機連結中，會針對金鑰的每個雜湊值決定分割區。如果連結金鑰的基數太低，雜湊函數更有可能在跨分割區分佈資料時執行不好的任務。因此，如果您的應用程式和商業邏輯支援它，請考慮使用較高的基數索引鍵或複合索引鍵。

```
# Use Single Primary Key
df_joined = df1_select.join(df2_select, ["primary_key"])

# Use Composite Key
df_joined = df1_select.join(df2_select, ["primary_key", "secondary_key"])
```

## 使用快取

當您使用重複DataFrames時，請使用 `df.persist()` 將計算結果快取到每個 Spark 執行器的記憶體和磁碟上，以避免額外的隨機播放`df.cache()`或運算。Spark 也支援在磁碟上保留 RDDs 或跨多個節點複寫 ([儲存層級](#))。

例如，您可以透過新增 `df.persist()` 來保留 DataFrames。當不再需要快取時，您可以使用 `df.unpersist()` 來捨棄快取的資料。

```
df = spark.read.parquet("s3://<Bucket>/parquet/product_category=Books/")
df_high_rate = df.filter(col("star_rating")>=4.0)
df_high_rate.persist()

df_joined1 = df_high_rate.join(<Table1>, ["key"])
df_joined2 = df_high_rate.join(<Table2>, ["key"])
df_joined3 = df_high_rate.join(<Table3>, ["key"])
...
df_high_rate.unpersist()
```

## 移除不需要的 Spark 動作

避免執行不必要的動作，例如 `count`、`show` 或 `collect`。如 [Apache Spark 中的關鍵主題一節中所述](#)，Spark 是延遲的。每次執行動作時，可能會重新計算每個轉換的 RDD。當您使用許多 Spark 動作時，會呼叫每個動作的多個來源存取、任務計算和隨機執行。

如果您在商業環境中不需要 `collect()` 或其他動作，請考慮將其移除。

### Note

盡可能避免`collect()`在商業環境中使用 Spark。`collect()` 動作會將 Spark 執行器中計算的所有結果傳回 Spark 驅動程式，這可能會導致 Spark 驅動程式傳回 OOM 錯誤。為了避免 OOM 錯誤，Spark `spark.driver.maxResultSize = 1GB` 預設會設定，將傳回 Spark 驅動程式的資料大小上限限制為 1 GB。


## 將規劃開銷降至最低

如 [Apache Spark 中討論的關鍵主題](#)所述，Spark 驅動程式會產生執行計畫。根據該計畫，任務會指派給 Spark 執行器以進行分散式處理。不過，如果有大量小型檔案或 包含大量分割區，AWS Glue Data Catalog Spark 驅動程式可能會成為瓶頸。若要識別高規劃開銷，請評估下列指標。

## CloudWatch 指標

檢查 CPU 負載和記憶體使用率是否有下列情況：

- Spark 驅動程式 CPU 負載和記憶體使用率會記錄為高。一般而言，Spark 驅動程式不會處理您的資料，因此 CPU 負載和記憶體使用率不會遽增。不過，如果 Amazon S3 資料來源有太多小型檔案，列出所有 S3 物件和管理大量任務可能會導致資源使用率過高。
- 在 Spark 執行器中開始處理之前有很長的間隙。在下列範例螢幕擷取畫面中，Spark 執行器的 CPU 負載太低，直到 10:57，即使 AWS Glue 任務是從 10:00 開始。這表示 Spark 驅動程式可能需要很長的時間才能產生執行計畫。在此範例中，擷取 Data Catalog 中的大量分割區，並列出 Spark 驅動程式中的大量小型檔案需要很長的時間。



## Spark 使用者介面

在 Spark UI 的任務索引標籤上，您可以看到提交的時間。在下列範例中，Spark 驅動程式在 10:56:46 啟動 job0，即使 AWS Glue 任務在 10:00:00 啟動。

Job Id	Description	Submitted	Duration	Stages: Succeeded/Total	Tasks (for all stages): Succeeded/Total
0	count at DynamicFrame.scala:1414 count at DynamicFrame.scala:1414	2023/04/18 10:56:46	4.9 h	1/1	58100/58100

您也可以在任務索引標籤上查看任務（所有階段）：成功/總時間。在此情況下，任務數量會記錄為 58100。如[平行處理任務](#)頁面的 Amazon S3 一節中所述，任務數量大約對應至 S3 物件數量。這表示 Amazon S3 中大約有 58,100 個物件。

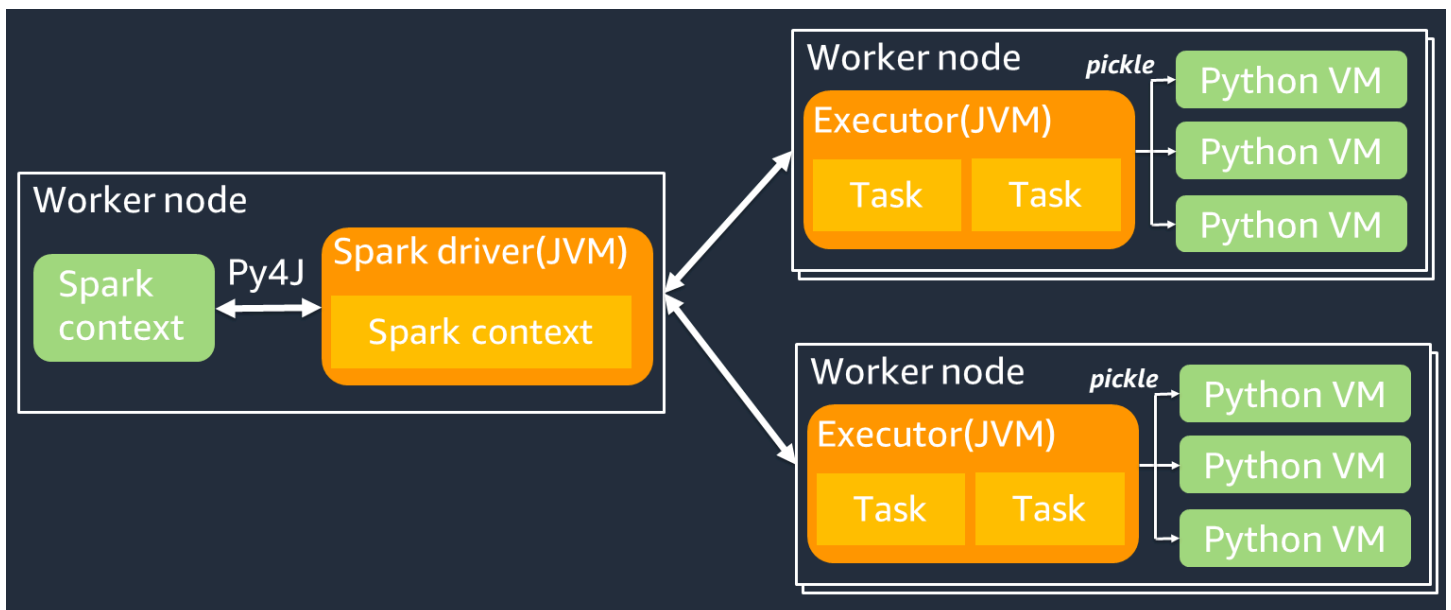
如需此任務和時間軸的詳細資訊，請檢閱階段索引標籤。如果您發現 Spark 驅動程式存在瓶頸，請考慮下列解決方案：

- 當 Amazon S3 有太多檔案時，請考慮[平行處理任務](#)頁面的太多分割區區段中有關過度平行處理的指引。
- 當 Amazon S3 有太多分割區時，請考慮[減少資料掃描](#)頁面的太多 Amazon S3 分割區區段中有關過度分割區的指引。如果有許多分割區可降低從 Data Catalog 擷取分割區中繼資料的延遲，請啟用[AWS Glue 分割區索引](#)。如需詳細資訊，請參閱[使用 AWS Glue 分割區索引改善查詢效能](#)。
- 當 JDBC 有太多分割區時，請降低該hashpartition值。
- 當 DynamoDB 有太多分割區時，請降低該dynamodb.splits值。
- 當串流任務具有太多分割區時，請降低碎片的數量。

## 最佳化使用者定義的函數

PySpark RDD.map中的使用者定義函數 (UDFs) 和 通常會大幅降低效能。PySpark 這是因為在 Spark 的基礎 Scala 實作中準確代表 Python 程式碼所需的額外負荷。

下圖顯示 PySpark 任務的架構。當您使用 PySpark 時，Spark 驅動程式會使用 Py4j 程式庫從 Python 呼叫 Java 方法。呼叫 Spark SQL 或 DataFrame 內建函數時，Python 和 Scala 之間的效能差異不大，因為這些函數使用最佳化的執行計畫在每個執行器的 JVM 上執行。



如果您使用自己的 Python 邏輯，例如使用 map/ mapPartitions/ udf，任務將在 Python 執行時間環境中執行。管理兩個環境會產生額外負荷成本。此外，您必須轉換記憶體中的資料，以供 JVM 執

行時間環境的內建函數使用。Pickle 是預設用於 JVM 和 Python 執行時間之間交換的序列化格式。不過，此序列化和還原序列化的成本非常高，因此以 Java 或 Scala 編寫的 UDFs 比 Python UDFs 更快。

若要避免 PySpark 中的序列化和還原序列化額外負荷，請考慮下列事項：

- 使用內建 Spark SQL 函數 – 考慮使用 Spark SQL 或 DataFrame 內建函數取代您自己的 UDF 或映射函數。執行 Spark SQL 或 DataFrame 內建函數時，Python 和 Scala 之間的效能差異不大，因為任務會在每個執行器的 JVM 上處理。
- 在 Scala 或 Java 中實作 UDFs – 考慮使用以 Java 或 Scala 撰寫的 UDF，因為它們在 JVM 上執行。
- 將 Apache Arrow 型 UDFs 用於向量化工作負載 – 考慮使用 Arrow 型 UDFs。此功能也稱為向量化 UDF (Pandas UDF)。[Apache Arrow](#) 是一種與語言無關的記憶體內資料格式，AWS Glue 可用來在 JVM 和 Python 程序之間有效率地傳輸資料。這目前對使用 Pandas 或 NumPy 資料的 Python 使用者最有益。

Arrow 是一種單欄式（向量化）格式。其用量並非自動，可能需要稍微變更組態或程式碼，才能充分利用並確保相容性。如需詳細資訊和限制，請參閱 [PySpark 中的 Apache Arrow](#)。

下列範例會比較標準 Python、向量化 UDF 和 Spark SQL 中的基本增量 UDF。

## 標準 Python UDF

範例時間為 3.20（秒）。

範例程式碼

```
# DataSet
df = spark.range(10000000).selectExpr("id AS a","id AS b")

# UDF Example
def plus(a,b):
    return a+b
spark.udf.register("plus",plus)

df.selectExpr("count(plus(a,b))").collect()
```

執行計畫

```
== Physical Plan ==
```

```

AdaptiveSparkPlan isFinalPlan=false
+- HashAggregate(keys=[], functions=[count(pythonUDF0#124)])
+- Exchange SinglePartition, ENSURE_REQUIREMENTS, [id=#580]
+- HashAggregate(keys=[], functions=[partial_count(pythonUDF0#124)])
+- Project [pythonUDF0#124]
+- BatchEvalPython [plus(a#116L, b#117L)], [pythonUDF0#124]
+- Project [id#114L AS a#116L, id#114L AS b#117L]
+- Range (0, 10000000, step=1, splits=16)

```

## 向量化 UDF

範例時間為 0.59 ( 秒 )。

向量化 UDF 比上一個 UDF 範例快 5 倍。檢查 Physical Plan 時，您可以看到 ArrowEvalPython，顯示此應用程式是由 Apache Arrow 向量化。若要啟用向量化 UDF，您必須在程式碼 `spark.sql.execution.arrow.pyspark.enabled = true` 中指定。

### 範例程式碼

```

# Vectorized UDF
from pyspark.sql.types import LongType
from pyspark.sql.functions import count, pandas_udf

# Enable Apache Arrow Support
spark.conf.set("spark.sql.execution.arrow.pyspark.enabled", "true")

# DataSet
df = spark.range(10000000).selectExpr("id AS a","id AS b")

# Annotate pandas_udf to use Vectorized UDF
@pandas_udf(LongType())
def pandas_plus(a,b):
    return a+b
spark.udf.register("pandas_plus",pandas_plus)

df.selectExpr("count(pandas_plus(a,b))").collect()

```

### 執行計畫

```

== Physical Plan ==
AdaptiveSparkPlan isFinalPlan=false

```

```
+ HashAggregate(keys=[], functions=[count(pythonUDF0#1082L)],
  output=[count(pandas_plus(a, b))#1080L])
+ Exchange SinglePartition, ENSURE_REQUIREMENTS, [id=#5985]
+ HashAggregate(keys=[], functions=[partial_count(pythonUDF0#1082L)],
  output=[count#1084L])
+ Project [pythonUDF0#1082L]
+ ArrowEvalPython [pandas_plus(a#1074L, b#1075L)], [pythonUDF0#1082L], 200
+ Project [id#1072L AS a#1074L, id#1072L AS b#1075L]
+ Range (0, 10000000, step=1, splits=16)
```

## Spark SQL

範例時間為 0.087 ( 秒 )。

Spark SQL 比量化 UDF 快得多，因為任務會在每個執行器的 JVM 上執行，而沒有 Python 執行時間。如果您可以使用內建函數取代 UDF，建議您這麼做。

範例程式碼

```
df.createOrReplaceTempView("test")
spark.sql("select count(a+b) from test").collect()
```

## 將 panda 用於大數據

如果您已經熟悉 [pandas](#) 並想要將 Spark 用於大數據，則可以在 Spark. AWS Glue 4.0 上使用 pandas API 和更新版本支援它。若要開始使用，您可以使用官方筆記本 [Quickstart : Pandas API on Spark](#)。如需詳細資訊，請參閱 [PySpark 文件](#)。

## 資源

- [AWS Glue](#)
- [效能調校](#) (Spark SQL 指南 )
- [AWS Glue 最佳化研討會](#)

## 文件歷史紀錄

下表描述了本指南的重大變更。如果您想收到有關未來更新的通知，可以訂閱 [RSS 摘要](#)。

變更	描述	日期
<a href="#">初次出版</a>	—	2024 年 1 月 2 日

# AWS 規範性指引詞彙表

以下是 AWS Prescriptive Guidance 提供的策略、指南和模式中常用的術語。若要建議項目，請使用詞彙表末尾的提供意見回饋連結。

## 數字

### 7 R

將應用程式移至雲端的七種常見遷移策略。這些策略以 Gartner 在 2011 年確定的 5 R 為基礎，包括以下內容：

- 重構/重新架構 – 充分利用雲端原生功能來移動應用程式並修改其架構，以提高敏捷性、效能和可擴展性。這通常涉及移植作業系統和資料庫。範例：將您的現場部署 Oracle 資料庫 遷移至 Amazon Aurora PostgreSQL 相容版本。
- 平台轉換 (隨即重塑) – 將應用程式移至雲端，並引入一定程度的優化以利用雲端功能。範例：將內部部署 Oracle 資料庫 遷移至 中的 Amazon Relational Database Service (Amazon RDS) for Oracle AWS 雲端。
- 重新購買 (捨棄再購買) – 切換至不同的產品，通常從傳統授權移至 SaaS 模型。範例：將您的客戶關係管理 (CRM) 系統 遷移至 Salesforce.com。
- 主機轉換 (隨即轉移) – 將應用程式移至雲端，而不進行任何變更以利用雲端功能。範例：將您的現場部署 Oracle 資料庫 遷移至 中 EC2 執行個體上的 Oracle AWS 雲端。
- 重新放置 (虛擬機器監視器等級隨即轉移) – 將基礎設施移至雲端，無需購買新硬體、重寫應用程式或修改現有操作。您可以將伺服器從內部部署平台遷移到相同平台的雲端服務。範例：將 Microsoft Hyper-V 應用程式 遷移至 AWS。
- 保留 (重新檢視) – 將應用程式保留在來源環境中。其中可能包括需要重要重構的應用程式，且您希望將該工作延遲到以後，以及您想要保留的舊版應用程式，因為沒有業務理由來進行遷移。
- 淘汰 – 解除委任或移除來源環境中不再需要的應用程式。

## A

### ABAC

請參閱 [屬性型存取控制](#)。

## 抽象服務

請參閱 [受管服務](#)。

## ACID

請參閱 [原子性、一致性、隔離性、持久性](#)。

## 主動-主動式遷移

一種資料庫遷移方法，其中來源和目標資料庫保持同步 (透過使用雙向複寫工具或雙重寫入操作)，且兩個資料庫都在遷移期間處理來自連接應用程式的交易。此方法支援小型、受控制批次的遷移，而不需要一次性切換。它更靈活，但比 [主動-被動遷移](#) 需要更多的工作。

## 主動-被動式遷移

一種資料庫遷移方法，其中來源和目標資料庫保持同步，但只有來源資料庫會在資料複寫至目標資料庫時處理來自連線應用程式的交易。目標資料庫在遷移期間不接受任何交易。

## 彙總函數

在一組資料列上運作的 SQL 函數，會計算群組的單一傳回值。彙總函數的範例包括 SUM 和 MAX。

## AI

請參閱 [人工智慧](#)。

## AIOps

請參閱 [人工智慧操作](#)。

## 匿名化

永久刪除資料集中個人資訊的程序。匿名化有助於保護個人隱私權。匿名資料不再被視為個人資料。

## 反模式

經常用於經常性問題的解決方案，其中解決方案具有反生產力、無效或比替代解決方案更有效。

## 應用程式控制

一種安全方法，僅允許使用核准的應用程式，以協助保護系統免受惡意軟體攻擊。

## 應用程式組合

有關組織使用的每個應用程式的詳細資訊的集合，包括建置和維護應用程式的成本及其商業價值。此資訊是 [產品組合探索和分析程序](#) 的關鍵，有助於識別要遷移、現代化和優化的應用程式並排定其優先順序。

## 人工智慧 (AI)

電腦科學領域，致力於使用運算技術來執行通常與人類相關的認知功能，例如學習、解決問題和識別模式。如需詳細資訊，請參閱[什麼是人工智慧？](#)

## 人工智慧操作 (AIOps)

使用機器學習技術解決操作問題、減少操作事件和人工干預以及提高服務品質的程序。如需有關如何在 AWS 遷移策略中使用 AIOps 的詳細資訊，請參閱[操作整合指南](#)。

## 非對稱加密

一種加密演算法，它使用一對金鑰：一個用於加密的公有金鑰和一個用於解密的私有金鑰。您可以共用公有金鑰，因為它不用於解密，但對私有金鑰存取應受到高度限制。

## 原子性、一致性、隔離性、持久性 (ACID)

一組軟體屬性，即使在出現錯誤、電源故障或其他問題的情況下，也能確保資料庫的資料有效性和操作可靠性。

## 屬性型存取控制 (ABAC)

根據使用者屬性 (例如部門、工作職責和團隊名稱) 建立精細許可的實務。如需詳細資訊，請參閱《AWS Identity and Access Management (IAM) 文件》中的[ABAC for AWS](#)。

## 授權資料來源

存放主要版本資料的位置，被視為最可靠的資訊來源。您可以將授權資料來源中的資料複製到其他位置，以處理或修改資料，例如匿名、修訂或假名化資料。

## 可用區域

中的不同位置 AWS 區域，可隔離其他可用區域中的故障，並提供相同區域中其他可用區域的低成本、低延遲網路連線能力。

## AWS 雲端採用架構 (AWS CAF)

的指導方針和最佳實務架構 AWS，可協助組織制定高效且有效的計劃，以成功地移至雲端。AWS CAF 將指導方針組織到六個重點領域：業務、人員、治理、平台、安全和營運。業務、人員和控管層面著重於業務技能和程序；平台、安全和操作層面著重於技術技能和程序。例如，人員層面針對處理人力資源 (HR)、人員配備功能和人員管理的利害關係人。因此，AWS CAF 為人員開發、訓練和通訊提供指引，協助組織做好成功採用雲端的準備。如需詳細資訊，請參閱[AWS CAF 網站](#)和[AWS CAF 白皮書](#)。

## AWS 工作負載資格架構 (AWS WQF)

評估資料庫遷移工作負載、建議遷移策略並提供工作預估值的工具。AWS WQF 隨附於 AWS Schema Conversion Tool (AWS SCT)。它會分析資料庫結構描述和程式碼物件、應用程式程式碼、相依性和效能特性，並提供評估報告。

## B

### 錯誤的機器人

旨在中斷或傷害個人或組織的[機器人](#)。

### BCP

請參閱[業務持續性規劃](#)。

### 行為圖

資源行為的統一互動式檢視，以及一段時間後的互動。您可以將行為圖與 Amazon Detective 搭配使用來檢查失敗的登入嘗試、可疑的 API 呼叫和類似動作。如需詳細資訊，請參閱偵測文件中的[行為圖中的資料](#)。

### 大端序系統

首先儲存最高有效位元組的系統。另請參閱 [Endianness](#)。

### 二進制分類

預測二進制結果的過程 (兩個可能的類別之一)。例如，ML 模型可能需要預測諸如「此電子郵件是否是垃圾郵件？」等問題 或「產品是書還是汽車？」

### Bloom 篩選條件

一種機率性、記憶體高效的資料結構，用於測試元素是否為集的成員。

### 藍/綠部署

一種部署策略，您可以在其中建立兩個不同但相同的環境。您可以在一個環境（藍色）中執行目前的應用程式版本，並在另一個環境（綠色）中執行新的應用程式版本。此策略可協助您快速復原，並將影響降至最低。

### 機器人

透過網際網路執行自動化任務並模擬人類活動或互動的軟體應用程式。有些机器人有用或有益，例如在網際網路上編製資訊索引的 Web 爬蟲程式。某些其他机器人稱為惡意机器人，旨在中斷或傷害個人或組織。

## 殭屍網路

受到[惡意軟體](#)感染且受單一方控制之[機器人的](#)網路，稱為機器人繼承器或機器人運算子。殭屍網路是擴展機器人及其影響的最佳已知機制。

## 分支

程式碼儲存庫包含的區域。儲存庫中建立的第一個分支是主要分支。您可以從現有分支建立新分支，然後在新分支中開發功能或修正錯誤。您建立用來建立功能的分支通常稱為功能分支。當準備好發佈功能時，可以將功能分支合併回主要分支。如需詳細資訊，請參閱[關於分支](#) (GitHub 文件)。

## 碎片存取

在特殊情況下，以及透過核准的程序，讓使用者快速取得他們通常無權存取 AWS 帳戶 之 的存取權。如需詳細資訊，請參閱 Well-Architected 指南中的 AWS [實作打破玻璃程序](#) 指標。

## 棕地策略

環境中的現有基礎設施。對系統架構採用棕地策略時，可以根據目前系統和基礎設施的限制來設計架構。如果正在擴展現有基礎設施，則可能會混合棕地和[綠地](#)策略。

## 緩衝快取

儲存最常存取資料的記憶體區域。

## 業務能力

業務如何創造價值 (例如，銷售、客戶服務或營銷)。業務能力可驅動微服務架構和開發決策。如需詳細資訊，請參閱在 [AWS 上執行容器化微服務](#) 白皮書的 [圍繞業務能力進行組織](#) 部分。

## 業務連續性規劃 (BCP)

一種解決破壞性事件 (如大規模遷移) 對營運的潛在影響並使業務能夠快速恢復營運的計畫。

# C

## CAF

請參閱[AWS 雲端採用架構](#)。

## Canary 部署

版本對最終使用者的緩慢和增量版本。當您有信心時，您可以部署新版本並完全取代目前的版本。

## CCoE

請參閱 [Cloud Center of Excellence](#)。

## CDC

請參閱[變更資料擷取](#)。

### 變更資料擷取 (CDC)

追蹤對資料來源 (例如資料庫表格) 的變更並記錄有關變更的中繼資料的程序。您可以將 CDC 用於各種用途，例如稽核或複寫目標系統中的變更以保持同步。

### 混沌工程

故意引入故障或破壞性事件，以測試系統的彈性。您可以使用 [AWS Fault Injection Service \(AWS FIS\)](#) 執行實驗，為您的 AWS 工作負載帶來壓力，並評估其回應。

## CI/CD

請參閱[持續整合和持續交付](#)。

### 分類

有助於產生預測的分類程序。用於分類問題的 ML 模型可預測離散值。離散值永遠彼此不同。例如，模型可能需要評估影像中是否有汽車。

### 用戶端加密

在目標 AWS 服務接收資料之前，在本機加密資料。

### 雲端卓越中心 (CCoE)

一個多學科團隊，可推動整個組織的雲端採用工作，包括開發雲端最佳實務、調動資源、制定遷移時間表以及領導組織進行大規模轉型。如需詳細資訊，請參閱 AWS 雲端企業策略部落格上的 [CCoE 文章](#)。

### 雲端運算

通常用於遠端資料儲存和 IoT 裝置管理的雲端技術。雲端運算通常連接到[邊緣運算](#)技術。

### 雲端操作模型

在 IT 組織中，用於建置、成熟和最佳化一或多個雲端環境的操作模型。如需詳細資訊，請參閱[建置您的雲端操作模型](#)。

### 採用雲端階段

組織在遷移至時通常會經歷的四個階段 AWS 雲端：

- 專案 – 執行一些與雲端相關的專案以進行概念驗證和學習用途
- 基礎 – 進行基礎投資以擴展雲端採用 (例如，建立登陸區域、定義 CCoE、建立營運模型)

- 遷移 – 遷移個別應用程式
- 重塑 – 優化產品和服務，並在雲端中創新

這些階段由 Stephen Orban 在部落格文章 [The Journey Toward Cloud-First](#) 和 [企業策略部落格上的採用階段](#) 中定義。AWS 雲端 如需有關它們如何與 AWS 遷移策略相關的詳細資訊，請參閱 [遷移整備指南](#)。

## CMDB

請參閱 [組態管理資料庫](#)。

## 程式碼儲存庫

透過版本控制程序來儲存及更新原始程式碼和其他資產 (例如文件、範例和指令碼) 的位置。常見的雲端儲存庫包括 GitHub 或 Bitbucket Cloud。程式碼的每個版本都稱為分支。在微服務結構中，每個儲存庫都專用於單個功能。單一 CI/CD 管道可以使用多個儲存庫。

## 冷快取

一種緩衝快取，它是空的、未填充的，或者包含過時或不相關的資料。這會影響效能，因為資料庫執行個體必須從主記憶體或磁碟讀取，這比從緩衝快取讀取更慢。

## 冷資料

很少存取且通常是歷史資料的資料。查詢這類資料時，通常可接受慢查詢。將此資料移至效能較低且成本較低的儲存層或類別，可以降低成本。

## 電腦視覺 (CV)

AI 欄位 [???](#)，使用機器學習從數位影像和影片等視覺化格式分析和擷取資訊。例如，Amazon SageMaker AI 提供 CV 的影像處理演算法。

## 組態偏離

對於工作負載，組態會從預期狀態變更。這可能會導致工作負載不合規，而且通常是漸進和無意的。

## 組態管理資料庫 (CMDB)

儲存和管理有關資料庫及其 IT 環境的資訊的儲存庫，同時包括硬體和軟體元件及其組態。您通常在遷移的產品組合探索和分析階段使用 CMDB 中的資料。

## 一致性套件

您可以組合的 AWS Config 規則和修補動作集合，以自訂您的合規和安全檢查。您可以使用 YAML 範本，將一致性套件部署為 AWS 帳戶 和 區域中或整個組織的單一實體。如需詳細資訊，請參閱 AWS Config 文件中的 [一致性套件](#)。

## 持續整合和持續交付 (CI/CD)

自動化軟體發程序的來源、建置、測試、暫存和生產階段的程序。CI/CD 通常被描述為管道。CI/CD 可協助您將程序自動化、提升生產力、改善程式碼品質以及加快交付速度。如需詳細資訊，請參閱[持續交付的優點](#)。CD 也可表示持續部署。如需詳細資訊，請參閱[持續交付與持續部署](#)。

## CV

請參閱[電腦視覺](#)。

## D

### 靜態資料

網路中靜止的資料，例如儲存中的資料。

### 資料分類

根據重要性和敏感性來識別和分類網路資料的程序。它是所有網路安全風險管理策略的關鍵組成部分，因為它可以協助您確定適當的資料保護和保留控制。資料分類是 AWS Well-Architected Framework 中安全支柱的元件。如需詳細資訊，請參閱[資料分類](#)。

### 資料偏離

生產資料與用於訓練 ML 模型的資料之間有意義的變化，或輸入資料隨時間有意義的變更。資料偏離可以降低 ML 模型預測的整體品質、準確性和公平性。

### 傳輸中的資料

在您的網路中主動移動的資料，例如在網路資源之間移動。

### 資料網格

架構架構，提供分散式、分散式資料擁有權與集中式管理。

### 資料最小化

僅收集和處理嚴格必要資料的原則。在中實作資料最小化 AWS 雲端可以降低隱私權風險、成本和分析碳足跡。

### 資料周邊

AWS 環境中的一組預防性防護機制，可協助確保只有信任的身分才能從預期的網路存取信任的資源。如需詳細資訊，請參閱[在上建置資料周邊 AWS](#)。

## 資料預先處理

將原始資料轉換成 ML 模型可輕鬆剖析的格式。預處理資料可能意味著移除某些欄或列，並解決遺失、不一致或重複的值。

## 資料來源

在整個生命週期中追蹤資料的原始伺服器 and 歷史記錄的程序，例如資料的產生、傳輸和儲存方式。

## 資料主體

正在收集和處理資料的個人。

## 資料倉儲

支援商業智慧的資料管理系統，例如分析。資料倉儲通常包含大量歷史資料，通常用於查詢和分析。

## 資料庫定義語言 (DDL)

用於建立或修改資料庫中資料表和物件之結構的陳述式或命令。

## 資料庫處理語言 (DML)

用於修改 (插入、更新和刪除) 資料庫中資訊的陳述式或命令。

## DDL

請參閱[資料庫定義語言](#)。

## 深度整體

結合多個深度學習模型進行預測。可以使用深度整體來獲得更準確的預測或估計預測中的不確定性。

## 深度學習

一個機器學習子領域，它使用多層人工神經網路來識別感興趣的輸入資料與目標變數之間的對應關係。

## 深度防禦

這是一種資訊安全方法，其中一系列的安全機制和控制項會在整個電腦網路中精心分層，以保護網路和其中資料的機密性、完整性和可用性。當您在上採用此策略時 AWS，您可以在 AWS Organizations 結構的不同層新增多個控制項，以協助保護資源。例如，defense-in-depth 方法可能會結合多重驗證、網路分割和加密。

## 委派的管理員

在中 AWS Organizations，相容的服務可以註冊 AWS 成員帳戶，以管理組織的帳戶和管理該服務的許可。此帳戶稱為該服務的委派管理員。如需詳細資訊和相容服務清單，請參閱 AWS Organizations 文件中的[可搭配 AWS Organizations運作的服務](#)。

## deployment

在目標環境中提供應用程式、新功能或程式碼修正的程序。部署涉及在程式碼庫中實作變更，然後在應用程式環境中建置和執行該程式碼庫。

## 開發環境

請參閱[環境](#)。

## 偵測性控制

一種安全控制，用於在事件發生後偵測、記錄和提醒。這些控制是第二道防線，提醒您注意繞過現有預防性控制的安全事件。如需詳細資訊，請參閱在 AWS 上實作安全控制中的[偵測性控制](#)。

## 開發值串流映射 (DVSM)

一種程序，用於識別並優先考慮對軟體開發生命週期中的速度和品質造成負面影響的限制。DVSM 延伸了原本專為精簡製造實務設計的價值串流映射程序。它著重於透過軟體開發程序建立和移動價值所需的步驟和團隊。

## 數位分身

真實世界系統的虛擬呈現，例如建築物、工廠、工業設備或生產線。數位分身支援預測性維護、遠端監控和生產最佳化。

## 維度資料表

在[星星結構描述](#)中，較小的資料表包含有關事實資料表中量化資料的資料屬性。維度資料表屬性通常是文字欄位或離散數字，其行為與文字相似。這些屬性通常用於查詢限制、篩選和結果集標記。

## 災難

防止工作負載或系統在其主要部署位置實現其業務目標的事件。這些事件可能是自然災難、技術故障或人為動作的結果，例如意外設定錯誤或惡意軟體攻擊。

## 災難復原 (DR)

您用來將[災難](#)造成的停機時間和資料遺失降至最低的策略和程序。如需詳細資訊，請參閱 AWS Well-Architected Framework 中的[上工作負載的災難復原 AWS：雲端中的復原](#)。

## DML

請參閱[資料庫處理語言](#)。

## 領域驅動的設計

一種開發複雜軟體系統的方法，它會將其元件與每個元件所服務的不斷發展的領域或核心業務目標相關聯。Eric Evans 在其著作 *Domain-Driven Design: Tackling Complexity in the Heart of Software* (Boston: Addison-Wesley Professional, 2003) 中介紹了這一概念。如需有關如何將領域驅動的設計與 strangler fig 模式搭配使用的資訊，請參閱[使用容器和 Amazon API Gateway 逐步現代化舊版 Microsoft ASP.NET \(ASMX\) Web 服務](#)。

## DR

請參閱[災難復原](#)。

## 偏離偵測

追蹤與基準組態的偏差。例如，您可以使用 AWS CloudFormation 來偵測系統資源中的偏離，也可以使用 AWS Control Tower 來[偵測登陸區域中可能影響控管要求合規性的變更](#)。<https://docs.aws.amazon.com/AWSCloudFormation/latest/UserGuide/using-cfn-stack-drift.html>

## DVSM

請參閱[開發值串流映射](#)。

## E

### EDA

請參閱[探索性資料分析](#)。

### EDI

請參閱[電子資料交換](#)。

## 邊緣運算

提升 IoT 網路邊緣智慧型裝置運算能力的技術。與[雲端運算](#)相比，邊緣運算可以減少通訊延遲並改善回應時間。

## 電子資料交換 (EDI)

在組織之間自動交換商業文件。如需詳細資訊，請參閱[什麼是電子資料交換](#)。

## 加密

將人類可讀取的純文字資料轉換為加密文字的運算程序。

### 加密金鑰

由加密演算法產生的隨機位元的加密字串。金鑰長度可能有所不同，每個金鑰的設計都是不可預測且唯一的。

### 端序

位元組在電腦記憶體中的儲存順序。大端序系統首先儲存最高有效位元組。小端序系統首先儲存最低有效位元組。

### 端點

請參閱 [服務端點](#)。

### 端點服務

您可以在虛擬私有雲端 (VPC) 中託管以與其他使用者共用的服務。您可以使用 [建立端點服務](#)，AWS PrivateLink 並將許可授予其他 AWS 帳戶 或 AWS Identity and Access Management (IAM) 委託人。這些帳戶或主體可以透過建立介面 VPC 端點私下連接至您的端點服務。如需詳細資訊，請參閱 Amazon Virtual Private Cloud (Amazon VPC) 文件中的 [建立端點服務](#)。

### 企業資源規劃 (ERP)

一種系統，可自動化和管理企業的關鍵業務流程（例如會計、[MES](#) 和專案管理）。

### 信封加密

使用另一個加密金鑰對某個加密金鑰進行加密的程序。如需詳細資訊，請參閱 AWS Key Management Service (AWS KMS) 文件中的 [信封加密](#)。

### 環境

執行中應用程式的執行個體。以下是雲端運算中常見的環境類型：

- 開發環境 – 執行中應用程式的執行個體，只有負責維護應用程式的核心團隊才能使用。開發環境用來測試變更，然後再將開發環境提升到較高的環境。此類型的環境有時稱為測試環境。
- 較低的環境 – 應用程式的所有開發環境，例如用於初始建置和測試的開發環境。
- 生產環境 – 最終使用者可以存取的執行中應用程式的執行個體。在 CI/CD 管道中，生產環境是最後一個部署環境。
- 較高的環境 – 核心開發團隊以外的使用者可存取的所有環境。這可能包括生產環境、生產前環境以及用於使用者接受度測試的環境。

## epic

在敏捷方法中，有助於組織工作並排定工作優先順序的功能類別。epic 提供要求和實作任務的高層級描述。例如，AWS CAF 安全概念包括身分和存取管理、偵測控制、基礎設施安全、資料保護和事件回應。如需有關 AWS 遷移策略中的 Epic 的詳細資訊，請參閱[計畫實作指南](#)。

## ERP

請參閱[企業資源規劃](#)。

## 探索性資料分析 (EDA)

分析資料集以了解其主要特性的過程。您收集或彙總資料，然後執行初步調查以尋找模式、偵測異常並檢查假設。透過計算摘要統計並建立資料可視化來執行 EDA。

## F

### 事實資料表

[星狀結構描述](#)中的中央資料表。它存放有關業務操作的量化資料。一般而言，事實資料表包含兩種類型的資料欄：包含度量的資料，以及包含維度資料表外部索引鍵的資料欄。

### 快速失敗

一種使用頻繁和增量測試來縮短開發生命週期的理念。這是敏捷方法的關鍵部分。

### 故障隔離界限

在中 AWS 雲端，像是可用區域 AWS 區域、控制平面或資料平面等邊界會限制故障的影響，並有助於改善工作負載的彈性。如需詳細資訊，請參閱[AWS 故障隔離界限](#)。

### 功能分支

請參閱[分支](#)。

### 特徵

用來進行預測的輸入資料。例如，在製造環境中，特徵可能是定期從製造生產線擷取的影像。

### 功能重要性

特徵對於模型的預測有多重要。這通常表示為可以透過各種技術來計算的數值得分，例如 Shapley Additive Explanations (SHAP) 和積分梯度。如需詳細資訊，請參閱[機器學習模型可解釋性 AWS](#)。

## 特徵轉換

優化 ML 程序的資料，包括使用其他來源豐富資料、調整值、或從單一資料欄位擷取多組資訊。這可讓 ML 模型從資料中受益。例如，如果將「2021-05-27 00:15:37」日期劃分為「2021」、「五月」、「週四」和「15」，則可以協助學習演算法學習與不同資料元件相關聯的細微模式。

### 少量擷取提示

在要求 [LLM](#) 執行類似的任務之前，提供少量示範任務和所需輸出的範例。此技術是內容內學習的應用程式，其中模型會從內嵌在提示中的範例 (快照) 中學習。對於需要特定格式、推理或網域知識的任務，少量的提示非常有效。另請參閱[零鏡頭提示](#)。

## FGAC

請參閱[精細存取控制](#)。

### 精細存取控制 (FGAC)

使用多個條件來允許或拒絕存取請求。

### 閃切遷移

一種資料庫遷移方法，透過[變更資料擷取](#)使用連續資料複寫，以盡可能在最短的時間內遷移資料，而不是使用分階段方法。目標是將停機時間降至最低。

## FM

請參閱[基礎模型](#)。

### 基礎模型 (FM)

大型深度學習神經網路，已針對廣義和未標記資料的大量資料集進行訓練。FMs 能夠執行各種一般任務，例如了解語言、產生文字和影像，以及以自然語言交談。如需詳細資訊，請參閱[什麼是基礎模型](#)。

## G

### 生成式 AI

已針對大量資料進行訓練的 [AI](#) 模型子集，可使用簡單的文字提示建立新的內容和成品，例如影像、影片、文字和音訊。如需詳細資訊，請參閱[什麼是生成式 AI](#)。

### 地理封鎖

請參閱[地理限制](#)。

## 地理限制 (地理封鎖)

Amazon CloudFront 中的選項，可防止特定國家/地區的使用者存取內容分發。您可以使用允許清單或封鎖清單來指定核准和禁止的國家/地區。如需詳細資訊，請參閱 CloudFront 文件中的[限制內容的地理分佈](#)。

## Gitflow 工作流程

這是一種方法，其中較低和較高環境在原始碼儲存庫中使用不同分支。Gitflow 工作流程被視為舊版，而以[幹線為基礎的工作流程](#)是現代、偏好的方法。

## 黃金影像

系統或軟體的快照，做為部署該系統或軟體新執行個體的範本。例如，在製造中，黃金映像可用於在多個裝置上佈建軟體，並有助於提高裝置製造操作的速度、可擴展性和生產力。

## 綠地策略

新環境中缺乏現有基礎設施。對系統架構採用綠地策略時，可以選擇所有新技術，而不會限制與現有基礎設施的相容性，也稱為[棕地](#)。如果正在擴展現有基礎設施，則可能會混合棕地和綠地策略。

## 防護機制

有助於跨組織單位 (OU) 來管控資源、政策和合規的高層級規則。預防性防護機制會強制執行政策，以確保符合合規標準。透過使用服務控制政策和 IAM 許可界限來將其實施。偵測性防護機制可偵測政策違規和合規問題，並產生提醒以便修正。它們是透過使用 AWS Config AWS Security Hub CSPM、Amazon GuardDuty、Amazon Inspector AWS Trusted Advisor 和自訂 AWS Lambda 檢查來實施。

# H

## HA

請參閱[高可用性](#)。

## 異質資料庫遷移

將來源資料庫遷移至使用不同資料庫引擎的目標資料庫 (例如，Oracle 至 Amazon Aurora)。異質遷移通常是重新架構工作的一部分，而轉換結構描述可能是一項複雜任務。[AWS 提供有助於結構描述轉換的 AWS SCT](#)。

## 高可用性 (HA)

在遇到挑戰或災難時，工作負載能夠在不介入的情況下持續運作。HA 系統的設計目的是自動容錯移轉、持續提供高品質的效能，以及處理不同的負載和故障，並將效能影響降至最低。

## 歷史現代化

一種方法，用於現代化和升級操作技術 (OT) 系統，以更好地滿足製造業的需求。歷史資料是一種資料庫，用於從工廠中的各種來源收集和存放資料。

## 保留資料

從用於訓練機器學習模型的資料集中保留的部分歷史標記資料。您可以使用保留資料，透過比較模型預測與保留資料來評估模型效能。

## 異質資料庫遷移

將您的來源資料庫遷移至共用相同資料庫引擎的目標資料庫 (例如，Microsoft SQL Server 至 Amazon RDS for SQL Server)。同質遷移通常是主機轉換或平台轉換工作的一部分。您可以使用原生資料庫公用程式來遷移結構描述。

## 熱資料

經常存取的資料，例如即時資料或最近的轉譯資料。此資料通常需要高效能儲存層或類別，才能提供快速的查詢回應。

## 修補程序

緊急修正生產環境中的關鍵問題。由於其緊迫性，通常會在典型 DevOps 發行工作流程之外執行修補程式。

## 超級護理期間

在切換後，遷移團隊在雲端管理和監控遷移的應用程式以解決任何問題的時段。通常，此期間的長度為 1-4 天。在超級護理期間結束時，遷移團隊通常會將應用程式的責任轉移給雲端營運團隊。

## IaC

將[基礎設施視為程式碼](#)。

## 身分型政策

連接至一或多個 IAM 主體的政策，可定義其在 AWS 雲端環境中的許可。

## 閒置應用程式

90 天期間 CPU 和記憶體平均使用率在 5% 至 20% 之間的應用程式。在遷移專案中，通常會淘汰這些應用程式或將其保留在內部部署。

## IIoT

請參閱[工業物聯網](#)。

### 不可變的基礎設施

為生產工作負載部署新基礎設施的模型，而不是更新、修補或修改現有的基礎設施。不可變基礎設施本質上比[可變基礎設施](#)更一致、可靠且可預測。如需詳細資訊，請參閱 AWS Well-Architected Framework [中的使用不可變基礎設施的部署](#)最佳實務。

### 傳入 (輸入) VPC

在 AWS 多帳戶架構中，接受、檢查和路由來自應用程式外部之網路連線的 VPC。[AWS 安全參考架構](#)建議您使用傳入、傳出和檢查 VPC 來設定網路帳戶，以保護應用程式與更廣泛的網際網路之間的雙向介面。

### 增量遷移

一種切換策略，您可以在其中將應用程式分成小部分遷移，而不是執行單一、完整的切換。例如，您最初可能只將一些微服務或使用者移至新系統。確認所有項目都正常運作之後，您可以逐步移動其他微服務或使用者，直到可以解除委任舊式系統。此策略可降低與大型遷移關聯的風險。

## 工業 4.0

由 [Klaus Schwab](#) 於 2016 年推出的術語，透過連線能力、即時資料、自動化、分析和 AI/ML 的進展，指製造程序的現代化。

### 基礎設施

應用程式環境中包含的所有資源和資產。

### 基礎設施即程式碼 (IaC)

透過一組組態檔案來佈建和管理應用程式基礎設施的程序。IaC 旨在協助您集中管理基礎設施，標準化資源並快速擴展，以便新環境可重複、可靠且一致。

### 工業物聯網 (IIoT)

在製造業、能源、汽車、醫療保健、生命科學和農業等產業領域使用網際網路連線的感測器和裝置。如需詳細資訊，請參閱[建立工業物聯網 \(IIoT\) 數位轉型策略](#)。

### 檢查 VPC

在 AWS 多帳戶架構中，集中式 VPC 可管理 VPCs 之間（在相同或不同的 AWS 區域）、網際網路和內部部署網路之間的網路流量檢查。[AWS 安全參考架構](#)建議您使用傳入、傳出和檢查 VPC 來設定網路帳戶，以保護應用程式與更廣泛的網際網路之間的雙向介面。

## 物聯網 (IoT)

具有內嵌式感測器或處理器的相連實體物體網路，其透過網際網路或本地通訊網路與其他裝置和系統進行通訊。如需詳細資訊，請參閱[什麼是 IoT？](#)

### 可解釋性

機器學習模型的一個特徵，描述了人類能夠理解模型的預測如何依賴於其輸入的程度。如需詳細資訊，請參閱[的機器學習模型可解釋性 AWS](#)。

## IoT

請參閱[物聯網](#)。

## IT 資訊庫 (ITIL)

一組用於交付 IT 服務並使這些服務與業務需求保持一致的最佳實務。ITIL 為 ITSM 提供了基礎。

## IT 服務管理 (ITSM)

與組織的設計、實作、管理和支援 IT 服務關聯的活動。如需有關將雲端操作與 ITSM 工具整合的資訊，請參閱[操作整合指南](#)。

## ITIL

請參閱[IT 資訊庫](#)。

## ITSM

請參閱[IT 服務管理](#)。

## L

## 標籤型存取控制 (LBAC)

強制存取控制 (MAC) 的實作，其中使用者和資料本身都會獲得明確指派的安全標籤值。使用者安全標籤和資料安全標籤之間的交集會決定使用者可以看到哪些資料列和資料欄。

## 登陸區域

登陸區域是架構良好的多帳戶 AWS 環境，可擴展且安全。這是一個起點，您的組織可以從此起點快速啟動和部署工作負載與應用程式，並對其安全和基礎設施環境充滿信心。如需有關登陸區域的詳細資訊，請參閱[設定安全且可擴展的多帳戶 AWS 環境](#)。

## 大型語言模型 (LLM)

預先訓練大量資料的深度學習 [AI](#) 模型。LLM 可以執行多個任務，例如回答問題、摘要文件、將文字翻譯成其他語言，以及完成句子。如需詳細資訊，請參閱[什麼是 LLMs](#)。

### 大型遷移

遷移 300 部或更多伺服器。

### LBAC

請參閱[標籤型存取控制](#)。

### 最低權限

授予執行任務所需之最低許可的安全最佳實務。如需詳細資訊，請參閱 IAM 文件中的[套用最低權限許可](#)。

### 隨即轉移

請參閱 [7 個 R](#)。

### 小端序系統

首先儲存最低有效位元組的系統。另請參閱 [Endianness](#)。

## LLM

請參閱[大型語言模型](#)。

### 較低的環境

請參閱 [環境](#)。

## M

### 機器學習 (ML)

一種使用演算法和技術進行模式識別和學習的人工智慧。機器學習會進行分析並從記錄的資料 (例如物聯網 (IoT) 資料) 中學習，以根據模式產生統計模型。如需詳細資訊，請參閱[機器學習](#)。

### 主要分支

請參閱[分支](#)。

## 惡意軟體

旨在危及電腦安全或隱私權的軟體。惡意軟體可能會中斷電腦系統、洩露敏感資訊，或取得未經授權的存取。惡意軟體的範例包括病毒、蠕蟲、勒索軟體、特洛伊木馬程式、間諜軟體和鍵盤記錄器。

## 受管服務

AWS 服務會 AWS 操作基礎設施層、作業系統和平台，而您會存取端點來存放和擷取資料。Amazon Simple Storage Service (Amazon S3) 和 Amazon DynamoDB 是受管服務的範例。這些也稱為抽象服務。

## 製造執行系統 (MES)

一種軟體系統，用於追蹤、監控、記錄和控制生產程序，將原物料轉換為現場成品。

## MAP

請參閱[遷移加速計劃](#)。

## 機制

建立工具、推動工具採用，然後檢查結果以進行調整的完整程序。機制是在操作時強化和改善自身的循環。如需詳細資訊，請參閱 AWS Well-Architected Framework 中的[建置機制](#)。

## 成員帳戶

除了屬於組織一部分的管理帳戶 AWS 帳戶 之外的所有 AWS Organizations。帳戶一次只能是一個組織的成員。

## 製造執行系統

請參閱[製造執行系統](#)。

## 訊息佇列遙測傳輸 (MQTT)

根據[發佈/訂閱](#)模式的輕量型machine-to-machine(M2M) 通訊協定，適用於資源受限的 [IoT](#) 裝置。

## 微服務

一種小型的獨立服務，它可透過定義明確的 API 進行通訊，通常由小型獨立團隊擁有。例如，保險系統可能包含對應至業務能力 (例如銷售或行銷) 或子領域 (例如購買、索賠或分析) 的微服務。微服務的優點包括靈活性、彈性擴展、輕鬆部署、可重複使用的程式碼和適應力。如需詳細資訊，請參閱[使用無 AWS 伺服器服務整合微服務](#)。

## 微服務架構

一種使用獨立元件來建置應用程式的方法，這些元件會以微服務形式執行每個應用程式程序。這些微服務會使用輕量型 API，透過明確定義的介面進行通訊。此架構中的每個微服務都可以進行更新、部署和擴展，以滿足應用程式特定功能的需求。如需詳細資訊，請參閱[實作微服務 AWS](#)。

## Migration Acceleration Program (MAP)

此 AWS 計畫提供諮詢支援、訓練和服務，以協助組織建立強大的營運基礎，以移至雲端，並協助抵銷遷移的初始成本。MAP 包括用於有條不紊地執行舊式遷移的遷移方法以及一組用於自動化和加速常見遷移案例的工具。

## 大規模遷移

將大部分應用程式組合依波次移至雲端的程序，在每個波次中，都會以更快的速度移動更多應用程式。此階段使用從早期階段學到的最佳實務和經驗教訓來實作團隊、工具和流程的遷移工廠，以透過自動化和敏捷交付簡化工作負載的遷移。這是[AWS 遷移策略](#)的第三階段。

## 遷移工廠

可透過自動化、敏捷的方法簡化工作負載遷移的跨職能團隊。遷移工廠團隊通常包括營運、業務分析師和擁有者、遷移工程師、開發人員以及從事 Sprint 工作的 DevOps 專業人員。20% 至 50% 之間的企業應用程式組合包含可透過工廠方法優化的重複模式。如需詳細資訊，請參閱此內容集中的[遷移工廠的討論](#)和[雲端遷移工廠指南](#)。

## 遷移中繼資料

有關完成遷移所需的應用程式和伺服器的資訊。每種遷移模式都需要一組不同的遷移中繼資料。遷移中繼資料的範例包括目標子網路、安全群組和 AWS 帳戶。

## 遷移模式

可重複的遷移任務，詳細描述遷移策略、遷移目的地以及所使用的遷移應用程式或服務。範例：使用 AWS Application Migration Service 重新託管遷移至 Amazon EC2。

## 遷移組合評定 (MPA)

線上工具，提供驗證商業案例以遷移至的資訊 AWS 雲端。MPA 提供詳細的組合評定 (伺服器適當規模、定價、總體擁有成本比較、遷移成本分析) 以及遷移規劃 (應用程式資料分析和資料收集、應用程式分組、遷移優先順序，以及波次規劃)。[MPA 工具](#) (需要登入) 可供所有 AWS 顧問和 APN 合作夥伴顧問免費使用。

## 遷移準備程度評定 (MRA)

使用 AWS CAF 取得組織雲端整備狀態的洞見、識別優缺點，以及建立行動計劃以消除已識別差距的程序。如需詳細資訊，請參閱[遷移準備程度指南](#)。MRA 是[AWS 遷移策略](#)的第一階段。

## 遷移策略

用來將工作負載遷移至的方法 AWS 雲端。如需詳細資訊，請參閱本詞彙表中的 [7 個 Rs](#) 項目，並請參閱[動員您的組織以加速大規模遷移](#)。

## 機器學習 (ML)

請參閱[機器學習](#)。

## 現代化

將過時的 (舊版或單一) 應用程式及其基礎架構轉換為雲端中靈活、富有彈性且高度可用的系統，以降低成本、提高效率並充分利用創新。如需詳細資訊，請參閱 [《》中的現代化應用程式的策略 AWS 雲端](#)。

## 現代化準備程度評定

這項評估可協助判斷組織應用程式的現代化準備程度；識別優點、風險和相依性；並確定組織能夠在多大程度上支援這些應用程式的未來狀態。評定的結果就是目標架構的藍圖、詳細說明現代化程序的開發階段和里程碑的路線圖、以及解決已發現的差距之行動計畫。如需詳細資訊，請參閱 [《》中的評估應用程式的現代化準備 AWS 雲端](#) 程度。

## 單一應用程式 (單一)

透過緊密結合的程序作為單一服務執行的應用程式。單一應用程式有幾個缺點。如果一個應用程式功能遇到需求激增，則必須擴展整個架構。當程式碼庫增長時，新增或改進單一應用程式的功能也會變得更加複雜。若要解決這些問題，可以使用微服務架構。如需詳細資訊，請參閱[將單一體系分解為微服務](#)。

## MPA

請參閱[遷移產品組合評估](#)。

## MQTT

請參閱[訊息佇列遙測傳輸](#)。

## 多類別分類

一個有助於產生多類別預測的過程 (預測兩個以上的結果之一)。例如，機器學習模型可能會詢問「此產品是書籍、汽車還是電話？」或者「這個客戶對哪種產品類別最感興趣？」

## 可變基礎設施

更新和修改生產工作負載現有基礎設施的模型。為了提高一致性、可靠性和可預測性，AWS Well-Architected Framework 建議使用[不可變基礎設施](#)做為最佳實務。

---

## O

### OAC

請參閱[原始存取控制](#)。

### OAI

請參閱[原始存取身分](#)。

### OCM

請參閱[組織變更管理](#)。

### 離線遷移

一種遷移方法，可在遷移過程中刪除來源工作負載。此方法涉及延長停機時間，通常用於小型非關鍵工作負載。

### OI

請參閱[操作整合](#)。

### OLA

請參閱[操作層級協議](#)。

### 線上遷移

一種遷移方法，無需離線即可將來源工作負載複製到目標系統。連接至工作負載的應用程式可在遷移期間繼續運作。此方法涉及零至最短停機時間，通常用於關鍵的生產工作負載。

### OPC-UA

請參閱[開啟程序通訊 - 統一架構](#)。

### 開放程序通訊 - 統一架構 (OPC-UA)

用於工業自動化machine-to-machine(M2M) 通訊協定。OPC-UA 提供資料加密、身分驗證和授權機制的互通性標準。

### 操作水準協議 (OLA)

一份協議，闡明 IT 職能群組承諾向彼此提供的內容，以支援服務水準協議 (SLA)。

### 操作整備審查 (ORR)

問題和相關最佳實務的檢查清單，可協助您了解、評估、預防或減少事件和可能失敗的範圍。如需詳細資訊，請參閱 AWS Well-Architected Framework 中的[操作準備度審查 \(ORR\)](#)。

## 操作技術 (OT)

使用實體環境控制工業操作、設備和基礎設施的硬體和軟體系統。在製造中，OT 和資訊技術 (IT) 系統的整合是[工業 4.0](#) 轉型的關鍵重點。

## 操作整合 (OI)

在雲端中將操作現代化的程序，其中包括準備程度規劃、自動化和整合。如需詳細資訊，請參閱[操作整合指南](#)。

## 組織追蹤

建立的線索 AWS CloudTrail 會記錄 AWS 帳戶 組織中所有 的所有事件 AWS Organizations。在屬於組織的每個 AWS 帳戶 中建立此追蹤，它會跟蹤每個帳戶中的活動。如需詳細資訊，請參閱 CloudTrail 文件中的[建立組織追蹤](#)。

## 組織變更管理 (OCM)

用於從人員、文化和領導力層面管理重大、顛覆性業務轉型的架構。OCM 透過加速變更採用、解決過渡問題，以及推動文化和組織變更，協助組織為新系統和策略做好準備，並轉移至新系統和策略。在 AWS 遷移策略中，此架構稱為人員加速，因為雲端採用專案所需的變更速度。如需詳細資訊，請參閱[OCM 指南](#)。

## 原始存取控制 (OAC)

CloudFront 中的增強型選項，用於限制存取以保護 Amazon Simple Storage Service (Amazon S3) 內容。OAC 支援所有 S3 儲存貯體中的所有伺服器端加密 AWS KMS (SSE-KMS) AWS 區域，以及對 S3 儲存貯體的動態PUT和DELETE請求。

## 原始存取身分 (OAI)

CloudFront 中的一個選項，用於限制存取以保護 Amazon S3 內容。當您使用 OAI 時，CloudFront 會建立一個可供 Amazon S3 進行驗證的主體。經驗證的主體只能透過特定 CloudFront 分發來存取 S3 儲存貯體中的內容。另請參閱[OAC](#)，它可提供更精細且增強的存取控制。

## ORR

請參閱[操作整備審核](#)。

## OT

請參閱[操作技術](#)。

## 傳出 (輸出) VPC

在 AWS 多帳戶架構中，處理從應用程式內啟動之網路連線的 VPC。[AWS 安全參考架構](#)建議您使用傳入、傳出和檢查 VPC 來設定網路帳戶，以保護應用程式與更廣泛的網際網路之間的雙向介面。

## P

### 許可界限

附接至 IAM 主體的 IAM 管理政策，可設定使用者或角色擁有的最大許可。如需詳細資訊，請參閱 IAM 文件中的[許可界限](#)。

### 個人身分識別資訊 (PII)

當直接檢視或與其他相關資料配對時，可用來合理推斷個人身分的資訊。PII 的範例包括名稱、地址和聯絡資訊。

### PII

請參閱[個人身分識別資訊](#)。

### 手冊

一組預先定義的步驟，可擷取與遷移關聯的工作，例如在雲端中提供核心操作功能。手冊可以採用指令碼、自動化執行手冊或操作現代化環境所需的程序或步驟摘要的形式。

### PLC

請參閱[可程式設計邏輯控制器](#)。

### PLM

請參閱[產品生命週期管理](#)。

### 政策

可定義許可的物件（請參閱[身分型政策](#)）、指定存取條件（請參閱[資源型政策](#)），或定義組織中所有帳戶的最大許可 AWS Organizations（請參閱[服務控制政策](#)）。

### 混合持久性

根據資料存取模式和其他需求，獨立選擇微服務的資料儲存技術。如果您的微服務具有相同的資料儲存技術，則其可能會遇到實作挑戰或效能不佳。如果微服務使用最適合其需求的資料儲存，則可以更輕鬆地實作並達到更好的效能和可擴展性。

## 組合評定

探索、分析應用程式組合並排定其優先順序以規劃遷移的程序。如需詳細資訊，請參閱[評估遷移準備程度](#)。

## 述詞

傳回 true 或的查詢條件 false，通常位於 WHERE 子句中。

## 述詞下推

一種資料庫查詢最佳化技術，可在傳輸前篩選查詢中的資料。這可減少必須從關聯式資料庫擷取和處理的資料量，並改善查詢效能。

## 預防性控制

旨在防止事件發生的安全控制。這些控制是第一道防線，可協助防止對網路的未經授權存取或不必要變更。如需詳細資訊，請參閱在 AWS 上實作安全控制中的[預防性控制](#)。

## 委託人

中可執行動作和存取資源 AWS 的實體。此實體通常是 AWS 帳戶、IAM 角色或使用者的根使用者。如需詳細資訊，請參閱 IAM 文件中[角色術語和概念](#)中的主體。

## 依設計的隱私權

透過整個開發程序將隱私權納入考量的系統工程方法。

## 私有託管區域

一種容器，它包含有關您希望 Amazon Route 53 如何回應一個或多個 VPC 內的域及其子域之 DNS 查詢的資訊。如需詳細資訊，請參閱 Route 53 文件中的[使用私有託管區域](#)。

## 主動控制

旨在防止部署不合規資源的[安全控制](#)。這些控制項會在佈建資源之前對其進行掃描。如果資源不符合控制項，則不會佈建。如需詳細資訊，請參閱 AWS Control Tower 文件中的[控制項參考指南](#)，並參閱實作安全[控制項中的主動](#)控制項。 AWS

## 產品生命週期管理 (PLM)

管理產品整個生命週期的資料和程序，從設計、開發和啟動，到成長和成熟，再到拒絕和移除。

## 生產環境

請參閱[環境](#)。

## 可程式設計邏輯控制器 (PLC)

在製造中，高度可靠、可調整的電腦，可監控機器並自動化製造程序。

### 提示鏈結

使用一個 [LLM](#) 提示的輸出做為下一個提示的輸入，以產生更好的回應。此技術用於將複雜任務分解為子任務，或反覆精簡或展開初步回應。它有助於提高模型回應的準確性和相關性，並允許更精細、個人化的結果。

### 擬匿名化

以預留位置值取代資料集中個人識別符的程序。假名化有助於保護個人隱私權。假名化資料仍被視為個人資料。

### 發佈/訂閱 (pub/sub)

一種模式，可啟用微服務之間的非同步通訊，以提高可擴展性和回應能力。例如，在微服務型 [MES](#) 中，微服務可以將事件訊息發佈到其他微服務可訂閱的頻道。系統可以新增新的微服務，而無需變更發佈服務。

## Q

### 查詢計劃

一系列步驟，如指示，用於存取 SQL 關聯式資料庫系統中的資料。

### 查詢計劃迴歸

在資料庫服務優化工具選擇的計畫比對資料庫環境進行指定的變更之前的計畫不太理想時。這可能因為對統計資料、限制條件、環境設定、查詢參數繫結的變更以及資料庫引擎的更新所導致。

## R

### RACI 矩陣

請參閱 [負責、負責、諮詢、告知 \(RACI\)](#)。

### RAG

請參閱 [擷取增強產生](#)。

## 勒索軟體

一種惡意軟體，旨在阻止對計算機系統或資料的存取，直到付款為止。

## RASCI 矩陣

請參閱[負責、負責、諮詢、告知 \(RACI\)](#)。

## RCAC

請參閱[資料列和資料欄存取控制](#)。

## 僅供讀取複本

用於唯讀用途的資料庫複本。您可以將查詢路由至僅供讀取複本以減少主資料庫的負載。

## 重新架構師

請參閱 [7 Rs](#)。

## 復原點目標 (RPO)

自上次資料復原點以來可接受的時間上限。這會決定最後一個復原點與服務中斷之間可接受的資料遺失。

## 復原時間目標 (RTO)

服務中斷與服務還原之間的可接受延遲上限。

## 重構

請參閱 [7 Rs](#)。

## 區域

地理區域中的 AWS 資源集合。每個 AWS 區域 都獨立於其他，以提供容錯能力、穩定性和彈性。如需詳細資訊，請參閱[指定 AWS 區域 您的帳戶可以使用哪些](#)。

## 迴歸

預測數值的 ML 技術。例如，為了解決「這房子會賣什麼價格？」的問題 ML 模型可以使用線性迴歸模型，根據已知的房屋事實 (例如，平方英尺) 來預測房屋的銷售價格。

## 重新託管

請參閱 [7 Rs](#)。

## 版本

在部署程序中，它是將變更提升至生產環境的動作。

## 重新定位

請參閱 [7 個 R](#)。

## Replatform

請參閱 [7 個 R](#)。

## 回購

請參閱 [7 Rs](#)。

## 彈性

應用程式抵禦中斷或從中斷中復原的能力。在 [中規劃彈性時](#)，[高可用性](#)和[災難復原](#)是常見的考量 AWS 雲端。如需詳細資訊，請參閱[AWS 雲端 彈性](#)。

## 資源型政策

附接至資源的政策，例如 Amazon S3 儲存貯體、端點或加密金鑰。這種類型的政策會指定允許存取哪些主體、支援的動作以及必須滿足的任何其他條件。

## 負責者、當責者、事先諮詢者和事後告知者 (RACI) 矩陣

定義所有涉及遷移活動和雲端操作之各方的角色和責任的矩陣。矩陣名稱衍生自矩陣中定義的責任類型：負責人 (R)、責任 (A)、諮詢 (C) 和知情 (I)。支援 (S) 類型為選用。如果您包含支援，則矩陣稱為 RASCI 矩陣，如果您排除它，則稱為 RACI 矩陣。

## 回應性控制

一種安全控制，旨在驅動不良事件或偏離安全基準的補救措施。如需詳細資訊，請參閱在 AWS 上實作安全控制中的[回應性控制](#)。

## 保留

請參閱 [7 個 R](#)。

## 淘汰

請參閱 [7 Rs](#)。

## 檢索增強生成 (RAG)

[一種生成式 AI](#) 技術，其中 [LLM](#) 會在產生回應之前參考訓練資料來源以外的授權資料來源。例如，RAG 模型可能會對組織的知識庫或自訂資料執行語意搜尋。如需詳細資訊，請參閱[什麼是 RAG](#)。

## 輪換

定期更新[秘密](#)的程序，讓攻擊者更難存取登入資料。

## 資料列和資料欄存取控制 (RCAC)

使用已定義存取規則的基本、彈性 SQL 表達式。RCAC 包含資料列許可和資料欄遮罩。

## RPO

請參閱[復原點目標](#)。

## RTO

請參閱[復原時間目標](#)。

## 執行手冊

執行特定任務所需的一組手動或自動程序。這些通常是為了簡化重複性操作或錯誤率較高的程序而建置。

# S

## SAML 2.0

許多身分提供者 (IdP) 使用的開放標準。此功能會啟用聯合單一登入 (SSO)，讓使用者可以登入 AWS 管理主控台 或呼叫 AWS API 操作，而不必為您組織中的每個人在 IAM 中建立使用者。如需有關以 SAML 2.0 為基礎的聯合詳細資訊，請參閱 IAM 文件中的[關於以 SAML 2.0 為基礎的聯合](#)。

## SCADA

請參閱[監督控制和資料擷取](#)。

## SCP

請參閱[服務控制政策](#)。

## 秘密

您以加密形式存放的 AWS Secrets Manager 機密或限制資訊，例如密碼或使用者登入資料。它由秘密值及其中繼資料組成。秘密值可以是二進位、單一字串或多個字串。如需詳細資訊，請參閱 [Secrets Manager 文件中的 Secrets Manager 秘密中的什麼內容？](#)。

## 依設計的安全性

透過整個開發程序將安全性納入考量的系統工程方法。

## 安全控制

一種技術或管理防護機制，它可預防、偵測或降低威脅行為者利用安全漏洞的能力。安全控制有四種主要類型：[預防性](#)、[偵測性](#)、[回應性](#)和[主動性](#)。

## 安全強化

減少受攻擊面以使其更能抵抗攻擊的過程。這可能包括一些動作，例如移除不再需要的資源、實作授予最低權限的安全最佳實務、或停用組態檔案中不必要的功能。

### 安全資訊與事件管理 (SIEM) 系統

結合安全資訊管理 (SIM) 和安全事件管理 (SEM) 系統的工具與服務。SIEM 系統會收集、監控和分析來自伺服器、網路、裝置和其他來源的資料，以偵測威脅和安全漏洞，並產生提醒。

### 安全回應自動化

預先定義和程式設計的動作，旨在自動回應或修復安全事件。這些自動化可做為[偵測或回應](#)式安全控制，協助您實作 AWS 安全最佳實務。自動化回應動作的範例包括修改 VPC 安全群組、修補 Amazon EC2 執行個體或輪換登入資料。

### 伺服器端加密

由接收資料的 AWS 服務 在其目的地加密資料。

### 服務控制政策 (SCP)

為 AWS Organizations 中的組織的所有帳戶提供集中控制許可的政策。SCP 會定義防護機制或設定管理員可委派給使用者或角色的動作限制。您可以使用 SCP 作為允許清單或拒絕清單，以指定允許或禁止哪些服務或動作。如需詳細資訊，請參閱 AWS Organizations 文件中的[服務控制政策](#)。

### 服務端點

的進入點 URL AWS 服務。您可以使用端點，透過程式設計方式連接至目標服務。如需詳細資訊，請參閱 AWS 一般參考 中的 [AWS 服務 端點](#)。

### 服務水準協議 (SLA)

一份協議，闡明 IT 團隊承諾向客戶提供的服務，例如服務正常執行時間和效能。

### 服務層級指標 (SLI)

服務效能方面的測量，例如其錯誤率、可用性或輸送量。

### 服務層級目標 (SLO)

代表服務運作狀態的目標指標，由[服務層級指標](#)測量。

### 共同責任模式

描述您與共同 AWS 承擔雲端安全與合規責任的模型。AWS 負責雲端的安全，而負責雲端的安全。如需詳細資訊，請參閱[共同責任模式](#)。

## SIEM

請參閱[安全資訊和事件管理系統](#)。

## 單一故障點 (SPOF)

應用程式的單一關鍵元件故障，可能會中斷系統。

## SLA

請參閱[服務層級協議](#)。

## SLI

請參閱[服務層級指標](#)。

## SLO

請參閱[服務層級目標](#)。

## 先拆分後播種模型

擴展和加速現代化專案的模式。定義新功能和產品版本時，核心團隊會進行拆分以建立新的產品團隊。這有助於擴展組織的能力和服務，提高開發人員生產力，並支援快速創新。如需詳細資訊，請參閱[中的階段式應用程式現代化方法 AWS 雲端](#)。

## SPOF

請參閱[單一故障點](#)。

## 星狀結構描述

使用一個大型事實資料表來存放交易或測量資料的資料庫組織結構，並使用一或多個較小的維度資料表來存放資料屬性。此結構旨在用於[資料倉儲](#)或商業智慧用途。

## Strangler Fig 模式

一種現代化單一系統的方法，它會逐步重寫和取代系統功能，直到舊式系統停止使用為止。此模式源自無花果藤，它長成一棵馴化樹並最終戰勝且取代了其宿主。該模式由[Martin Fowler 引入](#)，作為重寫單一系統時管理風險的方式。如需有關如何套用此模式的範例，請參閱[使用容器和 Amazon API Gateway 逐步現代化舊版 Microsoft ASP.NET \(ASMX\) Web 服務](#)。

## 子網

您 VPC 中的 IP 地址範圍。子網必須位於單一可用區域。

## 監控控制和資料擷取 (SCADA)

在製造中，使用硬體和軟體來監控實體資產和生產操作的系統。

## 對稱加密

使用相同金鑰來加密及解密資料的加密演算法。

## 合成測試

以模擬使用者互動的方式測試系統，以偵測潛在問題或監控效能。您可以使用 [Amazon CloudWatch Synthetics](#) 來建立這些測試。

## 系統提示

一種向 [LLM](#) 提供內容、指示或指導方針以指示其行為的技術。系統提示有助於設定內容，並建立與使用者互動的規則。

# T

## 標籤

做為中繼資料的鍵/值對，用於組織您的 AWS 資源。標籤可協助您管理、識別、組織、搜尋及篩選資源。如需詳細資訊，請參閱 [標記您的 AWS 資源](#)。

## 目標變數

您嘗試在受監督的 ML 中預測的值。這也被稱為結果變數。例如，在製造設定中，目標變數可能是產品瑕疵。

## 任務清單

用於透過執行手冊追蹤進度的工具。任務清單包含執行手冊的概觀以及要完成的一般任務清單。對於每個一般任務，它包括所需的預估時間量、擁有者和進度。

## 測試環境

請參閱 [環境](#)。

## 訓練

為 ML 模型提供資料以供學習。訓練資料必須包含正確答案。學習演算法會在訓練資料中尋找將輸入資料屬性映射至目標的模式 (您想要預測的答案)。它會輸出擷取這些模式的 ML 模型。可以使用 ML 模型，來預測您不知道的目標新資料。

## 傳輸閘道

可以用於互連 VPC 和內部部署網路的網路傳輸中樞。如需詳細資訊，請參閱 AWS Transit Gateway 文件中的 [什麼是傳輸閘道](#)。

## 主幹型工作流程

這是一種方法，開發人員可在功能分支中本地建置和測試功能，然後將這些變更合併到主要分支中。然後，主要分支會依序建置到開發環境、生產前環境和生產環境中。

## 受信任的存取權

將許可授予您指定的服務，以代表您在組織中 AWS Organizations 及其帳戶中執行任務。受信任的服務會在需要該角色時，在每個帳戶中建立服務連結角色，以便為您執行管理工作。如需詳細資訊，請參閱文件中的 AWS Organizations [搭配使用 AWS Organizations 與其他 AWS 服務](#)。

## 調校

變更訓練程序的各個層面，以提高 ML 模型的準確性。例如，可以透過產生標籤集、新增標籤、然後在不同的設定下多次重複這些步驟來訓練 ML 模型，以優化模型。

## 雙比薩團隊

兩個比薩就能吃飽的小型 DevOps 團隊。雙披薩團隊規模可確保軟體開發中的最佳協作。

# U

## 不確定性

這是一個概念，指的是不精確、不完整或未知的資訊，其可能會破壞預測性 ML 模型的可靠性。有兩種類型的不確定性：認知不確定性是由有限的、不完整的資料引起的，而隨機不確定性是由資料中固有的噪聲和隨機性引起的。如需詳細資訊，請參閱[量化深度學習系統的不確定性指南](#)。

## 未區分的任務

也稱為繁重工作，這是建立和操作應用程式的必要工作，但不為最終使用者提供直接價值或提供競爭優勢。未區分任務的範例包括採購、維護和容量規劃。

## 較高的環境

請參閱 [環境](#)。

# V

## 清空

一種資料庫維護操作，涉及增量更新後的清理工作，以回收儲存並提升效能。

## 版本控制

追蹤變更的程序和工具，例如儲存庫中原始程式碼的變更。

## VPC 對等互連

兩個 VPC 之間的連線，可讓您使用私有 IP 地址路由流量。如需詳細資訊，請參閱 Amazon VPC 文件中的[什麼是 VPC 對等互連](#)。

## 漏洞

危害系統安全性的軟體或硬體瑕疵。

# W

## 暖快取

包含經常存取的目前相關資料的緩衝快取。資料庫執行個體可以從緩衝快取讀取，這比從主記憶體或磁碟讀取更快。

## 暖資料

不常存取的資料。查詢這類資料時，通常可接受中等速度的查詢。

## 視窗函數

SQL 函數，對與目前記錄在某種程度上相關的資料列群組執行計算。視窗函數適用於處理任務，例如根據目前資料列的相對位置計算移動平均值或存取資料列的值。

## 工作負載

提供商業價值的資源和程式碼集合，例如面向客戶的應用程式或後端流程。

## 工作串流

遷移專案中負責一組特定任務的功能群組。每個工作串流都是獨立的，但支援專案中的其他工作串流。例如，組合工作串流負責排定應用程式、波次規劃和收集遷移中繼資料的優先順序。組合工作串流將這些資產交付至遷移工作串流，然後再遷移伺服器 and 應用程式。

## WORM

請參閱[寫入一次，多次讀取](#)。

## WQF

請參閱[AWS 工作負載資格架構](#)。

## 寫入一次，讀取許多 (WORM)

儲存模型，可一次性寫入資料，並防止刪除或修改資料。授權使用者可以視需要多次讀取資料，但無法變更資料。此資料儲存基礎設施被視為[不可變](#)。

## Z

### 零時差入侵

利用[零時差漏洞](#)的攻擊，通常是惡意軟體。

### 零時差漏洞

生產系統中未緩解的缺陷或漏洞。威脅行為者可以使用這種類型的漏洞來攻擊系統。開發人員經常因為攻擊而意識到漏洞。

### 零鏡頭提示

提供 [LLM](#) 執行任務的指示，但沒有可協助引導任務的範例 (快照)。LLM 必須使用其預先訓練的知識來處理任務。零鏡頭提示的有效性取決於任務的複雜性和提示的品質。另請參閱[少量擷取提示](#)。

### 殭屍應用程式

CPU 和記憶體平均使用率低於 5% 的應用程式。在遷移專案中，通常會淘汰這些應用程式。

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。